



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



**GERİ DÖNÜŞTÜRÜLEBİLİR KATI**  
**ATIKLARIN YAPAY ZEKA TABANLI**  
**TANINMA VE SINIFLANDIRILMASI**

**Yusuf ERYEŞİL**

**YÜKSEK LİSANS TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalını**

**Haziran-2023**  
**KONYA**  
**Her Hakkı Saklıdır**

## 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

Yusuf ERYEŞİL

06.06.2023

## ÖZET

### YÜKSEK LİSANS TEZİ

#### GERİ DÖNÜŞTÜRÜLEBİLİR KATI ATIKLARIN YAPAY ZEKA TABANLI TANIMA VE SINIFLANDIRILMASI

Yusuf ERYEŞİL

Selçuk Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Şakir TAŞDEMİR

2023, 70 Sayfa

Jüri

Prof. Dr. Şakir TAŞDEMİR

Doç. Dr. Humar KAHRAMANLI ÖRNEK

Dr. Öğr. Üyesi Kübra UYAR

Dünyanın küreselleşmesi ve ekonomik büyüme; tüketimde ve atık üretiminde artışa yol açmıştır. Evsel atıkların önemli bir kısmı; özellikle plastik, elektronik ve piller gibi biyolojik olarak parçalanamayan tehlikeli maddeler içeren atıklar çevre dostu bir şekilde yok edilememektedir. Özellikle gelişmekte olan ülkelerde yetersiz atık yönetimi altyapısı, kontrolsüz depolama ve atık yakma gibi güvenli olmayan yok etme uygulamaları, çevresel ve sağlık açısından zararlı sonuçlara sebep olmaktadır. Verimli atık yönetim uygulamalarında, katı atığın uygun şekilde sınıflandırılması kaynakların geri kazanılmasını teşvik etmede ve çevresel etkiyi en aza indirmede önemli rol oynamaktadır. Bu tez çalışmasında, katı atıkların sınıflandırılması için yapay zekâ yöntemlerinden özellikle geleneksel makine öğrenimi modelleri (DVM ve Karar Ağacı) ve derin öğrenme modellerinin (InceptionResnet, EfficientNet ve MobileNet) geliştirilmesi amaçlanmıştır.

Atık sınıflandırma çalışmasında, derin öğrenme modelleri; InceptionResnet, EfficientNet ve MobileNet sırasıyla %92.49, %94.47 ve %91.30'luk doğruluk oranlarına ulaşarak atık sınıflandırmasında iyi bir performans göstermiştir. Buna karşılık, makine öğrenimi modelleri, DVM ve Karar Ağacı sırasıyla %62.31 ve %43.38 gibi daha düşük doğruluk oranlarına ulaşarak, atık sınıflandırmasında geleneksel makine öğrenimi yaklaşımlarının sınırlamalarını vurgulamaktadır. Geliştirilen derin öğrenme modelleri yapay zekâ kitine entegre edilmiştir. Geliştirilmiş olan modellerin Jetson yapay zekâ kiti üzerinde kullanılması, gerçek zamanlı atık sınıflandırmasının uygulanabilirliğini göstermektedir. Bu nedenle, bu çalışma, kullanılan metodolojinin katı atıkları sınıflandırmada derin öğrenme modellerinin makine öğrenme modellerine göre daha başarılı olduğunu göstermektedir. Bulgular, özellikle EfficientNet modelinin doğru atık sınıflandırması için önemli bir potansiyele sahip olduğunu göstermiştir.

Gelecekteki çalışmalar, sınıflandırma performansını daha da geliştirmek için özellikle derin öğrenme uygulamalarında önemli olan veri kümesi genişletilebilir. Bunun yanı sıra daha az ağ karmaşıklığına sahip hızlı ve doğru karar verebilen algoritmalar geliştirmeye odaklanılabilir.

**Anahtar Kelimeler:** Makine Öğrenmesi, Derin Öğrenme, Katı atık sınıflandırma, Geri Dönüşüm

## **ABSTRACT**

## **MS THESIS**

# **ARTIFICIAL INTELLIGENCE-BASED RECOGNITION AND CLASSIFICATION OF RECYCLABLE SOLID WASTE**

**Yusuf ERYEŞİL**

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

**Advisor: Prof. Dr. Şakir TAŞDEMİR**

**2023, 70 Pages**

**Jury**  
**Prof. Dr. Şakir TAŞDEMİR**  
**Assoc. Prof. Dr. Humar KAHRAMANLI ÖRNEK**  
**Assist. Prof. Dr. Kübra Uyar**

Globalization of the world and economic growth; has led to an increase in consumption and waste production. An important part of household waste; especially wastes containing non-biodegradable hazardous materials such as plastics, electronics and batteries cannot be disposed of in an environmentally friendly manner. Especially in developing countries, unsafe disposal practices such as inadequate waste management infrastructure, uncontrolled landfilling and waste incineration cause harmful environmental and health consequences. In efficient waste management practices, proper classification of solid waste plays an important role in promoting resource recovery and minimizing environmental impact. In this thesis, it is aimed to develop artificial intelligence methods, especially traditional machine learning models (DVM and Decision Tree) and deep learning models (InceptionResnet, EfficientNet and MobileNet) for the classification of solid waste.

In waste classification study, deep learning models; InceptionResnet, EfficientNet and MobileNet performed well in waste classification, achieving accuracy rates of 92.49%, 94.47% and 91.30%, respectively. In contrast, machine learning models, SVM and Decision Tree achieve lower accuracy rates of 62.31% and 43.38%, respectively, highlighting the limitations of traditional machine learning approaches to waste classification. The developed deep learning models are integrated into the artificial intelligence kit. The use of the developed models on the Jetson artificial intelligence kit demonstrates the feasibility of real-time waste classification. Therefore, this study shows that deep learning models are more successful than machine learning models in classifying solid wastes of the methodology used. The findings, in particular, showed that the EfficientNet model has significant potential for accurate waste classification.

Future work can expand the dataset to further improve classification performance, which is especially important in deep learning applications. In addition, it can be focused on developing algorithms that can make fast and accurate decisions with less network complexity.

**Keywords:** Machine Learning, Deep Learning, Solid waste sorting, Recycling

## ÖNSÖZ

Bu tez ile geri dönüştürülebilir katı atıkların yapay zeka yöntemleri ile tanıma ve sınıflandırılması araştırılmıştır. Tez çalışması süresince bana rehberlik eden Danışman Hocam Prof. Dr. Şakir TAŞDEMİR'e, Doç. Dr. Humar KAHRAMANLI ÖRNEK'e, Dr. Öğr. Üyesi Murat KÖKLÜ'ye, değerli öğretim üyelerine ve her zaman beni destekleyen aileme teşekkürlerimi sunarım.

Yusuf ERYEŞİL  
KONYA-2023



## İÇİNDEKİLER

|                                                                             |     |
|-----------------------------------------------------------------------------|-----|
| ÖZET .....                                                                  | iv  |
| ABSTRACT.....                                                               | v   |
| ÖNSÖZ .....                                                                 | vi  |
| İÇİNDEKİLER .....                                                           | vii |
| ŞEKİL LİSTESİ.....                                                          | ix  |
| ÇİZELGE LİSTESİ.....                                                        | x   |
| SİMGELER VE KISALTMALAR .....                                               | xi  |
| 1. GİRİŞ .....                                                              | 1   |
| 1.1. Tezin Amacı ve Özgün Yönü .....                                        | 1   |
| 1.2. Tezin Organizasyonu .....                                              | 3   |
| 2. KAYNAK ARAŞTIRMASI .....                                                 | 4   |
| 3. MATERYAL VE YÖNTEM.....                                                  | 13  |
| 3.1. Veri Kümesi .....                                                      | 13  |
| 3.2. Yapay Zekâ .....                                                       | 17  |
| 3.3. Makine Öğrenimi .....                                                  | 18  |
| 3.3.1. Atık Sınıflandırmada Kullanılan Makine Öğrenmesi Yöntemleri.....     | 19  |
| 3.4. Yapay Sinir Ağları .....                                               | 22  |
| 3.5. Derin Öğrenme .....                                                    | 24  |
| 3.6. Konvolüsyonel Sinir Ağları .....                                       | 24  |
| 3.6.1. Konvolüsyonel Sinir Ağlarının Katmanları .....                       | 26  |
| 3.7. Transfer Öğrenme .....                                                 | 30  |
| 3.8. Atık Sınıflandırmada Kullanılan Derin Öğrenme Modelleri .....          | 31  |
| 3.8.1. EfficientNet.....                                                    | 32  |
| 3.8.2. MobileNet .....                                                      | 34  |
| 3.8.3. InceptionResnet .....                                                | 35  |
| 3.9. Performans Değerlendirme Ölçütleri.....                                | 37  |
| 3.10. Veri Arttırma.....                                                    | 38  |
| 3.11. Yapay Zekâ Kiti.....                                                  | 39  |
| 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....                                     | 40  |
| 4.1. Makine Öğrenmesi Sonuçları .....                                       | 40  |
| 4.2. Derin Öğrenme Sonuçları .....                                          | 41  |
| 4.3. Makine Öğrenmesi ve Derin Öğrenme Sonuçlarının Karşılaştırılması ..... | 48  |
| 4.4. Sonuçların Literatür ile Karşılaştırılması.....                        | 48  |
| 4.5. Tartışma .....                                                         | 50  |

|                                     |           |
|-------------------------------------|-----------|
| 4.6. Yapay Zekâ Kiti.....           | 51        |
| <b>5. SONUÇLAR VE ÖNERİLER.....</b> | <b>53</b> |
| 5.1 Sonuçlar .....                  | 53        |
| 5.2 Öneriler .....                  | 53        |
| <b>KAYNAKLAR .....</b>              | <b>55</b> |
| <b>ÖZGEÇMİŞ .....</b>               | <b>59</b> |



## ŞEKİL LİSTESİ

|                                                                                                                                                                               |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 2. 1. TrashNet veri kümesine ait örnek görüntüler .....                                                                                                                 | 5  |
| Şekil 2. 2. Çöp kutusunun tasarımı .....                                                                                                                                      | 9  |
| Şekil 2. 3. Sistemin genel akış şeması .....                                                                                                                                  | 10 |
| Şekil 3. 1. TrashNet veri kümesinde çöp sınıfına ait görüntüler .....                                                                                                         | 14 |
| Şekil 3. 2. TrashNet veri kümesinde karton sınıfına ait görüntüler .....                                                                                                      | 15 |
| Şekil 3. 3. TrashNet veri kümesinde plastik sınıfına ait görüntüler .....                                                                                                     | 15 |
| Şekil 3. 4. TrashNet veri kümesinde metal sınıfına ait görüntüler .....                                                                                                       | 16 |
| Şekil 3. 5. TrashNet veri kümesinde cam sınıfına ait görüntüler .....                                                                                                         | 16 |
| Şekil 3. 6. TrashNet veri kümesinde karton sınıfına ait görüntüler .....                                                                                                      | 17 |
| Şekil 3. 7. Yapay zeka, makine öğrenimi ve derin öğrenme arasındaki ilişki.....                                                                                               | 18 |
| Şekil 3. 8. DVM algoritması.....                                                                                                                                              | 20 |
| Şekil 3. 9. Karar Ağacı.....                                                                                                                                                  | 21 |
| Şekil 3. 10. Yapay sinir hücresi .....                                                                                                                                        | 23 |
| Şekil 3. 11. Konvolüsyonel sinir ağı mimarisi.....                                                                                                                            | 25 |
| Şekil 3. 12. LeNet mimarisi .....                                                                                                                                             | 25 |
| Şekil 3. 13. Özellik haritası.....                                                                                                                                            | 27 |
| Şekil 3. 14. Maksimum ve Ortalama ortaklama için örnek .....                                                                                                                  | 29 |
| Şekil 3. 15. Tam Bağlantı Katmanı Mimarisi .....                                                                                                                              | 30 |
| Şekil 3. 16. Transfer Öğrenme Blok Diyagramı .....                                                                                                                            | 31 |
| Şekil 3. 17. EfficientNet-B3 mimarisi(Alhichri, Alswayed, Bazi, Ammour, & Alajlan, 2021).....                                                                                 | 33 |
| Şekil 3. 18. MobileNetV3 mimarisi(A. Howard et al., 2019).....                                                                                                                | 35 |
| Şekil 3. 19. InceptionResnet mimarisi (Szegedy et al., 2017) .....                                                                                                            | 36 |
| Şekil 3. 20. Veri artırma uygulanmış örnek görüntüler .....                                                                                                                   | 39 |
| Şekil 4. 1. Derin öğrenme modellerinin karmaşık matrisleri.....                                                                                                               | 42 |
| Şekil 4. 2. EfficientNet-B3 modelinin test sonucunda sınıflara göre yanlış sayıları .....                                                                                     | 43 |
| Şekil 4. 3. (a) EfficientNet-B3 eğitim ve test kayıp grafiği, (b) MobileNet-V3 eğitim ve test kayıp grafiği, (c) InceptionResnet-V2 eğitim ve test kayıp grafiği.....         | 44 |
| Şekil 4. 4. (a)EfficientNet-B3 eğitim ve test doğruluk grafiği, (b) MobileNet-V3 eğitim ve test doğruluk grafiği, (c) InceptionResnet-V2 eğitim ve test doğruluk grafiği..... | 46 |
| Şekil 4. 5. (a) MobileNet-V3 modelinin test sonucunda sınıflara göre yanlış sayıları, (b) InceptionResnet-V2 modelinin test sonucunda sınıflara göre yanlış sayıları .....    | 47 |

## ÇİZELGE LİSTESİ

|                                                                                  |    |
|----------------------------------------------------------------------------------|----|
| Çizelge 2. 1. İnce ayarlı model sonuçları.....                                   | 6  |
| Çizelge 2. 2. Modellerin doğruluk oranı.....                                     | 6  |
| Çizelge 2. 3. Farklı modellerin doğruluk oranı.....                              | 8  |
| Çizelge 2. 4. Farklı modellerin doğruluk oranı.....                              | 9  |
| Çizelge 3. 1. Biyoloji ve YSA arasındaki ilişki.....                             | 22 |
| Çizelge 4. 1. EfficientNet-B3 modelinin performans ölçütleri.....                | 43 |
| Çizelge 4. 2. MobileNet-V3 modelinin performans ölçütleri.....                   | 45 |
| Çizelge 4. 3. InceptionResnet-V2 modelinin performans ölçütleri .....            | 45 |
| Çizelge 4. 4. Test edilen modellerin performans ölçütleri.....                   | 46 |
| Çizelge 4. 5. Çalışmada önerilen modellerin literatür ile karşılaştırılması..... | 49 |



## SİMGELER VE KISALTMALAR

### Kısaltmalar

|                 |                                                                            |
|-----------------|----------------------------------------------------------------------------|
| DVM             | : Destek Vektör Makinesi                                                   |
| FN              | : Yanlış Negatif (False Negative)                                          |
| FP              | : Yanlış Pozitif (False Positive)                                          |
| GPU             | : Grafik İşlem Birimi (Graphics Processing Unit)                           |
| KSA             | : Konvolüsyonel Sinir Ağı                                                  |
| PMAM            | : Paralel Dikkat Mekanizması (Parallel Mixed Attention Mechanism)          |
| SIFT Transform) | : Ölçekten Bağımsız Öznitelik Dönüşümü (Scale Invariant Feature Transform) |
| SMM             | : Kendi Kendini İzleme Modülü (self- monitoring module)                    |
| TP              | : Gerçek Pozitif (True Positive)                                           |
| TN              | : Gerçek Negatif (True Negative)                                           |

## 1. GİRİŞ

Dünyanın küreselleşmesindeki hızlı artış ve ekonomik gelişmeler, çeşitli faktörlere bağlı olarak tüketiminin artmasına neden olmaktadır. Tüketim artışı da daha fazla atık üretimine yol açmıştır. Tüketimdeki artışın yanı sıra ekonomideki gelişmeler, sanayileşmeyi teşvik ederek endüstriyel atıkların daha fazla üretilmesine neden olmaktadır. Ayrıca etkili atık yönetim stratejilerinin olmaması bu sorunu daha da kötüleştirmektedir. Günümüzde, atık ayrıştırma tesislerinin dışında yaygın olarak zararlı çevresel sonuçları olan depolama ve yakma gibi verimsiz atık yok etme yöntemleri de kullanılmaktadır. Verimsiz atık yok etme yöntemleri toprak ve su kaynaklarının kirlenmesine yol açarak hem insan hem de hayvan sağlığını olumsuz yönde etkilemektedir(Hoornweg & Bhada-Tata, 2012).

Evsel atıkların en az üçte biri çeşitli sebeplerden dolayı çevre dostu bir şekilde yok edilememektedir. Evsel atıkların çeşitleri, zaman içerisinde farklılaşıp artık daha büyük oranda plastik, elektronik ve pil gibi biyolojik olarak parçalanamayan ve güvenli bir şekilde atılması gereken tehlikeli maddeler içermektedir. Özellikle gelişmekte olan ülkelerde yetersiz atık yönetimi altyapısı, güvenli yok etme seçeneklerinin mevcudiyetini sınırlandırmaktadır. Bu durum, olumsuz çevresel ve sağlık etkileri olan kontrolsüz çöplüklerin kullanılmasına veya atıkların açıkta yakılmasına yol açmaktadır. Yakma ve depolama gibi bazı atık yönetimi teknolojileri, "kabul edilebilir" yok etme yöntemleri olarak görülmelerine rağmen olumsuz çevresel etkilere sahiptir. Yaklaşan çevre felaketini en aza indirmek için önlemlerin gerekli olduğu açıktır. Geri dönüşüm gibi etkili atık yönetimi stratejilerinin uygulanması, doğal kaynaklarımızı korumak, enerji tüketimini azaltmak ve çevre kirliliğini en aza indirmek için önem arz etmektedir(Purvis, Mao, & Robinson, 2019). Ayrıca, atık yönetimi yalnızca çevreye fayda sağlamaz. Aynı zamanda atık malzemelerin işlenmesi sonucu ortaya çıkan ham maddeler yeniden üretimde kullanılarak ekonomiye de katkı sağlar.

### 1.1. Tezin Amacı ve Özgün Yönü

Türkiye’de en yaygın atıklar; peçeteler, plastik gıda ambalajları, plastik poşetler, lastik eldivenler ve plastik tıbbi atıklardır. Geri dönüşüm tesislerinde ise bu atıklar genel olarak kâğıt, metal, cam ve plastik olmak üzere dört kategoriye ayrılmaktadır. Bu dört

farklı kategoride atık sınıflandırması; geri dönüşüm süreçlerini optimize etmede, kirliliği en aza indirmede ve pazar taleplerini karşılamada önemli rol oynamaktadır. Bu yaklaşım, geri dönüşüm tesislerinin farklı atık malzeme türlerini verimli bir şekilde ayırmalarına ve işlemelerine olanak tanımaktadır. Atık sınıflandırması, atık yönetim sürecinin herhangi bir aşamasında olabilir. Ancak bu işlemin geri dönüşüm tesislerinde yapılması maliyet etkinliği, kullanılabilirlik ve kalite kontrol açısından önemli faydalar sunmaktadır. Bu tesislerde bulunan özel altyapı ve uzmanlıktan yararlanılarak atıklar verimli bir şekilde ayrıştırılabilir, işlenebilir ve yüksek kaliteli geri dönüştürülmüş malzemelere dönüştürülerek daha sürdürülebilir bir ekonomiye katkıda bulunulabilir.

Geri dönüşüm tesislerinde atıklar, düzgün işlenebilmesi için ilk etapta sınıflara ayrılmaktadır. Bu atıklar, insan eliyle ilkel bir şekilde ayrıştırılmaktadır. Atıkların elle ayrıştırılması, zaman almakla birlikte insan sağlığını da kötü etkilemektedir. Atıkların otomatik bir sistem yardımı ile ayrıştırılması geri dönüşüm tesislerinin zamandan tasarruf sağlamasını ve insan faktöründen dolayı meydana gelebilecek hataların ortadan kaldırılmasını sağlayacaktır (Meng et al., 2019). Ayrıştırma işleminde insan gücünün kullanılmaması, meydana gelen sağlık sorunlarını da ortadan kaldıracak böylelikle yaşam kalitesi artmış olacaktır. Bu çalışma ile atık sınıflandırma süreçlerinin verimliliğini ve optimizasyonunu iyileştirmek; sınıflandırma sonuçlarının doğruluğunu ve güvenilirliğini artırmak işçilerin sağlığını olumlu yönde etkileyecektir. Ayrıca geri dönüşüm tesislerinin verimliliğini arttırmak, doğal kaynakları korumak ve ham madde üretimi gibi birçok kazanç elde etmek amaçlanmıştır (Z. Wang, Peng, Huang, & Sun, 2019).

Bu çalışmada atık ayrıştırma süreçlerini iyileştirmeye yönelik yenilikçi yaklaşımları ve teknolojileri keşfetmeye odaklanılmıştır. Atık türleri hakkında doğru tahminler yapabilen akıllı modeller geliştirmek için yapay zeka teknikleri kullanılmaktadır (Azhaguramyaa, Janet, Narayanan, Sabari, & Santhosh, 2021). Atık sınıflandırma doğruluğunu ve uygulanabilir olmasını optimize etmek için yenilikçi algoritmalar, derin öğrenme mimarileri ve makine öğrenmesi teknikleri kullanılmıştır. Sınıflandırma doğruluğunu iyileştirmek için yeni yaklaşımlar araştırılmıştır. Atık öğelerin ayırt edici özelliklerini tespit edebilmek için makine öğrenmesi ve derin öğrenmeye dayalı özellik çıkarma teknikleri kullanılmıştır. Veri kümesinin çeşitliliğini ve boyutunu artırmak için veri artırma yöntemleri kullanıldı. Bu sayede, kullanılan modellerin doğru tahmin oranları

yükseltilmiştir. Geliştirilmiş olan derin öğrenme modelleri, performans ve verimliliğe sahip NVIDIA Jetson Xavier NX modülünde kullanılmıştır.


## 1.2. Tezin Organizasyonu

Bu çalışma, yapay zekâ yöntemlerin katı atıkların sınıflandırılmasında kullanılması, uygunluk ve performanslarının değerlendirilmesi amacıyla birkaç bölüm halinde hazırlanmıştır. Bölüm 2’de, atık sınıflandırması ve yapay zekâ yöntemleriyle ilgili önceki çalışmaları inceleyen kapsamlı bir literatür taraması yapılmıştır. Bölüm 3, veri kümesi, kullanılan yapay zekâ yöntemleri ve performans değerlendirme ölçütlerini özetleyerek bu çalışmada kullanılan metodolojiyi açıklamaktadır. Bölüm 4, araştırma bulgularını ve DVM, Karar Ağacı InceptionResnet, EfficientNet ve MobileNet modellerinin uygulanmasından elde edilen sonuçları anlatılmıştır. 5. Bölüm, çalışmadan çıkarılan sonuçları sunarak ana bulguları ve bunların yapay zekâ kullanılarak atık sınıflandırmasına yönelik etkileri özetlenip öneriler verilmiştir.

## 2. KAYNAK ARAŞTIRMASI

Derin öğrenme ve makine öğrenimi teknikleri kullanılarak katı atıkların otomatik olarak sınıflandırılması, verimli atık yönetim uygulamalarına olan acil ihtiyaç nedeniyle son yıllarda önemli ölçüde ilgi görmüştür. Kentleşmenin ve sanayileşmenin çoğalması, atık üretiminde artışa neden olmuştur. Günümüzde atıkları ayrıştırmak için manuel yöntemler kullanılmaktadır. Bu yöntemler yoğun emek ve zaman almaktadır. Atık malzemelerin artan hacmi ve karmaşıklığı ile başa çıkmakta zorlanmaktadır. Bu sorunlara çözüm üretebilmek için araştırmacılar; doğruluk, hız ve kaynak verimliliğini olumlu etkileyecek atık sınıflandırma sürecini otomatikleştirmek için gelişmiş yapay zekâ yaklaşımlarına yönelmişlerdir.

Thung ve Yang, katı atıkların sınıflara ayırmaya yönelik bir bilgisayar yaklaşımının uygulanabilir olduğunu ortaya koymuşlardır. Atık görüntülerini altı sınıfa (cam, kâğıt, metal, plastik, karton ve çöp) ayırmayı amaçlamışlar ve her sınıf için yaklaşık 400 görüntü toplamışlardır. Sonuç olarak 2527 görüntü ile TrashNet veri kümesi oluşturulmuş ve genel kullanıma sunmuşlardır. Bu veri kümesine ait örnek görüntüler şekil 2.1.'de gösterilmiştir. Bu çalışmada katı atıkları sınıflara ayırmak için makine öğrenmesi ve bilgisayarla görme algoritmalarını kullanmışlardır. Bu yöntemler ile iyi sonuç alabilmek için veri arttırma tekniklerini (görüntülerin rastgele döndürülmesi, parlaklığın rastgele değiştirilmesi, rastgele ötelenmesi ve rastgele kesilmesi) kullanmışlardır. Sınıflandırmak için önce Ölçekten Bağımsız Öznitelik Dönüşümü (Scale Invariant Feature Transform-SIFT) ile özellik çıkartılmış, 2. aşamada Destek Vektör Makinesi ile bu özellikleri kullanarak atıklar sınıflandırılmıştır. Ayrıca AlexNet'e çok benzeyen on bir katmanlı bir KSA mimarisi kullanmışlardır. DVM ile %63, KSA ile %22 doğruluk oranı elde etmişlerdir(M. Yang & Thung, 2016).



Şekil 2. 1. TrashNet veri kümesine ait örnek görüntüler

2018 yılında Bircanoğlu ve arkadaşları, sinir ağı mimarileri üzerinde deneyler yapmıştır. Resnet50, MobileNet, InceptionResnetV2, DenseNet121 ve Xception mimarileri dahil olmak üzere çeşitli modeller kullanarak test yapmışlardır. Optimize edilmiş bir model olan RecycleNet modelini önermişlerdir. Bu modelde önceden eğitilmiş Modellerin tahmin performansını artırmak için yoğun bloklar içindeki atlama bağlantılarının modelleri değiştirildi. Önerilen model, geri dönüştürülebilir atıkların sınıflandırılması için optimize edilmiş derin kovolüsyonel sinir ağı mimarisidir. Bu yeni model, 121 katmanlı bir ağdaki parametre sayısını 7 milyondan yaklaşık 3 milyona indirdi. Önerilen model %81 doğruluk oranına sahiptir(Bircanoğlu, Atay, Beşer, Genç, & Kızrak, 2018).

Aral ve arkadaşları, atıkların sınıflandırılmasında en verimli yaklaşımı bulmak için farklı derin öğrenme modellerini test etmişler. Nesnenin ait olduğu çöp kategorisini sadece bir görüntü kullanarak tahmin edebilmek için temiz beyaz arka plan üzerinde bir nesnenin bulunduğu görüntülerden oluşan TrashNet veri kümesi kullanmışlardır. Eğitim için veri setinin yetersiz bulunmasından dolayı veri arttırma teknikleri kullanarak veri sayısı arttırılmıştır. Bu çalışmada DenseNet121, DenseNet169, InceptionResnetV2, MobileNet ve Xception mimarileri kullanılmıştır. Modellerde optimize edici olarak Adam ve Adadelta kullanılmıştır. Modellere ince ayar uygulanarak doğruluk oranları arttırılmıştır. Yapılan deneyler sonucunda ince ayar uygulanmış DenseNet121 %95 test doğruluk oranıyla diğerlerinden daha yüksek orana sahiptir. Modellerin hassas ayar küme

boyutu, küme boyutu ve test doğruluk oranları Çizelge 2.1.'de verilmiştir(Aral, Keskin, Kaya, & Hacıömeroğlu, 2018).

Çizelge 2. 1. İnce ayarlı model sonuçları

| <b>Model</b>      | <b>Hassas Ayar<br/>Küme Boyutu</b> | <b>Küme Boyutu</b> | <b>Test Doğruluk<br/>Oranı (%)</b> |
|-------------------|------------------------------------|--------------------|------------------------------------|
| DenseNet121       | 10                                 | 100                | 95                                 |
| DenseNet169       | 10                                 | 120                | 95                                 |
| Inception-V4      | 7                                  | 120                | 94                                 |
| MobileNet         | 10                                 | 200                | 84                                 |
| InceptionResnetV2 | 10                                 | 210                | 89                                 |

Ruiz ve arkadaşları, TrashNet veri kümesini kullanarak farklı derin öğrenme mimarilerini (VGG, Inception ve ResNet) eğitip karşılaştırmıştır. TrashNet veri kümesinde bulunan 2527 adet görüntü derin sinir ağlarının eğitimi için yetersiz bulunmuştur. Bu yüzden orijinal görüntüler üzerinde döndürme, ölçeklendirme ve parlaklık düzeltmeleri yapılarak veri kümesindeki veri sayısı artırılmıştır. Eğitim için VGG-16, VGG-19, Inception, ResNet ve Inception-ResNet mimarileri kullanılmıştır. En yüksek doğruluk oranı %88,66 ile ResNet modeline aittir. Çizelge 2.2.'de çalışmadaki modellerin doğruluk oranları gösterilmiştir(Ruiz, Sánchez, Vélez, & Raducanu, 2019).

Çizelge 2. 2. Modellerin doğruluk oranı

| <b>Model</b>     | <b>Ortalama Doğruluk (%)</b> |
|------------------|------------------------------|
| VGG-16           | 76.94                        |
| VGG-19           | 79.32                        |
| Inception        | 87.71                        |
| ResNet           | 88.66                        |
| Inception-Resnet | 88.34                        |

Adedeji ve Wang, makine öğrenimi araçlarını kullanarak atığı farklı sınıflara ayırabilen bir atık sınıflandırma sistemi önermişlerdir. Çalışmada TrashNet veri kümesi kullanılmıştır. TrashNet veri kümesinde veri sayısının az olmasından dolayı veri arttırma tekniklerini kullanmışlardır. Önerilen sistemde ResNet-50 ön eğitilmiş model temel alınmıştır. ResNet-50 ağından sadece özellik çıkarılmıştır. Çıkarılan özellik daha sonra Çok Sınıflı DVM kullanılarak sınıflandırılır. Eğitimin tamamından sonra %87 doğruluk oranı elde edildi(Adedeji & Wang, 2019).

2019 yılında Özkaya ve Seyfi tarafından görüş sistemi ile geri dönüşüme katkı sağlamak için çöp türlerini sınıflandıran derin öğrenme uygulaması geliştirilmiştir. Eğitim ve testler, farklı çöp türleri üzerinde birkaç sınıftan oluşan TrashNet veri seti ile gerçekleştirilmiştir. Derin öğrenme uygulaması için kullanılan veri seti 6 farklı sınıfa sahip toplam 2527 görüntüye sahiptir. Eğitim ve test işlem sürelerini kısaltmak ve daha yüksek doğruluk oranı elde etmek için transfer öğrenimi kullanılmıştır. İnce ayarlı modeller olarak Alexnet, VGG16, Googlenet ve Resnet yapıları kullanılmıştır. Sınıflandırıcıların performansını test etmek için Softmax ve Destek Vektör Makineleri olmak üzere iki farklı sınıflandırıcı kullanılmıştır. GoogleNet+SVM ile 6 farklı tipteki çöp görüntüsü %97,86 ile en yüksek doğruluk oranına sahiptir(Ozkaya & Seyfi, 2019).

H. Vo ve arkadaşları, atık ayrıştırma makinelerinde kullanılabilecek ve atıkları sınıflandıran çöp sınıflandırması için derin sinir ağları (DNN-TC) isimli yeni derin sinir ağı modeli önermişlerdir. Bu çalışmada TrashNet veri kümesi ile birlikte VN-trash isimli bir veri kümesi kullanmışlardır. VN-trash, organik, inorganik ve tıbbi atıklar olmak üzere üç tür atıktan oluşmaktadır. Bu veri setinde 5904 adet görüntü yer almaktadır. Görüntüleri sınıflandırmak için ResNext modeli temel alınmıştır. ResNext modelinin ortaklama katmanından sonra iki tamamen bağlı katman ekleyerek orijinal ResNext-101 modelini değiştirdi. Deney sonucunda, DNN-TC'nin Trashnet ve VN-trash veri kümeleri için sırasıyla %94 ve %98 doğruluk sağladığı görülmüştür(Vo, Vo, & Le, 2019).


Tan ve V.Le basit ama oldukça etkili bir bileşik katsayı kullanarak tüm derinlik/genişlik/çözünürlük boyutlarını eşit şekilde ölçekleyen yeni bir ölçeklendirme yöntemi önermişlerdir. Önceki konvolüsyonel sinir ağlarından daha iyi performansa sahip EfficientNet modelini geliştirmişlerdir. Geliştirilen yeni model, hem ImageNet hem de yaygın olarak kullanılan beş transfer öğrenme veri kümesinde daha az parametre ve

FLOPS ile iyi performans göstermiştir. Çizelge 2.3'te herkese açık veri kümeleri üzerinde elde edilen en iyi doğruluk oranları ve EfficientNet'in elde ettiği doğruluk oranları gösterilmiştir(Tan & Le, 2019).

Çizelge 2. 3. Farklı modellerin doğruluk oranı

| Veri Kümesi      | Doğruluk (Model)     | EfficientNet |
|------------------|----------------------|--------------|
| CIFAR-10         | 98.0% (NASNet-A)     | 98.1% (B0)   |
| CIFAR-100        | 87.5% (NASNet-A)     | 88.1% (B0)   |
| Birdsnap         | 81.8% (Inception-v4) | 82.0% (B5)   |
| Stanford Cars    | 93.4% (Inception-v4) | 93.6% (B3)   |
| Flowers          | 98.5% (Inception-v4) | 98.5% (B5)   |
| FGVC Aircraft    | 90.9% (Inception-v4) | 90.7% (B3)   |
| Oxford-IIIT Pets | 94.5% (ResNet-152)   | 94.8% (B4)   |
| Food-101         | 90.8% (Inception-v4) | 91.5% (B4)   |

Kang ve arkadaşları derin öğrenme tabanlı otomatik bir çöp sınıflandırma sistemi önermişlerdir. Şekil 2.2.'de tasarlamış oldukları sistem modeli gösterilmektedir. Sistemin üst katmanında güneş paneli, pil, ışık, Rasperry pi ve kamera bulunmaktadır. Orta katmanda, servo motor yardımı ile döndürülen tahta ve yarım daire dahil olmak üzere mekanik iletişim cihazı bulunmaktadır. Alt katmanda ise geri dönüştürülebilir ve çöp (geri dönüştürülemez) atık kutuları bulunmaktadır. Yazılım tarafında Resnet-34 modeline dayalı bir model kullanılmıştır. Bu model, girdi görüntülerinin özellik birleştirilmesi, atlamalı bağlantıların yeniden kullanımı ve yeni bir aktivasyon tasarımı dahil olmak üzere üç yönüyle daha optimize edilmiştir. Deneysel sonuçlar sınıflandırma doğruluğunun %99 olduğunu göstermektedir(Kang, Yang, Li, & Zhang, 2020).



Şekil 2. 2. Çöp kutusunun tasarımı


Zeng ve arkadaşları, KSA mimarisine dayalı PublicGarbageNet adında bir genel çöp sınıflandırma algoritması önermişlerdir. TrashNet veri kümesi yetersiz bulunduğu için yeni bir veri kümesi oluşturmuşlardır. Bu veri kümesi 10624 görüntü oluşup, 10 alt kategoriye ayrılmıştır. Ayrıca, veri kümesini genişletmek için rastgele döndürme, rastgele çevirme, kırpmaya gibi çeşitli veri artırma işlemlerini de kullanmışlardır. Çalışmada DenseNet, ResNet ve ResNeXt mimarileri başlangıç modeli seçilerek testler yapılmıştır. Çizelge 2.4.'te deney sonuçları gösterilmiştir. Yapılan deneyler sonucunda PublicGarbageNet için doğruluk ve hız olmak üzere iki faktöre dikkat ederek DenseNet169'u seçmişlerdir(Zeng, Lu, Xu, Zhou, & Liu, 2020).

Çizelge 2. 4. Farklı modellerin doğruluk oranı

| Model       | Doğruluk (%) | Çıkarım Zamanı (ms) |
|-------------|--------------|---------------------|
| DenseNet121 | 95.35        | 20.8                |
| DenseNet169 | 96.35        | 23.7                |
| ResNet50    | 93.23        | 21.2                |

|            |       |      |
|------------|-------|------|
| ResNet101  | 93.29 | 36.6 |
| ResNeXt50  | 95.94 | 21.4 |
| ResNeXt101 | 95.47 | 35.8 |

Wang, çevre koruma alanında derin öğrenme uygulamalarını incelemek ve evsel çöplerin hem tanıma hem de sınıflandırma problemine çözüm üretmeyi hedeflemiştir. Bu amaçla ilk önce kamera çekimi ve web taraması ile veri kümesi oluşturulmuştur. 4 kategoride toplam 2650 resim toplanmıştır. Toplanan görüntü sayısı yeterli sayıda olmadığı için ve görüntülerin eğitim modelinin kullanabileceği formata uygun olmadığı için verilere görüntü ön işleme uygulanmıştır. Görüntülerin kontrast ve parlaklık değerlerini değiştirerek, görüntüyü 45°, 90°, 135°, 180° çevirerek veri sayısı artırılmıştır. OpenCv kütüphanesi ile görüntüler VGG-16 modeline uygun girdi formatına dönüştürülmüştür. Bu sayede gürültüler giderilmiş ve nesne tespit edilip, görüntü kırılmıştır. VGG-16 ile yapılan test sonuçlarında %75,6 doğruluk oranına ulaşılmıştır. Şekil 2.3.'te çalışmanın genel akış şeması gösterilmiştir(H. Wang, 2020).



Şekil 2. 3. Sistemin genel akış şeması

Zhang ve arkadaşları, farklı özelliklere sahip atık görüntülerini tanımlama ve sınıflandırma problemini çözmek için ResNet18 tabanlı geri dönüştürülebilir bir atık sınıflandırma modeli (CTR) önermişlerdir. Bu modeli ResNet18 ağ yapısına kendi

kendini izleme modülü (self- monitoring module SMM) ekleyerek oluşturmuşlardır. Modeli test etmek ve diğer algoritmalarla karşılaştırabilmek için TrashNet veri kümesi kullanılmıştır. Yapılan çalışma sonucunda, modelin görüntü sınıflandırma doğruluğunun %95,87'ye ulaştığını gözlemlemişlerdir(Zhang et al., 2021).

2021 yılında Fu ve arkadaşları, derin öğrenmeye dayalı yeni bir akıllı çöp sınıflandırma sistemi ve gömülü Linux sistemi önermiştir. Donanım sisteminde ana kart olarak bir Raspberry Pi 4B kullanmıştır. Sistemin çevre birimleri bir dokunmatik panel, sensörler, 2-DOF (serbestlik derecesi) ve bir kameradan oluşur. Algoritma tarafında ise orijinal MobileNetV3'e göre daha küçük bir model boyutu ve daha az hesaplama süresi ile yüksek tanıma doğruluğuna sahip geliştirilmiş MobileNetV3 modeli önerilmiştir. Böylece transfer öğrenmesine dayalı çöp sınıflandırması için yeni bir GNet modeli geliştirilmişlerdir. Son olarak, sistem gözlemi kolay bir insan-bilgisayar etkileşim sistemi oluşturmak için Python ve QT'ye dayalı bir arayüz oluşturulmuştur. Deneyler Huawei Garbage Classification Challenge Cup veri kümesi üzerinde yapılmıştır. Önerilen sınıflandırma sisteminin tahmin doğruluğu, 0.63 saniyede %92.62'dir(Fu et al., 2021).

Mao ve arkadaşları 2021 yılında yaptıkları çalışmada TrashNet veri seti kullanılarak KSA'ların performansını değerlendirmişlerdir. Ayrıca optimize edilmiş bir KSA kullanarak atıkları verimli bir şekilde sınıflandırmayı amaçlamışlardır. Model eğitimi için TrashNet veri kümesi kullanılmıştır. Eğitim için TrashNet veri kümesindeki görüntü sayısı (2527) yeterli bulunmamıştır. Veri kümesinde bulunan görüntüler; yatay, dikey ve rastgele 25° döndürülerek görüntü sayısı artırılmıştır. Bu çalışmada orijinal DenseNet121'in nöron sayısı ve tam bağlantı katmanının bırakma oranı genetik algoritma ile optimize edilmiştir. Optimize edilmiş DenseNet121 %99,6 doğruluk oranına sahiptir. Ayrıca bu çalışmada, optimize edilmiş DenseNet121'in tahmininin yorumlamak için gradyan ağırlıklı sınıf aktivasyon haritalaması (Grad-CAM) geliştirilmiştir. Grad-CAM, optimize edilmiş DenseNet121 tarafından çıkarılan atık görüntülerinin baskın özelliklerini ısı haritasına benzer bir haritalama ile yorumlanmasını sağlamaktadır(Mao, Chen, Wang, & Lin, 2021).

2022 yılında Chen ve arkadaşları, evsel çöpleri tanıyabilen ve geri dönüşüme kazandırabilen derin öğrenmeye dayalı bir çöp sınıflandırma sistemi geliştirmeyi amaçlamıştır. Sistem donanımsal olarak konveyör bant, sensör, kamera ve atığı uygun

sınıfa yönlendirecek mekanizmadan oluşmaktadır. Model eğitiminde 4256 resim ve 14 alt kategoriden oluşan kendi oluşturdukları veri kümesini kullanmışlardır. Model olarak ShuffleNetV2 mimarisi seçilmiştir. Doğruluk oranını arttırmak ve çıkarım süresini azaltmak için mimariye üç iyileştirme uygulanmış ve geliştirilmiş bu mimariye GCNet adı verilmiştir. Bu iyileştirmeler; “parallel mixed attention mechanism (PMAM)”, düzleştirilmiş doğrusal birim katmanı (FRelu) ve öğrenme aktarımıdır. Çalışma sonucunda GCNet’in %97.9 doğruluk oranına ulaşmıştır(Chen, Yang, Chen, & Jiao, 2022).

2023 yılında Nafiz ve arkadaşları, ConvoWaste isimli Derin Konvolüsyonel Sinir Ağı modeli geliştirmişlerdir. Bu model ile nesne algılama ve görüntü işleme teknikleri kullanarak atıkları otomatik bir yöntem ile sınıflandıran bir sistem önermişlerdir. Atıklar konveyör bant yardımı ile sistem boyunca hareket ettirilmiştir. Sisteme yerleştirilen sensör tarafından atık tespit edilip görüntüsü alınmaktadır. Alınan görüntü sınıflandırılma işlemi için derin öğrenme modelinin bulunduğu işlem birimine gönderilmektedir. Modelin sınıflandırma sonucuna göre servo motorlar, mikro denetleyici aracılığı ile hareket ettirilmektedir. Bu sayede konveyör bant üzerinde hareket ettirilen atık uygun çöp kutusuna atılmaktadır(Nafiz, Das, Morol, Al Juabir, & Nandi, 2023).

Katı atık sınıflandırması için derin öğrenme ve makine öğrenimi üzerine yapılan çalışmalarda araştırmacıların çeşitli zorluklarla karşılaştığı görülmektedir. Bunlar, atık malzemelerin doğal değişkenliği ve çeşitliliğini, etiketli verilerin azlığını ve derin öğrenme modellerinin hesaplama karmaşıklığını içermektedir. Bu sorunların çözülmesi, daha doğru ve verimli atık sınıflandırma sistemlerine katkıda bulunacaktır.

Çalışmada katı atıkların sınıflandırılması ile ilgili diğer çalışmalardan farklı olarak, yeni ve etkili yapay zekâ yöntemleri araştırılmıştır. Derin öğrenme ve makine öğrenmesi modellerinin katı atıkları sınıflandırma performansları karşılaştırılmıştır. Son zamanlarda geliştirilen ve literatürde daha önce kullanılmayan EfficientNet derin öğrenme modeli TrashNet veri kümesi üzerinde eğitilmiştir. Derin öğrenme modellerinin eğitimi esnasında kayıp ve doğruluk oranları izlenmiştir. Ayrıca geliştirilen model gömülü sisteme entegre edilmiştir. Gömülü sistem olarak katı atıkların sınıflandırılmasında daha önce kullanılmamış NVIDIA Jetson Xavier modülü kullanılmıştır. Bu sayede, bu çalışma ile derin öğrenme modellerinin başarı oranı artırılmış ve literatüre katkı sağlanmıştır.

### 3. MATERYAL VE YÖNTEM

Bu kısımda görüntü tanıma ve sınıflandırma uygulamalarında yaygın olarak kullanılan yöntemlerden bahsedilmiştir. Çalışmada kullanılan yapay zekâ yöntemlerinden makine öğrenimi ve derin öğrenme hakkında detaylı bilgi verilmiştir. Makine öğrenimi ve derin öğrenme modelleri hakkında bilgiler verilmiştir. Bu modellerin eğitim ve test aşamalarında kullanılan veri kümesinden bahsedilmiştir. Veri kümesini dengelemek ve daha fazla veri ile çalışabilmek için kullanılan veri arttırma teknikleri hakkında bilgi verilmiştir. Eğitilen derin öğrenme modelleri gömülü bir NVIDIA Jetson Xavier NX cihazında çalıştırılmıştır.

#### 3.1. Veri Kümesi

TrashNet (M. Yang & Thung, 2016) veri kümesi, atık sınıflandırma görevleri için hazırlanmış araştırmacıların kullanımına sunulan erişime açık bir veri kümesidir. Otomatik atık ayırma çalışmalarında kullanılmak üzere Stanford Üniversitesi'ndeki araştırmacılar tarafından 2016 yılında kullanıma sunulmuştur. Veri kümesi, günlük yaşamda yaygın olarak karşılaşılan farklı türdeki atık maddelerin görüntülerinden oluşmaktadır. Bu öğeler altı sınıfa ayrılır: karton, cam, metal, kağıt, plastik ve çöp (geri dönüştürülemeyen öğeler). Veri kümesinin örnek görüntüleri Şekil 3.1.-3.2.-3.3.-3.4.-3.5. ve 3.6.'da gösterilmiştir. Veri kümesi; farklı aydınlatma koşullarında, açılarda ve arka planlarda çekilmiş görüntüleri içermektedir. Bu sayede çeşitli senaryolarda atık malzemelerin bulunduğu görüntüler simule edilmiştir. Tez çalışmasında TrashNet Veri kümesi kullanılmıştır.



Şekil 3. 1. TrashNet veri kümesinde çöp sınıfına ait görüntüler





Şekil 3. 2. TrashNet veri kümesinde kağıt sınıfına ait görüntüler



Şekil 3. 3. TrashNet veri kümesinde plastik sınıfına ait görüntüler



Şekil 3. 4. TrashNet veri kümesinde metal sınıfına ait görüntüler



Şekil 3. 5. TrashNet veri kümesinde cam sınıfına ait görüntüler



Şekil 3. 6. TrashNet veri kümesinde karton sınıfına ait görüntüler

TrashNet veri seti, atık yönetimi ve geri dönüşüm araştırması kapsamındaki çeşitli uygulamalar için yaygın olarak tercih edilen bir kaynaktır. Araştırmacılar, atık sınıflandırma çalışmaları için makine öğrenimi ve derin öğrenme algoritmaları geliştirmek ve değerlendirmek için bu veri kümesini kullanmaktadır. Bu algoritmalar, otomatik atık ayırma sistemlerinde kullanılmaktadır, verimli geri dönüşüm süreçlerine katkıda bulunmakta ve insan gücü üzerindeki yükü azaltmaktadır. TrashNet veri seti, atık sınıflandırma araştırmalarında derin öğrenme ve bilgisayarla görme gibi ileri tekniklerin keşfedilmesini de katkı sağlamaktadır.


### 3.2. Yapay Zekâ

Yapay zekâ, makinelerin insanlar gibi düşünme, kavrama, planlama, hareket etme ve öğrenme gibi insana ait işlevleri taklit etmeye çalışan teknolojidir. Yapay zekâ sistemleri temel olarak ortamları algılar, nesneleri tanır, karar vermeye katkıda bulunur, karmaşık sorunları çözer ve geçmiş deneyimlerden öğrenir. Yapay zekâ sistemleri; konuşma, metin, görüntü vb. biçimindeki verileri girdi olarak kullanmaktadır. Sistem daha sonra çeşitli kurallar ve algoritmalar yardımı ile verileri yorumlar, tahmin eder ve girdi verileri üzerinde hareket ederek verileri işlemektedir. Veri işlemeden sonra sistem bir sonuç, yani başarı veya başarısızlık sağlamaktadır. Sonuç daha sonra analiz ve geri

bildirim yoluyla değerlendirilir. Son olarak sistem değerlendirilmesi için girdi verileri, kurallar, algoritmalar ve hedef sonuçları kullanılır. Bu döngü istenilen sonuca ulaşılan kadar devam eder(Winston, 1984).

Yapay zekâ modelleri, büyük miktarda görüntü verisini işlemenin hesaplama karmaşıklığının üstesinden gelmek için grafik işleme birimleri (GPU'lar) gibi büyük ölçekli hesaplama kaynakları kullanılarak eğitilmektedir. Modeller, sinir ağının ağırlıklarını ve parametrelerini ayarlayarak nesneleri sınıflandırmayı öğrendikleri yinelemeli bir eğitim sürecinden geçmektedir. Eğitim aşamasından sonra modeller, etiketlenmemiş görüntüler içeren ayrı bir test veri kümesinde değerlendirilir. Modeller, test görüntülerinin nesne kategorilerini tahmin eder. Tahmin sonucunda sınıflandırmalarının doğruluğu ve modelin performansı değerlendirilir(McCarthy, 2007).

Makine öğrenimi, verilere göre öğrenen bir yapay zekâ alt kümesidir. Derin öğrenme ise, yapay sinir ağlarının büyük miktarda veri ile öğrenme becerisinin kullanıldığı makine öğreniminin bir altkümesidir. Şekil 3.7.'de Yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki gösterilmiştir.



Şekil 3. 7. Yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki

### 3.3. Makine Öğrenimi

Makine öğrenimi, kalıpları otomatik olarak öğrenebilen ve verilerden tahminler veya kararlar alabilen algoritmalar tasarlamayı sağlayan yapay zekânın bir alt alanıdır. Bilgisayarların öğrenmesini ve zaman içinde performansı iyileştirmesini sağlamak için istatistiksel teknikleri, hesaplama gücünü ve optimizasyon yöntemlerini kullanır. Makine öğrenimindeki temel kavramlar, denetimli öğrenme, denetimsiz öğrenme, pekiştirmeli öğrenme, özellik çıkarma ve model değerlendirmeyi içerir (Mitchell, 2007).

Makine öğrenimi, her biri farklı sorun ve veri türlerine uygun çeşitli yaklaşımları kapsar. Denetimli öğrenme, görünmeyen veriler üzerinde tahminler veya sınıflandırmalar yapmak için etiketli örnekleri kullanan eğitim modellerini içerir. Denetimsiz öğrenme, etiketlenmemiş verilerdeki gizli kalıpları veya yapıları keşfetmeye odaklanır. Takviyeli öğrenme, deneme yanılma yoluyla en uygun davranışları öğrenebilen ve kendi başına kararlar alabilen sistemdir. Yarı denetimli öğrenme, transfer öğrenme ve derin öğrenme gibi diğer teknikler, makine öğreniminin farklı dalları olarak kullanılmaktadır.

Makine öğrenimi, birçok alanda etkin olarak kullanılmakta ve yeni otomatik sistemlerin kullanımına olanak tanımaktadır. Sağlık hizmetlerinde hastalık teşhisi, ilaç keşfi ve kişiselleştirilmiş tıp için kullanılır. Finansa, makine öğrenimi algoritmaları kredi puanlama, dolandırıcılık tespiti ve yatırım analizine yardımcı olur. Makine öğrenimi, diğer alanların yanı sıra öneri sistemlerinde, görüntü ve konuşma tanıma, otonom araçların geliştirilmesinde ve doğal dil işleme alanlarında yaygın olarak kullanılmaktadır.

### **3.3.1. Atık Sınıflandırmada Kullanılan Makine Öğrenmesi Yöntemleri**


Çalışmada makine öğrenmesi yöntemlerinden DVM ve Karar Ağacı kullanıldı. DVM, hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılmaktadır. En iyi sınıflandırma algoritmalarından biri olarak kabul edilmektedir. Seçilen yöntemler KSA modellerine göre daha az karmaşıklığa sahip olduğu için seçilmiştir.

#### **3.3.1.1. Destek Vektör Makinesi**

Destek Vektör Makinesi (DVM), görüntü sınıflandırma görevlerinde yaygın olarak kullanılan güçlü bir makine öğrenimi algoritmasıdır. DVM, özellikle yüksek boyutlu verilerin işlenmesinde etkilidir ve bu da onu görüntü analizi ve tanıma için çok

uygun hale getirmektedir (Chapelle, Haffner, & Vapnik, 1999). Görüntü sınıflandırmasında DVM, görüntüleri görsel özelliklerine göre önceden tanımlanmış kategorilere veya sınıflara ayırmak için kullanılmaktadır.

DVM'nin en önemli avantajlarından biri, görüntü özellikleri ve sınıf etiketleri arasındaki doğrusal olmayan ilişkileri işleme yeteneğidir. DVM bunu, girdi verilerini farklı sınıfları ayırmak için bir hiper düzlemin oluşturulduğu daha yüksek boyutlu bir özellik uzayına dönüştürerek sağlamaktadır. DVM'nin amacı, sınıflandırma hatalarını en aza indirirken sınıfları maksimum şekilde ayıran optimal hiper düzlemi elde etmektir(Noble, 2006). Şekil 3.8.'de DVM algoritmasının uygulanması gösterilmiştir.




Şekil 3. 8. DVM algoritması

DVM'nin görüntü sınıflandırmasında; nesne tanıma, yüz algılama ve tıbbi görüntü analizi gibi çeşitli uygulamalarda başarılı sonuçlar elde etmiştir. DVM'nin yüksek boyutlu verileri işleme yeteneği, gürültüye karşı sağlamlığı ve genelleme becerisi; onu görüntü sınıflandırma görevleri için popüler bir seçim haline getirmiştir (Thai, Hai, & Thuy, 2012). Ancak, DVM'nin büyük veri kümelerini veya çok sayıda sınıf içeren veri kümelerini işleme konusunda sınırlamaları olabilmektedir.

### 3.3.1.2. Karar Ağacı

Karar Ağacı; kategorik verilerin işlenmesinde etkili olan, parametrik olmayan denetimli bir öğrenme metodudur (C.-C. Yang et al., 2003). Her dahili düğümün belirli bir özelliğe dayalı bir kararı temsil ettiği ve her yaprak düğümün bir sınıf etiketini temsil ettiği, hiyerarşik ağaç benzeri bir yapı oluşturarak çalışmaktadır.

Görüntü sınıflandırmada Karar Ağacı algoritmaları, görüntüleri görsel özelliklerine göre farklı kategorilere veya sınıflara ayırmayı amaçlamaktadır. Algoritma, sağlanan eğitim verilerine dayalı olarak, karşılık gelen özellikleriyle birlikte etiketlenmiş görüntülerden bir dizi Evet-Hayır karar kuralı oluşturarak öğrenmektedir. Şekil 3.9.'da Karar Ağacı algoritması gösterilmiştir.



Şekil 3. 9. Karar Ağacı

Karar Ağacı modeli bir kez eğitildikten sonra, özellik değerlerine göre ağaç yapısını aşağı kaydırarak yeni görüntüleri sınıflandırmak için kullanılabilir. Her dahili düğümde, algoritma karşılık gelen özelliği değerlendirir ve giriş görüntüsü için tahmin edilen sınıf etiketini temsil eden bir yaprak düğüme ulaşana kadar hangi yolu izleyeceğini belirler. Karar Ağaçları, özellikle ağaç çok derin ve karmaşık hale geldiğinde aşırı uyum

sorunu yaşayabilmektedir. Budama ve maksimum derinliğin veya minimum numune gereksinimlerinin ayarlanması gibi teknikler, fazla uydurmanın azaltılmasına yardımcı olabilmektedir(Kingsford & Salzberg, 2008).

### 3.4. Yapay Sinir Ağları

Yapay Sinir Ağları, katmanlar halinde düzenlenmiş birbirine bağlı düğümlerden veya yapay nöronlardan oluşan hesaplamalı modellerdir. Bu ağlar, biyolojik sinir ağlarının bilgi işleme ve öğrenme yeteneklerini taklit etmek için tasarlanmıştır.

"Yapay sinir ağı" terimi, beyinden sonra modellenen yapay zekanın biyolojiden ilham alan bir alt alanını ifade eder. Yapay sinir ağları, genellikle insan beyninin yapısını oluşturan biyolojik sinir ağlarına dayalı hesaplamalı bir ağıdır (Egmont-Petersen, de Ridder, & Handels, 2002). İnsan beyinde birbirine bağlı nöronlar olduğu gibi, yapay sinir ağlarında da ağların çeşitli katmanlarında birbirine bağlı nöronlar bulunur. Bu nöronlar düğüm olarak bilinir. Çizelge 3.1.'de biyolojik sinir sistemi elemanlarının yapay sinir ağındaki karşılıkları gösterilmektedir.


Bir yapay sinir ağı, simüle edilmiş nöronlardan oluşmaktadır. Her nöron, biyolojik akson-sinaps-dendrit bağlantısı gibi bağlantılar aracılığıyla diğer düğümlere bağlanır. Bağlantılarla bağlanan tüm düğümler bazı verileri alır ve veriler üzerinde belirli işlemleri ve görevleri gerçekleştirmek için kullanır (Mehdy, Ng, Shair, Saleh, & Gomes, 2017). Her bağlantının bir ağırlığı vardır, bu da bir düğümün diğeri üzerindeki etkisinin gücünü belirler.

Çizelge 3. 1. Biyoloji ve YSA arasındaki ilişki

| Sinir Sistemi | Yapay Sinir Ağı     |
|---------------|---------------------|
| Nöron         | İşlemci Elemanı     |
| Dentrit       | Toplama Fonksiyonu  |
| Hücre Gövdesi | Transfer Fonksiyonu |
| Aksonlar      | Yapay Nöron Çıkışı  |

| Sinapslar | Ağırlıklar |
|-----------|------------|
|-----------|------------|

Yapay sinir ağları, her biri farklı türde problemlere ve verilere uygun çeşitli mimarileri ve öğrenme algoritmalarını kapsamaktadır. Çok katmanlı algılayıcılar dahil olmak üzere ileri beslemeli sinir ağları, örüntü tanıma ve sınıflandırma görevleri için yaygın olarak kullanılmaktadır. Tekrarlayan sinir ağları, sıralı ve zamana bağlı verileri işlemede tercih edilmektedir. Konvolüsyonel sinir ağları, görüntü ve video analiz görevlerinde etkilidir. Geri yayılım, radyal tabanlı fonksiyon ağlar ve kendi kendini düzenleyen haritalar gibi öğrenme algoritmaları, sinir ağlarının verilerden öğrenmesini ve dahili parametrelerini uyarlamasını sağlamaktadır(Krogh, 2008). Şekil 3.10.'da örnek yapay sinir hücresi gösterilmektedir.



Şekil 3. 10. Yapay sinir hücresi

YSA, endüstrileri dönüştüren ve yenilikçi çözümler sağlayan çok sayıda alanda kullanılmaktadır. Bilgisayar görüşünde sinir ağları; nesne algılama, görüntü tanıma ve yüz tanıma sistemlerinde tercih edilmektedir. Doğal dil işleme, duygu analizi, dil çevirisi ve konuşma tanıma gibi görevlerde sinir ağlarından yararlanır. Çok yönlülükleri ve karmaşık verilerden öğrenme yetenekleri, onları bilimsel araştırma ve veri analitiğinde yaygın olarak çalışmalarda yer bulmaktadır.

### 3.5. Derin Öğrenme


Derin Öğrenme, çeşitli alanlarda çokça tercih edilen bir dizi mimariyi ve tekniği kapsamaktadır. Konvolüsyonel Sinir Ağları (KSA), nesne tanıma, görüntü segmentasyonu ve video analizi görevlerinde başarılı sonuçlar vermektedir (Pak & Kim, 2017). Tekrarlayan Sinir Ağları, sıralı veri işlemede etkilidir; doğal dil işleme ve konuşma tanımada kullanılmaktadır. Çekişmeli Üretici Ağlar, gerçekçi veriler üretmek için kullanılır. Bilgisayarla görme ve veri sentezinde uygulama alanlarında kullanılmaktadır.

Görüntü sınıflandırması bağlamında, derin öğrenme modelleri, görüntülerle büyük ölçekli etiketli veri kümeleri üzerinde eğitilir. Eğitim sırasında KSA, farklı özellik düzeylerindeki görüntülerden ilgili özellikleri otomatik olarak çıkarmayı öğrenmektedir. İlk katmanlar, kenarlar ve dokular gibi alt düzey özellikleri yakalar. Sonraki katmanlar daha karmaşık ve üst düzey özellikleri öğrenir. Son katmanlar, bu öğrenilen özellikleri belirli görüntü kategorileriyle eşler. Derin öğrenme modelleri, milyonlarca etiketli görüntünün binlerce nesne kategorisini kapsadığı ImageNet veri kümesi gibi çeşitli görüntü sınıflandırma kıyaslamalarında yüksek doğruluk oranı elde etmektedir. Bu modeller, bazı durumlarda insan seviyesindeki performansı aşarak bu teknolojinin potansiyellerini ve etkilerini ortaya koymaktadır. Derin öğrenme teknolojisinin farklı alanlardaki başarılarına rağmen, görüntü sınıflandırması için derin öğrenme modelleri, büyük miktarlarda etiketlenmiş eğitim verisine ihtiyaç duymaktadır (LeCun, Bengio, & Hinton, 2015).

### 3.6. Konvolüsyonel Sinir Ağları


KSA, görüntüler veya sinyaller gibi verileri işlemek için tasarlanmış özel bir yapay sinir ağı türüdür. KSA'lar, insan beyninin görsel işleme mekanizmasını taklit edecek şekilde tasarlanmıştır. Bu da onları özellikle görüntülerden anlamlı özelliklerin analiz edilmesinde ve çıkarılmasında etkili kılmaktadır. KSA, Konvolüsyon tabanı ve sınıflandırıcı olmak üzere iki bölümden oluşmaktadır. Konvolüsyon tabanı, konvolüsyon katmanları ve havuzlama katmanları yığınınından oluşmaktadır. Ana işlevi belirli pikseller, konturlar ve yönler dahil olmak üzere görüntünün soyut özelliklerini oluşturmaktır, bu nedenle özellik çıkarıcı olarak da adlandırılmaktadır. Sınıflandırıcı, birden çok tam

bağlantılı katmandan oluşur ve ana işlevi, algılanan özelliklere dayalı olarak görüntüyü sınıflandırmaktır(Gu et al., 2018). Şekil 3.11.'de KSA mimarisi gösterilmektedir.



Şekil 3. 11. Konvolüsyonel sinir ağı mimarisi

Konvolüsyonel Sinir Ağları, bilgisayarla görme görevlerinde yüksek performans gösteren çeşitli mimarileri ve teknikleri kapsamaktadır (Sharma, Jain, & Mishra, 2018). Konvolüsyonel ve tamamen bağlantılı katmanlardan oluşan LeNet-5 mimarisi bu alandaki çalışmaların temeli olarak gösterilebilir. Şekil 3.12.'de LeNet mimarisi gösterilmiştir. AlexNet, VGGNet, GoogLeNet ve ResNet; görüntü sınıflandırma, nesne algılama ve segmentasyon görevlerinde yaygın olarak kullanılan mimarilerdir. Transfer öğrenimi, veri artırma ve dikkat mekanizmaları gibi teknikler KSA'ların tahmin becerilerini daha da geliştirmektedir.



Şekil 3. 12. LeNet miamrısı

KSA'ların en güçlü yönlerinden biri, görüntü verilerinden ayırt edici özellikleri otomatik olarak öğrenme yetenekleridir. Manuel çıkarım gerektiren geleneksel

yöntemlerin aksine, KSA'lar görsel verilerden özellik çıkarıp öğrenme işlemini gerçekleştirebilir (Sultana, Sufian, & Dutta, 2018). Bu sayede aydınlatma koşulları, ölçekleme, döndürme ve kesme gibi değişikliklere karşı tahmin becerisi korunmuş olur. Bu sayede görüntü sınıflandırma alanlarında sıkça kullanılan bir yöntem haline gelmiştir.


### **3.6.1. Konvolüsyonel Sinir Ağlarının Katmanları**

Konvolüsyonel sinir ağı; girdi katmanı, gizli katmanlar ve bir çıktı katmanından oluşur. Gizli katmanlar, konvolüsyon gerçekleştiren bir veya daha fazla katman içermektedir. Konvolüsyon çekirdeği, katman için giriş matrisi boyunca kayarken, konvolüsyon işlemi, bir sonraki katmanın girdisine katkıda bulunan bir özellik haritası oluşturur. Bunu havuzlama katmanları, tamamen bağlı katmanlar ve normalleştirme katmanları gibi diğer katmanlar takip eder.

#### **3.6.1.1. Konvolüsyon Katmanı**

Konvolüsyon katmanı, görüntü sınıflandırma görevleri için kullanılan KSA'da temel bir bileşendir. Konvolüsyon katmanının amacı, yerel özellikleri çıkarmak ve girdi görüntülerinden uzamsal desenleri yakalamaktır.

Konvolüsyon katmanında, girdi görüntüsüne bir dizi öğrenilebilir filtre uygulanır. Her filtre, görüntünün üzerinde kaydırılarak ve filtre ile görüntünün karşılık gelen kısmı arasındaki eleman bazında çarpmayı hesaplayarak bir konvolüsyon işlemi gerçekleştirir. Bu işlem, kenarlar, köşeler veya dokular gibi belirli görsel modellerin varlığını vurgulayan bir özellik haritasıyla sonuçlanır. Şekil 3.13.'de özellik haritası gösterilmiştir.



Şekil 3. 13. Özellik haritası

Konvolüsyon işlemi, görüntü sınıflandırmasında oldukça etkili olan iki temel özelliğe sahiptir. Birincisi parametrelerin paylaşılması, filtrelerin farklı uzamsal konumlarda aynı kalıpları algılamasını sağlar. Parametre paylaşımı, ağı girdideki değişikliklere karşı daha verimli ve sağlam hale getirir. İkincisi yerel bağlantı özelliği, özellik haritasındaki her bir nöronun girdinin yalnızca sınırlı bir bölgesini dikkate almasını, yerel kalıpları yakalamasını ve uzamsal bilginin korumasını sağlar(O'Shea & Nash, 2015).

Ağ, çoklu konvolüsyon katmanlarını istifleyerek, girdi görüntülerinden giderek daha karmaşık ve soyut özellikler öğrenebilir. İlk katmanlar tipik olarak kenarlar ve dokular gibi düşük seviyeli özellikleri yakalarken, daha derin katmanlar şekiller veya nesne parçaları gibi daha yüksek seviyeli özellikleri yakalar. Bu özellik öğrenme metodu, ağın farklı sınıfları veya kategorileri etkili bir şekilde temsil etmesini ve ayırt etmesini sağlar.

Konvolüsyon katmanının performansını artırmak için, genellikle aktivasyon fonksiyonları ve havuzlama katmanları gibi ek bileşenler dahil edilir. Aktivasyon fonksiyonları, her konvolüsyon nöronun çıktısına doğrusal olmayan özellikler getirerek, ağın özellikler arasındaki karmaşık ilişkileri öğrenmesini sağlar. Öte yandan havuzlama katmanları, yerel bölgelerden bilgileri toplayarak ve uzamsal boyutları azaltarak özellik haritalarını alt örnekler.


Sonuç olarak, konvolüsyon katmanı, yerel özellikleri çıkararak ve girdi görüntülerinden uzamsal örüntüleri yakalayıp görüntü sınıflandırmasında çok önemli bir rol oynar. Hiyerarşik doğası, parametre paylaşımı ve yerel bağlantı ile birleştiğinde,

derin öğrenme modellerinin karmaşık görsel özellikleri öğrenmesini ve temsil etmesini sağlamaktadır. Konvolüsyonel katman, görüntü sınıflandırma alanını önemli ölçüde geliştirmiştir ve son teknoloji ürünü derin öğrenme mimarilerinde önemli bir bileşen haline gelmiştir.

### **3.6.1.2. Ortaklama Katmanı**

Ortaklama katmanı, KSA mimarileri içinde önemli bir bileşendir. Uzamsal boyutların azaltılmasına ve sağlam özelliklerin çıkarılmasına katkıda bulunmaktadır. Konvolüsyonel Sinir Ağı'ndaki havuzlama katmanı, önceki konvolüsyonel katmanlar tarafından oluşturulan özellik haritaları üzerinde çalışan temel bir modüldür (Sun, Song, Jiang, Pan, & Pang, 2017). İlgili bilgileri korurken boyutlarını küçülterek, özellik haritalarının uzamsal boyutlarını alt örnekleme amaçlamaktadır.

Ortaklama katmanı, girdi görüntüsünü havuzlama pencereleri veya alıcı alanlar adı verilen örtüşmeyen bölgelere bölerek alt örnekleme gerçekleştirir. Her havuzlama penceresi içinde, yerel bilgileri özetlemek için bir havuzlama işlemi uygulanır. En yaygın havuzlama işlemi, havuzlama penceresindeki maksimum değerin temsili değeri olarak seçildiği maksimum havuzlamadır (Albawi, Mohammed, & Al-Zawi, 2017). Ortalama havuzlama gibi diğer havuzlama işlemleri de her bir havuzlama penceresindeki ortalama değeri hesaplamak için kullanılabilir. Şekil 3.14.'te örnek ortaklama işlemleri gösterilmiştir.




Şekil 3. 14. Maksimum ve ortalama ortaklama için örnek

### 3.6.1.3. Tam Bağlantı Katmanı

Bir KSA'daki tamamen bağlı katman, her nöronun bir önceki katmandaki her nörona bağlı olduğu bir tür sinir ağı katmanıdır. Girdi verilerinin yerel yamaları üzerinde çalışan konvolüsyonel ve havuzlama katmanlarının aksine, tamamen bağlı katman, özellik haritaları veya önceki katmanlardan düzleştirilmiş çıktı üzerinde genel olarak çalışır (Basha, Dubey, Pulabaigari, & Mukherjee, 2020). Üst düzey temsilleri öğrenmeyi ve öğrenilen özelliklere dayanarak tahminlerde bulunmayı amaçlar.

Tamamen bağlı katman, bir dizi matris çarpımı ve doğrusal olmayan aktivasyon fonksiyonlarını gerçekleştirir. Tam bağlı katmandaki her bir nöron, Şekil 3.15.'te gösterildiği gibi bir önceki katmandaki tüm nöronlara bağlanarak yoğun bir bağlantı modeli oluşturur. Bu bağlantılarla ilişkili ağırlıklar, eğitim sürecinde geri yayılım yoluyla öğrenilir ve ağındaki karmaşık ilişkileri ve kalıpları yakalamasını sağlar (Sainath, Vinyals, Senior, & Sak, 2015). ReLU (Düzeltilmiş Lineer Birim) veya sigmoid gibi lineer olmayan aktivasyon fonksiyonları, ağı lineer olmamayı sağlamak için eleman bazında uygulanır.



Şekil 3. 15. Tam Bağlantı Katmanı Mimarisi


### 3.7. Transfer Öğrenme

Transfer öğrenme, derin öğrenmedeki gelişmelerle birlikte önemli bir ilgi ve popülerlik kazanmıştır. Büyük ölçekli etiketli veri setlerindeki artış, modern GPU'ların (Graphics Processing Unit) hesaplama gücüyle birleştiğinde, araştırmacıların derin sinir ağlarını çok büyük miktarda veri üzerinde önceden eğitmelerine ve öğrenilen bilgileri sınırlı etiketli verilerle yeni görevlere aktarmalarına olanak sağlamıştır (Torrey & Shavlik, 2010).

Transfer öğrenimi, bir görevi çözerek elde edilen bilginin farklı ancak ilgili bir görevdeki performansı artırmak için kullanıldığı bir makine öğrenimi yaklaşımı olarak tanımlanabilir. Amaç, kaynak ve hedef alanlar arasındaki paylaşılan kalıpları, yapıları veya kavramları kullanmak, böylece modelin öğrenme kabiliyetini ve genellemesini geliştirmektir.

Transfer öğrenimi birkaç temel kavram ve tekniği kapsar. Ön eğitim, genel özellik temsillerini öğrenmek için derin bir sinir ağının ImageNet gibi büyük ölçekli bir veri kümesi üzerinde eğitildiği yaygın bir uygulamadır (Weiss, Khoshgoftaar, & Wang, 2016).

Daha sonra önceden eğitilmiş ağ kullanılarak hedef görev üzerinde ince ayar yapılır ve modelin belirli hedef alan için uyarlanması ve uzmanlaşmasına izin verilir. Başka bir yaklaşım, önceden eğitilmiş ağın sabit özellik çıkarıcı olarak kullanıldığı ve çıkarılan özelliklerin üzerinde ayrı bir sınıflandırıcının eğitildiği özellik çıkarımıdır (Lu et al., 2015). Şekil 3.16.'da transfer öğrenmenin diyagramı gösterilmiştir.



Şekil 3. 16. Transfer öğrenme blok diyagramı

Transfer öğrenimi çeşitli avantajlar sunar ve pratik makine öğrenimi senaryolarında büyük önem taşır. Hedef alanlarda kapsamlı etiketlenmiş veri kümelerine olan ihtiyacı azaltarak, mevcut bilginin ve etiketlenmiş verilerin etkili bir şekilde kullanılmasını sağlar. Önceden eğitilmiş modelleri başlangıç noktaları olarak kullanarak, model geliştirme ve model eğitimi hızlandırır (Cireşan, Meier, & Schmidhuber, 2012). Transfer öğrenimi ayrıca, kaynak etki alanından ilgili ve aktarılabilir özellikleri yakalayarak, özellikle sınırlı etiketli verilere sahip senaryolarda genellemeyi geliştirir.


### 3.8. Atık Sınıflandırmada Kullanılan Derin Öğrenme Modelleri

Atıkları sınıflandırmak için farklı yönlerde daha başarılı olan üç model seçilmiştir. İlk olarak mobil sistemlerde hızlı karar verebilen hafif ağ yapısına sahip MobileNetV3 modeli kullanılmıştır. Ardından Inception mimarisini temel alan ancak artık bağlantıları da içeren InceptionResnetV2 mimarisi kullanılmıştır. Son olarak ağ parametrelerini azaltan ve tanıma doğruluğunu arttıran EfficientNet-B3 modeli kullanılmıştır.

### 3.8.1. EfficientNet

EfficientNet mimarisi, görüntü sınıflandırma görevleri için güçlü ve verimli bir model olarak 2019 yılında literatüre kazandırılmıştır. Hesaplama verimliliğini korurken daha iyi performans elde etmek için ağın derinliğini, genişliğini ve çözünürlüğünü aynı anda ölçeklendirme ilkesine dayanmaktadır. EfficientNet, ağın boyutlarını sistematik olarak dengeli bir şekilde ölçeklendirmeyi içeren bileşik ölçeklendirmedir (Duong, Nguyen, Di Sipio, & Di Ruscio, 2020). Bunu yaparak, model, hesaplama maliyetini çok fazla arttırmadan iyi bir doğruluk oranı elde edebilmektedir.

EfficientNet; konvolüsyon katmanı, sıkıştır ve uyarma blokları (squeeze-and-excitation) ve yeni bir bileşik ölçekleme yöntemi dahil olmak üzere çok sayıda yapı taşından oluşmaktadır. Mimari, verimli hesaplamalara izin veren ve ayrılabilir konvolüsyonlara sahip MobileNetV2 omurgasının bir varyasyonunu kullanmaktadır. Öte yandan sıkıştır ve uyarma blokları, özellik haritalarını uyarlamalı olarak yeniden kalibre ederek kanal bazındaki bağılıkları yakalar (Zheng et al., 2023). EfficientNet'te kullanılan bileşik ölçeklendirme (compound scaling) yöntemi, tek bir ölçeklendirme parametresi kullanarak ağın derinliğini, genişliğini ve çözünürlüğünü eşit şekilde ölçeklendirmeyi içermektedir (Baheti, Innani, Gajre, & Talbar, 2020). Bu yaklaşım, modelin, model kapasitesi ile hesaplama verimliliği arasında iyi bir denge sağlamaktadır. EfficientNet, boyutları ölçeklendirerek girdi görüntülerinde daha karmaşık özellikleri ve kalıpları yakalayabilmektedir. Bu sayede başarılı sınıflandırma performansına sahip olmaktadır. EfficientNet'in öne çıkan özelliklerinden biri, çeşitli görüntü sınıflandırma problemlerindeki güçlü performansıdır. ImageNet gibi popüler veri kümelerinde kompakt model boyutunu korurken önceki mimarilerden daha iyi performans gösteren sonuçlar elde etmiştir. Bu durum bileşik ölçeklendirme yaklaşımının ve hesaplama kaynaklarının verimli bir şekilde kullanılmasının yüksek doğruluk elde edilmesindeki etkinliğini göstermektedir (Tan & Le, 2019). Şekil 3.17.'de EfficientNet-B3 mimarisi gösterilmiştir.



Şekil 3. 17. EfficientNet-B3 mimarisi(Alhichri, Alswayed, Bazi, Ammour, & Alajlan, 2021)

Sonuç olarak EfficientNet mimarisi, bileşik ölçeklendirme kavramını ortaya sürmüştür. Model doğruluğu ile hesaplama verimliliği arasında bir denge sağlayarak görüntü sınıflandırmasına yeni bir bakış açısı getirmiştir. Çeşitli ölçütlerdeki güçlü


performansı ve diğer görevlere aktarılabilirliği, bilgisayarla görme alanında etkinliğini ve geniş uygulanabilirliğini vurgulamaktadır.

### 3.8.2. MobileNet

MobileNet mimarisi, kısıtlı kaynaklara sahip cihazlarda verimli ve cihaza yük bindirmeyen görüntü sınıflandırma uygulamaları için özel olarak tasarlanmıştır. Hesaplama karmaşıklığı ve model boyutunu azaltmayı amaçlarken doğruluk oranı da yüksek tutulmak istenmiştir.

MobileNet mimarisinde, derinlemesine konvolüsyon ve noktasal konvolüsyon olmak üzere iki ayrı derinlemesine ayrılabilir (depthwise separable) filtreler olan temel katmanlar bulunmaktadır. Bu filtreler ile parametre ve işlem sayısı azaltılarak verimli hesaplamalar yapmak amaçlanmıştır. MobileNet, derinlemesine ayrılabilir konvolüsyonları kullandığı için geleneksel konvolüsyonel sinir ağlarına kıyasla model boyutunda ve hesaplama maliyetinde önemli bir azalma sağlamaktadır (Y. Chen et al., 2022). Bu durum onu mobil cihazlara, gömülü sistemlere ve diğer düşük güçlü platformlarda kullanımı için uygun hale getirmiştir. MobileNet'te ayrıca her katmandaki kanal sayısını kontrol eden bir genişlik çarpanı parametresi mevcuttur. Bu parametre, doğruluk ve model boyutu arasındaki değiş tokuş üzerinde ayrıntılı kontrol sağlamaktadır. Genişlik çarpanı ayarlanarak, kullanıcılar modeli kendi özel gereksinimlerini karşılayacak şekilde özelleştirebilmektedir. Bu mimaride verimliliğe odaklanılmasına rağmen, standart görüntü sınıflandırma kıyaslamalarında başarılı sonuçlar elde etmiştir(A. G. Howard et al., 2017). Şekil 3.18.'de MobileNetV3 mimarisi gösterilmiştir.





Şekil 3. 19. InceptionResnet mimarisi (Szegedy et al., 2017)

InceptionResNet mimarisi, ImageNet de dahil olmak üzere görüntü sınıflandırmasında çeşitli veri kümelerinde başarılı sonuçlar elde etmiştir. Derin ve verimli tasarımı, sınırlı hesaplama kaynaklarıyla bile doğru sınıflandırmayı sağlamaktadır (Mahdianpari, Salehi, Rezaee, Mohammadimanesh, & Zhang, 2018). Mimari, önceden eğitilmiş InceptionResNet modellerinin daha küçük veri kümeleriyle belirli görüntü sınıflandırma görevlerinde ince ayarının yapıldığı transfer öğrenme senaryolarında da yaygın olarak kullanılmıştır.

### 3.9. Performans Değerlendirme Ölçütleri

Performans değerlendirme kriterleri, yapay zekâ algoritmalarının etkinliğini ve verimliliğini objektif olarak değerlendirebilmek için kullanılmaktadır. Yapay zekâ çalışmalarında karmaşıklık matrisi, ikili sınıflandırma modellerinin performansını değerlendirmek için kullanılmaktadır. Tahmin edilen ve gerçek sınıf etiketlerinin kapsamlı bir özetini sunarak araştırmacıların modelin doğruluk, hassaslık, duyarlılık, F1-Puanı ve diğer performans ölçümlerini analiz etmelerini sağlamaktadır (Jiao & Du, 2016).

Karmaşıklık matrisi, tahmin ve gerçek sınıf etiketlerini temsil eden kare bir matris olarak gösterilmektedir. Matrisin dört hücresi farklı sonuçları temsil eder:

- Gerçek Pozitif (TP): Gerçekte pozitif olan ve model tarafından doğru bir şekilde pozitif olarak tahmin edilen durumlar.
- Gerçek Negatif (TN): Gerçekte negatif olan ve model tarafından doğru bir şekilde negatif olarak tahmin edilen durumlar.
- Yanlış Pozitif (FP): Gerçekte negatif olan ve model tarafından yanlış bir şekilde pozitif olarak tahmin edilen durumlar.
- Yanlış Negatif (FN): Gerçekte pozitif olan ve model tarafından yanlış bir şekilde negatif olarak tahmin edilen durumlar.

**Doğruluk:** Yapay zekâ çalışmalarında kullanılan, karmaşıklık matrisinden türetilen bir performans ölçüsüdür. Doğruluk metriği, modelin performansının genel değerlendirmesini sağlar ve tüm durumlarda doğru tahminlerin oranını gösterir. Doğru sınıflandırılmış örnek sayısının toplam örnek sayısına oranı olarak ifade edilmektedir ve Denklem 3.1.'de gösterildiği gibi hesaplanmaktadır.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

**Duyarlılık:** Tüm gerçek pozitif örneklerden, gerçek pozitif tahminlerin oranını ölçer. Başka bir deyişle, modelin pozitif durumları doğru bir şekilde belirleme yeteneği hakkında bilgi vermektedir. Denklem 3.2.'de gösterildiği gibi hesaplanmaktadır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.2)$$

**Hassasiyet:** Doğru olarak sınıflandırılan pozitif tahmin sayısının, pozitif olarak sınıflandırılan toplam (doğru ve yanlış) tahmin sayısına oranıdır. Denklem 3.3.'e göre hesaplanmaktadır. Bu metrik modelin bir tahmini pozitif olarak sınıflandırmadaki doğruluğunu ölçer.

$$Hassasiyet = \frac{TP}{TP + FP} \quad (3.3)$$

**F1-Puanı:** Duyarlılık ve hassasiyet metriklerinin harmonik ortalamaları alınarak hesaplanır. Hassasiyeti ve duyarlılığı tek bir metriğe birleştiren F1 puanı, modelin performansının kapsamlı bir değerlendirmesini sağlamaktadır. Denklem 3.4.'de gösterildiği gibi hesaplanmaktadır.

$$F1 - Puanı = \frac{2 * Hassasiyet * Duyarlılık}{Hassasiyet + Duyarlılık} \quad (3.4)$$


### 3.10. Veri Arttırma

Derin öğrenme çalışmalarında büyük veri kümeleri ile çalışmak performans açısından önem teşkil etmektedir. Az miktarda veri ile yapılan çalışmalarda genellikle düşük doğruluk oranı veya ezberleme problemi ile karşılaşılır. Bu problemlerle karşılaşmamak ve modelin iyi bir şekilde öğrenip, performansını artırmak için veri artırma yöntemlerine başvurulur (Shorten & Khoshgoftaar, 2019).

Veri artırma ile daha büyük ve daha çeşitli bir veri kümesi oluşturulmuştur. Artırılmış veri seti, eğitim örneklerinin değişkenliğini arttırmaktadır, aşırı öğrenme riskini azaltmaktadır ve modellerin performansını arttırmaktadır.

Çalışmada, katı atık görüntülerinin çeşitliliğini ve değişkenliğini artırmak için çeşitli veri arttırma teknikleri kullanıldı. Bu teknikler arasında rasgele döndürmeler,

ötelemeler, yatay çevirme ve yakınlaştırma yer almaktadır. Bu dönüşümleri uygulayarak, yapay zekâ yöntemlerinin genelleme yeteneğini geliştirmek amaçlanmıştır. Şekil 3.20.’de veri artırma uygulanmış örnek görüntüler gösterilmektedir.



Şekil 3. 20. Veri artırma uygulanmış örnek görüntüler

### 3.11. Yapay Zekâ Kiti

NVIDIA Jetson, özellikle gömülü sistemler ve uç sistemler için tasarlanmış yüksek performanslı bilgi işlem yetenekleri sunan, görüntü sınıflandırma görevleri için kullanılan bir araçtır (Mittal, 2019). Sınırlı hesaplama kaynaklarına sahip cihazlarda gerçek zamanlı görüntü sınıflandırması sağlamak için güçlü GPU (Grafik İşleme Birimi) teknolojisini verimli işleme birimleriyle birleştirmektedir.

Görüntü sınıflandırması için NVIDIA Jetson kullanmanın en önemli avantajlarından biri, derin öğrenme modellerini çalıştırabilmesidir. Platform, TensorFlow ve PyTorch gibi popüler derin öğrenme kütüphanelerini destekleyerek, geliştiricilerin görüntü sınıflandırma görevleri için KSA’ların eğitmesine ve kullanmasına olanak tanır. Jetson, GPU hızlandırması ile büyük miktarda görüntü verisini verimli bir şekilde işleyebilir ve yüksek sınıflandırma doğruluğu elde edebilmektedir.

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tezde, yapay zekâ teknikleri, özellikle ve geleneksel makine öğrenimi modelleri (DVM ve Karar Ağacı) ve derin öğrenme modelleri (InceptionResnet, EfficientNet ve MobileNet) kullanarak katı atıkların sınıflandırılması incelenmiştir. Amaç, verimli atık yönetimi uygulamalarına katkıda bulunabilecek etkili bir atık sınıflandırma sistemi geliştirmektir. Eğitim ve test için 16 GB birleşik RAM'e (GPU/CPU) ve bir M1 SoC'a sahip Macbook Pro kullanılmıştır. Ek olarak, gerçek zamanlı atık sınıflandırması için modelleri uygulamak ve devreye almak için NVIDIA Jetson Xavier modülü kullanıldı.

##### 4.1. Makine Öğrenmesi Sonuçları

Bu tezde Katı atıkları tanıma ve sınıflandırma için makine öğrenmesi yöntemlerinden DVM ve Karar Ağacı kullanılmıştır. Bu modellerin atık malzemeleri doğru bir şekilde tanımlama ve sınıflandırmadaki etkinliği araştırılmıştır.

Bu tez çalışmasında, katı atıkların sınıflandırılması için DVM ve Karar Ağacı metotlarının etkinliği araştırılmıştır. DVM %62,31 doğruluk oranı elde ederken, Karar Ağacı %43,38 doğruluk oranı elde etmiştir. DVM yüksek miktarda veriyle daha iyi doğruluk oranları elde ettiği için Karar Ağacı metodundan daha yüksek doğruluk oranına ulaşmıştır. Bu bulgular; DVM'nin, farklı katı atık türlerini doğru bir şekilde kategorize etmede Karar Ağacı'ndan daha iyi performans gösterdiğini ortaya koymaktadır.


Gözlemlenen doğruluk oranları, katı atık sınıflandırması için DVM ve Karar Ağacı metotlarının performansı hakkında bilgi sağlamaktadır. DVM tarafından elde edilen daha yüksek doğruluk oranı ile farklı sınıflar arasındaki marjının büyük olması atıkları daha etkin bir şekilde sınıflandırabildiğini göstermektedir. DVM'nin karmaşık karar sınırlarını yönetme becerisi, onu atık sınıflandırma görevleri için Karar Ağacına göre daha uygun bir seçim haline getirmektedir. Öte yandan, Karar Ağacı daha düşük doğruluk oranı, katı atık veri setinde bulunan karmaşıklıkları ve varyasyonları yakalamadaki sınırlamalarını göstermektedir.

Bu çalışmada elde edilen nispeten düşük doğruluk oranları, katı atığın doğru bir şekilde sınıflandırılmasıyla ilgili zorlukların altını çizmektedir. Katı atık sınıflandırması; çeşitli atık türleri, atık bileşimindeki farklılıklar ve görsel özelliklerdeki olası benzerlikler nedeniyle karmaşık bir görevdir. Bu zorluklar muhtemelen Karar Ağacı'nın nispeten daha düşük doğruluk oranına sahip olmasının sebebi olabilir.

#### 4.2. Derin Öğrenme Sonuçları

Bu tezde atıkları, geri dönüştürülebilir katı atıkların tanımlanması ve sınıflandırılması için derin öğrenme yöntemlerinden InceptionResnet, EfficientNet ve MobileNet modellerinin etkinliğini araştırılmıştır. Bu bölümde, atık malzemelerinin daha karmaşık özelliklerini algılama ve anlama yeteneğiyle derin öğrenme modellerinin başarılı bir şekilde kullanıldığı görülmektedir. Modellerin yüksek doğruluk oranlarıyla atık malzemeleri doğru bir şekilde sınıflandırmada etkili olduğu gösterilmektedir.

Bu çalışmada, katı atıkların sınıflandırılmasında farklı derin öğrenme modelleri kullanılmıştır. Bunlar; InceptionResnet, EfficientNet ve MobileNet'tir. InceptionResnet %92,49, EfficientNet %94,47 ve MobileNet %91,30 doğruluk oranı elde etmiştir. Bu sonuçlar, EfficientNet'in farklı katı atık türlerini doğru bir şekilde sınıflandırmada hem InceptionResnet hem de MobileNet'ten daha iyi performans gösterdiğini ortaya koymaktadır.



Şekil 4. 1. Derin öğrenme modellerinin karmaşık matrisleri


Şekil 4.1.'deki karmaşık matrisleri incelendiğinde, en fazla doğru sonuçları EfficientNet modeli verirken, MobileNet modeli en az doğru sonuçları vermektedir. InceptionResnet modeli çöplerin (%92.9 doğru tahmin oranı) sınıflandırılmasında diğer iki modelden daha doğru tahminler yapmış olsa da diğer sınıflarda aynı başarıyı gösterememektedir. MobileNet modeli ise camları (%96 doğru tahmin oranı) sınıflandırmada EfficientNet modelinden daha doğru tahminler yapmıştır. Karton sınıfında bütün modeller aynı doğruluk oranına sahiptir. Ancak geri kalan sınıflarda EfficientNet daha doğru tahminler yapmıştır.

Araştırma bulguları, katı atıkların sınıflandırılmasında derin öğrenme modellerinin etkinliğini göstermektedir. EfficientNet hem InceptionResnet'i hem de

MobileNet'i geride bırakarak %94,47 ile daha yüksek doğruluk oranı elde etti. Bu, EfficientNet'in atık görüntülerden anlamlı özellikler çıkarmada daha kullanışlı olduğunu ve doğru sınıflandırmalar yaptığını göstermektedir. EfficientNet'in yüksek başarısı, katı atık veri setinde bulunan karmaşıklığı ve varyasyonları ele almadaki becerisini göstermektedir. Çizelge 4.1.'de EfficientNet-B3 modelinin TrashNet veri kümesi kullanılarak yapılan eğitim ve test sonucunda elde ettiği performans değerleri gösterilmektedir. Şekil 4.2.'de ise EfficientNet-B3 test veri kümesinde her sınıf için yaptığı yanlış tahmin sayıları gösterilmektedir.

Çizelge 4. 1. EfficientNet-B3 modelinin performans ölçütleri


| Sınıf   | Hassasiyet | Duyarlılık | F1-Puanı |
|---------|------------|------------|----------|
| Cam     | 95.83      | 92.00      | 93.88    |
| Karton  | 97.56      | 97.56      | 97.56    |
| Kağıt   | 96.61      | 96.61      | 96.61    |
| Metal   | 84.78      | 97.50      | 90.70    |
| Plastik | 95.83      | 95.83      | 95.83    |
| Çöp     | 100        | 71.43      | 83.33    |



Şekil 4. 2. EfficientNet-B3 modelinin test sonucunda sınıflara göre yanlış sayıları

Eğitim kaybı, bir derin öğrenme modelinin eğitim verilerine ne kadar uyduğunu değerlendirmek için kullanılan bir ölçümdür. Yani modelin hatasını eğitim veri kümesinde değerlendirir. Eğitim kaybı, eğitim setindeki her örnek için hataların toplamı alınarak hesaplanır. Doğrulama kaybı, bir derin öğrenme modelinin doğrulama veri kümesinde performansını değerlendirmek için kullanılan bir ölçümdür. Doğrulama kaybı, eğitim kaybına benzer ve doğrulama verilerindeki her örnek için hataların toplamı ile hesaplanır. Şekil 4.3.'te eğitilen derin öğrenme modellerinin eğitim ve doğrulama

kaybı grafikleri gösterilmektedir. Bu grafikler, modelin performansını teşhis etmek ve hangi yönlerin ayarlanması gerektiğinin belirlenmesine yardımcı olmaktadır. Elde edilen sonuçlarda, eğitim kaybı ve doğrulama kaybı hem azalmakta hem de belirli bir noktada sabitlenmektedir. Bu, modelin optimal bir uyuma sahip olduğunu göstermektedir.



Şekil 4. 3. (a) EfficientNet-B3 eğitim ve test kayıp grafiği, (b) MobileNet-V3 eğitim ve test kayıp grafiği, (c) InceptionResnet-V2 eğitim ve test kayıp grafiği

MobileNet ise EfficientNet ve InceptionResnet'in doğruluklarından daha düşük olan %91,30'luk bir doğruluk oranı elde etmiştir. MobileNet, katı atıkları sınıflandırma konusunda yetkinlik gösterirken, performansı diğer modellere göre biraz daha düşüktü. Bu, nispeten daha basit mimarisine ve atık görüntülerindeki karmaşık ayrıntıları ve desenleri yakalama yeteneğini sınırlamış olabilecek azaltılmış hesaplama karmaşıklığına bağlanabilir. Çizelge 4.2.'de MobileNet-V3 modelinin TrashNet veri kümesi kullanılarak yapılan eğitim ve test sonucunda elde ettiği performans değerleri gösterilmektedir. Çizelge 4.3.'te ise InceptionResnet-V2 modeli için bu ölçütler gösterilmektedir. Çizelge

4.1. – Çizelge 4.2. ve Çizelge 4.3.'e göre F1-Puanı incelendiğinde en yüksek oranlar karton sınıfına ait olurken en düşük oranlar çöp sınıfına aittir. Çöp sınıfında diğer kategorilerdeki atık türlerine görsel olarak benzeyen atıklar bulunduğu için en düşük F1-Puanına sahiptir.

Çizelge 4. 2. MobileNet-V3 modelinin performans ölçütleri

| Sınıf   | Hassasiyet | Duyarlılık | F1-Puanı |
|---------|------------|------------|----------|
| Cam     | 76.19      | 96.00      | 84.96    |
| Karton  | 88.80      | 97.56      | 93.02    |
| Kâğıt   | 96.15      | 84.75      | 90.09    |
| Metal   | 80.95      | 85.00      | 82.93    |
| Plastik | 94.87      | 77.08      | 85.06    |
| Çöp     | 90.91      | 71.43      | 80.00    |


Çizelge 4. 3. InceptionResnet-V2 modelinin performans ölçütleri

| Sınıf   | Hassasiyet | Duyarlılık | F1-Puanı |
|---------|------------|------------|----------|
| Cam     | 92.16      | 94.00      | 93.07    |
| Karton  | 97.56      | 97.56      | 97.56    |
| Kâğıt   | 98.25      | 94.92      | 96.55    |
| Metal   | 88.10      | 92.50      | 90.24    |
| Plastik | 93.62      | 91.67      | 92.63    |
| Çöp     | 92.86      | 92.86      | 92.86    |


Üç modelin sınıflandırma performansları Çizelge 4.4.'de verilmiştir. F1-puanı, duyarlılık ve hassasiyet metriklerinin harmonik ortalamaları kullanılarak hesaplanır. F1-puanını yüksek olması hem duyarlılık hem de geri hassasiyeti yüksek olması anlamına gelir. Böylece F1-puanı, modelleri doğrulukla birlikte değerlendirmek için tercih edilmektedir. Çizelge 4.4.'e göre EfficientNet-B3 modeli en yüksek F1-Puanına sahip olmuştur.

Çizelge 4. 4. Test edilen modellerin performans ölçütleri


| Model              | Doğruluk | Hassasiyet | Duyarlılık | F1-Puanı |
|--------------------|----------|------------|------------|----------|
| EfficientNet-B3    | 94.47    | 94.77      | 94.44      | 94.40    |
| InceptionResnet-V2 | 92.49    | 94.13      | 94.05      | 94.07    |
| MobileNet-V3       | 91.30    | 88.06      | 86.90      | 86.89    |



(a)



(b)




(c)

Şekil 4. 4. (a)EfficientNet-B3 eğitim ve test doğruluk grafiği, (b) MobileNet-V3 eğitim ve test doğruluk grafiği, (c) InceptionResnet-V2 eğitim ve test doğruluk grafiği

Şekil 4.4.'te eğitim ve test veri kümeleri için doğruluk grafikleri gösterilmiştir. EfficientNet-B3 modelinin eğitim sürecinde küçük bir dalgalanma meydana gelmiştir. Ancak diğer iki model grafiği hemen hemen doğrusal bir şekilde artmıştır. Modellerin en iyi sonuca ulaştığı devir sayısı; EfficientNet-B3 için 10, MobileNet-V3 modeli için 7 InceptionResnet-V2 modeli için 22 olmuştur. InceptionResnet-V2 modelinin daha

yüksek devir sayısı ağı karmaşıklığından kaynaklanmaktadır. Diğer iki modelin daha az devir sayısına sahip olması eğitim ve tahmin sürelerinin kısa olduğunu göstermektedir. Derin öğrenme modelleri arasındaki başarı farklılıkları, mimari farklılıklarına ve karmaşıklığına bağlanabilir. EfficientNet, bileşik ölçekleme yaklaşımı ile en yüksek doğruluk oranına sahiptir. Inception ve Resnet mimarilerinin bir kombinasyonu olan InceptionResnet de farklı mimari unsurları birleştirmenin faydalarını vurgulayan iyi bir performans sergilemiştir. MobileNet, daha düşük bir doğruluk oranı elde etmesine rağmen, azalan hesaplama gereksinimleri nedeniyle katı atık sınıflandırması için hala kullanılabilir bir seçenek olabilir. MobileNet-V3 ve InceptionResnet-V2 modellerinin sınıflara göre yanlış tahmin sayıları da Şekil 4.5'te gösterilmektedir.



Şekil 4. 5. (a) MobileNet-V3 modelinin test sonucunda sınıflara göre yanlış sayıları, (b) InceptionResnet-V2 modelinin test sonucunda sınıflara göre yanlış sayıları

Modellerin sınıflara göre yanlış tahminleri incelendiğinde, InceptionResnet-V2 modelinin çöp atıkları ayrıştırmada daha başarılı olduğu görülmektedir. MobileNet-V2 modeli cam atıkları tahmin etmede diğer iki sınıftan daha başarılıdır. EfficientNet-B3 modeli ise plastik, kâğıt ve metal atıkların sınıflandırılmasında daha doğru tahminler yapmıştır. Her model kendi özgü tahmin başarısına sahip olsa da genel değerlendirmede EfficientNet-B3 modeli daha az yanlış tahmin sayısına sahiptir. Ayrıca bu karşılaştırma ile farklı mimarilerin farklı sorunları çözmede daha başarılı olduğu gösterilmiştir. İleride

birden fazla mimari kullanılarak geliştirilecek modeller daha doğru tahmin yapmada daha yüksek başarı gösterebilir.

Bu çalışmanın bulguları, otomatik katı atık sınıflandırması alanına katkıda bulunarak, atık yönetimi uygulamalarını iyileştirmeye yönelik derin öğrenme modellerinin potansiyelini kanıtlamaktadır. Özellikle EfficientNet katı atıkları doğru bir şekilde sınıflandırmada etkili olduğunu göstermiştir. Bu model; verimli atık yönetimi ve kaynak geri kazanım süreçlerine yardımcı olarak, atık ayırma uygulamalarında değerli bir araç olarak hizmet edebilir.

#### **4.3. Makine Öğrenmesi ve Derin Öğrenme Sonuçlarının Karşılaştırılması**

Çizelge 4.5.'te bu çalışmada önerilen yöntemlere bakıldığında derin öğrenme modelleri özellikle EfficientNet, farklı katı atık türlerini doğru bir şekilde sınıflandırmada makine öğrenimi modellerinden daha iyi performans göstermiştir. EfficientNet'in atık görüntülerinden ilgili özellikleri çıkarma yeteneği, InceptionResnet ve MobileNet'e kıyasla daha başarılı olmuştur. Öte yandan DVM ve Karar Ağacı, daha düşük doğruluk oranı ile atık görüntülerinde bulunan karmaşık kalıpları ve varyasyonları yakalamada daha başarısız olduğu görülmüştür.

Bulgular, atık sınıflandırma görevlerinde derin öğrenme yöntemlerinin avantajlarını vurgulayarak, görüntülerin karmaşık özelliklerini otomatik olarak öğrenme ve çıkarma yeteneklerini öne çıkarmaktadır. Bu çalışma, atık sınıflandırma süreçlerinin verimliliğini ve doğruluğunu iyileştirerek atık yönetimi uygulamalarını geliştirmede yapay zekanın, özellikle derin öğrenmenin potansiyelini göstermektedir.

Sonuçlar, atık sınıflandırma sistemlerini ilerletmek ve daha sürdürülebilir atık yönetimi uygulamalarına katkıda bulunmak için derin öğrenme modellerinin daha fazla araştırılması ve optimizasyonu için bir temel görevi görmektedir.

#### **4.4. Sonuçların Literatür ile Karşılaştırılması**

Çizelge 4.5.'te katı atıkların sınıflandırılması ile ilgili yapılmış önceki çalışmaların doğruluk oranları ve kullanılan veri kümeleri verilmiştir. Ayrıca bu tez çalışmasında kullanılan yöntemler literatür ile karşılaştırılmıştır.

Çizelge 4. 5. Çalışmada önerilen modellerin literatür ile karşılaştırılması

| Yayın Adı                                                                                                         | Yayın Yılı | Veri Kümesi (Veri Sayısı)                                                       | Doğruluk Oranı |
|-------------------------------------------------------------------------------------------------------------------|------------|---------------------------------------------------------------------------------|----------------|
| Common Garbage Classification Using MobileNet(Rabano, Cabatuan, Sybingco, Dadios, & Calilung, 2018)               | 2018       | TrashNet (2527)                                                                 | 87.2%          |
| Fine-Tuning Models Comparisons on Garbage Classification for Recyclability(Ozkaya & Seyfi, 2019)                  | 2019       | TrashNet (2527)                                                                 | 97.86%         |
| Automatic Image-Based Waste Classification(Ruiz et al., 2019)                                                     | 2019       | TrashNet (2527)                                                                 | 88.66%         |
| Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network(Adedeji & Wang, 2019)    | 2019       | TrashNet (2527)                                                                 | 87%            |
| A Combination Model Based on Transfer Learning for Waste Classification(Huang, He, Xu, & Huang, 2020)             | 2019       | ImageNet (2527)                                                                 | 94%            |
| An Automatic Garbage Classification System Based on Deep Learning(Kang et al., 2020)                              | 2020       | Kendi Hazırladıkları Veri Kümesi (4168)                                         | 89%            |
| Xception Architecture Transfer Learning for Garbage Classification(Endah & Shiddiq, 2020)                         | 2020       | TrashNet (2527)                                                                 | 84%            |
| Garbage Recognition and Classification System Based on Convolutional Neural Network VGG16(H. Wang, 2020)          | 2020       | Kendi Hazırladıkları Veri Kümesi (2650)                                         | 75.60%         |
| GarbageNet: A Unified Learning Framework for Robust Garbage Classification(J. Yang, Zeng, Wang, Zou, & Xie, 2021) | 2021       | HUAWEI Cloud Garbage Classification yarışmasında yayınlanan veri kümesi (19459) | 96,96%         |
| Recycling Waste Classification Using                                                                              | 2021       | TrashNet (2527)                                                                 | 95%            |

|                                                          |      |                 |         |
|----------------------------------------------------------|------|-----------------|---------|
| Optimized Convolutional Neural Network(Mao et al., 2021) |      |                 |         |
| Bu çalışmada önerilen yöntem (DVM)                       | 2023 | TrashNet (2527) | 62.31 % |
| Bu çalışmada önerilen yöntem (Karar Ağacı)               | 2023 | TrashNet (2527) | 43.38 % |
| Bu çalışmada önerilen yöntem (EfficientNet-B3)           | 2023 | TrashNet (2527) | 94.47%  |
| Bu çalışmada önerilen yöntem (InceptionResnet-V2)        | 2023 | TrashNet (2527) | 92.49%  |
| Bu çalışmada önerilen yöntem (MobileNet-V3)              | 2023 | TrashNet (2527) | 91.30%  |

Literatür ile karşılaştırıldığında makine öğrenmesi yöntemlerinin düşük doğruluk oranına sahip olduğu görülmektedir. Bu tez çalışmasında kullanılan EfficientNet-B3 modelinin ise literatürdeki çalışmalardan üç tanesi dışında ger kalan çalışmalardan daha iyi doğruluk oranına sahip olduğu görülmektedir. Özkaya ve Seyfi'nin (Ozkaya & Seyfi, 2019) yaptıkları çalışmada ince ayar kullanmaları doğruluk oranını büyük ölçüde arttırmıştır. Yang ve arkadaşlarının (J. Yang et al., 2021) 2021 yılında önerdikleri yöntemin doğruluk oranını hem geliştirilen algoritma hem de veri kümesinin genişliği arttırmıştır. Mao ve arkadaşları (Mao et al., 2021) ise sinir ağlarının genetik algoritma ile optimize edilmesinin doğruluk oranını arttırabileceğini göstermektedir. Veri arttırma, güncel mimarilerin kullanılması ve model performansının izlenebilirliği sayesinde kullandığımız EfficientNet-B3 modelinin doğru tahmin yapmadaki başarısı önemli ölçüde artmıştır. Bu sayede literatürdeki diğer çalışmalardan daha yüksek doğruluk oranına ulaşılmıştır. Gelecekteki çalışmalarda optimize edilmiş sinir ağı, modellere ince ayar uygulanması ve daha büyük veri kümelerinin kullanılması daha iyi sonuçlar verebilir.

#### 4.5. Tartışma

Bu çalışmada elde edilen sonuçlar, farklı yapay zekâ yöntemleri kullanılarak geri dönüştürülebilir katı atıkların tanıma ve sınıflandırma konusundaki performans farklılıklarını göstermektedir. InceptionResNet, EfficientNet, MobileNet, DVM (Derin Vektör Makinesi) ve Karar Ağacı gibi farklı modellerin kullanıldığı deneylerde doğruluk oranları karşılaştırılmıştır.

Sonuçlar incelendiğinde, EfficientNet'in en yüksek doğruluk oranı (%94,47) elde ettiği görülmektedir. Bu, EfficientNet modelinin geri dönüştürülebilir katı atıkları tanıma ve sınıflandırmada diğer modellere göre daha başarılı olduğunu göstermektedir. InceptionResNet (%92,49) ve MobileNet (%91,30) modelleri de yüksek doğruluk oranlarına sahiptir ve etkili sonuçlar elde etmiştir.

Diğer yandan, DVM (%62,31) ve Karar Ağacı (%43,38) modelleri daha düşük doğruluk oranlarına sahip olmuştur. Bu sonuçlar, bu modellerin geri dönüştürülebilir katı atıkları tanıma ve sınıflandırmada diğer derin öğrenme modellerine kıyasla daha sınırlı başarı elde ettiğini göstermektedir.

Tartışma bölümünde elde edilen sonuçlar, model seçiminin geri dönüştürülebilir katı atıkların tanıma ve sınıflandırmadaki başarı üzerinde önemli bir etkiye sahip olduğunu vurgulamaktadır. EfficientNet gibi daha karmaşık ve derin mimarilere sahip modellerin daha yüksek doğruluk oranlarına ulaştığı görülmektedir. Ancak, DVM ve Karar Ağacı gibi daha basit modellerin doğruluk oranları daha düşüktür.

Bu çalışma, gelecekte geri dönüştürülebilir katı atık tanıma ve sınıflandırmada kullanılan derin öğrenme modellerinin daha fazla incelenmesi ve iyileştirilmesi gerektiğini ortaya koymaktadır. Ayrıca, veri kümesinin çeşitliliğinin ve veri miktarının artırılmasının model performansını etkileyebileceği göz önünde bulundurulmalıdır. Bu çalışmanın sonuçları, atık yönetimi ve geri dönüşüm süreçlerinde yapay zekâ tabanlı çözümlerin potansiyelini göstermekte olup, ilerideki araştırmalar ve uygulamalar için yol gösterici niteliktedir.

#### **4.6. Yapay Zekâ Kiti**

Bu çalışmada, NVIDIA tarafından satılan Xavier NX 16 GB kullanıldı. Jetson modülü ConnectTech Quark Carrier taşıyıcıya entegre edildi. İşletim sistemi (sürüm 32.7.2), Ubuntu tabanlı NVIDIA tarafından sağlanan SDK Yöneticisi aracılığıyla yüklendi. CUDA, cuDnn yüklemek ve derin öğrenmeyle ilgili kitaplık ortamı kurulumunu yapmak üzere Jetpack paketi (sürüm 4.6.2) yüklenmiştir.

Yapay sinir ağı uygulamalarında donanımın hızlı çalışması, düşük güç tüketimi ve yüksek doğruluk oranı elde etmek gerçek hayatta kullanım açısından önemli ölçütlerdir. Çalışmada kullanılan NVIDIA Jetson için hem donanım hem de yazılımsal optimizasyonlar uygulanmıştır. Jetson'daki GPU'nun CUDA ile programlanabilmesi sayesinde kısıtlı kaynaklara sahip cihazlarda kullanıma uygun olarak tasarlanmış olan MobileNet ve yüksek doğruluk oranına sahip EfficientNet Jetson'da sorunsuz çalışmıştır.

Elde edilen sonuçlar derin öğrenme uygulamalarında Jetson yapay zekâ kitinin gerçek hayatta kullanılabilir olduğunu göstermiştir. Önerilen sistem bir prototip olarak geliştirilmiştir. Bu çalışma, ileride yapılacak çalışmalar için özellikle geri dönüştürülebilir katı atıkların sınıflandırılmasında geliştirilecek sistemler için temel olabilir.

## 5. SONUÇLAR VE ÖNERİLER

### 5.1 Sonuçlar

Bu tezde, katı atıkların sınıflandırılması için derin öğrenme ve makine öğrenmesi gibi yapay zekâ yöntemleri kullanılmıştır. DVM ve Karar Ağacı gibi makine öğrenimi modellerinin yanı sıra InceptionResnet, EfficientNet ve MobileNet gibi derin öğrenme modelleri de kullanılmıştır. Elde edilen sonuçlar, modeller arasında değişen doğruluk oranları ortaya çıkardı: InceptionResnet %92,49, EfficientNet %94,47, MobileNet %91,30, DVM %62,31 ve Karar Ağacı %43,38 doğruluk oranı elde edilmiştir.

Elde edilen bulgulara göre, EfficientNet başta olmak üzere derin öğrenme modellerinin, katı atıkları doğru bir şekilde sınıflandırmada makine öğrenimi modellerinden daha iyi performans gösterdiği açıktır. EfficientNet'in üstün doğruluğu, atık görüntülerinden ilgili özellikleri etkili bir şekilde çıkarma yeteneğine bağlanabilir ve bu da iyileştirilmiş sınıflandırma performansı sağlamaktadır. Buna karşılık, makine öğrenimi modelleri yani DVM ve Karar Ağacı, daha düşük doğruluk oranları ile atık görüntülerinde bulunan karmaşık kalıpları ve varyasyonları yakalamada sınırlamalara sahip olduklarını göstermektedir.

Bu araştırmanın sonuçları, katı atık sınıflandırma görevleri için yapay zeka, özellikle derin öğrenme teknikleri kullanmanın avantajlarını vurgulamaktadır. EfficientNet'in başarılı performansı, doğru atık sınıflandırması yoluyla atık yönetimi uygulamalarını otomatikleştirme ve geliştirmede derin öğrenmenin potansiyelini göstermektedir. Bu, yalnızca etkili atık ayrıştırmaya yardımcı olmakla kalmaz, aynı zamanda değerli kaynakların geri kazanılmasını da kolaylaştıracaktır.

### 5.2 Öneriler

Çalışmada elde edilen sonuçlar ışığında, gelecekteki araştırmalar için çeşitli önerilerde bulunulabilir. İlk olarak, özellikle atık sınıflandırması için tasarlanmış derin öğrenme mimarilerini ve tekniklerini keşfetmek için daha fazla araştırma yapılmalıdır. Bu, karmaşık atık bileşimlerini işleyebilen ve sınıflandırma doğruluğunu iyileştirebilen yeni modellerin geliştirilmesini sağlayabilir. Ayrıca eğitim ve değerlendirme amaçlı

kullanılan veri setinin genişletilmesi daha kapsamlı ve güvenilir sonuçlara katkı sağlayacaktır.

Gerçek zamanlı veri toplama ve analiz sistemlerinin entegrasyonu, yapay zekâ kullanarak atık sınıflandırmasının pratik uygulamasını geliştirebilir. Bu, mevcut atık yönetimi altyapılarına sorunsuz bir şekilde entegre edilebilecek otomatik atık ayırma teknolojilerinin geliştirilmesini sağlayacaktır.

Genel olarak, bu tez yapay zekanın, özellikle derin öğrenmenin, katı atık sınıflandırmasını geliştirmedeki potansiyelini göstermektedir. Bulgular, atık yönetimi uygulamalarını daha da geliştirmek, daha verimli ve sürdürülebilir atık ayrıştırma ve kaynak geri kazanım süreçlerini iyileştirmek için gelecekteki çalışmalara öncülük edebilir.

## KAYNAKLAR

- Adedeji, O., & Wang, Z. (2019). Intelligent waste classification system using deep learning convolutional neural network. *Procedia Manufacturing*, 35, 607-612.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). *Understanding of a convolutional neural network*. Paper presented at the 2017 international conference on engineering and technology (ICET).
- Alhichri, H., Alswayed, A. S., Bazi, Y., Ammour, N., & Alajlan, N. A. (2021). Classification of remote sensing images using EfficientNet-B3 CNN model with attention. *IEEE Access*, 9, 14078-14094.
- Aral, R. A., Keskin, Ş. R., Kaya, M., & Hacıömeroğlu, M. (2018). *Classification of trashnet dataset based on deep learning models*. Paper presented at the 2018 IEEE International Conference on Big Data (Big Data).
- Azhaguramyaa, V., Janet, J., Narayanan, V. V. L., Sabari, R., & Santhosh, K. K. (2021). *An intelligent system for waste materials segregation using IoT and deep learning*. Paper presented at the Journal of Physics: Conference Series.
- Baheti, B., Innani, S., Gajre, S., & Talbar, S. (2020). *Eff-unet: A novel architecture for semantic segmentation in unstructured environment*. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops.
- Basha, S. S., Dubey, S. R., Pulabaigari, V., & Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112-119.
- Bhatia, Y., Bajpayee, A., Raghuvanshi, D., & Mittal, H. (2019). *Image captioning using Google's inception-resnet-v2 and recurrent neural network*. Paper presented at the 2019 Twelfth International Conference on Contemporary Computing (IC3).
- Bircanoğlu, C., Atay, M., Beşer, F., Genç, Ö., & Kızrak, M. A. (2018). *RecycleNet: Intelligent waste sorting using deep neural networks*. Paper presented at the 2018 Innovations in intelligent systems and applications (INISTA).
- Chapelle, O., Haffner, P., & Vapnik, V. N. (1999). Support vector machines for histogram-based image classification. *IEEE transactions on Neural Networks*, 10(5), 1055-1064.
- Chen, Y., Dai, X., Chen, D., Liu, M., Dong, X., Yuan, L., & Liu, Z. (2022). *Mobile-former: Bridging mobilenet and transformer*. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.
- Chen, Z., Yang, J., Chen, L., & Jiao, H. (2022). Garbage classification system based on improved shufflenet v2. *Resources, Conservation and Recycling*, 178, 106090.
- Cireşan, D. C., Meier, U., & Schmidhuber, J. (2012). *Transfer learning for Latin and Chinese characters with deep neural networks*. Paper presented at the The 2012 international joint conference on neural networks (IJCNN).
- Duong, L. T., Nguyen, P. T., Di Sipio, C., & Di Ruscio, D. (2020). Automated fruit recognition using EfficientNet and MixNet. *Computers and Electronics in Agriculture*, 171, 105326.
- Egmont-Petersen, M., de Ridder, D., & Handels, H. (2002). Image processing with neural networks—a review. *Pattern recognition*, 35(10), 2279-2301.
- Endah, S. N., & Shiddiq, I. N. (2020). *Xception architecture transfer learning for garbage classification*. Paper presented at the 2020 4th International Conference on Informatics and Computational Sciences (ICICoS).

- Fu, B., Li, S., Wei, J., Li, Q., Wang, Q., & Tu, J. (2021). A Novel Intelligent Garbage Classification System Based on Deep Learning and an Embedded Linux System. *IEEE Access*, 9, 131134-131146.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., . . . Cai, J. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- Hoornweg, D., & Bhada-Tata, P. (2012). What a waste: a global review of solid waste management.
- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., . . . Vasudevan, V. (2019). *Searching for mobilenetv3*. Paper presented at the Proceedings of the IEEE/CVF international conference on computer vision.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., . . . Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Huang, G. L., He, J., Xu, Z., & Huang, G. (2020). A combination model based on transfer learning for waste classification. *Concurrency and Computation: Practice and Experience*, 32(19), e5751.
- Jiao, Y., & Du, P. (2016). Performance measures in evaluating machine learning based bioinformatics predictors for classifications. *Quantitative Biology*, 4, 320-330.
- Kang, Z., Yang, J., Li, G., & Zhang, Z. (2020). An automatic garbage classification system based on deep learning. *IEEE Access*, 8, 140019-140029.
- Kingsford, C., & Salzberg, S. L. (2008). What are decision trees? *Nature biotechnology*, 26(9), 1011-1013.
- Krogh, A. (2008). What are artificial neural networks? *Nature biotechnology*, 26(2), 195-197.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lu, J., Behbood, V., Hao, P., Zuo, H., Xue, S., & Zhang, G. (2015). Transfer learning using computational intelligence: A survey. *Knowledge-Based Systems*, 80, 14-23.
- Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F., & Zhang, Y. (2018). Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery. *Remote Sensing*, 10(7), 1119.
- Mao, W.-L., Chen, W.-C., Wang, C.-T., & Lin, Y.-H. (2021). Recycling waste classification using optimized convolutional neural network. *Resources, Conservation and Recycling*, 164, 105132.
- McCarthy, J. (2007). What is artificial intelligence.
- Mehdy, M., Ng, P., Shair, E., Saleh, N., & Gomes, C. (2017). Artificial neural networks in image processing for early detection of breast cancer. *Computational and mathematical methods in medicine*, 2017.
- Meng, X., Tan, X., Wang, Y., Wen, Z., Tao, Y., & Qian, Y. (2019). Investigation on decision-making mechanism of residents' household solid waste classification and recycling behaviors. *Resources, Conservation and Recycling*, 140, 224-234.
- Mitchell, T. M. (2007). *Machine learning* (Vol. 1): McGraw-hill New York.
- Mittal, S. (2019). A Survey on optimized implementation of deep learning models on the NVIDIA Jetson platform. *Journal of Systems Architecture*, 97, 428-442.
- Nafiz, M. S., Das, S. S., Morol, M. K., Al Juabir, A., & Nandi, D. (2023). *Convowaste: An automatic waste segregation machine using deep learning*. Paper presented at the 2023 3rd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST).

- Noble, W. S. (2006). What is a support vector machine? *Nature biotechnology*, 24(12), 1565-1567.
- O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- Ozkaya, U., & Seyfi, L. (2019). Fine-tuning models comparisons on garbage classification for recyclability. *arXiv preprint arXiv:1908.04393*.
- Pak, M., & Kim, S. (2017). *A review of deep learning in image recognition*. Paper presented at the 2017 4th international conference on computer applications and information processing technology (CAIPT).
- Purvis, B., Mao, Y., & Robinson, D. (2019). Three pillars of sustainability: in search of conceptual origins. *Sustainability science*, 14, 681-695.
- Rabano, S. L., Cabatuan, M. K., Sybingco, E., Dadios, E. P., & Calilung, E. J. (2018). *Common garbage classification using mobilenet*. Paper presented at the 2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM).
- Ruiz, V., Sánchez, Á., Vélez, J. F., & Raducanu, B. (2019). *Automatic image-based waste classification*. Paper presented at the International Work-Conference on the Interplay Between Natural and Artificial Computation.
- Sainath, T. N., Vinyals, O., Senior, A., & Sak, H. (2015). *Convolutional, long short-term memory, fully connected deep neural networks*. Paper presented at the 2015 IEEE international conference on acoustics, speech and signal processing (ICASSP).
- Sharma, N., Jain, V., & Mishra, A. (2018). An analysis of convolutional neural networks for image classification. *Procedia computer science*, 132, 377-384.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big data*, 6(1), 1-48.
- Sultana, F., Sufian, A., & Dutta, P. (2018). *Advancements in image classification using convolutional neural network*. Paper presented at the 2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN).
- Sun, M., Song, Z., Jiang, X., Pan, J., & Pang, Y. (2017). Learning pooling for convolutional neural network. *Neurocomputing*, 224, 96-104.
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). *Inception-v4, inception-resnet and the impact of residual connections on learning*. Paper presented at the Proceedings of the AAAI conference on artificial intelligence.
- Tan, M., & Le, Q. (2019). *Efficientnet: Rethinking model scaling for convolutional neural networks*. Paper presented at the International conference on machine learning.
- Thai, L. H., Hai, T. S., & Thuy, N. T. (2012). Image classification using support vector machine and artificial neural network. *International Journal of Information Technology and Computer Science*, 4(5), 32-38.
- Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264): IGI global.
- Vo, A. H., Vo, M. T., & Le, T. (2019). A novel framework for trash classification using deep transfer learning. *IEEE Access*, 7, 178631-178639.
- Wang, H. (2020). *Garbage recognition and classification system based on convolutional neural network VGG16*. Paper presented at the 2020 3rd

- International Conference on Advanced Electronic Materials, Computers and Software Engineering (AEMCSE).
- Wang, Z., Peng, B., Huang, Y., & Sun, G. (2019). Classification for plastic bottles recycling based on image recognition. *Waste management*, 88, 170-181.
- Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big data*, 3(1), 1-40.
- Winston, P. H. (1984). *Artificial intelligence*: Addison-Wesley Longman Publishing Co., Inc.
- Yang, C.-C., Prasher, S. O., Enright, P., Madramootoo, C., Burgess, M., Goel, P. K., & Callum, I. (2003). Application of decision tree technology for image classification using remote sensing data. *Agricultural Systems*, 76(3), 1101-1117.
- Yang, J., Zeng, Z., Wang, K., Zou, H., & Xie, L. (2021). GarbageNet: a unified learning framework for robust garbage classification. *IEEE Transactions on Artificial Intelligence*, 2(4), 372-380.
- Yang, M., & Thung, G. (2016). Classification of trash for recyclability status. *CS229 project report*, 2016(1), 3. Retrieved from <https://github.com/garythung/trashnet>
- Zeng, M., Lu, X., Xu, W., Zhou, T., & Liu, Y. (2020). *PublicGarbageNet: a deep learning framework for public garbage classification*. Paper presented at the 2020 39th Chinese Control Conference (CCC).
- Zhang, Q., Zhang, X., Mu, X., Wang, Z., Tian, R., Wang, X., & Liu, X. (2021). Recyclable waste image recognition based on deep learning. *Resources, Conservation and Recycling*, 171, 105636.
- Zheng, B., Gao, A., Huang, X., Li, Y., Liang, D., & Long, X. (2023). A modified 3D EfficientNet for the classification of Alzheimer's disease using structural magnetic resonance images. *IET Image Processing*, 17(1), 77-87.