



MALATYA  
**TURGUTÖZAL**  
ÜNİVERSİTESİ

T.C.  
MALATYA TURGUT ÖZAL ÜNİVERSİTESİ  
LİSANSÜSTÜ EGİTİM ENSTİTÜSÜ

Çevresel Atıkların Sınıflandırılmasında Derin Öğrenmeye Dayalı Yaklaşımların  
Uygulanması

ELİF NUR YILDIZ

YÜKSEK LİSANS TEZİ  
ENFORMATİK ANABİLİM DALI

TEMMUZ-2024

T.C.  
MALATYA TURGUT ÖZAL ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Çevresel Atıkların Sınıflandırılmasında Derin Öğrenmeye Dayalı Yaklaşımların  
Uygulanması

ELİF NUR YILDIZ

YÜKSEK LİSANS TEZİ  
ENFORMATİK ANABİLİM DALI

TEMMUZ-2024

## ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduğum "Çevresel Atıkların Sınıflandırılmasında Derin Öğrenmeye Dayalı Yaklaşımların Uygulanması " başlıklı bu çalışmanın tarafımca yazıldığını ve kaynakların yönetime uygun bir şekilde gösterildiğini belirtir, bunu onurumla doğrularım.

Elif Nur YILDIZ



# ÖZET

Yüksek Lisans Tezi

Çevresel Atıkların Sınıflandırılmasında Derin Öğrenmeye Dayalı Yaklaşımların Uygulanması

Elif Nur YILDIZ

Malatya Turgut Özal Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Enformatik Anabilim Dalı

33 + ix sayfa

2024

Danışman: Doç. Dr. Harun BİNGÖL

Dünya genelindeki çarpık kentleşme, sanayileşme ve insanların bilinçsiz bir şekilde hareket etmesi sonucunda atık problemi ortaya çıkmıştır. Bu problem hayatımızı olumsuz etkiler ve kirliliğin olduğu bir ortamda yaşam sürmemizi zorunlu kılar. Bilinçli ya da bilinçsiz rastgele atılan her çöp doğaya karışır. Böylece bu çöplerin doğada kendi kendine çözünmesi yılları alır. Atıkların ayrıştırılması ile çevre kirliliği sorunu en aza indirgenir. Böylece geri dönüşüme katkı sağlanarak ortalama yaşam süresi uzatılmış olur.

Yapılan bu çalışma da Derin Öğrenme modelleri ve makine Öğrenme yöntemlerinden yararlanılarak geri dönüşüme olan faydasından bahsedilmiştir. Atık ayrıştırma veri seti kullanılarak çevresel atıkların sınıflandırma işlemi gerçekleştirilmiştir.

Bu çalışmada atık ayrıştırma tespitinde AlexNet, GoogLeNet, ResNet50, DenseNet201, ShuffleNet, SqueezeNet mimarileri ile sonuçlar elde edilmiştir. Sonraki aşama da derin mimarilerden elde edilen özellik haritaları çıkarılmıştır. Sonraki aşama da destek vektör makinelerin sınıflandırma yöntemlerinden sonuçlar alınmıştır. Önerilen hibrit modelden elde edilen deneyler sonucunda en iyi doğruluğun %85.96 değeri olduğu gözlemlenmiştir.

ANAHTAR KELİMELER: Atık sınıflandırma, yapay zekâ, derin öğrenme, ESA, DVM.

# ABSTRACT

M.Sc. Thesis

Application of Deep Learning-Based Approaches in Classifying Environmental Wastes

Elif Nur YILDIZ

Malatya Turgut Ozal University

Institute of Graduate Studies

Department of Informatics

33+ ix pages

2024

Supervisor: Doç. Dr. Harun BİNGÖL

The waste problem has emerged worldwide due to distorted urbanization, industrialization, and people's unconscious actions. This problem negatively affects our lives and necessitates living in an environment with pollution. Every piece of randomly discarded waste, whether intentional or unintentional, becomes part of nature. As a result, the self-disposal of these wastes in nature takes years.

The environmental pollution problem is minimized by separating the waste. Thus, contributing to recycling extends the average lifespan by reducing environmental pollution.

In this study, the benefit of recycling was mentioned by using Deep Learning models and machine learning methods. The classification process of environmental waste was carried out using the waste separation dataset and architectures such as AlexNet, GoogLeNet, ResNet50, DenseNet201, ShuffleNet, SqueezeNet. In the next stage, feature maps obtained from deep architectures were extracted. Results were also obtained from the classification methods of support vector machines. As a result of the experiments obtained from the proposed hybrid model, it was observed that the best accuracy was 85.96%.

**KEYWORDS:** Garbage classification, artificial intelligence, deep learning, CNN, SVM.

## TEŐEKKÜR

Yüksek lisans tezimin hazırlanma süresince bilgi birikimlerini paylaşan, desteęini esirgemeyen danışman hocam Doç. Dr. Harun BİNGÖL'e, her zaman yanımda olup bu süreci yönetmemde yardımcı olan aileme teşekkür ederim.



## İÇİNDEKİLER

ONUR SÖZÜ.....	i
ÖZET .....	ii
ABSTRACT .....	iii
TEŞEKKÜR .....	iv
İÇİNDEKİLER .....	v
SİMGELER VE KISALTMALAR DİZİNİ .....	vii
ŞEKİLLER DİZİNİ .....	viii
ÇİZELGELER DİZİNİ .....	ix
1. GİRİŞ.....	1
1.1. Tezin Amacı ve Önemi .....	1
1.2. Tezin Organizasyonu .....	1
2. KAYNAK ÖZETLERİ .....	2
2.1. Tezin Literatüre Katkısı .....	3
3. MATERYAL VE METOT .....	4
3.1. Veri Seti .....	4
3.2. Yapay Sinir Ağları .....	5
3.2.1. Makine öğrenmesi.....	5
3.2.2. Derin öğrenme .....	5
3.3. Makine Öğrenme Yöntemleri.....	6
3.3.1. K-En Yakın Komşu (KNN) .....	6
3.3.2. Destek Vektör Makineleri (DVM).....	6
3.3.3. Karar Ağaçları (KA) .....	6
3.3.4. Naive Bayes Sınıflandırıcıları .....	7
3.3.5. Neural Network Sınıflandırıcıları (ANN) .....	7
3.4. Komşuluk Bileşenleri Analizi (NCA-Neighbourhood Components An.) ....	7
3.5. Derin Öğrenme Mimarileri .....	7
3.5.1. Konvolüsyonel sinir ağları (CNN- Convulational Neural Network) .....	7
3.5.2. Tekrarlayan sinir ağı (RNN- Recurrent Neural Network) .....	8
3.5.3. Uzun-Kısa süreli bellek (LSTM- Long Short-Term Memory) .....	8
3.5.4. Kısıtlı Boltzmann Makinesi (RBM-Restricted Boltzmann Machine)....	9
3.5.5. Derin inanç ağı (DBN-Deep Belief Network) .....	9
3.5.6. Derin oto-kodlayıcılar (Auto Encoder).....	10
3.6. Evrişimsel Sinir Ağı Katmanları.....	11
3.6.1. Giriş (Input) katmanı .....	11
3.6.2. Konvolüsyon(Convolution) katmanı .....	11
3.6.3. Aktivasyon (ReLU) katmanı.....	12
3.6.4. Havuzlama (Pooling) katmanı .....	12
3.6.5. Tam bağlı (Full-Connected) katman.....	13
3.6.6. Dropout katmanı .....	13
3.6.7. Sınıflandırma (Classification) katmanı .....	14
3.6.8. Yumuşatma (Softmax) katmanı .....	14
3.6.9. Normalizasyon (Normalization) katmanı .....	14
3.7. Evrişimsel Sinir Ağı Algoritmaları .....	15
3.7.1. AlexNet.....	15
3.7.2. DenseNet201.....	15
3.7.3. GoogleNet.....	16
3.7.4. ResNet50 .....	16

3.7.5. SqueezeNet .....	17
3.7.6. ShuffleNet.....	17
3.8. Önerilen Derin Öğrenme Tabanlı Hibrit Yöntem.....	18
3.8.1. Veri kümesinin tespiti ve oluşum aşamaları .....	18
3.8.2. Sonuçların toplanması ve değerlendirme aşaması .....	18
4. ARAŞTIRMA BULGULARI VE TARTIŞMA .....	20
4.1. Veri Kümesinin Derin Öğrenme Mimarileriyle Eğitimi, Başarısı ve Araştırma Sonuçları .....	20
4.1.1. Önerilen Modelden Elde Edilen Sonuçlar .....	22
4.1.2. Komşuluk Bileşenleri Analizi ile elde edilen sonuçlar .....	24
4.1.3. Tartışma .....	26
5. SONUÇ VE ÖNERİLER.....	27
6. KAYNAKLAR.....	28
ÖZGEÇMİŞ.....	33



## SİMGELER VE KISALTMALAR DİZİNİ

ANN	: Yapay Sinir Ağı
CNN	: Konvolüsyonel Sinir Ağı
DVM	: Destek Vektör Makineleri
DBN	: Derin İnanç Ağı
ESA	: Evrimsel Sinir Ağları
FDR	: Yanlış Keşif Oranı
FPR	: Yanlış Pozitif Oran
FNR	: Yanlış Negatif Oran
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
KNN	: K-en Yakın Komşu
KA	: Karar Ağaçları
LTSM	: Uzun-Kısa Süreli Bellek
NCA	: Komşuluk Bileşen Analizi
RBM	: Kısıtlı Boltzmann Makinesi
ReLU	: Aktivasyon
RNN	: Tekrarlayan Sinir Ağı
TN	: Doğru Negatif
TF	: Doğru Pozitif
YSA	: Yapay Sinir Ağları
%	: Yüzde işareti
x	: Çarpma işareti
/	: Bölme işareti

## ŞEKİLLER DİZİNİ

Şekil 3.1. Veri Setinde Yer Alan Sınıflara Ait Örnek Görüntüler .....	5
Şekil 3.2. Derin Öğrenme Modeli Örneği.....	6
Şekil 3.3. CNN Mimarisi .....	7
Şekil 3.4. RNN'nin Genel Yapısı.....	8
Şekil 3.5. LSTM Sinir Ağı Mimarisi .....	9
Şekil 3.6. Kısıtlı Boltzmann Makinesi'nin Yapısı .....	9
Şekil 3.7. Derin İnanç Ağı'nın Temel Yapısı .....	10
Şekil 3.8. Derin Oto Kodlayıcılar Şeması.....	10
Şekil 3.9. Filtrenin Uygulandığı Konvolüsyon İşlemi .....	11
Şekil 3.10. Aktivasyon (ReLU) Katmanı İşlevi .....	12
Şekil 3.11. Havuzlama (Pooling) Katmanı .....	13
Şekil 3.12. Tam Bağlı (Fully-Connected) Katmanı Yapısı .....	13
Şekil 3.13. Standart Sinir Ağı Görünümü ve Dropout Katmanına sahip Sinir Ağı Görünümü .....	14
Şekil 3.14. Normalizasyon Katmanı Yapısı .....	15
Şekil 3.15. AlexNet Mimarisi .....	15
Şekil 3.16. DenseNet201 Mimarisi.....	16
Şekil 3.17. GoogleNet Mimarisi .....	16
Şekil 3.18. ResNet50 Mimarisi.....	17
Şekil 3.19. SqueezeNet Mimarisi .....	17
Şekil 3.20. ShuffleNet Mimarisi .....	18
Şekil 3.21. Çevresel Atıkların Ayrıştırılması.....	18
Şekil 4.1. ESA Mimarilerine ait karmaşıklık Matrisleri .....	21
Şekil 4.2. Önerilen Model.....	22
Şekil 4.3. DVM+DenseNet201.....	23
Şekil 4.4. NCA+Sınıflandırıcı Karmaşıklık Matris Sonuçları .....	25

## ÇİZELGELER DİZİNİ

Çizelge 3.1. Performans Kriterleri.....	19
Çizelge 4.1. ESA Mimarilerinden Elde Edilen Doğruluk Değerleri .....	20
Çizelge 4.2. Mimariler ve Sınıflandırıcı Sonuçları.....	23
Çizelge 4.3. Performans Ölçütleri .....	24
Çizelge 4.4. Literatürdeki Çalışmalar.....	26



## 1. GİRİŞ

Çevrenin yaşanılabilir şekilde olması canlıların yaşam kalitesini arttırmaktadır. Dünyanın her yerinde ağaçların kesilip zarar görmesi, atıkların bilinçsizce etrafa saçılması ve fabrikaların çevreye zarar vermesi bu tür problemleri ortaya çıkarır. Bu atıklar; hava kirliliğine, bitkilerin zarar görmesine yol açmaktadır [1]. Bu problemi en aza indirmek için geri dönüşüm önemli bir çözüm olarak ortaya çıkmaktadır. Derin öğrenme Bitkisel ya da farklı türlerin hastalıklarının ayrıştırılmasında büyük rol oynamaktadır. Birçok hastalığın teşhisinde bu yöntemler kullanılmıştır [2-4]. Bu çalışma da ilk olarak derin öğrenme mimariler için sonuçlar alınmıştır. Bir sonraki aşama da bu mimarilerden elde edilen özellik haritalarından sonuçlar alınmıştır. Sonraki aşamada makine öğrenme yöntemleri olan sınıflandırıcılardan, doğruluk ve karmaşıklık matris sonuçları alınmıştır. Bu sınıflandırıcılar KNN, Naive Bayes Classifiers, DVM, KA ve Neural Network Classifiers'dir. DVM sınıflandırıcısından elde edilen değerler, diğer sınıflandırıcılara göre daha iyi sonuç verdiği gözlemlenmiştir. Optimize edilmiş özellikleri elde etmek için indirgeme yöntemlerinden biri olan NCA kullanılmıştır.

### 1.1. Tezin Amacı ve Önemi

Bu tez de derin öğrenme ve derin öğrenme mimarileri ile ilgili bilgilere yer verilmiştir. Çevresel Atıkların Sınıflandırılmasında Derin Öğrenmeye Dayalı Yaklaşımların Uygulanması çalışmasında çevreye olan zararın en aza indirgenmesi vurgulanmıştır. Atıkların sınıflandırılması için yeni bir hibrit yaklaşım önerilmiştir. Optimize edilmiş özellikleri elde etmek için indirgeme yöntemlerinden biri olan NCA kullanılmıştır.

### 1.2. Tezin Organizasyonu

İkinci bölüm de kaynak özetleri başlığı altında diğer çalışmalara, literatüre olan katkısından ve tezin literatüre katkısından bahsedilmiştir. Üçüncü bölüm de materyal ve yöntem kısmında kullanılan veri setine değinilmiştir. ESA mimarilerinden, Makine öğrenme yöntemlerinden bahsedilmiştir. Optimize edilmiş özellikleri elde etmek için NCA yönteminden bahsedilmiştir. Bölümün son kısmında mimarilerden ve sınıflandırıcılardan alınan sonuçlara yer verilmiştir. Sonuç bölümünde ise önerilen model için en iyi değere ve NCA yöntemi ile elde edilmiş değere yer verilmiştir.

## 2. KAYNAK ÖZETLERİ

Çevreye verilen zarar günlük yaşantımızı olumsuz etkilediği ve ciddi bir sorun haline geldiği için literatürde bu konu hakkında birçok çalışma yapılmıştır.

Sürücü ve arkadaşları yaptıkları çalışma da çöpleri otomatik olarak sınıflandıran transfer yöntemi kullanmışlardır. Resne50-V2 modeli kullanarak transfer öğrenme yöntemlerinden yararlanmışlardır. Sonuç olarak bu çalışmadan %97.07 oranında başarı elde edilmiştir. [5].

Varol ve arkadaşları yaptıkları çalışma da Atık görüntülerinin sınıflandırılması için açık erişimli Garbage Classification adlı veri setini kullanmışlardır. Deneysel süreçlerde nitelik çıkarımı için DarkNet-19 modeli ile çalışma yapmışlardır. Sonuç olarak bu çalışma da %96 oranında doğruluk elde edilmiştir [6].

Endah ve arkadaşları yaptıkları çalışma da atık yönetimi sorununu çözmeyi amaçlamışlardır. Bu işlemi makine öğrenme yöntemini kullanarak yapmışlardır. Bu çalışmada kullanılan modeller VGG16, ResNet-50 ve Xception'dır. Deney sonucunda, Xception modelinin %88'lik doğruluğu verdiği gözlemlenmiştir [7].

Rabano ve arkadaşları yaptıkları çalışma da cam, kâğıt, karton, plastik, metal ve diğer çöpleri kullanmışlardır. Eğitimde “.jpg” uzantılı 2527 adet çöp görselden oluşan veri seti kullanılmıştır. Modelin test doğruluğu %87.2 olduğu gözlemlenmiştir [8].

Mittal ve arkadaşları yaptıkları çalışma da gelişmekte olan ülkeler için temiz bir ortamın zorluğundan bahsetmişlerdir. Çöpleri algılayan ve kabaca bölümlere ayıran SpotGarbage adlı bir uygulama sunmuşlardır. Uygulama, görüntülerdeki çöpleri tespit etmek için tamamen evrişimli ağların derin mimarisini kullanmaktadır. Model, veri kümesiyle eğitilmiştir ve %87,69 doğruluk elde edilmiştir [9].

Sidhart ve arkadaşları yaptıkları çalışma da birçok kategoriden yararlanmışlardır. Kategorilerden olan plastik, kâğıt, karton, metal ve camdan oluşan bir veri seti ile sınıflandırma yapmışlardır. Yapılan çalışmada doğruluk değeri %76 olarak elde edilmiştir [10].

Karaca ve arkadaşları yaptıkları çalışma da canlının doğadaki yaşamını ve doğanın kendi yapısını konu almışlardır. Böylece ayrıştırma yöntemi kullanarak derin öğrenme modeline başvurmuşlardır. Bu çalışma da evrensel atıklardan oluşan birçok

kategoriden toplam 3773 görüntü alınmıştır. Veri setindeki bu görüntülerin %70'i eğitim sınıfı için ayrılmıştır ve %30'u ise test sınıfı için ayrılmıştır. Çalışma da çeşitli mimarilerden sonuçlar alınmıştır. Bu sonuçların kıyaslanmasıyla birlikte model için en iyi doğruluk değerine ulaşılmıştır. Verilere göre yapılan bu çalışmada ResNet50 mimarisi %74.76 ile en iyi doğruluk değerini vermiştir. [11].

Altınors ve arkadaşları yaptıkları bu çalışmada YOLOv3 algoritması kullanmışlardır. Çevreye ciddi bir şekilde zarar veren ve çözünmesi yılları alan pet ve cam şişelerinin tespitini gerçekleştirmişlerdir. Bu tespitler sonucunda da başarılı sonuçlar elde edilmiştir. Sonuç olarak YOLOv3 algoritmasına göre doğruluk %84.81 olarak elde edilmiştir [12].

## **2.1. Tezin Literatüre Katkısı**

Çevre, insan yaşamını hem olumlu hem de olumsuz yönde etkileyebilen oldukça önemli bir faktördür. Canlıların yaşamını devam ettirebilmesi için çevrenin temizliği son derece önemlidir. Aynı zaman da çevresel temizliği sağlamak için sunulan birçok yöntem mevcuttur. Belediyeler tarafından insanların atık olarak bıraktıkları malzemeleri çevreye saçılmadan toplanılması ön bilindik yöntemlerdendir. Burada atıkların yerinde ayrıştırılması son derece önemlidir. Bazı durumlarda atık ayrıştırılması yapılmayıp karışık halde çöpler atılabilmektedir. Bu durumda ayrıştırma işlemi hem geri dönüşüme son derece zarar vermekte hem de oldukça vakit almaktadır. İlgili çalışmalar bölümünde çevresel atıklarla ilgili literatürde yer alan çeşitli çalışmalardan bahsedilmiştir. Bu tez de Çevresel atıkların ayrıştırılmasında Derin öğrenme ve Makine öğrenme kullanılarak çeşitli çalışmalar yapılmıştır. Bu çalışmaların derlenip bir araya getirilmesi ve incelenmesi bizim literatüre sunduğumuz önemli bir katkıdır.

### 3. MATERYAL VE METOT

Bu bölümde Önerilen Derin Öğrenme ve Makine Öğrenme Tabanlı Hibrit Model ile Çevresel Atıkların Sınıflandırılması çalışmasında kullanılan teknolojilere değinilmiştir. Bu çalışmanın içeriğinden kısaca bahsedilirse, veri seti olarak Garbage Classification veri seti kullanılmıştır. Bu veri seti 6 sınıflı olup çalışma ortamında elde edilen sonuçlar Matlabdan alınmıştır. Modelin eğitim sürecinde epoch değeri 5, batchsize değeri 16 alınarak sonuç alınmıştır. Veri setindeki görüntülerin %80'i eğitim aşaması için %20'si ise test aşaması için kullanılmıştır. Eğitimin sonunda doğruluk değerleri ve karmaşıklık matrisleri hesaplanmıştır. Bu mimariler ile elde edilen sonuçlara göre önerilen bir model ortaya çıkmış ve Densenet201 mimarisi kullanılmıştır. Veri setinde her sınıfın görüntüleri ile özellik haritaları elde edilmiştir. Bu özellik haritaları beş farklı sınıflandırıcıdan sonuçlar almıştır. Kullanılan sınıflandırıcılar KNN, Naive Bayes Classifiers, DVM, KA ve Neural Network Classifiers olmuştur. Kullanılan mimariler AlexNet, DenseNet201, ResNet50, GoogLeNet, SqueezeNet ve ShuffleNet olmuştur. Bu bölümde ise çalışmada kullanılan veri setinden, ESA mimarilerinde ve Makine öğrenme yöntemlerinden bahsedilmiştir.

#### 3.1. Veri Seti

Yapılan bu çalışmada Garbage Classification veri setinden yararlanılarak modelden sonuçlar alınmıştır. Bu veri seti Kaggle'dan alınmış ve halka açık bir veri setidir [13]. Kullanılan bu veri seti 6 sınıflıdır. Her sınıfta belli miktarda görüntü olup, toplam görüntü sayısı 2527'dir. Bu sınıflar sırasıyla Cardboard, Glass, Metal, Paper, Plastic ve Trash olarak ayrılmıştır. Bu 2527 görüntünün %80'i eğitimde, kalan %20'si test aşamasında kullanılmıştır. Bu veri seti her mimari için eğitildiğinde epoch değeri 5, batchsize değeri 16 alınarak sonuçlar elde edilmiştir. Bu belirlenen değerlere göre sonuç hesaplanmıştır. Şekil 3.1'de görüldüğü üzere her sınıfa ait görüntüler verilmiştir.



Şekil 3.1. Veri setinde yer alan sınıflara ait örnek görüntüler

### 3.2. Yapay Sinir Ağları

Yapay Sinir Ağı Sistemi, verilen örnek veriden bilgi toplar, bu bilgiyi listeleyip genelleme yapar. Daha sonra bu genellemelere bakar ve hiç karşılaşmadığı örneklerden yola çıkarak tahmin yapar. Bu işlemleri gerçekleştiren bilgisayar yazılımları olarak bilinmektedir. YSA, genellikle tahmin etme, ayrıştırma, veri ilişkilendirme ve yorumlama gibi durumlarda kullanılmaktadır. Öğrenme işlemi gerçekleştirirken giriş ve çıkış bilgileri verilir, ona göre kurallar yazılır. Yapay Sinir Ağlarının bir başka adlandırılma şekilleri ise bağlantılı ağlar, nuromorfik ağlar ve paralel dağılmış ağlar olarak bilinmektedir [14].

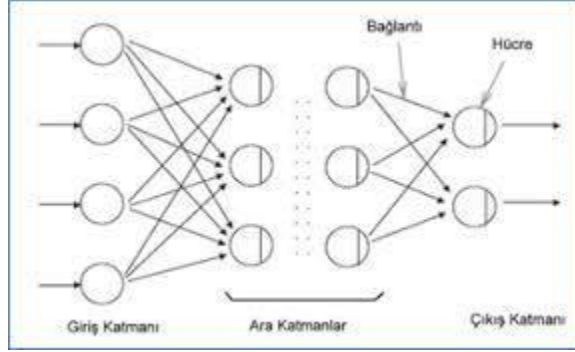
#### 3.2.1. Makine Öğrenmesi

Makine Öğrenmesi, Bilgisayara öğrenebilme kabiliyeti kazandırmayı hedeflemektedir. Temelde ilk olarak veri girilir, makine bunu kendisine karşı defalarca oynatır ve bütün ihtimalleri ezberler. Bundan dolayı birçok yöntem geliştirilmiştir. Yapılan bu çalışmada da k-en yakın komşu algoritması, Naive Bayes sınıflandırıcısı, karar ağaçları, neural network classifiers ve destek vektör makine yöntemlerinden yararlanılmıştır. Öğrenme yolları ise pekiştirmeli, denetimsiz ve denetimli olarak üç başlıkta ortaya çıkmaktadır [15].

#### 3.2.2. Derin Öğrenme

Makine öğrenme yönteminin bir diğer kolu da derin öğrenmedir. Makine öğrenmeye olan ilgi her geçen gün artmıştır. Günümüzde de yaygınlaşmasıyla birlikte Derin öğrenme mimarilerinin ortaya çıkmasına katkıda bulunmuştur. Yapay zekâ sorunlarının çözümünde birçok derin öğrenme yaklaşımları ortaya çıkmıştır. Böylece nesne tespitinde, sağlık alanında, finans anlamında, robotik alanında, ses-görüntü tanımadada bunun gibi birçok konuya çözümler sunmuştur. Sunulan bu çözümlerde

hayatı kolaylaştırarak, birçok konuda belirsizliği ortadan kaldırır. [16]. Şekil 3.2.'de görüldüğü üzere Derin Öğrenme modeli örneği verilmiştir.



Şekil 3.2. Derin Öğrenme Modeli Örneği

### 3.3. Makine Öğrenme Yöntemleri

Yapılan bu çalışma da KNN, Naive Bayes Classifiers, DVM, KA ve Neural Network Classifiers sınıflandırıcılarından sonuçlar alınmıştır. Bu sınıflandırıcılar bünyesinde çeşitli özellikleri barındırır.

#### 3.3.1. K-En Yakın Komşu (KNN)

KNN algoritması bir sınıflandırma algoritması olduğundan veri setinin belirli özelliklerinden ve etiketlerinden yararlanarak modeli bir kalıba sokar. Sonraki aşamada etiketsiz olan verinin herhangi bir sınıfa katıldığını tahmin eder. [17].

#### 3.3.2. Destek Vektör Makineleri (DVM)

Kontrollü sınıflandırma algoritması olan Destek Vektör Makineleri (DVM) istatistiksel öğrenmeye dayalı olan bir algoritma çeşididir. İlk olarak ikili doğrusal verilerin sınıflandırılması için tasarlanan algoritmalarıdır. Sonraki aşamalarda çok sınıflı, doğrusallığı olmayan verilerin sınıflandırılması için yaygınlaştırılmıştır. [18].

#### 3.3.3. Karar Ağaçları (KA)

Veri madenciliği yöntemleri arasındaki Karar ağaçları algoritması önemli sınıflandırma yöntemlerinden biridir. Karar ağacı, ağaç sınıflandırma yapısı olarak kök düğümü, yaprak ve dallardan oluşan modelleri kapsamaktadır [19].

### 3.3.4. Naive Bayes Classifiers

Naive Bayes sınıflandırıcı algoritması, esas olarak bağımsızlık nitelikleri üzerinde çalışan, Bayes olasılık teoreminden türetilmiş bir algoritmadır [20].

### 3.3.5. Neural Network Classifiers (ANN)

Neural Network Classifiers, giriş ve çıkış katmanını içerir. ANN, bilginin çeşitli yollarla iletilmesi için arada güçlü bağlantıları sağlamaktadır [21].

### 3.4. Komşuluk Bileşenleri Analizi (NCA-Neighbourhood Components Analyzer)


Neighborhood Component Analysis (NCA): Makine öğrenmesi uygulamalarında ön plana çıkan öznelik seçimi çok sayıda veri boyutlarının ortaya çıkmasıyla önem kazanmıştır. Neighborhood Component Analysis (Komşuluk bileşen analizi), öznelik seçme yöntemlerinden biri olarak bilinir. Bu algoritma, sınıflandırma doğruluğunu maximum düzeye çıkarır. [22]. NCA ile programın çalışması hızlanır, 1000 özellik yerine içlerinden seçerek optimize edilir. Böylece optimize edilmiş özellikleri elde etmek için kullanılır.

### 3.5. Derin Öğrenme Mimarileri

Yapılan bu Tez çalışmasında Konvolüsyonel Sinir Ağ (CNN) algoritmaları üzerinde durulmuştur. Aşağıda diğer derin öğrenme mimarilerinden de bahsedilmiştir.

#### 3.5.1. Konvolüsyonel sinir ağları (CNN- Convolutional Neural Network)


Doğrusal olmayan sorunların çözümünde CNN'lerin başarılı sonuç verdiği gözlemlenmiştir. Görüntülerin tespitinde en sık kullanılan çözümlerdir. Temelde CNN Şekil 3.3.'de görüldüğü üzere, evrişim katmanı, havuzlama katmanı, düzleştirme ve tam bağlı katmanlardan oluşmaktadır [23].



Şekil 3.3. CNN Mimarisi

### 3.5.2. Tekrarlayan sinir ağı (RNN- Recurrent Neural Network)

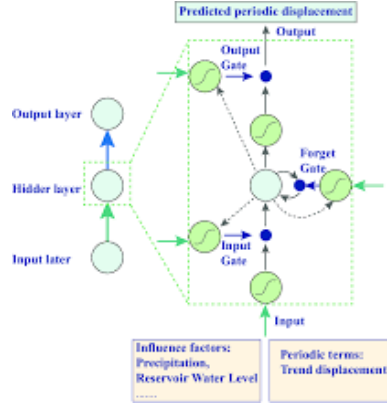
Günümüzde kullanılan en ileri ağlardan biri RNN'dir. Sıralı olarak bilgileri kullanan bir sınıf olarak bilinir. Alt katmanların ve önceki adımların çıktıları girdi olarak kullanılır. Böylece Aktivasyon değerlerinin hesaplanmasında gizli katmanlardan yararlanır. Bu kendini yenileme özelliğiyle ortaya çıkan çıktılar, eski verilerin ve yeni verilerin birleştirilmesiyle sağlanır. Yapay Sinir ağına bir hafıza eklenerek daha önceden aldığı girişleri örnek alır ve çıkış üretir. Üretilen çıktıdan sonra RNN'ye tekrar giriş olarak iletilir, bu da yeni girdilerde kullanılır [24]. Şekil 3.4.'de görüldüğü üzere RNN'nin genel yapısı bunu oluşturmaktadır.



Şekil 3.4. RNN'nin Genel Yapısı

### 3.5.3. Uzun-Kısa süreli bellek (LSTM- Long Short-Term Memory)


LSTM, Makine öğrenmesidir ve tekrarlayan sinir ağına sahip bir algoritmadır. Bu model kısa zaman diliminde bilgileri depolar ve belli bir süre eğitim aşamasında kullanır. Böylece oluşan gizli katmanda çeşitli birimler ortaya çıkar. Geleneksel yinelenen sinir ağlarında bu birimler "gizli" olarak tanımlanır. Oluşan birimler kendi bünyesinde çeşitli bellek hücrelerini barındırır. Gelen bilgi akışını kontrol etmek için portlar vardır ve bu portlar giriş, çıkış portları olarak bilinir. Aktivasyon bilgilerini kontrol eden bu yapı, giriş kapısı için giriş akışını kontrol eder, çıkış kapısı ise çıkış akışının kontrolünü sağlar. Bir sonraki aşama da başka bir kapı olan "unutma kapısı" olarak ortaya çıkar. Hücre de ölçeklendirme yapan bu kapı, giriş aktivasyonu aşamasından önce belleği sıfırlamaya yarayan kapıdır [25]. Şekil 3.5'de görüldüğü üzere LSTM Sinir Ağı Mimarisinin yapısı gösterilmiştir.



Şekil 3.5. LSTM Sinir Ağı Mimarisi

### 3.5.4. Kısıtlı Boltzmann Makinesi (RBM-Restricted Boltzmann Machine)

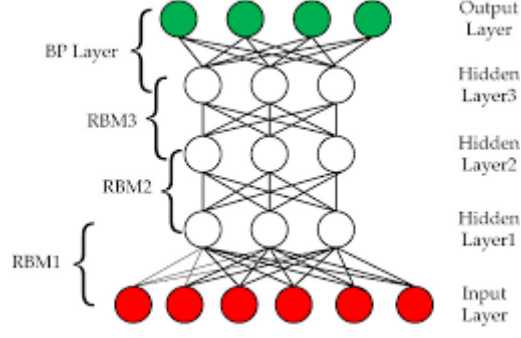
Sınıflandırma ve özellikle kullanılan kısıtlı Boltzmann makinesi ile öğrenme, girdi verilerinden olasılıksal grafik modelleri oluşturan bir sinir ağıdır. Sırasıyla giriş ve gizli katman adı verilen iki katmanlı bir yapıya sahiptir [26]. Şekil 3.6.'da görüldüğü üzere Kısıtlı Boltzmann Makinesi nodelerden oluşmaktadır.



Şekil 3.6. Kısıtlı Boltzmann Makinesi'nin Yapısı

### 3.5.5. Derin İnanç Ağı (DBN-Deep Belief Network)


Grafiksel model olan ve veri setinin hiyerarşisini oluşturan yapı Derin İnanç ağlarıdır. RBM'den yararlanılarak yığın oluşturulmuş ve ağıın eğitim aşamasını göstermiştir [27]. Şekil 3.7.'de görüldüğü üzere Derin İnanç Ağı'nın basit yapısı gösterilmiştir. Ağıın yapısında Giriş katmanı vardır ve bu katmandan sonra RBM'den oluşan yığınlar oluşur. Bu oluşan yığından sonra çıkış katmanı olduğu gözlemlenmiştir.



Şekil 3.7. Derin İnanç Ağı'nın Temel Yapısı

### 3.5.6. Derin Oto-Kodlayıcılar (Auto Encoder)

Derin Oto-Kodlayıcılar denetimsiz öğrenme tabanlıdır ve yapay sinir ağı modellerinden biri olarak bilinir. Diablo ağı olarak da adlandırılan bir sinir ağıdır. Derin Oto-Kodlayıcılarının amacı veri kümesini sıkıştırıp, kaybı olabildiğince en aza indirgeyerek öğrenmektir. Bu sinir ağı ileri beslemelidir ve katman sayısı 3'tür. Bu katmanlarda sırasıyla Girdi katmanı, Gizli katman ve çıkış katmanı olarak bilinir. Nöron sayıları her katmanda farklılık gösterir. Giriş ve çıkış katmanı için nöronlarda eşitlik varken, gizli katmanda değişkenlik olduğu gözlemlenmiştir [28]. Şekil 3.8.'de görüldüğü üzere Oto Kodlayıcı şeması gösterilmiştir.



Şekil 3.8. Derin Oto-Kodlayıcılar Şeması


## 3.6. Evrişimsel Sinir Ağı Katmanları

### 3.6.1. Giriş (Input) Katmanı

ESA mimarisinin ilk katmanı Giriş katmanıdır. Bu katmanda ağa veri gönderilir. Modelin bu katmandaki başarısının artması için veri boyutu önemli rol oynamaktadır. Giriş için görüntü boyutu önemlidir, yüksek olması durumunda eğitim süresini, her görüntü için oluşturulan test süresini ve kullanılacak bellek ihtiyacını uzatabilir. Diğer yandan ise ağdaki başarısını önemli ölçüde arttırabilir. Tam tersi durumda yani görüntünün düşük olması durumunda eğitim süresi kısalmış ve kullanılacak bellek tüketimi azalır. Böyle bir durum ise ağdaki başarıyı azaltabilir. Giriş olarak görüntü boyutu hem ağın başarısını hem donanımsal olarak hesaplamayı hem de ağ derinliğini önemli ölçüde etkiler [29].

### 3.6.2. Konvolüsyon (Convolution) Katmanı


Dönüşüm katmanı olarak bilinen ve ESA mimarisinin temeli olan bir katmandır. Dönüşüm işlemi, belirlenen filtre üzerinde oluşturulan görüntünün dolaştırılmasıdır. Bundan dolayı katmanlı mimarinin önemli bileşeni filtrelerdir. Bu filtreler çeşitli boyutlarda ortaya çıkabilir. Önceki katmandan gelen görüntülere konvülyasyon işlemi uygulanır ve çıkış verisini ortaya çıkarırlar. Yapılan bu işlem sonucunda aktivasyon haritası oluşur. Filtrelerin her birine uygun özelliklerin keşfedildiği alanlar Aktivasyon haritalarıdır. Filtrelerde oluşan katsayılar eğitim aşamasında ve bununla birlikte öğrenme aşamasıyla sürekli değişir [30]. Şekil 3.9.'da görüldüğü üzere konvolüsyon işlemi vardır. Evrişim Sinir Ağları algoritmalarında da farklı ölçeklerde filtreler kullanılmıştır.



Şekil 3.9. Filtrenin Uygulandığı Konvolüsyon İşlemi

### 3.6.3. Aktivasyon (ReLU) katmanı


Aktivasyon fonksiyonu, Yapay sinir ağlarında kullanıldığı gibi CNN'de de kullanılır. Giriş sinyallerinden yapılan ve doğrusallığı olmayan işlemi kapsar. Sigmoid olarak bilinen aktivasyon fonksiyonu, YSA'larda kullanılır. ReLU ise CNN'de aktivasyon fonksiyonu olarak kullanılır. ReLU fonksiyonu  $h(y) = \max(0, y)$  şeklinde ifade edilebilir [31]. Şekil 3.10.'da görüldüğü üzere aktivasyon katmanı fonksiyonu verilmiştir.



Şekil 3.10. Aktivasyon (ReLU) Katmanı İşlevi

### 3.6.4. Havuzlama (Pooling) katmanı


Temel amacı, bir sonraki evrişim katmanı için girişin boyutunu azaltmayı amaçlayan bir katmandır. Giriş boyutunun azalmasıyla beraber bilgi kaybı da olur. Bu kayıp ile sonraki katmanların iş yükü hafifler ve sistemin ezberini engellediği için olumlu olarak katkıda bulunur. Havuzlama Katmanı, evrişimsel sinir ağında olmayabilir ve modellerin bazıları da bu katmanı kullanmaz. Diğer katmanlarda olduğu gibi bu katmanda da filtreler tanımlanır. Performans olarak daha iyi sonuç veren, görüntü üzerinde gezdirilme rolüyle oluşan pixellerin maksimum değerini alan MaxPooling katmanı vardır. Bu katman genellikle tercih edilir [32]. Şekil 3.11.'de görüldüğü üzere havuzlama katmanından dolayı boyutta azalma görülmüştür.



Şekil 3.11. Havuzlama (Pooling) Katmanı

### 3.6.5. Tam bağlı (Full-Connected) katman


Bu katmana gelmeden önce gelen veriler, tek bir matris şeklinde bu katmanda bulunur. Oluşan nöronlar bu katmanda yer alır ve nöronların her biri kendinden sonraki nörona bağlanarak devam eder. Her giriş için diğer girişlerinde bir nörona bağlı olduğu katmandır. Bu sebeple tam bağlı katman olarak bilinir [33]. Şekil 3.12’de görüldüğü üzere tam bağlı katman yapısına yer verilmiştir.



Şekil 3.12. Tam Bağlı (Fully-Connected) Katman Yapısı

### 3.6.6. Dropout katmanı

Öğrenimi tamamlanmış ağda ezberlemeyi engellemek için kullanılan önemli katmanlardan biridir. Ağ içinde aşırı öğrenmeyi sağlayan bağlantıları engellemek için kullanılır. Bu yöntem ile ağın ezberlemesi engellenir. [34]. Şekil 3.13’te görüldüğü üzere Dropout Katman yapısına yer verilmiştir. Bu yapıda ilk şekil standart bir sinir ağını gösterirken, diğer şekil dropout katman yapısına sahip sinir ağını gösterir. Bu yapıya göre ağdaki ezberlemeyi engellemek için bu katmandan yararlanılır.



Şekil 3.13. Standart Sinir Ağı Görünümü ve Dropout Katmanına Sahip Sinir Ağı Görünümü

### 3.6.7. Sınıflandırma (Classification) katmanı

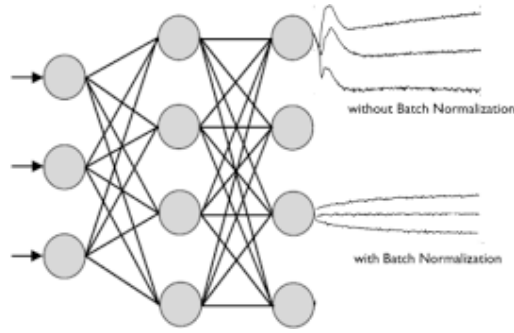
Tam bağlı katman yapısından sonraki katman sınıflandırma katmanıdır ve sınıflandırma işlemi bu katman da yapılır. Katmandaki çıkış değeri, sınıflandırma için kullanılacak nesne sayısıdır. Bu sınıflandırmaya örnek verilirse; 10 farklı nesne için sınıflandırma yapılırsa, eşit olacak şekilde de 10 çıkış değeri olur. Başka bir katman olan tam bağlı katman için ise, çıkış değeri 1000 olursa, sınıflandırma katmanında çıkış değeri dikkate alınır. Böylece bu katmana göre 1000x10 ağırlık matrisi elde edilmiş olur. Birçok sınıflandırıcı bu katmanda kullanılır ve Softmax de tercih edilen sınıflandırıcılardan biridir. Sınıflandırma yaparken 10 farklı nesne için 0-1 aralığında çıkış üretilir ve çıkış 1'e yakınsa ağı tahmin ettiği nesnedir [35].

### 3.6.8. Yumuşatma (SoftMax) Katmanı

Tam bağlı katmandan gelen verileri inceleyen, değerlendiren bir yapısı vardır ve ağı çıkışını oluşturur. Bu katman da sadece sınıflandırma bilgisine yer verilmez, aynı zamanda oluşan eğrileri de hesaplayan bir yapısı vardır. Derin öğrenme algoritmalarında genellikle sınıflandırıcı olarak bu katman kullanılır [36].

### 3.6.9. Normalizasyon (Normalization) Katmanı

Normalizasyon katmanı, tüm katmanlardan elde edilen verileri belli bir düzene göre toparlayan bir katmandır. Böylece girdi olarak verilen verilerin aralıklarını belirler ve ağıdaki performansı maksimum düzeye çıkarır [37]. Şekil 3.14.'de görüldüğü üzere Normalizasyon Katmanına yer verilmiştir.




Şekil 3.14. Normalizasyon Katman Yapısı

### 3.7. Evrişimsel Sinir Ağı Algoritmaları

#### 3.7.1. AlexNet

AlexNet mimarisi sekiz katmandan oluşmaktadır. Bu katmanlardan beşi katlanmış katmanlardır. AlexNet'te üç adet tam bağlantılı katman bulunmaktadır. Her katman sonucunda 1000 adet sınıflandırma yapılabilmektedir. Bunun için bir softmax katmanı vardır. AlexNet mimarisin de giriş olarak 224 x 224 x 3 katmanlı görüntüler vardır. İlk katmanda 11x11 filtre uygulanır, birinci katmanın sonunda 48 adet görüntü elde edilir. Maxpooling, AlexNet mimarisinde birinci, ikinci ve beşinci katmanlardan sonra uygulanır [38]. Şekil 3.15.'de görüldüğü üzere AlexNet mimarisine yer verilmiştir.




Şekil 3.15. AlexNet Mimarisi

#### 3.7.2. DenseNet201

DenseNet mimarisi, katmanların hepsini ileri beslemeli bir biçimde doğrudan birbirine bağlayan bir bağlantı modeli kullanır. Her katman, önceki tüm katmanlardan girdiler alır ve sonraki tüm katmanlara kendi özellik çıkarımını aktarır. Böylece ağdaki bilgi akışını en üst düzeye çıkarmaya çalışır. Bu mimari, kaybolan gradyan problemini


azaltır, özellik yayılımını artırır, ayrıca parametre sayısında önemli miktarda azalma sağlar [39]. Şekil 3.16.'da görüldüğü üzere DenseNet201 mimarisine yer verilmiştir.



Şekil 3.16. DenseNet201 Mimarisi

### 3.7.3. GoogleNet


Katmanlara filtre ekleme, hesaplama yapma, bellek olarak maliyetli olacağı için bu katman bellek ve güç kullanımında büyük rol oynamaktadır. Modül olarak başlangıçta, model zıtlığını ve parametre derecesini sınırlandıran küçük boyutlu çekirdekten oluşmaktadır. Bu mimari 100'den fazla katmandan oluşur. Giriş olarak genellikle 224x224 piksel boyutundaki görüntüler kullanılır [40]. Şekil 3.17.'de görüldüğü üzere GoogleNet mimarisine yer verilmiştir.



Şekil 3.17. GoogleNet Mimarisi

### 3.7.4. ResNet50

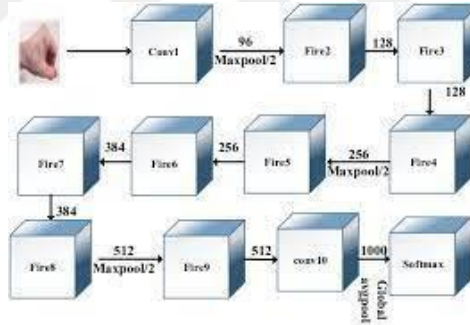
Derin Sinir Ağları sayı olarak az olan katmanlara karşı daha iyi performans sergilemektedir. Artan ağ derinliğiyle beraber modellerin performansını etkileyen gradyan sorunu ortaya çıkmaktadır. ResNet50 modelleri katman sayılarına göre birden çok yapıda bulunmaktadır. Katman sayısı 50'dir ve giriş olarak 224x224 piksel boyutundaki görüntüler kullanılır [41]. Şekil 3.18.'de görüldüğü üzere ResNet50 mimarisine yer verilmiştir.



Şekil 3.18. ResNet50 Mimarisi

### 3.7.5. SqueezeNet

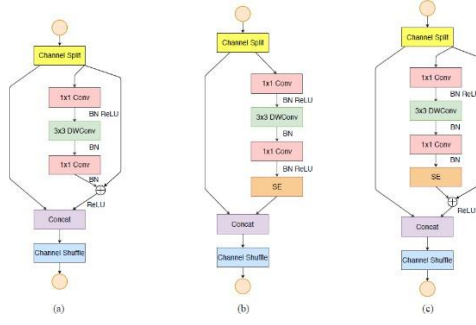
SqueezeNet tasarımında ESA olarak birçok yöntem kullanılmaktadır. İlk yapılacak olan 4x4 filtreleri 2x2 filtreler ile yerini değiştirmek olacaktır. Sonraki adımda ise giriş kanalları 4x4 filtrelere tekrar düşürülür. Alt örnekleme yapılarak evrişim katmanları ile büyük aktivasyon haritaları oluşturulur [42]. SqueezeNet mimarinin katman sayısı 18'dir ve Giriş olarak genellikle 224x224 piksel boyutundaki görüntüler kullanılır. Şekil 3.19.'da görüldüğü üzere SqueezeNet mimarisine yer verilmiştir.



Şekil 3.19. SqueezeNet Mimarisi

### 3.7.6. ShuffleNet

ShuffleNet, evrişimli katman yapısı ile özellik haritasını alarak sonuç verir. ShuffleNet çeşitli evrişimli işlemi içerir. Bu işlemler grup evrişimi için BN, kanal ve relu aktivasyon katmanı olarak bilinir [43]. Katman sayısı 172'dir ve giriş olarak 224x224 piksel boyutundaki görüntüler kullanılır. Şekil 3.20.'de görüldüğü üzere ShuffleNet mimarisine yer verilmiştir.



Şekil 3.20. ShuffleNet Mimarisi

### 3.8. Önerilen Derin Öğrenme Tabanlı Hibrit Yöntem

#### 3.8.1. Veri kümesinin tespiti ve oluşum aşamaları

Çevresel Atıkların ayrıştırılması için kullanılan veri setinde 2527 görüntü vardır. Bu veri seti 6 sınıflıdır ve her sınıfta belirli oranda görüntü vardır. Bu sınıflar Cardboard, Glass, Metal, Paper, Plastic ve Trash olarak ayrılmıştır. Şekil 3.21.'de görüldüğü üzere atıklar kategorilerine göre ayrılmıştır. Kategorilere ayrılma yöntemi ile nesne tespiti kolaylaşır. Böylece çevredeki atık problemi en aza indirgenmesi söz konusu olur.



Şekil 3.21. Çevresel Atıkların Ayrıştırılması

#### 3.8.2. Sonuçların toplanması ve değerlendirme aşaması

Çalışmada karmaşıklık matrisinin analizinde kullanılan bazı performans metrikleri vardır. Hassasiyet kriteri, doğru pozitifin yanlış negatif ile toplamının, doğru pozitif ile oranı alınarak hesaplanmıştır. Özgüllük kriteri, yanlış pozitifin doğru negatif ile toplamının, doğru negatif ile oranı alınarak hesaplanmıştır. Kesinlik kriteri, doğru pozitifin yanlış pozitif ile toplamının, doğru pozitif ile oranı alınarak hesaplanmıştır. Yanlış pozitif oran kriteri, yanlış pozitifin doğru negatif ile toplamının, yanlış pozitif ile oranı alınarak hesaplanmıştır. Yanlış keşif oran kriteri, yanlış pozitifin doğru pozitif

ile toplamının, yanlış pozitif ile oranı alınarak hesaplanmıştır. Yanlış negatif oran kriteri, yanlış negatifin doğru pozitif ile toplamının, yanlış negatif ile oranı alınarak hesaplanmıştır. Doğruluk kriteri, doğru pozitifin doğru negatif ile toplamının, pozitif ve negatiflerin toplamı ile oranı alınarak hesaplanmıştır. F1 skoru kriteri, iki doğru pozitifin, yanlış pozitifin ve yanlış negatifin toplamının, iki doğru pozitif ile oranı alınarak hesaplanmıştır. Çizelge 3.1.'de görüldüğü üzere formülleri ayrıntılı bir şekilde verilmiştir.

Çizelge 3.1. Performans Kriterleri

<b>Kriterler</b>	<b>Formülizasyon</b>
Hassasiyet (Sens.)	$TP / (TP+FN)$
Özgünlük	$TN / (FP+TN)$
Kesinlik	$TP / (TP+FP)$
Yanlış Pozitif Oran (FPR)	$FP / (FP+TN)$
Yanlış Keşif Oran (FDR)	$FP / (FP+TP)$
Yanlış Negatif Oran (FNR)	$FN / (FN+TP)$
Doğruluk	$(TP+TN) / (P+N)$
F1 Skoru	$F1 = 2TP / (2TP+FP+FN)$

## 4. ARAŞTIRMA BULGULARI VE TARTIŞMA

### 4.1. Veri Kümesinin Derin Öğrenme Mimarileriyle Eğitimi, Başarısı ve Araştırma Sonuçları

Yapılan bu çalışma altı sınıflı olup, Matlab ortamında gerçekleşmiştir. Veri setindeki sınıflar sırasıyla Cardboard, Glass, Metal, Paper, Plastic ve Trash olarak adlandırılmıştır. Model eğitilirken görüntülerin %20'si test için, %80'i eğitim için ayrılmıştır. Bu eğitimde epoch değeri 5 ve batchsize değeri 16 alınarak eğitim tamamlanmıştır. Mimarilerden elde edilen doğruluk değerleri Tablo 1. de görüldüğü üzere verilmiştir. Çizelge 4.1.'de görüldüğü üzere mimarilerden alınan sonuçlara yer verilmiştir.

Çizelge 4.1. ESA mimarilerinden elde edilen doğruluk değerleri

AlexNet	GoogleNet	ResNet50	DenseNet201	ShuffleNet	SqueezeNet
%80.10	%81	%81.25	%85.96	%77.28	%76.80

Model, mimariler ile eğitildikten sonra Densenet201 mimarisi %85.96 ile en iyi sonucu verdiği gözlemlenmiştir. Diğer mimarilerde sonuçlar AlexNet için %80.10, GoogleNet için %81, ResNet50 için 81.25, DenseNet201 için %85.96, ShuffleNet için %77.28, SqueezeNet için %76.80 olmuştur. Bu sonuçlara göre en düşük sonucu veren mimari de ShuffleNet mimarisi olmuştur. Şekil 4.1.'de görüldüğü üzere model eğitildikten sonra karmaşıklık matrisi verilmiştir. Bu karmaşıklık matrisinde 1. sınıf Cardboard, 2. sınıf Glass, 3. sınıf Metal, 4. sınıf Paper, 5. sınıf plastic ve 6. sınıfta Trash olarak ayrılmıştır.

GoogleNet							AlexNet						
1	72	3		6			1	79			2		
2		85	8		6	1	2		76	14	1	9	
3		10	69	1	1	1	3	1	4	70	3	4	
4	4	4	1	104	1	5	4	6	2	2	100	2	7
5	3	13	6	9	60	5	5	1	8	6	15	62	4
6	1	1	2	7	2	13	6	1	1	2	10	2	11
	1	2	3	4	5	6		1	2	3	4	5	6
DenseNet201							ResNet50						
1	77	1		3			1	75			6		
2		89	3		5	3	2		86	6	1	7	
3		3	77		1	1	3		2	73		7	
4	3		1	109	2	5	4	5	1	1	106	2	4
5	2	7	3	10	64	10	5	1	10	8	9	62	6
6	1		3	8		15	6	3	1	3	7		13
	1	2	3	4	5	6		1	2	3	4	5	6
SqueezeNet							ShuffleNet						
1	77			4			1	75			6		
2		77	14		8	1	2		83	6	2	9	
3		7	72	2		1	3		8	66	4	4	
4	7	2	3	102	1	4	4	4	3	1	106	1	4
5	3	20	13	9	48	3	5	3	14	9	10	49	11
6	1		4	9	1	12	6	5		5	9		8
	1	2	3	4	5	6		1	2	3	4	5	6


Şekil 4.1. ESA mimarilerine ait karmaşıklık matrisleri

Şekil 4.1.'e göre yapılan bu çalışmada çeşitli mimariler kullanılmıştır. Bu mimariler içinde en iyi doğruluk %85.96 oranı ile DenseNet201 olmuştur. Bu veri seti altı sınıftan oluşmaktadır. Bu sınıflar Cardboard, Glass, Metal, Paper, Plastic, Trash olarak adlandırılır. Bu sınıflarda toplam 2537 görüntünün %20'si test için ve %80'i

eğitim için kullanılmıştır. Bu mimaride 505 görüntü test için kullanılmıştır. DenseNet201 modeli, bu görüntü sayısından 431 görüntüyü doğru sınıflandırırken, 74 görüntüyü yanlış sınıflandırmıştır. DenseNet201 modeli, CardBoard sınıfının 77 görüntüsünü doğru sınıflandırmıştır. Model 1 tanesini glass, 3 tanesini metal görüntü olarak yanlış sınıflandırmıştır. Glass sınıfının toplam görüntüsü 501'dir ve bu görüntünün 100 tanesi test için ayrılmıştır. DenseNet201 modeli, glass sınıfının 89 görüntüsünü doğru sınıflandırmıştır. Model 3 tanesini trash, 5 tanesini plastic, 3 tanesini metal olarak yanlış sınıflandırmıştır. Metal sınıfının görüntü sayısı 410'dur ve bu görüntünün 82 tanesi test için ayrılmıştır. DenseNet201 modeli, metal sınıfının 77 görüntüsünü doğru sınıflandırmıştır. Model 3 tanesini glass, 1 tanesini plastic ve 1 tanesini trash olarak yanlış sınıflandırmıştır. Paper sınıfının toplam görüntüsü 594'dür ve bu görüntünün 119 tanesi test için ayrılmıştır. DenseNet201 modeli, paper sınıfının 109 görüntüsünü doğru sınıflandırmıştır. Model 3 tanesini cardboard, 1 tanesini metal, 2 tanesini plastic ve 5 tanesini trash olarak yanlış sınıflandırmıştır. Plastic sınıfının toplam görüntüsü 482'dir ve bu görüntünün 96 tanesi test için ayrılmıştır. DenseNet201 modeli, plastic sınıfının 64 görüntüsünü doğru sınıflandırmıştır. Model 10 tanesini trash, 2 tanesini cardboard, 10 tanesini paper, 3 tanesini metal ve 2 tanesini cardboard olarak yanlış sınıflandırma yapmıştır. Trash sınıfının toplam görüntüsü 137'dir ve bu görüntünün 27 tanesi test için ayrılmıştır. DenseNet201 modeli, trash sınıfının 15 görüntüsü için doğru sınıflandırma yapmıştır. Model 3 tanesini metal, 8 tanesini paper ve 1 tanesini cardboard olarak yanlış sınıflandırma yapmıştır.

#### 4.1.1. Önerilen Modelde Elde Edilen Sonuçlar

Elde edilen sonuçlara göre önerilen modelde Densenet201 mimarisinden yararlanılmıştır. Veri setindeki görüntülerden özellik haritaları çıkarılmıştır. Bu çıkarılan özellik haritaları sonuçlarına göre en yüksek doğruluk değerini DVM sınıflandırıcısı vermiştir. Şekil 4.2.' de görüldüğü üzere bu aşamalar özet şeklinde verilmiştir.



Şekil 4.2. Önerilen Model

Çizelge 4.2.'de verilen mimariler ile model farklı sınıflandırıcılarda sınıflandırıldığında ortaya çıkan doğruluk değerleri verilmiştir.

Çizelge 4.2. Mimariler ve Sınıflandırıcı Sonuçları

ESA Mimarileri	KA	Naive	DVM	KNN	Neural
		Bayes Classifiers			Network Classifiers
AlexNet	57.60%	64.10%	80.80%	76.10%	76.80%
GoogleNet	61.50%	69.90%	83.70%	80.00%	81.60%
DenseNet201	66.50%	77.90%	89.30%	86.00%	86.70%
ResNet50	66.40%	76.60%	87.30%	84.80%	84.20%
ShuffleNet	59.90%	68.50%	85.80%	82.00%	83.60%
Squeezenet	57.25%	61.30%	85.90%	79.10%	83.10%

Çizelge 4.2.'de gösterildiği gibi özellik haritaları KA, Naive Bayes Classifiers, DVM, KNN ve Neural Network Classifiers sınıflandırıcılarda sınıflandırılmıştır. Bu sınıflandırma sonuçlarına göre %89.30 ile DenseNet201 mimarisi ve DVM sınıflandırıcısı birlikte en iyi sonucu elde etmişlerdir. Özellik haritaları ile beş sınıflandırıcıda sınıflandırıldıktan sonra en iyi değeri DVM sınıflandırıcısı verirken, en düşük değeri KA sınıflandırıcısı vermiştir. Şekil 4.3.'te DenseNet201 mimarisi ile DVM sınıflandırıcısının birlikte oluşturdukları hibrit modelin karmaşıklık matrisi verilmiştir.

1	366		1	32	4	
2		454	24	3	19	1
3		17	368	9	11	5
4	11	2	7	555	9	10
5	1	27	14	10	420	10
6	4	2	7	19	11	94
	1	2	3	4	5	6

Şekil 4.3. DVM+DenseNet201

Bu model altı sınıflı olup 2527 görüntü sayısına sahiptir. Önerilen bu model 2257 görüntüyü doğru tahmin ederken, 270 görüntüyü yanlış tahmin etmiştir. Çizelge 4.3.'te gösterildiği gibi modelin performans ölçütlerine göre sonuçlar verilmiştir.

Çizelge 4.3. Performans Ölçütleri

	Acc.	Sens.	Pre.	F1	FDR	FPR	FNR
Cardboard	96.75	95.81	90.81	93.23	0.09	0.01	0.04
Glass	96.83	90.43	90.98	90.70	0.09	0.02	0.09
Metal	95.12	87.41	89.75	88.65	0.10	0.01	0.12
Paper	97.85	88.90	93.75	91.25	0.06	0.02	0.11
Plastic	93.30	88.60	87.13	87.85	0.12	0.02	0.11
Trash	82.55	78.33	68.61	73.14	0.32	0.01	0.21

Çizelge 4.3.'te görüldüğü üzere model, performans kriterlerine göre incelenmiştir ve en yüksek doğruluk %97.85 ile Paper sınıfı olduğu gözlemlenmiştir.

#### 4.1.2. Komşuluk Bileşeni Analizi ile Elde Edilen Sonuçlar

Komşuluk Bileşeni Analizi ile elde edilen sonuçlarla programın çalışması hızlandırılmıştır. Optimize edilmiş özellikleri elde etmek için bu yöntem kullanılır. Kullanılan yöntemin sonuçları Şekil 4.4.'de görüldüğü üzere verilmiştir. Yöntemin sonuçlarına göre en iyi doğruluk değerini KNN vermiştir. KNN sınıflandırıcısı dikkate alındığı zaman 2327 görüntüyü doğru sınıflandırırken, 199 görüntüyü yanlış sınıflandırmıştır. KNN sınıflandırıcı modeli görüntülerin, Cardboard sınıfındaki 373 görüntüsünü doğru sınıflandırmıştır. Bu sınıflandırıcı modeli görüntülerin, 2 tanesini metal, 26 tanesini paper, 1 tanesini plastic ve 1 tanesini de trash olarak yanlış sınıflandırmıştır. KNN sınıflandırıcı modeli görüntülerin, Glass sınıfındaki 467 görüntüsünü doğru sınıflandırmıştır. KNN sınıflandırıcı modeli görüntülerin, Metal sınıfındaki 379 görüntüsünü doğru sınıflandırmıştır. KNN sınıflandırıcı modeli görüntülerin, Paper sınıfındaki 572 görüntüsünü doğru sınıflandırmıştır. KNN sınıflandırıcı modeli görüntülerin, Plastic sınıfındaki 437 görüntüsünü doğru sınıflandırmıştır. KNN sınıflandırıcı modeli görüntülerin, Trash sınıfındaki 99 görüntüsünü doğru sınıflandırmıştır.

SVM						KNN							
1	368	4		31		1	79		2	26	1	1	
2		85	8		6	1	2		467	16		16	2
3		10	69	1	1	1	3		16	379	5	4	6
4	4	4	1	104	1	5	4	4	1	2	572	5	10
5	3	13	6	9	60	5	5	1	24	8	6	437	6
6	1	1	2	7	2	13	6	1	2	3	23	9	99
	1	2	3	4	5	6		1	2	3	4	5	6
	<b>Ensemble</b>						<b>Neural Network</b>						

Naive Bayes						Linear Discriminant							
1	378	1		23		1	370			33			
2		467	17		3	14	2		452	17	5	27	
3		13	381		8	8	3	4	12	376	7	11	
4	3		3	577	3	8	4	5	1	1	106	2	4
5	1	21	8	7	441	4	5		32	14	7	421	8
6	3	10	21	11		92	6	5	15	7	20		90
	1	2	3	4	5	6		1	2	3	4	5	6
	<b>Naive Bayes</b>						<b>Linear Discriminant</b>						

1	336	24		43		1	355	5	3	40			
2		409	31		56	5	2		442	21	5	33	
3		20	317	26		47	3		15	370	15	10	
4	18	2	4	520	5	45	4	4	2	9	549	7	23
5	1	36	19	14	389	23	5		31	23	7	406	16
6	7		16	16	6	92	6	3		11	27		96
	1	2	3	4	5	6		1	2	3	4	5	6

Şekil 4.4. NCA + Sınıflandırıcı Karmaşıklık Matris Sonuçları

Yapılan bu çalışmada ikili birleştirme yapıp, özelliklerin optimize edilmesi için NCA kullanılmıştır. NCA kullanıldıktan sonra optimize edilmiş hali ile çeşitli sınıflandırıcılara verilmiştir. Sınıflandırıcı sonuçlarına göre en iyi doğruluk değerini %92.80 ile KNN sınıflandırıcısı vermiştir. En düşük doğruluk değerini ise %81.60 ile Naive Bayes sınıflandırıcısı vermiştir.

### 4.1.3. Tartışma

Sanayi alanındaki gelişmeler ile birlikte atık sorununda ciddi bir artış meydana gelmiştir. Bu artış ile birlikte sorunun büyümesini engellemek için birçok çalışma başlatılmıştır. Bu çalışmalardan biri de oluşan atıkların geri dönüşüme geri kazandırılması olmuştur. Çevredeki atıkların sınıflandırılması ile atıklar ayrıştırılarak geri dönüşüme kazandırılır ve çevre daha yaşanılabilir hale gelir. Bunun için illerdeki belediyelere büyük rol düşmektedir. Nüfusun artmasıyla birlikte her bireyin ürettiği atık miktarı ortalama 2 kattan fazla olmuştur. Bu tez çalışmasında bahsedilen çevresel atıkların ayrıştırılması çözümünde literatürde farklı çalışmalar yapılmıştır. Çizelge 4.4.'de görüldüğü üzere literatürde yapılan çalışmalara yer verilmiştir. Bu çalışmalarda çevresel atıkların ayrıştırılması dikkate alınmıştır. Her çalışma da farklı model/metot kullanılmıştır ve doğruluk değerleri bulunmuştur.

Çizelge 4.4. Literatürdeki Çalışmalar

Çalışma	Model/Metot	Doğruluk
Sürücü vd. [5]	ResNet50-V2	%97.07
Varol vd. [6]	DarkNet-19	%96
Endah vd. [7]	Xception	%88
Rabano vd. [8]	DenseNet-201	%87.20
Mittal vd. [9]	ResNet50	%87.69
Sidhart vd. [10]	GoogleNet	%76
Karaca vd. [11]	ResNet50	%74.76
Altınors vb. [12]	YOLOv3	%84.81

Yapılan bu çalışma da Veri setinden alınan görüntüler ile model eğitilip farklı mimarilerden sonuçlar alınmıştır. Sonuçlar kıyaslandığında model için en iyi sonucu veren mimari dikkate alınmıştır. Son aşamada ise en iyi sonucu veren iki model birleştirilip, indirgeme yöntemlerinden olan NCA'ya verilmiştir. Bu sonuçlar kıyaslanarak model için doğruluk değeri elde edilmiştir. Sınıflandırıcı sonuçlarına göre en iyi doğruluk değerini %92.80 ile KNN sınıflandırıcısı vermiştir. En düşük doğruluk değerini ise %81.60 ile Naive Bayes sınıflandırıcısı vermiştir.

## 5. SONUÇ VE ÖNERİLER

Derin Öğrenme, günümüzde görüntü işleme ve sınıflandırmada sağlık, endüstri, ilaç gibi çoğu konu olan problemlerde başarılı sonuçlar vermektedir. Birçok atık modeli vardır ve bu modellerin tespit edilip, ona göre sınıflandırılma yapılması oldukça zordur. Günümüzde ciddi bir problem haline gelen sorunun çözümü ise Derin öğrenmeyle nesne tespiti yöntemiyle kolay hale gelmiş olur. Çevresel Atıkların Ayırıştırılması ile ilgili konuda bu teknikten yararlanılmıştır.

Bu tezde günümüz problemi olan ve üstünde ciddi çalışmalar yapılan bir konuyla ilgili sonuçlar alınmıştır. Atıkların çevreye verdiği zarar, canlıların yaşamını kısıtlayan bir faktördür. Bu sorun bilinçsizce atılan çöplerin doğada kendi kendine çözünmesinin beklenilmesi sonucu ortaya çıkmıştır. Araştırmaların birçoğuna göre atılan atıkların doğada çözünmesi uzun yıllar sürüyor. Bu süre zarfında ise doğaya verilen zarar ciddi bir orandır. Bunu önlemek için birçok yöntem vardır. Bu sorunu en aza indirmenin bir yolu da atıkları kategorilerine göre sınıflandırmak olacaktır. Böylece atıkların geri dönüşüme kazandırılması kolaylaşacaktır.

Yapılan bu çalışma da Çevresel atıkları ayırştırmak için yeni bir hibrit model geliştirilmiştir. Modelden sonuçlar alınırken birçok yöntem kullanılarak sonuçlar alınmıştır. Bu sonuçlar dikkate alınarak model için en iyi sonuç elde edilmeye çalışılmıştır. ESA mimarilerinden ve birçok sınıflandırıcıdan sonuçlar alınmıştır. Bu sonuçlar dikkate alındığında en yüksek doğruluk değerini %89.30 ile önerilen modelden elde edildiği gözlemlenmiştir. Bir sonraki aşamada iki mimari birleştirilip NCA'ya verildiğinde sınıflandırıcı sonuçlarına göre en iyi doğruluk değerini %92.80 ile KNN sınıflandırıcısı vermiştir. Ensemble sınıflandırıcısı %92.08 doğruluk değerini vermiştir. Bir başka sınıflandırıcı olan DVM sınıflandırıcısı %91.09 doğruluk değerini vermiştir. Neural Network sınıflandırıcısı %88.80 doğruluk değerini vermiştir. Linear Discriminant %87.70 doğruluk değerini vermiştir. En düşük doğruluk değerini ise %81.60 ile Naive Bayes sınıflandırıcısı vermiştir. Bu sonuç ile Çevresel atıkların ayırıştırılmasında bu yöntemin kullanılabileceği gözlemlenmiştir.

## 6. KAYNAKLAR

- [1] Özbuğutu, E., Karahan, S., & Tan, Ç. (2014). Çevre Eğitimi ve Alternatif Yöntemler–Literatür Taraması/Environmental Education and Its Alternative Methods–A Literature Review. *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 11(25), 393-408.
- [2] Bayram, H. Y., Bingol, H., & Alatas, B. (2022). Hybrid Deep Model for Automated Detection of Tomato Leaf Diseases. *Traitement du Signal*, 39(5), 1781-1787.
- [3] Eroğlu, O., & Yildirim, M. (2022). Automatic detection of eardrum otoendoscopic images in patients with otitis media using hybrid-based deep models. *International Journal of Imaging Systems and Technology*, 32(3), 717-727.
- [4] Yildirim, K., Yildirim, M., Eryesil, H., Talo, M., Yildirim, O., Karabatak, M., ... & Acharya, U. R. (2022). Deep learningbased PI-RADS score estimation to detect prostate cancer using multiparametric magnetic resonance imaging. *Computers and Electrical Engineering*, 102, 108275.
- [5] SÜRÜCÜ, S., & ECEMİŞ, İ. N. (2022). Garbage Classification Using Pre-Trained Models. *Avrupa Bilim ve Teknoloji Dergisi*, (36), 73-77.
- [6] Varol, S., Hark, C., & Kızıloluk, S. Geri Dönüştürülebilir Atıkların Sınıflandırılması Classification of Recyclable Waste.
- [7] Endah, S. N., & Shiddiq, I. N. (2020, November). Xception architecture transfer learning for garbage classification. In 2020 4th International Conference on Informatics and Computational Sciences (ICICoS) (pp. 1-4). IEEE.
- [8] Rabano, S. L., Cabatuan, M. K., Sybingco, E., Dadios, E. P., & Calilung, E. J. (2018, November). Common garbage classification using mobilenet. In 2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM) (pp. 1-4). IEEE.
- [9] Mittal, G., Yagnik, K. B., Garg, M., & Krishnan, N. C. (2016, September). Spotgarbage: smartphone app to detect garbage using deep learning. In

Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing (pp. 940-945).

- [10] Sidharth, R., Rohit, P., Vishagan, S., Karthika, R., & Ganesan, M. (2020, June). Deep learning based smart garbage classifier for effective waste management. In 2020 5th International Conference on Communication and Electronics Systems (ICCES) (pp. 1086-1089).
- [11] Karaca, Y. E., Aslan, S., & Hark, C. (2022). EVSEL ATIKLARIN DERİN ÖĞRENME TEKNİKLERİ İLE AYRIŞTIRILMASI. *Computer Science*, 7(1), 10-19..
- [12] ALTINÖRS, A., & ÇELİK, S. YOLOv3 Derin Öğrenme Algoritması ile İHA Görüntülerinden Çevresel Atık Tespiti. *International Journal of Innovative Engineering Applications*, 7(1), 76-85.
- [13] Endah, S. N., & Shiddiq, I. N. (2020, November). Xception architecture transfer learning for garbage classification. In 2020 4th International Conference on Informatics and Computational Sciences (ICICoS) (pp. 1-4). IEEE.
- [13] URL1:url:<https://www.kaggle.com/datasets/asdasdasdas/garbage-classification>, Erişim tarihi: 04/22/2024.
- [14] Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- [15] Atalay, M., & Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- [16] DOĞAN, F., & TÜRKOĞLU, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- [17] Suat, A. T. A. N. (2020). Knn, Naive Bayes ve Karar Ağacı Makine Öğrenme Algoritmaları, Bu Algoritmaların Sosyal Bilimlerde Kullanım İmkânları.
- [18] Kavzoğlu, T., & Çölkesen, İ. (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.

- [19] Gacar, B. K., & Kocakoç, İ. D. (2020). Regression analyses or decision trees?. *Manisa Celal Bayar Üniversitesi Sosyal Bilimler Dergisi*, 18(4), 251-260.
- [20] Nur, I. M., & Ülker, E. (2020). A Novel Hybrid IoT Based IDS Using Binary Grey Wolf Optimizer (BGWO) and Naive Bayes (NB). *Avrupa Bilim ve Teknoloji Dergisi*, 279-286.
- [21] Ashı, B. O. R. U. (2021). Prediction of market-clearing price using neural networks based methods and boosting algorithms. *International Advanced Researches and Engineering Journal*, 5(2), 240-246.
- [22] Gizem, Ö. T. E. R., & HANÇER, E. X-Ray Görüntülerinden Covid-19 Tespiti için Hibrit Bir Derin Öğrenme Yaklaşımı. *Avrupa Bilim ve Teknoloji Dergisi*, (52), 27-36.
- [23] Hulya, H. A. R. K., Karakurt, M., Cengiz, H. A. R. K., & KARCİ, A. GloVe Kelime Gömmeleri ve Sinir Ağları ile Haber Metinlerinin Sınıflandırılması. *International Journal of Pure and Applied Sciences*, 9(1), 175-187.
- [24] Arslankaya, S., & Toprak, Ş. (2021). Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. *International Journal of Engineering Research and Development*, 13(1), 178-192.
- [25] Sevinç, A., & Kaya, B. (2021). Derin Öğrenme Yöntemleri ile Sıcaklık Tahmini: Diyarbakır İli Örneği. *Computer Science, (Special)*, 217-225.
- [26] SÜN BÜL, G., & SOYLUK, A. (2024). A Review of Using Deep Learning Technology in the Built Environment of Disaster Management Phases. *Journal of Architectural Sciences and Applications*, 9(Special Issue), 201-218.
- [27] DOĞAN, F., & TÜRKOĞLU, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- [28] DOĞAN, F., & TÜRKOĞLU, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- [29] Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.

- [30] Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- [31] AKTÜRK, S., & SERBEST, K. (2022). Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi. *Journal of Smart Systems Research*, 3(2), 97-119.
- [32] Buket, K. A. Y. A., & Muhammed, Ö. N. A. L. (2021). COVID-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 1296-1303.
- [33] DOĞAN, F., & TÜRKOĞLU, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- [34] DOĞAN, F., & TÜRKOĞLU, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- [35] Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- [36] KAYAALP, K., & METLEK, S. (2020). Classification of robust and rotten apples by deep learning algorithm. *Sakarya University Journal of Computer and Information Sciences*, 3(2), 112-120.
- [37] Türkoğlu, M., Hanbay, K., SİVRİKAYA, I. S., & Hanbay, D. (2020). Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334-345
- [38] Kesler, S., Karakan, A., & Yüksel, O. Ğ. U. Z. AlexNet Mimarisi ile Muz Olgunlaşma Evrelerinin Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (51), 135-141.
- [39] TÜMAY, M., CİVELEK, Z., & Mustafa, T. E. K. E. (2023). Glakom ve Katarakt Hastalığının Derin Öğrenme Modelleri ile Teşhisi. *Politeknik Dergisi*, 1-1.
- [40] ÖZKÜÇÜK, M., Alçin, Ö. F., & GENÇOĞLU, M. (2022). EMG Sinyalleri Kullanılarak GoogLeNet ve Çok Seviyeli DPD ile El Tutma Hareketlerinin

Sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 34(1), 33-43.

- [41] Kemal, A. Ğ. C. A., & TAKCI, H. (2022). Hibrit Bir Model Oluşturarak Diyabetik Retinopati Sınıflandırılması. Avrupa Bilim ve Teknoloji Dergisi, (36), 227-236.
- [42] Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. arXiv preprint arXiv:1602.07360.
- [43] Ullah, N. Raza, A. Khan, J. A., & Khan, A. A. (2022). An Effective Approach for Automatic COVID-19 Detection from Multiple Image Sources Using Shufflenet Convolutional Neural Network (CNN).