

## Evsel Atıkların Derin Öğrenme Teknikleri ile Ayrıştırılması

### Separation Of Domestic Waste with Deep Learning Techniques

Yunus Emre Karaca\*<sup>1</sup> , Serpil Aslan<sup>2</sup> , Cengiz Hark<sup>3</sup> 

<sup>1</sup>Malatya Turgut Özal Üniversitesi (Malatya, Turkey)

<sup>2</sup> Malatya Turgut Özal Üniversitesi (Malatya, Turkey)

<sup>3</sup> İnönü Üniversitesi (Malatya, Turkey)

([yunusemre.karaca@inonu.edu.tr](mailto:yunusemre.karaca@inonu.edu.tr), [serpil.aslan@ozal.edu.tr](mailto:serpil.aslan@ozal.edu.tr), [cengiz.hark@inonu.edu.tr](mailto:cengiz.hark@inonu.edu.tr))

Received date: Feb.10, 2022

Accepted date: Mar.19, 2022

Published date: Jun.6, 2022

**Özetçe**— Derin öğrenme teknolojisinin hızlı gelişimi sayesinde günlük yaşantımızın hemen hemen her noktasında kullanılan akıllı sistemler geliştirilmektedir. Geliştirilen uygulamalar hayatımızı kolaylaştırdığı gibi doğaya da olumlu katkılar sağlamıştır. Geleneksel atık ayrıştırma yöntemleri, verimlilik ve doğruluk açısından yetersiz kalmaktadır. Ayrıca yüksek maliyetli olmasının yanında çevresel riskler bakımından da sıkıntılar doğurabilir. Son yıllarda, yapay zekâ, makine öğrenmesi ve beraberinde getirdiği derin öğrenme teknikleri organik, evsel ve ambalaj atıkların ayrıştırılması gibi karmaşık problemlerin çözümünde popüler bir yöntem olmuştur. Bu çalışmada, hem insan ve canlı yaşamı hem de doğanın korunması açısından büyük öneme sahip olan evsel atıkların ayrıştırılması problemi ele alınmıştır. Yapay zeka kümesinde yer alan; makine öğrenmesinin bir alt kolu olan derin öğrenme ile evsel atıkların tespit edilip ayrıştırılması için popüler evrimsel sinir ağı (Conventional Neural Network, CNN) tabanlı ResNet-50, DenseNet-121, Inception-V3, VGG-16 mimarileri kullanılarak sınıflandırma performansları karşılaştırılmıştır.

**Anahtar Kelimeler** : Derin Öğrenme, Evrimsel Sinir Ağları(CNN), Görüntü İşleme, Geri Dönüşüm, Biyolojik Yaşam

**Abstract**— Thanks to the rapid development of deep learning technology, smart systems used in almost every part of our daily life are being developed. Developed applications not only made our lives easier, but also contributed positively to nature. Traditional waste separation methods fall short in terms of efficiency and accuracy. In addition to its high cost, it can also cause problems in terms of environmental risks. In recent years, artificial intelligence, machine learning and the deep learning techniques it brings have become a popular method for solving complex problems such as organic, household and packaging waste sorting. In this study, the problem of separation of domestic wastes, which is of great importance in terms of both human and living life and the protection of nature, is discussed. In the artificial intelligence cluster; Classification performances were compared by using popular conventional neural network (CNN) based ResNet-50, DenseNet-121, Inception-V3, VGG-16 architectures to detect and sort household waste with deep learning, a sub-branch of machine learning.

**Keywords** : Deep Learning, Conventional Neural Networks (CNN), Image Processing, Recycling, Biological Life

## 1. Giriş

Dünya çapında yıllık 800 bin olimpik yüzme havuzunu dolduracak kapasitede yani yaklaşık olarak iki milyar tonun üzerinde çöp üretiliyor (BBC, 2019). Medeniyetin gün geçtikçe daha da ilerlemesi buna bağlı alım gücünün iyileşmesi ile birlikte dünya çapındaki nüfusun çoğalmasının bir sonucu olarak farklı

atık çeşitlerinde ve miktarında büyük artış olmuştur (Ziadat & Mott, 2005). Bu kapsamda geçen zaman ile birlikte var olan kaynakların hızla tükenebilir olduğu görülmüş, atıkların geri dönüştürülüp değerlendirilmesi kavramının ise ciddi ekonomik kazanımlar sağladığı farkındalığı ortaya çıkmıştır (Beliën, Boeck, & Ackere, 2011).

Atıkların geri dönüştürülmemesi, ayrıştırılmaması veya yanlış şekilde organize edilmesi yukarıda da belirtildiği üzere doğal kaynakların zamanla yok olmasına ve ekonomik olarak büyük kayıplara sebep olmuştur. Bununla birlikte yanlış atık yönetimi çevre kirliliği ile birlikte hastalıkların bulaşma ve yayılma hızını artırmıştır (Gulec, Gunal, & Erler, 2001). Bu olumsuz durumun devam etmesi, atıkların gelecekte önü alınamaz bir şekilde çoğalmasına sebep olacaktır. Ayrıştırılma kavramı kulak ardı edilip önemsenmez ise hiç görülmemiş sağlık sorunlarına neden olacaktır (Themelis, 2002). Bu sebeplerden dolayı atıkların ayrıştırılmasıyla ilgili ortaya çıkan problemlerin aşılması birçok araştırmacının ilgi odağı olmuştur. Bu hususta yapay zeka kavramında kullanılan tekniklerin gelişmesiyle atıkların ayrıştırılmasına çözüm olabilecek çeşitli teknikler öne sürülmüştür.

Yapay zekâ kavramının tarihsel süreci belki daha eski yıllara dayanabilir lakin 1941 yılında ENIAC adlı elektronik sayısal entegreli hesaplayıcının yapımına başlanmış (Wikipedia, 2021) böylelikle makinaların zeka kavramı ile tanışması gerçekleşmiştir. Daha sonra 1950’li yıllara geldiğimizde Alan Turing çalışmasının başlangıcında yönelttiği ‘makinalar düşünebilir mi?’ (Turing, 1950) sorusunu muhakeme etmeyi önermiş ve bu öneri tarihe bir kilometre taşı olarak yerleşerek makinaların düşünme olasılığı hakkında Turing testi olarak hem tarih sahnesinde hem de literatürdeki yerini almıştır. ‘Yapay zeka’ kavramı resmi olarak ise ilk 1956 yılında yapılan Dartmouth yaz araştırma projesinde tasarlanmış bu tasarımı hazırlayan McCarty yapay zeka kavramını ‘akıllı makinalar ya da akıllı bilgisayarlar oluşturma bilim ve mühendisliğidir’ ifadelerini kullanmıştır (El Naqa, Haider, Giger, & Ten Haken, 2020). 1960’lı yılların sonuna doğru ise yapay zeka araştırmalarının teorilerinin olumsuz sonuçlanması, yapay zeka kavramının 1950’li yıllarda başlayan popülerliği oluşturduğu pozitif hava yerini hayal kırıklığına ve sessizliğe bırakmıştır. Bu sessiz dönem yapay zeka kışı olarak anılmıştır (Evans, 2017). Yapay zekâ kışı tartışmaya açık bir ifadedir. Çünkü hava ne kadar da negatif olsa alanla ilgili çalışmalar devam etmiş büyük teknoloji laboratuvarları oluşturulmuş ve hatta 1997 yılında IBM’in geliştirdiği Deep Blue adlı yazılım ünlü satranç ustasını yenmiştir (Evans, 2017). Gary Kasparov’un Deep Blue yazılımına karşı yenilgisi teknoloji dünyasında tekrar gözleri yapay zekâ kavramına çevirmiş bu sayede yazılım sektöründe yapay zekâ alanında yapılan çalışmalarda hızla artma olmuş ve yapay zekâ ile öğrenme birçok farklı alanda kullanılmaya başlamıştır.

Bu farklı alanlardan biri de çağımızın ve geleceğimizin önemli problemi olan atıkların ayrıştırılması işlemidir. Atık ayrıştırma teknolojisi, atıkları kaynağında ayrıştırmak, kontrol etmek, sınıflandırmak ve geri dönüşüm yoluyla tekrar kaynağa dönüşümü için kullanılır. Geçmişte, atık ayrıştırmak için çok fazla insan gücü ve malzeme kaynağı gerektiriyordu. Yapay zekânın gelişmesiyle birlikte derin öğrenme de bu alanda kullanılmaya başlandı. Literatürü taradığımız zaman spesifik olarak sadece yapay zekâ ve atıkların ayrıştırılması ile ilgili çalışmaların kısıtlılığı fark edilmiştir. Bu nedenle, özellikli olarak sadece bu iki kavramın önemine yönelik yapılan çalışmalar incelendiğinde; yapılan çalışmaların bize daha güçlü ağ mimarilerini bulmamızı kolaylaştıran yöntemler sunduğu görülmüştür. Şöyle ki çalışmaların birinde, sinir ağlarının doğrultucu özellikleri tarafından yönlendirilmesi iki kapsamda incelenir. İlki, Parametrik Düzeltilmiş Doğrusal Birim diye yeni bir ReLU uzantısı tasarlanmasıdır. Bu uzantı, doğrultucuların parametrelerini uyarlamalı olarak öğrenir ve ihmal edilebilir ekstra hesaplama maliyetiyle doğruluğu artırabilir. İkinci ise daha derin düzeltilmiş modellerin eğitiminin zorluğunu incelenir. Doğrultucuların doğrusal olmama durumunu açıkça modelleyerek, sıfırdan eğitilmiş daha derin modellerin direkt yakınsamasına yardımcı olan teorik olarak sağlam bir başlatma yöntemi çıkarılır (He, Zhang, Ren, & Sun, 2015).

Chu ve arkadaşlarının yaptığı çalışmada, kamusal alanda bireyler tarafından atılan atıkları otomatik olarak ayırmak için çok katmanlı bir hibrit derin öğrenme sistemi önerilmektedir. Bu sistem, atık görüntüyü yakalamak için yüksek çözünürlüklü bir kamera ve diğer faydalı özellik bilgilerini yakalamak için algılayıcılar kullanır. Çok katmanlı hibrit derin öğrenme sistemi, görüntü özelliklerini çıkarmak için CNN tabanlı bir algoritma ve atıkları geri dönüştürülebilir veya diğerleri olarak sınıflandırmak için görüntü özelliklerini ve diğer özellik bilgilerini birleştirmek için çok katmanlı algılayıcılar yöntemini kullanır. Ayrıca çok katmanlı hibrit derin öğrenme sistemi, manuel olarak etiketlenen ögelere karşı

eğitilir ve doğrulanır, iki farklı test senaryosu altında %90'dan daha yüksek genel sınıflandırma doğruluğu elde eder; bu, yalnızca görüntü girdilerine dayanan referans CNN tabanlı bir yöntemden önemli ölçüde daha iyi performans gösterir (Chu, ve diğerleri, 2018).

Atık sınıflandırması için yapay zekâ kavramını kullanan ilk çalışmalardan birinde, Bayes yöntemi çerçevesinde klasik bir örüntü tanımaya dayanmaktadır. Kaliteli bir matematiksel arka plan kullanılmış fakat bu yöntem, elle çıkarılan özellikler gerektirdiği için iyi bir otomasyon yeteneğinin varlığı tartışma konusu olmuştur (Liu, Sharan, Adelson,, & Rosenholtz,, 2010, June).

Diğer başka bir çalışmada ise makalenin temel amacı bizim çalışmamız ile paralellik göstermekte ve atık malzeme sınıflarını sınıflandırmak için rantabl bir akıllı sistem göstermeyi amaçlamaktadır. Biz ise daha kapsamlı olarak yapılan bu çalışmayı genişletip farklı derin öğrenme modelleri kullanarak ayrışımı yapıp en iyi performans sağlayan metodolojiyi bulmayı hedefliyoruz (Bircanoğlu, Atay, Beşer, Genç, & Kızrak, 2018).

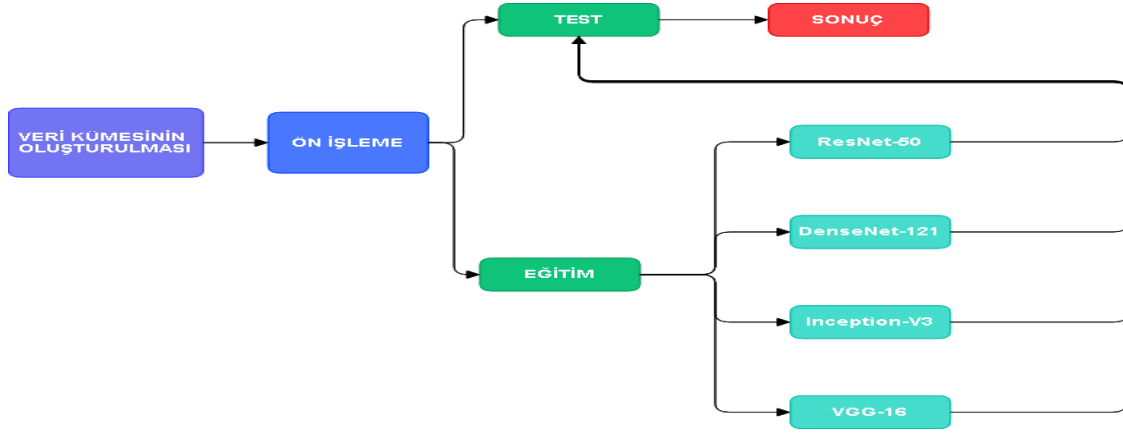
## 2. Materyal

Çalışmamızda kullanıcıların ihtiyaçlarına uygun veri kümelerini bulup yayınlamasına yardımcı olan Kaggle'dan (www.kaggle.com, 2019) temin edilen veri kümesi kullanılmıştır. İçerik olarak veriler, evsel atıklar olan karton, cam, kağıt ve plastikten oluşan 3773 adet görüntüden oluşturulmuştur. Alınan veri setinde eğitim sınıfı için toplam görüntülerin %70'i olan 2638 adet görüntü, test sınıfı için de toplam görüntülerin %30'u olan 1135 adet görüntü ayrılmıştır. Daha sonra bu görüntüler; çalışma zamanı GPU olan, Python programlama dili kullanılan Google Colab Notebook'ta derin öğrenme yöntemleri içinde yer alan ResNet-50, DenseNet-121, Inception-V3, VGG-16 mimarileri kullanılarak eğitime tabi tutulmuştur. Model oluşturmaya, eğitime ve değerlendirmeye yardımcı olan TensorFlow ve Sklearn kütüphanelerinden kod boyunca geniş ve kapsamlı olarak kullanılmaktadır. Kullanılan mimarilerin sonuçları grafiksel olarak deneysel sonuçlar kısmında ayrıntılı olarak paylaşılmıştır. Ayrıca çalışmamızda kullanılan CNN mimarileri, veri kümemiz ve eğitim sonuçları detaylı bir şekilde başlıklar halinde sunulmuştur.

## 3. Metot

İlk olarak Kaggle'da yer alan 'solidwaste' veri kümesinden 3773 adet geri dönüşümü olabilen evsel atıklar alınarak veri kümesi oluşturulmuştur. Veri seti içerisinde karton, cam, plastik, kâğıt resimleri etiketlenmiştir. Farklı dört sınıf bulunan veri kümesinde eğitim için 2638 resim bu da toplam görüntülerin %70'ini oluştururken, test için kalan %30 görüntü yani 1135 resim kullanılmıştır.

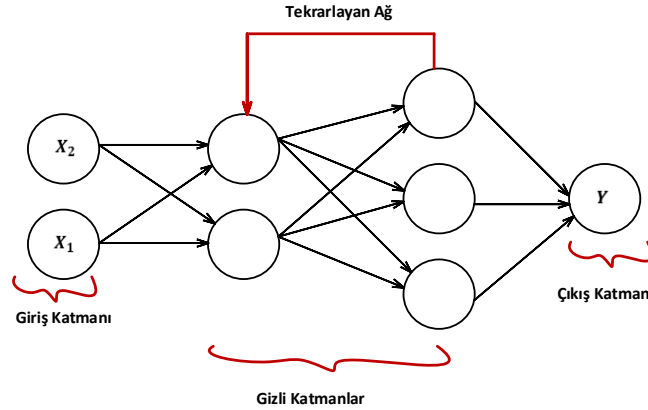
Şekil 1'de çalışmanın iş akış diyagramı gösterilmektedir. Veri kümesinin oluşturulup ön işlenmesinden sonra görüntülerin derin öğrenme ile tespit edilip ayrıştırılmasında CNN kullanıldı. Bunlardan ilki 2015 yılında düzenlenen ImageNet Large Scale Visual Recognition Challenge yarışmasının kazananı ve 152 katmandan meydana gelen Residual Network mimarisi ResNet'tir. Çalışmada kullanılan diğer mimari ise her katmanın doğrudan diğer katmana ileri beslemeli bir şekilde bağlı olduğu 121 katmandan oluşan DenseNet-121 mimarisidir. Çalışmamızda ki başka bir metot ise Tensorflow bu mimarinin son katmanını transfer öğrenimini kullanarak yeni kategoriler için yeniden eğitmelerle ayrıntılı çözümler sağlayan Inception-V3'tür. Son olarak kullanılan metot ise şimdiye kadar yapılan en iyi vizyon modeli mimarilerinden biri olarak kabul edilen VGG-16 mimarisidir. Çalışmamızda bu dört derin öğrenme mimarileriyle eğitime tabi tutulup en doğru metot tespit edilmeye çalışılmıştır.



Şekil 1. İş Akış Diyagramı

### 3.1. Derin Öğrenme

Makine öğrenimi metotları, toplumun modernleşmesi ve ilerlemesi adına büyük işler yapmaktadır. Örneğin webde merak edilen bir kavramın aranmasından, sosyal medyada ki içeriği veya paylaşımları filtrelemeye, e-ticaret sitelerinde bize sunulan teklif veya önerilere kadar geniş bir alan kaplamaktadır. Bunların yanı sıra artan teknoloji ile cebimize kadar giren akıllı cihazlarda aktif kullanılmasıyla da gün geçtikçe hayatımızın büyük kısmında yer almıştır. Makine öğrenmesi ayrıca, bir resimdeki nesneyi tanıyabilirken, konuşulan sözel ifadeleri yazarak metne dönüştürebilmektedir, belli bir haber veya sosyal medya paylaşımını, kullanıcıların ilgi alanlarına göre eşleştirebilir (LeCun, Bengio, & Hinton, 2015). Bu saydığımız uygulamalar "derin" ağ mimarilerinde yatan makine öğrenimi yöntemlerinin bir dalı olan derin öğrenme adı verilen bir teknikler sınıfını kullanır.



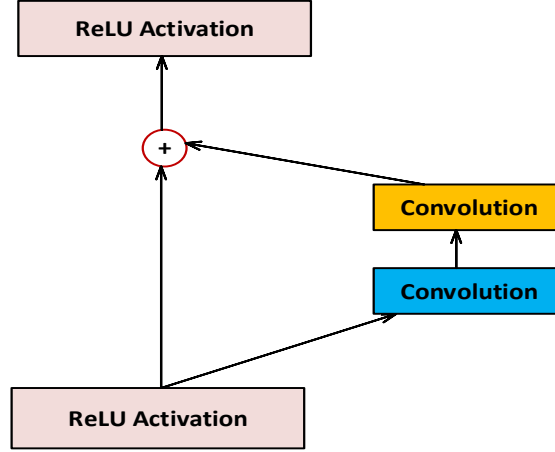
Şekil 2. Tekrarlayan Sinir Ağı Modeli

Derin öğrenme, bir veya birden daha fazla katmandan oluşan hesaplama modelleri ve algoritmalar ile verilerin öğrenilmesine olanak tanır. Derin öğrenme geri yayılım algoritmasını kullanarak büyük veri kümelerinde karmaşık yapıyı tespit eder. Bu yöntemler ile konuşma, resim tanıma veya nesne algılama gibi birçok farklı alanda geliştirilmiş teknolojiyi en üst değerlerine taşımıştır. Derin evrimsel ağlar yardımıyla resim, video, konuşma ve ses işleme gibi durumların tespitinde önemli rol oynarken, tekrarlayan ağlar ile de metin ve konuşma gibi sıralı verilerin bulunması sağlanmıştır (LeCun, Bengio, & Hinton, 2015).

Çalışmamızda ise insan yaşamı ve doğanın korunması açısından büyük öneme sahip olan atık ayrıştırılmasının derin öğrenme ile tespit edilip ayrıştırılması için CNN kullanıldı.


### 3.1.1. ResNet- 50

Residual Network mimarisi ResNet, 2015 yılında düzenlenen ILSVRC (ImageNet Large Scale Visual Recognition Challenge)'in galibi olmuştur (He, Zhang, Ren, & Sun, 2015). Resnet, önceki mimarilerin sahip olduğu kaybolan gradyan probleminden etkilenmeyen ultra derin ağlar tasarlama amacıyla geliştirildi. ResNet, birçok farklı sayıda katmanla geliştirilmiştir; 34, 50,101, 152 ve hatta 1202. Popüler ResNet50, ağın sonunda 49 evrişim katmanı ve 1 tam bağlantılı katman içermektedir.



Şekil 3. ResNet Kalıntı Modülü

ResNet mimarisi iki RELU doğrusal katman arasında bir kez rezidüel değeriyle beslenen bir rezidüel bloktan meydana gelmiştir. Bu şekilde öğrenmenin daha seri bir şekilde oluşacağı tahmin edilmiştir. Şekil 3'te bu rezidüel modüle yer verilmiştir. Resnet mimarisi 152 katmandan meydana gelmektedir. Şekil 4'te ise bu mimari resmedilmektedir.

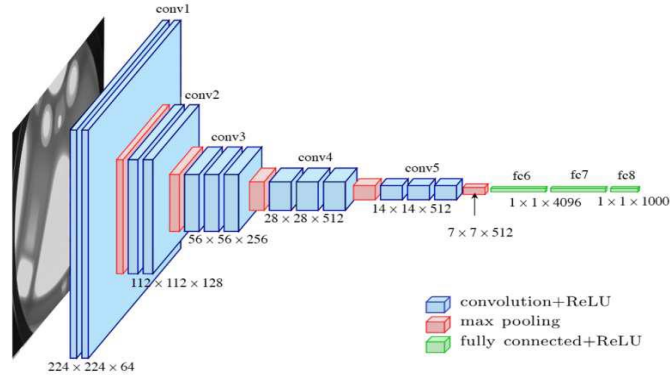


Şekil 4. ResNet ilk 34 katmanının ağ mimarisi (He, Zhang, Ren, & Sun, 2015)

### 3.1.2. VGG-16

VGG-16 (Karen & Zisserman, 2014), 2014 ILSVR yarışmasının ikincisidir. Evrişimli sinir ağı mimarisi olan yöntem şimdiye kadar yapılan en iyi vizyon modeli mimarilerinden biri olarak kabul edilir. VGG-16'nın en ayırt edici özelliği, çok sayıda hiper parametreye sahip olmak yerine, adım 1 ile 3x3 filtrenin evrişim katmanlarına odaklanmaları ve ayrıca adım 2 ile aynı dolgu ve 2x2 filtrenin maxpool katmanını kullanmalarıdır. Mimaride evrişim düzenlemesi ve maksimum havuz katmanları tutarlıdır. Son olarak, iki FC'ye (tamamen bağlı katmanlara) ve çıktı için bir softmax'a sahiptir. VGG-16'daki 16, 16 ağırlıklı katmana sahip olduğu gerçeğini ifade eder.


Genel yapı, bir MaxPool tarafından takip edilen beş küme evrişim katmanından oluşur.



Şekil 5. VGG-16 ağ mimarisi (Ferguson, Ak, Lee, & Law, 2017)

### 3.1.3. DenseNet-121


DenseNet-121’de her katmanın doğrudan diğer katmana ileri beslemeli bir şekilde bağlı olduğu mimaridir. DenseNet mimarilerinin handicap olarak özellik yayılımını sağlamak ve özelliğin tekrardan kullanılması ortamını oluşturarak parametre sayısını düşürmesidir. Şekil 6’da gösterildiği gibi, dört yoğun blok ve üç geçiş katmanıyla toplam 121 katmandan meydana gelir. Sınıflandırma alt ağı,  $7 \times 7$  küresel ortalama havuzlama, 1000D tam bağlantılı katman ve softmax içerir (Li, Shen, Zhou, Wang, & Li, 2020).



Şekil 6. DenseNet-121 mimarisi (Li, Shen, Zhou, Wang, & Li, 2020)

### 3.1.4. Inception-v3

Inception-v3, TensorFlow’da önceden eğitilmiş modellerden biridir. 2015’te yapılan bir çalışmada Inception-v3 modeli, 1000 tanımlayabilen bilgileri içeren ImageNet veri kümeleri üzerinde eğitilmiş ve ImageNet’teki sınıflarda hata oranlarında ciddi bir düşüş sağlamıştır (Szegedy, Vanhoucke, Ioffe, Shlens, & Wojna, 2016). Tensorflow’da ayrıca, Inception’ın son katmanını transfer öğrenimini kullanarak yeni kategoriler için yeniden eğitmelerle ayrıntılı çözümler sağlar (Xia, Xu, & Nan, 2017, June).



Şekil 7. Inception-v3 modelinin ana grafiği (Xia, Xu, & Nan, 2017, June)

#### 4. Deneysel Sonuçlar

Makalemizde, çalışma zamanı GPU olarak ve Python programlama dili kullanılan Google Colab Notebook'ta gerçekleştirilmiştir. Model oluşturmaya, eğitime ve değerlendirmeye yardımcı olan TensorFlow ve Sklearn kitaplıkları kod boyunca yaygın olarak kullanılmaktadır.


Eğitim ve doğrulama doğruluğu ile eğitim ve doğrulama kaybı, aşağıdaki grafikte her dönem için belirlenir. Grafik, zaman içinde kayıptaki azalmayla doğru orantılı olan eğitim doğruluğundaki artışı göstermektedir.

Epoch miktarı, modelin eğitimi sırasında verilerin modelden kaç defa geçme sayısını verir. Bu sayı eğer küçük bir değer ise eğitim zamanı da buna paralel kısa sürecektir ve tam olgunlaşmamış model performansı ortaya çıkabilir. Büyük bir değer olması durumunda eğitim zamanı fazla olabilir ama model gelişimini bitirmiş olabilir. Fakat bu durumda da gereksiz eğitim yapılmış olabilir uygun değer bulunması zorlaşabilir. İdeal olan metot ise büyük bir değer verilip, modelin gelişimini bitirdiği esnada eğitimi sonlandırmak olacaktır. Bu metodun diğer bir adı ise 'early stopping' deniyor. Çalışmamızda ResNet-50, DenseNet-121, Inception-V3, VGG-16 mimarileri 100 epoch sayısınca çalıştırılmıştır.

	loss	accuracy	val_loss	val_accuracy
<b>ResNet50</b>	0.6516	0.7476	0.6614	0.7749
<b>Inception-V3</b>	0.0407	0.9977	0.0033	0.9991
<b>DenseNet-121</b>	0.0264	0.9962	0.0013	0.9991
<b>VGG-16</b>	0.0046	0.9989	0.0018	0.9991


Tablo 1. Dört modelin kayıp, doğrulama, doğrulama kaybı ve doğrulamanın doğruluğu

Tablo 1'de, tüm modellerin kayıp, doğrulama, doğrulama kaybı ve doğrulamanın doğruluğu özetlemektedir. Tabloda da görüldüğü üzere DenseNet-121, Inception-V3, VGG-16 mimarileri 100 epoch sonrasında ki başarı ve hata oranları kapsamında birbirine benzer ve gayet başarılı sonuçlar elde etmiştir. Fakat ResNet-50 mimarisi diğer üç mimariye nazaran daha düşük bir doğruluk ve daha yüksek hata sonucu çıkardı. Bu sonuçlar ResNet-50 mimarisini diğer üç mimariye kıyasla daha başarısız model olma duruma getirdi.




**Şekil 8.** 100 dönem boyunca ResNet-50'in eğitim ve doğrulama setinin doğruluğu ve kaybı

Şekil 8'e bakıldığında ResNet-50 mimarisinin 100 epoch sayısına ulaşmaya kadar gerçekleşen başarı ve hata grafiği gösterilmektedir. Her ne kadar epoch sayısı arttığında başarı oranı artıp hata oranında düşüş sağlansa da diğer üç mimarinin sonuçlarıyla kıyaslandığında başarı olarak bariz bir şekilde altında kaldığı görülmektedir.



**Şekil 9.** 100 dönem boyunca DenseNet-121'in eğitim ve doğrulama setinin doğruluğu ve kaybı


Şekil 9'da ise DenseNet-121 mimarisinin 100 epoch sayısına ulaşmaya kadar gerçekleşen başarı ve hata grafiği gösterilmektedir. 100 Epoch boyunca benzer doğruluk ve hata oranı ile çalışmış gayet başarılı bir sonuç elde etmiştir.



**Şekil 10.** 100 dönem boyunca Inception V3'ün eğitim ve doğrulama setinin doğruluğu ve kaybı



Şekil 10'da ise Inception V3 mimarisinin 100 epoch sayısına ulaşınca kadar gerçekleşen başarı ve hata grafiği gösterilmektedir. 100 Epoch boyunca grafik her ne kadar inişli çıkışlı gözükse de doğruluk ve hata sonuç oranındaki iyi sonuçlar çıkarmış dolayısıyla başarılı bir sonuç elde etmiştir



**Şekil 11.** 100 dönem boyunca VGG-16'nın eğitim ve doğrulama setinin doğruluğu ve kaybı

Şekil 11'de ise VGG-16 mimarisinin 100 epoch sayısına ulaşınca kadar gerçekleşen başarı ve hata grafiği gösterilmektedir. 100 Epoch boyunca benzer doğruluk ve hata oranına sahip sonuçlar çıkarmış hatta bu çalışmanın en başarılı doğruluk ve hata oranını elde etmiştir.

## 5. Sonuç

Atıkların geri dönüştürülmemesi, ayrıştırılmaması veya yanlış şekilde organize edilmesi doğal kaynakların zamanla yok olmasına ve ekonomik olarak büyük kayıplara yol açacaktır. Bununla birlikte yanlış atık yönetimi çevre kirliliği ile birlikte hastalıkların bulaş ve yayılma hızını arttırmaktadır. Sadece bu durumlar bile atıkların geri dönüşümünün ne kadar önemli bir kavram olduğunu göstermektedir. Makine öğrenimi yöntemleri, insanlığın modernleşmesi, ilerlemesi adına büyük işler yapmakta ve yapmaya devam etmektedir. Bu çalışmada ise canlı yaşamı ve doğanın korunması açısından büyük öneme sahip olan atık ayrıştırılmasının derin öğrenme ile tespit edilip ayrıştırılması için CNN kullanıldı. Bu kapsamda çalışmamızda Kaggle'dan alınan bir veri kümesi kullanılarak evsel atıklar olan karton, cam, kâğıt ve plastikten oluşan 3773 adet görüntü kullanıldı. Alınan veri setinde eğitim sınıfı için toplam görüntülerin %70'i, test sınıfı için de toplam görüntülerin %30u ayrılmıştır. Akabinde çalışmamızda, CNN kapsamında ResNet-50, DenseNet-121, Inception-V3, VGG-16 mimarileri evsel atıkların ayrıştırılmasının tespitinde uygulanmıştır.

Inception-V3, DenseNet-12, VGG-16 mimarileri birbirine yakın ve ciddi anlamda başarılı doğruluk payına sahipken VGG-16 mimarisi eğitim boyunca benzer doğruluk ve hata oranına sahip sonuçlar çıkarmış bu çalışmanın en başarılı doğruluk ve hata oranını elde etmiştir. ResNet-50 mimarisi eğitiminde epoch sayısı arttığında başarı oranı artıp hata oranında düşüş sağlansa da diğer üç mimariye göre hem hata hem doğruluk oranına nazaran daha düşük sonuçlar elde etmiştir

Çalışmamız daha geniş, özgün ve büyük veri setleri ile kapsamlı bir şekilde getirilip mimarilerin çalışma düzeylerinin o setler üzerinde de başarıları test edilebilir.

## Kaynakça

- (2019, Temmuz 3). Aralık 7, 2021 tarihinde BBC: <https://www.bbc.com/turkce/haberler-dunya-48851661> adresinden alındı
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., . . . Asari, V. K. (2018). The history began from alexnet: A comprehensive survey on deep learning approaches. *arXiv preprint arXiv:1803.01164*.
- Beliën, J., Boeck, L. D., & Ackere, J. V. (2011). Municipal Solid Waste Collection Problems: A Literature Review.
- Bircanoğlu, C., Atay, M., Beşer, F., Genç, Ö., & Kızrak, M. (2018). RecycleNet: Intelligent waste sorting using deep neural networks. *In 2018 Innovations in Intelligent Systems and Applications (INISTA)*, (s. 1-7).
- Chu, Y., Huang, C., Xie, X., Tan, B., Kamal, S., & Xiong, X. (2018). Multilayer hybrid deep-learning method for waste classification and recycling. *Computational Intelligence and Neuroscience*.
- Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 409-445.
- El Naqa, I., Haider, M. A., Giger, M. L., & Ten Haken, R. K. (2020). Artificial Intelligence: reshaping the practice of radiological sciences in the 21st century. *The British journal of radiology*.
- Evans, G. W. (2017). *Artificial intelligence: where we came from, where we are now, and where we are going*.
- Ferguson, M., Ak, R., Lee, Y. T., & Law, K. H. (2017). Automatic localization of casting defects with convolutional neural networks. *In 2017 IEEE international conference on big data (big data)*, (s. 1726-1735).
- Gulec, N., Gunal, B., & Erler, A. (2001). Assessment of soil and water contamination around an ash-disposal site: a case study from the Seyitömer coal-fired power plant in western Turkey.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. *In Proceedings of the IEEE international conference on computer vision*, (s. 1026-1034).
- Karen, S., & Zisserman, A. (2014). Deep Convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 436-444.
- Li, X., Shen, X., Zhou, Y., Wang, X., & Li, T. Q. (2020). Classification of breast cancer histopathological images using interleaved DenseNet with SENet (IDSNet). *PloS one*, 15(5).
- Liu, C., Sharan, L., Adelson, E., & Rosenholtz, R. (2010, June). Exploring features in a bayesian framework for material recognition. *In 2010 IEEE computer society conference on computer vision and pattern recognition*, (s. 239-246).
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (s. 2818-2826).
- Themelis, N. J. (2002). Integrated management of solid wastes for New York City. *In North American Waste-to-Energy Conference*, (s. 69-86).
- Turing, A. M. (1950). *Computing machinery and intelligence*. Cambridge: MA: MIT Press.
- Wikipedia. (2021, Ekim 24). Aralık 7, 2021 tarihinde <https://tr.wikipedia.org/wiki/ENIAC> adresinden alındı
- www.kaggle.com. (2019, Kasım 12). Aralık 7, 2021 tarihinde <https://www.kaggle.com/imrshu/solidwaste> adresinden alındı
- Xia, X., Xu, C., & Nan, B. (2017, June). Inception-v3 for flower classification. *In 2017 2nd International Conference on Image, Vision and Computing (ICIVC)*, (s. 783-787).
- Ziadat, A., & Mott, H. (2005). Assessing solid waste recycling opportunities for closed campuses. *Management of Environmental Quality: An International Journal*, 250-256.