



**ÇOCUKLARA GERİ DÖNÜŞÜM BİLİNCİ KAZANDIRMAK İÇİN
GÖMÜLÜ DERİN ÖĞRENMEYE SAHİP BİR ATIK KUTUSU
TASARLAMAK**

Onur KARA

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

TEMMUZ 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Onur KARA

10/07/2023

ÇOCUKLARA GERİ DÖNÜŞÜM BİLİNCİ KAZANDIRMAK İÇİN GÖMÜLÜ DERİN ÖĞRENMEYE SAHİP BİR ATIK KUTUSU TASARLAMAK

(Yüksek Lisans Tezi)

Onur KARA

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2023

ÖZET

Günümüzde atıkların doğru sınıflandırılmasındaki en büyük sorunlardan birisi insanların geri dönüşüm bilincine sahip olmamasıdır. Bu bilincin çocukluk döneminde insanlara kazandırılması için anaokullarında ya da ilkokullarda eğitim verilmekte ve çocukların kendileri için tasarlanmış geri dönüşüm kutularını doğru kullanmaları beklenmektedir. Bu çalışmada, çocuklarda çevre bilincini artırmak ve geri dönüşüm kutularını daha etkin kullanmaları için çocukları eğitmek amacıyla akıllı ve gömülü sisteme sahip bir geri dönüşüm kutusu tasarlanmıştır. Bu akıllı geri dönüşüm kutusu, Raspberry Pi 4B işlemci tarafından kontrol edilen bir görüntü işleme sistemine sahiptir. 4 hazneli ve kapaklı geri dönüşüm kutusunda çocuk herhangi bir hazne kapağına atık bıraktığında sistem çalışmaya başlar. Kameralar yardımıyla atık görüntüler elde edilir ve eğitilmiş derin sinir ağı ile sınıflandırılır. Çocuğun atığı doğru hazneye mi yoksa yanlış hazneye mi attığı belirlenir. Geri dönüşüm kutusuna konulan LCD ekran ile eğlenceli içeriklerle yönlendirmeler yapılarak çocuğun atıkları doğru hazneye koymasına sağlanır. Atık görüntülerin sınıflandırılması için DenseNet-201, NasNetMobile ve VGG16 modellerinden oluşan önceden eğitilmiş bir MultiNet sinir ağı kullanılmaktadır. Bu çalışmada önceden eğitilmiş derin sinir ağlarının ilgili probleme göre eğitiminin devam ettirilmesine imkan veren transfer öğrenme yöntemi kullanılmıştır. Çocukların okullarda kullanabilecekleri 4 tür atıktan (kağıt, plastik, cam, metal) oluşan toplam 1075 adet görsel içeren yeni bir veri seti oluşturulmuştur. Bu çalışma sonucunda 7-kat çapraz doğrulama kullanılarak %98'lik sınıflama doğruluğu elde edilmiştir.

Bilim Kodu : 90541

Anahtar Kelimeler : Derin öğrenme, gömülü sistem, görüntü tanıma, atıkları sınıflandırma, geri dönüşüm farkındalığı, çocukların eğitilmesi

Sayfa Adedi : 61

Danışman : Doç. Dr. Ayşe DEMİRHAN

DESIGNING A WASTE BIN WITH INSTALLED DEEP LEARNING TO GIVE
RECYCLING AWARENESS TO CHILDREN

(M. Sc. Thesis)

Onur KARA

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2023

ABSTRACT

Today, one of the biggest problems in the correct classification of waste is that people do not have the awareness of recycling. In order to bring this awareness to people in childhood, education is given in kindergartens or primary schools and children are expected to use the recycling bins designed for them correctly. In this study, a smart and embedded recycling bin was designed in order to increase environmental awareness in children and to train children to use recycling bins more effectively. This smart recycle bin has an image processing system controlled by the Raspberry Pi 4B processor. The system starts to work in the 4-compartment and lidded recycling bin when the child leaves garbage on any compartment cover. With the help of cameras, waste images are obtained and classified by a trained deep neural network. It is determined whether the child puts the trash in the correct bin or the wrong bin. With the LCD screen placed in the recycling bin, the child is guided to put the waste in the right compartment by making directions with entertaining content. A pre-trained MultiNet neural network consisting of DenseNet-201, NasNetMobile and VGG16 models is used for classification of waste images. For this study, the transfer learning method was used while retraining the pre-trained deep neural network. A new data set containing a total of 1075 images consisting of 4 types of waste (paper, plastic, glass, metal) that children can use in schools was created. As a result of this study, 98% classification accuracy was obtained by using 7-fold cross validation.

Science Code : 90541

Key Words : Deep learning, embedded system, image recognition, waste classification, recycling awareness, education of children

Page Number : 61

Supervisor : Assoc. Prof. Ayşe DEMİRHAN

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde, iki yıl boyunca değerli bilgilerini bizlerle paylaşan, kullandığı her kelimenin hayatıma kattığı önemini asla unutmayacağım saygıdeğer danışman hocam; Doç. Dr. Ayşe DEMİRHAN'a ve çalışma süresince tüm zorlukları benimle göğüsleyen ve hayatımın her evresinde bana destek olan değerli eşim Elif KARA'ya sonsuz teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	viii
ŞEKİLLERİN LİSTESİ	ix
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. MATERYAL VE YÖNTEM.....	9
2.1. Veri Seti ve Veri Ön İşleme	9
2.2. MultiNet Modeli	11
2.3. DenseNet Modeli.....	13
2.4. NasNetMobile Modeli	14
2.5. VGGNet Modeli	15
2.6. İnce Ayar Süreci.....	16
2.7. Gömülü Sisteme Sahip Geri Dönüşüm Kutusunun Tasarımı ve Çalışma Prensibi	17
2.8. Raspberry Pi 4B'nin Kurulumu ve Kullanılan Tüm Kodlar	26
3. DENEYSEL SONUÇLAR.....	43
4. TARTIŞMA.....	49
5. SONUÇ VE ÖNERİLER	53
KAYNAKLAR	55
ÖZGEÇMİŞ	60

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Veri sayısını arttırmak için kullanılan parametreler	10
Çizelge 2.2. Veri seti bilgileri	11
Çizelge 3.1. K-kat çapraz doğrulama sonuçları.....	45
Çizelge 3.2. Eğitim parametreleri	46
Çizelge 3.3. 6 farklı önceden eğitilmiş model kullanılarak elde edilen sonuçlar	47
Çizelge 4.1. MultiNet'in diğer yöntemlerle karşılaştırılması	51

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Veri setinden örnek resimler	9
Şekil 2.2. Veri arttırma yöntemi sonrasında oluşan örnek görüntüler	10
Şekil 2.3. MultiNet yapısı.....	12
Şekil 2.4. DenseNet yapısı.....	13
Şekil 2.5. NasNet yapısı	14
Şekil 2.6. VGGNet yapısı.....	15
Şekil 2.7. 3D modellenmiş geri dönüşüm kutusu	17
Şekil 2.8. Geri dönüşüm kutusunun önden görünümünün 2D çizimi.....	19
Şekil 2.9. Kesit 1'den bakıldığında görülen.....	19
Şekil 2.10. Kesit 2'den bakıldığında görülen.....	20
Şekil 2.11. Esnek şerit led ve güç sağlayan 60 watt trafo	21
Şekil 2.12. Servo motor örnek Raspberry Pi bağlantısı	21
Şekil 2.13. Kamera çoklayıcı modül ve 4 adet Raspberry Pi kamera örnek bağlantısı .	22
Şekil 2.14. Mesafe sensörünün Raspberry Pi'ye örnek bağlantısı	23
Şekil 2.15. Gömülü sisteme sahip geri dönüşüm kutusu.....	24
Şekil 2.16. Geri dönüşüm kutusunun çalışma prensibi	25
Şekil 2.17. Raspberry Pi'nin pin dizilimi.....	26
Şekil 2.18. Tez çalışmasında Raspberry Pi üzerinde kullanılan pinler	27
Şekil 2.19. Raspberry Pi imager arayüzü	28
Şekil 2.20. Raspberry Pi kurulum ekranı	28
Şekil 2.21. Python 3,7 versiyonunun kurulumu için kullanılan kodlar.....	29
Şekil 2.22. Python'a kütüphane eklenmesi için kullanılan kodlar	30
Şekil 2.23. Python kodlarında kullanılması zorunlu olan kodlar.....	30

Şekil	Sayfa
Şekil 2.24. Servo motor pinlerinin tanımlanmasını sağlayan kodlar	30
Şekil 2.25. Mesafe sensörlerini kontrol etmek için pinleri tanımlayan kodlar	31
Şekil 2.26. Mesafelerin sürekli olarak kontrol edilmesini sağlayan kodlar	32
Şekil 2.27. Mesafe sensörlerinin atık konulduğunun tespitini sağlayan kodlar.....	33
Şekil 2.28. Mesafe sensörlerinin haznelerin dolduğunun tespitini sağlayan kodlar	34
Şekil 2.29. Atık sınıflandırılmasını ve servo motorları kontrol etmeyi sağlayan kodlar	35
Şekil 2.30. Kameraların çalışması için kullanılan kod.....	35
Şekil 2.31. Kameralardan atık görüntüsü alan ve kaydedilmesini sağlayan kodlar.....	36
Şekil 2.32. Eğitici videonun oynatılması için kullanılan kodlar.....	37
Şekil 2.33. Doğru tercih sonrasında video oynatılmasını sağlayan kodlar	37
Şekil 2.34. Atık haznelerinin dolduğunu tespit edebilmek için kullanılan kodlar.....	38
Şekil 2.35. Tüm sistemi kontrol eden kodlar ve bir klasörde toplanması	39
Şekil 2.36. Raspberry Pi'ye yapılan tüm bağlantılar	40
Şekil 2.37. Geri dönüşüm kutusunun içerisinde son hali.....	41
Şekil 2.38. Kamera ve atık algılamak için kullanılan mesafe sensörü.....	42
Şekil 3.1. Multinet modelinin katmanları ve parametre sayıları	43
Şekil 3.2. MultiNet eğitim ve doğrulama doğrulukları, eğitim ve doğrulama kayıpları	44
Şekil 3.3. K-kat çapraz doğrulama sonuçlarının grafiği.....	45
Şekil 3.4. Test görüntülerinden doğru ve yanlış sınıflandırılan örnekler.....	48
Şekil 4.1. Aşırı öğrenme durumunda ortaya çıkan doğruluk ve kayıp grafiği	50

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

GB

Gigabayt

GHz

GigaHertz

Kısaltmalar

Açıklamalar

CNN

Convolutional Neural Network

DCNN

Deep Convolutional Neural Network

GPS

Global Positioning System

GPU

Global Photographic Union

ILSVRC

ImageNet Large Scale Visual Recognition Competition

IR

Infrared

LCD

Liquid Crystal Display

LDR

Light Dependent Resistor

LED

Light Emitting Diode

RAM

Random Access Memory

VGG

Visual Geometry Group

YOLO

You Only Look Once

1. GİRİŞ

Son 12 yılda dünya nüfusunun yaklaşık 1 milyar artması [1] buna paralel olarak dünya üzerindeki atık madde miktarının da artmasına neden olmuştur [2]. Bu atıkların yeterince geri dönüştürülememesi önemli çevre kirliliğine ve ekonomik zararlara neden olmaktadır. Dünyada ülkelerin ürettiği atık miktarı yılda 1,3 milyar ton olup, 2100 yılında bu sayının 4 milyar tona ulaşacağı tahmin edilmektedir [3]. Büyük miktardaki atığın yanı sıra doğadaki atığın yok olma süresi de oldukça uzundur: plastik 1000 yıl, cam 4000 yıl, kola kutusu 10 yıl, kâğıt 3 ay, pet şişe 400 yıl, metal 100 yıl sonra yok olmaktadır [4].

Atıkların doğada uzun süre kalması hayvanların yaşam ortamlarını da kötü etkilemektedir. Hayvanlar plastiğe takılıp dolanabilmekte yâda plastiği yiyerek sağlıkları olumsuz etkilenmekte ve hatta ölmelerine sebep olmaktadır. Hatta yapılan bir araştırmada deniz hayvanlarının plastiğin kokusunu yiyecek kokusuna benzeterek yedikleri ortaya çıkmıştır [5]. Çevre kirliliği yalnızca hayvan hayatını değil aynı zamanda insan hayatını da riske sokmaktadır. Çevredeki atıklardan toprağa ve su kaynaklarına sızan kirli sular insan bedenine bir şekilde girmekte ve hastalıklara sebep olmaktadır. Toprağın kirlenmesiyle birlikte topraktan elde edilen gıdaların tam olarak yetişmemesi yâda mahsullerin az olması da çevre kirliliğinin başka olumsuz etkileridir ve insan hayatını olumsuz etkilediği açıkça görülmektedir.

Atık maddenin hızla artması çevresel zararların yanı sıra ekonomik zararlara da sebep olmaktadır. Atıkların geri dönüştürülmemesinin ekonomik zararları incelendiğinde, kullanılan her nesne bir hammadde olarak yapılmaktadır ve insan nüfusunun artmasıyla birlikte hammadde ihtiyacı da artmaktadır. Geri dönüştürülmeyen atıklar, hammadde kaybına yol açmaktadır. Türkiye’de 2016 yılında İstanbul Ticaret Odası’nın yaptığı çalışmaya göre sadece kâğıt ithali için harcanan para 2.5 milyar dolardır [6]. Atıkların geri kazanımıyla çok büyük gelir elde edilebileceğinden Avrupa’daki ülkeler hammadde savaşı vermekte ve atık ithali yapmaktadırlar. Hatta Avrupa, Türkiye’nin 3 katı daha fazla atık ithal etmekte ve bunları hammadde olarak kullanmaktadırlar [7].

Atıkların geri kazanımının önemini rakamlarla ve örneklerle anlatmak gerekirse; 25 kullanılmış plastik şişeden bir ceket üretilebilir, 1 ton kâğıt kazanımıyla 34 kişinin oksijen ihtiyacını sağlayan 17 yetişkin ağaç korunabilir, camın geri dönüşümüyle su tüketiminde

%50 azalma sağlanabilir [8]. Profesyonel bazı şirketlerin atık geri kazanımı konusunda elde ettikleri gelir ile ilgili araştırma yapan New Jersey Waste Wise Business Network'un verilerine göre, aralarında Lockheed Martin şirketinin de bulunduğu birçok büyük şirket yılda en az 145 bin dolar ile 400 bin dolar arasında geliri atık geri kazanımından elde etmiştir [9].

Ülkemizdeki geri dönüştürülebilir atıkların geri kazanım miktarları Çevre ve Şehircilik Bakanlığının verilerine göre şu şekildedir: 2020'de geri dönüşümü sağlanan 1 milyon 836 bin 279 ton ambalaj atığıyla ekonomiye 2 milyar 188 milyon 739 bin lira katkı sağlanmıştır [10]. Türkiye'de kâğıt atıkların %12'si, metal atıkların %3'ü, cam atıkların %5'i geri dönüştürülebilmektedir [11]. Dünya genelindeki ülkelerde atık geri kazanım oranlarına bakılırsa, 2018 verilerine göre Avrupa Birliği ülkelerindeki geri kazanım seviyelerinin (en çok Almanya: %67) [12] Türkiye'dekinden (%12) [13] çok daha yüksek seviyelerde olduğu görülebilir. Geri dönüşümün olumlu etkilerinin birden çok olması sebebiyle geri kazanım oranının yükseltilmesi için çalışmalar yapılması ve temel problemlerin çözülmesi gerekmektedir.

Atıkların geri dönüştürülebilmesi için 2 yöntem vardır. Bunlardan birincisi atıkların toplandıktan sonra ayrıştırılmasıdır ancak bu yöntem maliyetli ve risklidir. Çünkü atık toplama merkezlerinde yapılan bir araştırmaya göre kullanılan insan gücünün fazla olması ve insanların hata yapma olasılığı nedeniyle atıkları doğru bir şekilde sınıflandırmak tam olarak mümkün değildir [14]. Bunu insanlar yerine robot kolların yapması durumunda da robot kolların maliyeti yüksek olduğundan tercih edilememektedir [15].

İkinci yöntem, atıkların ayrıştırılmış olarak toplanmasıdır. Bu yöntemi gerçekleştirmek için geri dönüşüm kutularına ihtiyaç vardır. Literatürde günümüzde yaygın olarak bulunan geri dönüşüm kutularının doğru kullanılmadığını gösteren çalışmalar bulunmaktadır [16, 17]. Bu sorunu çözmek için atıkları kendi içinde ayrıştıran geri dönüşüm kutuları kullanılabilmektedir [18]. Barkod okuyucu yöntemi kullanılarak, plastik ve teneke kutuların geri dönüşüm kutularında doğru hazneye atılması durumunda insanlara para ödenmesi veya kullanılabılır puanlarla ödüllendirme yapılması gibi çalışmalar da bulunmaktadır [19]. Bu atık kutularının yaygın olarak kullanılamamasının sebepleri maliyetlerinin yüksek olması, atık kutularında meydana gelebilecek arızaların takip edilerek düzeltilmesi gerekmesi ve insanların bu atık kutularına zarar verme olasılığıdır.

Atıkların geri kazanılması ve sınıflandırılmasının önündeki en büyük problemlerden biri, insanların geri dönüşüm kutularına önem vermeden atıklarını atmasıdır. Günümüzde kullanılan geri dönüşüm kutularının atık türüne göre boyanması ve üzerlerine her hazneye atılması gereken atığın cinsi yazılmasına rağmen atıklar doğru hazneye atılmamaktadır. Bunun sebebi, insanların bu konuda eğitim almaması ve geri kazanımın önemini tam olarak bilmemesidir. İnsanlara ilköğretim döneminde çevre bilinci ve çevre eğitimi vermenin gerekliliği bazı makalelerde de yer almaktadır [20].

Eğitim, geri dönüşümü artırmak için kritik öneme sahiptir ve geri dönüşüm kutularının doğru kullanılmaması, başarılı atık yönetiminin önündeki en önemli engellerden biridir. Önceki çalışmalar, çocukların geri dönüşüm eğitiminin, ebeveynlerinin yaşam tarzlarını değiştirmede etkili olabileceğini, geri dönüşüme katılımı artırdığını ve artık atık miktarını azalttığını kanıtlamıştır [21, 22]. İngiltere merkezli bir çalışma, okullarda çocuklara verilen atık eğitiminin ebeveynlerinin yaşam tarzlarına etkisini araştırmıştır. 39 okulda 6705 çocukla çalışmış ve öğrencilerin atık azaltma konusundaki bilgi ve anlayışlarındaki artışın geri dönüşüm oranlarını %8,6 artırdığını göstermişlerdir. Seçilen örnek okullar için geri dönüşüme artan katılım ve artan geri dönüşüm tonajları ile azalan artık atık seviyeleri tespit edilmiştir [21].

Bu çalışmalar dikkate alındığında atık oluşumunun kaynağı olan geri dönüşüm sorununun insan eliyle çözülmesi en ucuz ve etkili yöntem olarak görülmektedir. Bunun için de insanların çocukluktan itibaren geri dönüşüm bilincine sahip olmaları sağlanmalıdır. Atıkların geri dönüşüm oranının düşük olması, anaokulu/ilkokul dönemlerinde verilen çevre bilinci ve çevre eğitiminin yetersiz olmasından kaynaklanmaktadır [23].

Anaokullarında/ilkokullarda çocuklara geri dönüşüm bilincini kazandırmak için bazı uygulamalı dersler verilmektedir. Öncelikle öğretmenler tarafından geri dönüştürülebilir atıklar anlatılmakta, atık türleri örneklerle gösterilmekte [24] ve çevre bilincinin çocuklar için önemini anlatan oyunlar hazırlanmaktadır [25]. Daha sonra geri dönüştürülebilir atıkların ayrıştırılarak toplandığı ve atık geri kazanım tesislerinde aşamalardan geçtiği anlatılmakta ve bu tesislere geziler düzenlenmektedir. Çocuklara verilen bu eğitimin ardından okullarda geri dönüşüm kutuları tasarlanmakta ve çocukların öğrendiklerini uygulamaları beklenmektedir.

Çocukların geri dönüşüm kutularını doğru kullanmaları için Milli Eğitim Bakanlığı tarafından yürütülen bazı çalışmalar da bulunmaktadır. Örnek olarak çocuklara geri dönüşüm sembolleri [26] gösterilerek öğretilmekte ve ardından atıkların yere atılması durumunda atık kutularının üzüleceği söylenmektedir. Daha sonra çocukların geri dönüşüm kutusuyla kendilerini özleştirmeleri sağlanarak atıkları geri dönüşüm kutusuna atmaları amaçlanmaktadır [27]. Bu tür etkinliklerin en büyük dezavantajı çocuklara o an verilen eğitimin zamanla unutulması ve geri dönüşüm kutularını yanlış kullanmalarına engel olacak bir geri dönüşüm kutusunun bulunmamasıdır. Çocuklar genellikle hangi tür atığı hangi hazneye atacaklarını anlayamadıkları için geri dönüşüm kutusunu doğru kullanmakta zorlanmaktadırlar.

Literatürde çocuklara atık türlerini öğretmek için kullanılan yapay zekâ uygulamaları bulunmaktadır. Bir çalışmada, TensorFlow yardımıyla görüntü tanıma yeteneğine sahip bir robot tasarlanmıştır [28]. Bu robot atığın geri dönüştürülebilir olup olmadığını tespit etmekte ve bu bilgiyi çocuğa vermektedir. Ayrıca okulda çocukların atığın türünü bilmeden robotun üzerindeki butona basarak atığı robota göstermesi ve robotun atığın türünü söylemesi ile ilgili bir çalışma da bulunmaktadır [29].

Başka bir çalışmada, robotların ve çocukların atığın türünü tahmin etmek için yarıştığı bir oyun oynanmaktadır. Çocuğa önce atığın türü öğretmen tarafından sorulur ve doğru tahmin ederlerse öğretmen tarafından çocuğa 1 puan verilir, ardından atık robota gösterilir ve doğru tahmin ederse robota da 1 puan verilir [30]. Bu tür çalışmaların dezavantajı, çocukların atığın türünü bilmesine rağmen, atıkları yanlış bir şekilde geri dönüşüm kutusuna atmasını engelleyecek bir mekanizmanın olmamasıdır.

Bu çalışmada önerilen eğitici geri dönüşüm kutusu tasarımında atıkları sınıflandırabilmek için derin sinir ağı kullanılmıştır. Atık sınıflandırması ile ilgili birçok derin sinir ağı çalışması bulunmaktadır. RecycleNet adlı bir çalışmada TrashNet veri seti kullanılarak atıkları 6 farklı sınıfa (kâğıt, cam, plastik, metal, karton, atık) ayırmak için transfer öğrenme yöntemi içeren ve içermeyen derin modeller kullanılmıştır. İlgili çalışmada, Inception-v4 kullanarak transfer öğrenme olmadan test doğruluğunu %90 olarak bulunmuş ve hazır bir DenseNet121 ağı kullanıldığında %95 test doğruluğu elde edilmiştir [31]. Ahmad ve arkadaşları tarafından yapılan başka bir çalışmada erken ve geç füzyon yöntemleri birlikte

kullanılarak ve TrashNet veri seti kullanılarak atıkları 6 farklı sınıfa (kâğıt, cam, plastik, metal, karton, atık) ayırmak amaçlanmıştır ve %94,58 doğruluk oranı elde edilmiştir [32].

Wang ve arkadaşları TrashNet veri setini kullanarak transfer öğrenme yöntemi ile atıkları 6 farklı sınıfa ayırmak için bir genetik algoritma kullanmışlardır ve DenseNet121'deki tam bağlı katmanı optimize ederek %99,6 doğruluğa ulaşmışlardır [33]. 2021 yılında yapılan başka bir çalışmada, yine TrashNet veri seti kullanılarak transfer öğrenme yöntemi ile atıkları 6 farklı sınıfa ayırmak için ResNet18 modeline self monitoring modülü eklenerek %95,87 doğruluk elde edilmiştir [34]. Altıkat ve arkadaşları 400 görüntüden oluşan kendi oluşturdukları veri setini kullanarak transfer öğrenme yöntemi ile atıkların 4 farklı sınıfa (kâğıt, cam, plastik, organik) ayrılması için DCNN modeli kullanılmış ve %89 doğruluk oranına ulaşmışlardır [35].

Atıkları kendi içinde sınıflandıran geri dönüşüm kutuları ile ilgili çalışmalar da bulunmaktadır ve bu çalışmalarda da derin sinir ağları kullanılmıştır. 2018 yılında yapılan bir çalışmada metal, kâğıt ve plastiği kendi içinde sınıflandıran bir atık kutusu tasarlanmıştır. Metali sınıflandırmak için metal endüktif yakınlık sensörü ve kâğıt ve plastiği sınıflandırmak için de LED ve LDR yöntemleri kullanılmıştır. Atıkların ayrıştırılmasını sağlamak için servo motorlar ve mikro denetleyiciler kullanılmıştır [36]. 2021 yılında yapılan bir diğer çalışmada ise metal, kâğıt ve cam atık kutusunda sınıflandırılmaya çalışılmıştır. Malzemenin varlığını ve türünü belirlemek için kızılötesi sensörler ve iki yakınlık sensörü, bir endüktif sensör ve bir kapasitans sensörü kullanılmıştır. Ayrıca her hazne, konteynerdeki atık seviyesini tespit etmek için bir IR sensörü içermektedir [37].

2022 yılında yapılan bir çalışmada teneke kutu, kâğıt, cam ve diğer kategoriler atık kutusu içinde sınıflandırılmaya çalışılmıştır. Bu çalışmada geri dönüştürülebilir atıkları tespit etmek ve sınıflandırmak için Raspberry Pi'de YOLO ile gerçek zamanlı nesne tespiti yapılmıştır ve sınıflandırma doğruluğu %91 olmuştur. Atık kutusundaki haznelerin kapasitesini takip etmek için ultrasonik sensörler kullanılmıştır ve atık kutusunun koordinatlarını bulmak için GPS kullanılmıştır [38].

2022 yılında yapılan bir diğer çalışmada ise atık kutusunda karton, cam, metal, kâğıt, plastik, atık kategorileri sınıflandırılmaya çalışılmıştır. Veri seti sindirilebilir ve sindirilemez olarak adlandırılan iki geniş kategoriye ayrılmıştır. ResNet34 modeli, VGG-16 ve AlexNet gibi

modellerle kıyaslandığında %95 ile en iyi doğruluğu vermiştir. Raspberry Pi atık kutusunu kontrol etmek için kullanılmıştır [39]. Bu çalışmada önerilen eğitici geri dönüşüm kutusunun diğer çalışmalardan farkı, atıkları kendi içinde otomatik olarak sınıflandıracak bir atık kutusu yerine, atığın sınıflandırılması, atığın geri dönüşüm kutusunun doğru haznesine konup konulmadığının belirlenmesi, çocuğun atığı yanlış hazneye koymasının engellenmesi ve atığı doğru hazneye koymasına rehberlik ederek eğitilmesi amaçlanmaktadır.

Tez çalışmasında kullanılan MultiNet derin sinir ağı önceden eğitilmiş 3 modelden (DenseNet-201, NasNetMobile ve VGG16) oluşmaktadır ve daha önce meme kanseri tespiti için kullanılmıştır [40]. MultiNet yöntemi, karmaşık çalışmalarda bile yüksek doğruluk değerine sahiptir ve 4 tip meme kanserini başarıyla sınıflandırmıştır. Önceden eğitilmiş derin sinir ağı yeniden eğitilirken, görüntü sınıflandırma görevi için transfer öğrenme yöntemi kullanılmaktadır. Bu çalışma kapsamında çocukların okullarda kullanabilecekleri 4 tür atıktan (kâğıt, plastik, cam, metal) oluşan toplam 1075 adet görsel içeren bir veri seti oluşturulmuştur. Atık görüntülerinin sınıflandırılmasında daha önce kullanılmayan MultiNet derin sinir ağı kullanılarak %98'lik doğruluk 7-kat çapraz doğrulama yöntemiyle elde edilmiştir.

Önerilen geri dönüşüm kutusu, çocuklara atık türlerini öğretmeyi amaçlayarak, çocukların atığı kutunun yanlış haznesine atmalarını engellemektir. Çocuğa doğru hazneyi göstermek için LCD ekranda eğitici ve yol gösterici müzikli videolar gösterilmektedir. Bu geri dönüşüm kutusunda 4 tip atık (kâğıt, plastik, cam, metal) haznesi ve Raspberry Pi 4B işlemci kullanan gömülü görüntü işleme sistemi bulunmaktadır. Haznelerin kapakları servo motorlar ile açılıp kapatılmaktadır. Hazneye konulan atıkların kameralar yardımıyla görüntüsü alınmakta ve eğitilmiş bir derin sinir ağı olan MultiNet yardımıyla atıklar sınıflandırılmaktadır.

Çocuğun atığı hangi hazneye koyduğu sensörler yardımıyla öğrenilmektedir. Mesafe ölçen sensör yardımıyla atığın hangi hazneye koyulduğu tespit edilmektedir. Atığın türü de Pi kamera ile alınan görüntünün derin sinir ağı yardımıyla sınıflandırılması ile belirlenmektedir. Çocuğun atığı doğru hazneye koyup koymadığı atık türü ve hazne karşılaştırılarak tespit edilmektedir. Çocuk atığı yanlış hazneye koymuşsa, LCD ekranda atığın cinsine göre eğitici video oynatılır ve çocuk doğru hazneyi bulana kadar atığın hazneye düşmesi engellenmektedir. Çocuk atığı doğru hazneye koyduğunda alkış sesi

duyulmaktadır ve çocuk LCD ekranda oynatılacak videolar yardımıyla övülmektedir. Sensörler yardımıyla haznelerin doluluk durumu değerlendirilmektedir. Eğer haznenin boşaltılması gerekiyorsa LCD ekranda uyarı verilmekte ve hazne boşaltılana kadar bu hazneye atık atılması engellenmektedir.

Bu tez çalışmasıyla önerilen geri dönüşüm kutusu ile çocuklara daha etkili bir şekilde geri dönüşüm bilinci kazandırılacaktır. Çünkü atığın türüne göre yanlış hazneye atık atılması önlenerek ve çocuklara atığın türüyle ilgili bilgi verilecektir. Hem çocuklar atık türlerini öğrenecek hem de atıkları doğru hazneye atmaları alışkanlık haline gelecektir. Çocukların atığı doğru hazneye koymaları sonucunda karşılaşacakları takdir edici ifade sayesinde iyi bir şey yaptıklarını anlayıp tekrar tekrar doğru yapmayı isteyeceklerdir. Aynı zamanda öğretmen gözetiminde olma zorunluluğu olmadan geri dönüşüm kutusunu istedikleri zaman doğru biçimde kullanabileceklerdir.



2. MATERYAL VE YÖNTEM

2.1. Veri Seti ve Veri Ön İşleme

Çocukların okullarda kullanabilecekleri kâğıt, plastik, cam ve metal atıkların görüntüleri geri dönüşüm kutusundaki hazne kapaklarına konularak Raspberry Pi kamera versiyon 2.1 kullanılarak elde edilmiştir. Toplam 258 adet görüntü .jpg formatında ve 2592x1944 piksel olarak kaydedilmiştir. Veri arttırma yöntemi kullanılarak .img formatında ve 224x224 piksel boyutunda toplam 1075 adet görüntü elde edilmiştir. Şekil 2.1'de veri setini oluşturan farklı atık türlerinin örnek görüntüleri verilmiştir.



Şekil 2.1. Veri setinden örnek resimler

Görüntüleri sınıflandırmak için derin öğrenme modeli kullanılacağından ve derin öğrenme yöntemleri daha fazla veri ile daha başarılı öğrenme gerçekleştirdiği için görüntüler üzerinde veri arttırma işlemi uygulanmıştır. Kullanılan veri artırma yöntemlerinin detayları Çizelge 2.1'de verilmiştir. Şekil 2.2'de ise veri arttırma yöntemi sonrasında oluşan örnek görüntüler verilmiştir.

Çizelge 2.1. Veri sayısını arttırmak için kullanılan parametreler

Numara	Veri Çoğaltma Tekniği Parametreleri	Parametre değeri
1	Yakınlaştırma Aralığı	2
2	Döndürme Aralığı	360
3	Kesme Aralığı	.5
4	Genişlik Kayması Aralığı	.4
5	Yükseklik Kayması Aralığı	.4
6	Yatay Çevirme	Evet
7	Dikey Çevirme	Evet



Şekil 2.2. Veri arttırma yöntemi sonrasında oluşan örnek görüntüler

Modeli daha hızlı eğitmek ve daha az bellek kullanmak için tüm görüntüler numpy dizisine dönüştürülmüştür.

Geri dönüşüm kutusundaki atıkların net görüntülerini elde etmek ve ışık yansımalarını önlemek için hazne kapakları siyaha boyanmış ve atıklar şerit LED'ler yardımıyla aydınlatılmıştır. Veri setindeki görüntülerin %75'i eğitim verisi, %15'i doğrulama verisi ve %10'u test verisi olarak kullanılmıştır (Çizelge 2.2).


Çizelge 2.2. Veri seti bilgileri

Malzeme Tipi	Görüntü Sayısı	Eğitim İçin Kullanılan Görüntü Sayısı (%75)	Doğrulama İçin Kullanılan Görüntü Sayısı (%15)	Test İçin Kullanılan Görüntü Sayısı (%10)
Kâğıt	340	255	51	34
Cam	255	192	38	25
Plastik	246	185	38	24
Metal	234	175	35	23
Toplam	1024	768	155	101

2.2. MultiNet Modeli

MultiNet modeli, CNN'in önceden eğitilmiş modelleri olan DenseNet-201, NASNetMobile ve VGG16'nın bir kombinasyonundan oluşmaktadır (Şekil 2.3) [40]. MultiNet, yüksek doğrulukta sınıflandırma oranına sahip olduğu için hastalıkları sınıflandırmak için başka çalışmalarda da kullanılmıştır [41, 42]. Veri kümesindeki bir görüntü girdi olarak alındığında, önceden eğitilmiş her bir model ayrı ayrı kullanılarak bu görüntüden alt düzey öznetelikler çıkarılır. Kullanılan Global Average Pooling katmanı sayesinde filtrede bulunan değerlerin ortalaması alınmaktadır. Bu işlem sayesinde boyut azaltılmış olur ve önemli özelliklerin elde edilmesi sağlanır.

Önceden eğitilmiş bu 3 modelden elde edilen özellikler, görüntü keskinleştirme, bulanıklaştırma, dokular ve degrade yönlendirme gibi üst düzey işlevleri temsil eden, tamamen bağlantılı bir katman olan Concatenate Layer'ın yardımıyla birleştirilmektedirler. Bölüm 2.6'da açıklanan Fine Tuning (ince ayar) aşamasından geçilerek, aşırı uyum gibi sorunların önlenmesi ve yeniden ölçeklenmiş veriler kullanılarak daha hızlı ağ eğitimi sağlanması amaçlanmaktadır. Elde edilen özneteliklerden anlamlı sonuçlar elde etmek için softmax fonksiyonu kullanılarak sınıflandırma işlemi gerçekleştirilir. Softmax fonksiyonu bir K gerçek sayı vektörünü K olası sonuçların olasılık dağılımına dönüştürerek sınıflandırma işlemini yapmaktadır. MultiNet modeli, tüm özelliklerin birleşiminden sonra 37 767 702 parametreye sahiptir.




Şekil 2.3. MultiNet yapısı

2.3. DenseNet Modeli

Huang ve diğerleri tarafından geliştirilen DenseNet modeli, CIFAR-10, CIFAR-100 ve ImageNet veri setleriyle en yüksek sınıflandırma doğruluğunu elde eden önceden eğitilmiş modeldir [43]. Bu model, her katmanın diğer katmanı önde beslemesiyle ResNet mimarisine benzer şekilde geliştirilmiştir (Şekil 2.4). Bu bağlantı yapısı, modeldeki önemli bilgilerin paylaşılmasını sağlayarak daha verimli ve güçlü ağ performansı sağlar [44].

Yoğun bağlantı yoluyla farklı katmanlardaki özellik haritalarının yeniden kullanılmasıyla katmanlar arasındaki karşılıklı bağımlılığı azaltılması, farklı uzunluklardaki kısayol bağlantılarıyla farklılaştırılmış giriş özellikleri sağlaması ve derin ağlarda optimize edilmesi zor olan gradyan kaybolma sorununu güçlü bir şekilde azaltılması DenseNet'in avantajlarıdır. DenseNet-201, toplam 201 derin CNN katmanına ve 20 013 928 adet parametreye sahiptir [45]. AlexNet, GoogleNet ve ResNet mimarileri ile karşılaştırıldığında, DenseNet-201 ön eğitilmiş modelinin daha derin CNN katmanları nedeniyle daha karmaşık ve zorunlu özelliklerden oluştuğu görülmektedir. Bu çalışmada, önceden eğitilmiş DenseNet-201 modeli kullanılarak ilk öznitelik çıkarımı yapılmıştır.




Şekil 2.4. DenseNet yapısı

2.4. NasNetMobile Modeli

NasNet mimarisi temel olarak NasNetMobile ve NasNetLarge olmak üzere iki sınıfa ayrılır. NasNetMobile ağı, NasNetLarge'a kıyasla daha küçük veri kümeleri için tasarlanmıştır. NasNetMobile önceden eğitilmiş modeli ilk olarak Google makine öğrenimi grubu tarafından ImageNet veri setinde [46] 1 milyondan fazla görüntü ile eğitilerek geliştirilmiştir. NasNetMobile, yaklaşık 5,3 milyon eğitim parametresi ile 224x224 piksel görüntüler kullanarak eğitim sağlamaktadır (Şekil 2.5).

Farklı evrişimler, havuzlama ve ayrılabilir evrişim işlemleri, modeli daha güvenilir kılmaktadır [47]. Nispeten daha küçük görüntü veri kümelerinde en iyi bağlantılara sahip katmanları veya hücreleri aramak için bir strateji olarak kullanılmaktadır. Evrişimli hücreler, daha küçük bir hesaplama işlemi ile daha iyi sınıflandırma performansı elde etmek için kullanılır. NasNet'te mimari önceden belirlenmiş olmasına rağmen hücre veya blok sayısı arama yöntemi ile bulunur [45].




Şekil 2.5. NasNet yapısı

2.5. VGGNet Modeli

VGGNet, Simonyan ve diğerleri tarafından geliştirilen yenilikçi bir nesne tanıma modelidir. [46]. VGGNet, evrişim katmanlarının sayısına bağlı olarak VGG16 ve VGG19 versiyonlarına sahiptir. VGG16, 13 evrişimli katmana ve 3 tam bağlı katmana sahiptir ve VGG19, 16 evrişimli katmana ve 3 tam bağlı katmana sahiptir. VGGNet, ImageNet'in görüntü sınıflandırma görevlerinde diğer modellerden daha iyi performans gösterir. Derin bir CNN yapısında oluşturulan VGGNet, ImageNet dışındaki birçok görev ve veri setinde de temel modellerden daha iyi performans gösterir (Şekil 2.6). VGGNet, halen en çok kullanılan görüntü tanıma mimarilerinden biridir [48].

Bu çalışmada özellik çıkarımı için VGG16 kullanılmıştır. Önceden eğitilmiş VGG16 mimarisi, ilk 2 blokta ilk 4 evrişim katmanı ve 3 blokta diğer 9 evrişim katmanı olmak üzere toplam 5 bloğa sahiptir [49]. Her bloktan sonra bir maksimum havuzlama katmanı yerleştirilir ve özellik haritasından en baskın özellikleri çıkarmaktadır [50]. Tüm konvolüsyon katmanlarında ReLu aktivasyon fonksiyonu kullanılmaktadır.



Şekil 2.6. VGGNet yapısı

2.6. İnce Ayar Süreci

Her üç model için de GlobalAveragePooling2D kullanılarak tam bağlı katmandan çıkan özelliklerin ortalama değeri hesaplanarak tüm katmanlar bir vektörde birleştirilmiştir. Ardından, her vektörü tek bir vektörde birleştirmek için concatenate katmanı kullanılmaktadır. Birleştirilen özniteliklere ince ayar yapmak için dropout, batch normalleştirme ve yoğun katmanlar bulunmaktadır. Elde edilen özniteliklerden anlamlı sonuçlar oluşturmak için softmax aktivasyon fonksiyonu kullanılmıştır.

Eğitim veri seti, aşırı eğitildiğinde derin sinir ağlarında aşırı uyum ortaya çıkar ve test sonuçlarını olumsuz etkiler [51]. Bu sorunu çözmek ve öznitelikleri azaltmak için 2 adet dropout katmanı kullanılmaktadır. Eğitim sırasında, birinci ve ikinci dropout katmanı, verilerin %40'ını hariç tutmaya yaramaktadır.


Kullanılan 2 toplu normalleştirme (batch normalization) katmanı tüm verileri yeniden ölçeklendirerek eğitim aşamasını hızlandırmaya ve hassasiyeti azaltmaya yardımcı olmaktadır. Dense katmanı tam bağlantılı bir katmandır ve sınıflandırma için softmax aktivasyon fonksiyonundan sonra kullanılan son yoğun katman olarak kullanılmaktadır. Softmax aktivasyon fonksiyonu özniteliklerin en çok hangi sınıfa (K) ait olabileceğini belirler ve 0 ile 1 arasında bir çıkış değeri (Z_i) alır. Softmax fonksiyonu Eş. 2.1 ile aşağıdaki gibi tanımlanır. Burada Z softmax fonksiyonunun giriş vektörüdür, Z_i giriş vektörünün giriş değeridir, K sınıf sayısıdır, e^{z_i} standart üstel fonksiyondur.

$$\sigma(\vec{Z})_i = \frac{e^{Z_i}}{\sum_{j=1}^K e^{Z_j}} \quad (2.1)$$

Softmax fonksiyonu, çok sınıflı bir problemde her sınıfa ondalık olasılıklar verir ve bu olasılıkların toplamı 1'e eşittir. Böylece elde edilen öznitelikler, softmax tarafından verilecek her sınıf için olasılık değerlerinin en büyüğüne göre sınıflandırılacaktır.

2.7. Gömülü Sisteme Sahip Geri Dönüşüm Kutusunun Tasarımı ve Çalışma Prensibi

Geri dönüşüm kutusunda kâğıt, metal, cam ve plastik atıklar için 4 farklı hazne bulunmaktadır. Kutu önce 3 boyutlu olarak NX programında Şekil 2.7'deki gibi modellenmiştir. NX'ten alınan step dosyası üretici firma ile paylaşılarak geri dönüşüm kutusunun daha kolay ve hatasız şekilde üretilmesi sağlanmıştır.




Şekil 2.7. 3D modellenmiş geri dönüşüm kutusu


Bu 3D model özel firmalara gönderilerek istenilen şekilde üretilmesini sağlayacak firma ile anlaşılmıştır. 1,5 mm kalınlığında siyah sacın lazerle kesilmesi ve kaynaklanmasıyla birleştirilmiştir. 1 mm gibi daha ince sac kullanılması durumunda daha hafif bir geri dönüşüm kutusu elde edilebilirdi fakat kendini taşıyamayıp eğilip bükülme riskinden dolayı 1,5 mm kalınlık tercih edilmiştir.

Geri dönüşüm kutusu üzerindeki her haznenin bir kapağı bulunmaktadır. Bu kapaklar sayesinde çocukların atığı yanlış hazneye atması engellenecektir. Hazne kapaklarının dönebilecek şekilde tasarlanması en zor kısımlardan biridir. Bunu sağlayabilmek için her bir hazne kapağı kesildikten sonra ortasına demir çubuk kaynak edilmiştir, sonrasında bu demir çubuğun her iki yanı bilye mantığıyla hazneye tutturulmuştur ve böylece kapağın dönmesi sağlanmıştır. Tek motor ile kapakları kontrol edebilmek için kapakların sadece tek yönde açılıp kapanması gerekmektedir. Bunu sağlayabilmek için kapağın dönmesi istenilmeyen tarafına iç kısımda engelleyici aparat yapıştırılmıştır. Şekil 2.8, Şekil 2.9, Şekil 2.10'daki teknik çizimlerle geri dönüşüm kutusunun nasıl çalışacağı planlanmıştır. Şekil 2.8, Şekil 2.9, Şekil 2.10'da bulunan etiketlerin açıklamaları aşağıdaki gibidir:


1. Ses çıkışının yapılacağı hoparlörler
2. Eğlenceli ve eğitici videoların oynatılacağı lcd ekran
3. Atık kutusunu hareket ettirebilmek/durdurmak için kilitlenebilir teker
4. Atıkların görüntülerini elde edebilmek için kullanılacak kamera haznesi
- 5 ve 6. Dolan atık torbalarını alabilmek için yanlardan kapı
7. Koyulan atığın doğrudan hazneye düşmesini engelleyecek kapak
8. Atık torbalarının takılacağı kanca
9. Hazne kapaklarını açıp kapatacak motor
10. Hazne kapaklarını açıp kapatacak motor aparatı
11. Hazne kapağının altına ve motor aparatının ucuna yapıştırılan ip
12. Hazne kapağının iki taraflı dönmesini engelleyici aparat
13. Hazne kapağının dönmesini sağlayan mil
14. Mesafe sensörü
15. Esnek şerit led



Şekil 2.8. Geri dönüşüm kutusunun önden görünümünün 2D çizimi




Şekil 2.9. Kesit 1'den bakıldığında görülen



Şekil 2.10. Kesit 2'den bakıldığında görülen


Haznenin kolay taşınması ve sabitlenmesi için tabanda 5 adet tekerlek bulunmaktadır. Çocukların geri dönüşüm kutusunu hareket ettirmelerini engellemek ve geri dönüşüm kutusunu sabitleyebilmek için kilitlenebilir tekerlekler kullanılmıştır. Geri dönüşüm kutusu, plastik hazne sarı, cam haznesi yeşil, kâğıt haznesi mavi ve metal haznesi gri olacak şekilde 4 farklı renge boyanmıştır. Her bir hazne önüne ilgili atığın türünün resmi ve çocuklara yönelik resimler yapıştırılmıştır.

Sınıflarda kullanılacak geri dönüşüm kutusunun atık görüntülerini alınırken ışıktan etkilenmesini engellemek ve net görüntüler elde edebilmek için aydınlatma kullanmak gerekmektedir. Aydınlatmak için 5 metre uzunluğundaki esnek şerit led hazne kapaklarını aydınlatacak şekilde yapıştırılmıştır. Şerit led'i prizden besleyebilmek için Şekil 2.11'deki 60 watt'lık trafo kullanılmıştır.



Şekil 2.11. Esnek şerit led ve güç sağlayan 60 watt trafo

Atık torbalarını takmak için geri dönüşüm kutusunun içine kancalar monte edilmiştir. Dolan atık torbalarına kolayca ulaşabilmek için geri dönüşüm kutusunun her iki yanında kalem menteşelerle monte edilmiş kilitli kapaklar bulunmaktadır. Hazne kapaklarının açılıp kapanması için Raspberry Pi işlemci tarafından kontrol edilen servo motorlar kullanılmaktadır. Kullanılan servo motorlar Şekil 2.12’de verilmiştir. Bu motorlar 12 kg taşıma kapasitelidir ve 5 volt ile çalışmaktadır [52]. Raspberry üzerinde 5 volt çıkış bulunmasına rağmen işlemcinin zarar görmesini engelleyebilmek için dışardan bir adaptör yardımıyla güç sağlanmaktadır.



Şekil 2.12. Servo motor örnek Raspberry Pi bağlantısı


Hazne kapaklarına konulan atıkların görüntülerini elde edebilmek için kamera haznelerine her hazneyi yukarıdan görüntüleyecek şekilde 4 adet Raspberry Pi kamera versiyon 2,1 konulmuştur. Raspberry Pi üzerinde bir adet kamera çıkışı bulunduğundan 4 farklı kamera kullanabilmek için kamera çoklayıcı modül Şekil 2.13'teki gibi bağlanarak kameralar çoğaltılmıştır. Kameraların bağlantısı özel ribbon kablolar kullanılarak yapılmıştır [53].



Şekil 2.13. Kamera çoklayıcı modül ve 4 adet Raspberry Pi kamera örnek bağlantısı

Hazne kapağına atık koyulup koyulmadığını anlayabilmek için Şekil 2.14'te verilen ultrasonik mesafe sensörleri kullanılmıştır [54]. Bu sensörler 4-5 metreye kadar mesafe ölçümü yapabilmektedir. Bu sensörler kameraların yanına koyulmuş ve hazne kapağını doğrudan görececek şekilde yapıştırılmıştır. Ek olarak hazne kapaklarının altına yapıştırılan ultrasonik mesafe sensörleri sayesinde atık torbasının doluluk seviyesi kontrol edilmektedir. Herhangi bir hazne dolduğunda atık torbası doldu uyarısı verilecek ve atık torbaları boşaltılmadan atık atılmasına izin verilmeyecektir. Bu sensörlerin 5 volt beslemesi ve toprak bağlantısı Raspberry pi üzerindeki çıkışlardan sağlanmaktadır. Sensörlerin Echo pinine aşağıdaki gibi dirençlerin bağlanması gerekmektedir. Sonar ses dalgalarını kullanarak cismin uzaklığını hesaplamaktadır. TRIG pini ses sinyallerini tetiklemek için kullanılırken

ECHO pini yansıtılan sinyal alındığında elde edilen pulse uzunluğuna göre mesafe hesaplanmaktadır.



Şekil 2.14. Mesafe sensörünün Raspberry Pi'ye örnek bağlantısı

Çocuklar için eğlenceli ve eğitici videoların oynatılacağı 10,1 inçlik LCD ekran geri dönüşüm kutusunun önüne monte edilmiştir. LCD ekran üzerindeki 2 adet 5 volt çıkışları ve toprak bağlantısı için doğrudan Raspberry Pi üzerindeki pinler kullanılmıştır. Aynı zamanda mikro USB portuyla LCD ekran ve Raspberry Pi arasında bağlantı da bulunmaktadır. LCD ekranda oynatılacak eğitici videoların ses çıkışı üst kısımda bulunan hoparlörlerin Raspberry Pi üzerindeki USB portuna bağlanarak sağlanmaktadır. Tez çalışması kapsamında geliştirilen geri dönüşüm kutusu Şekil 2.15'de verilmiştir.

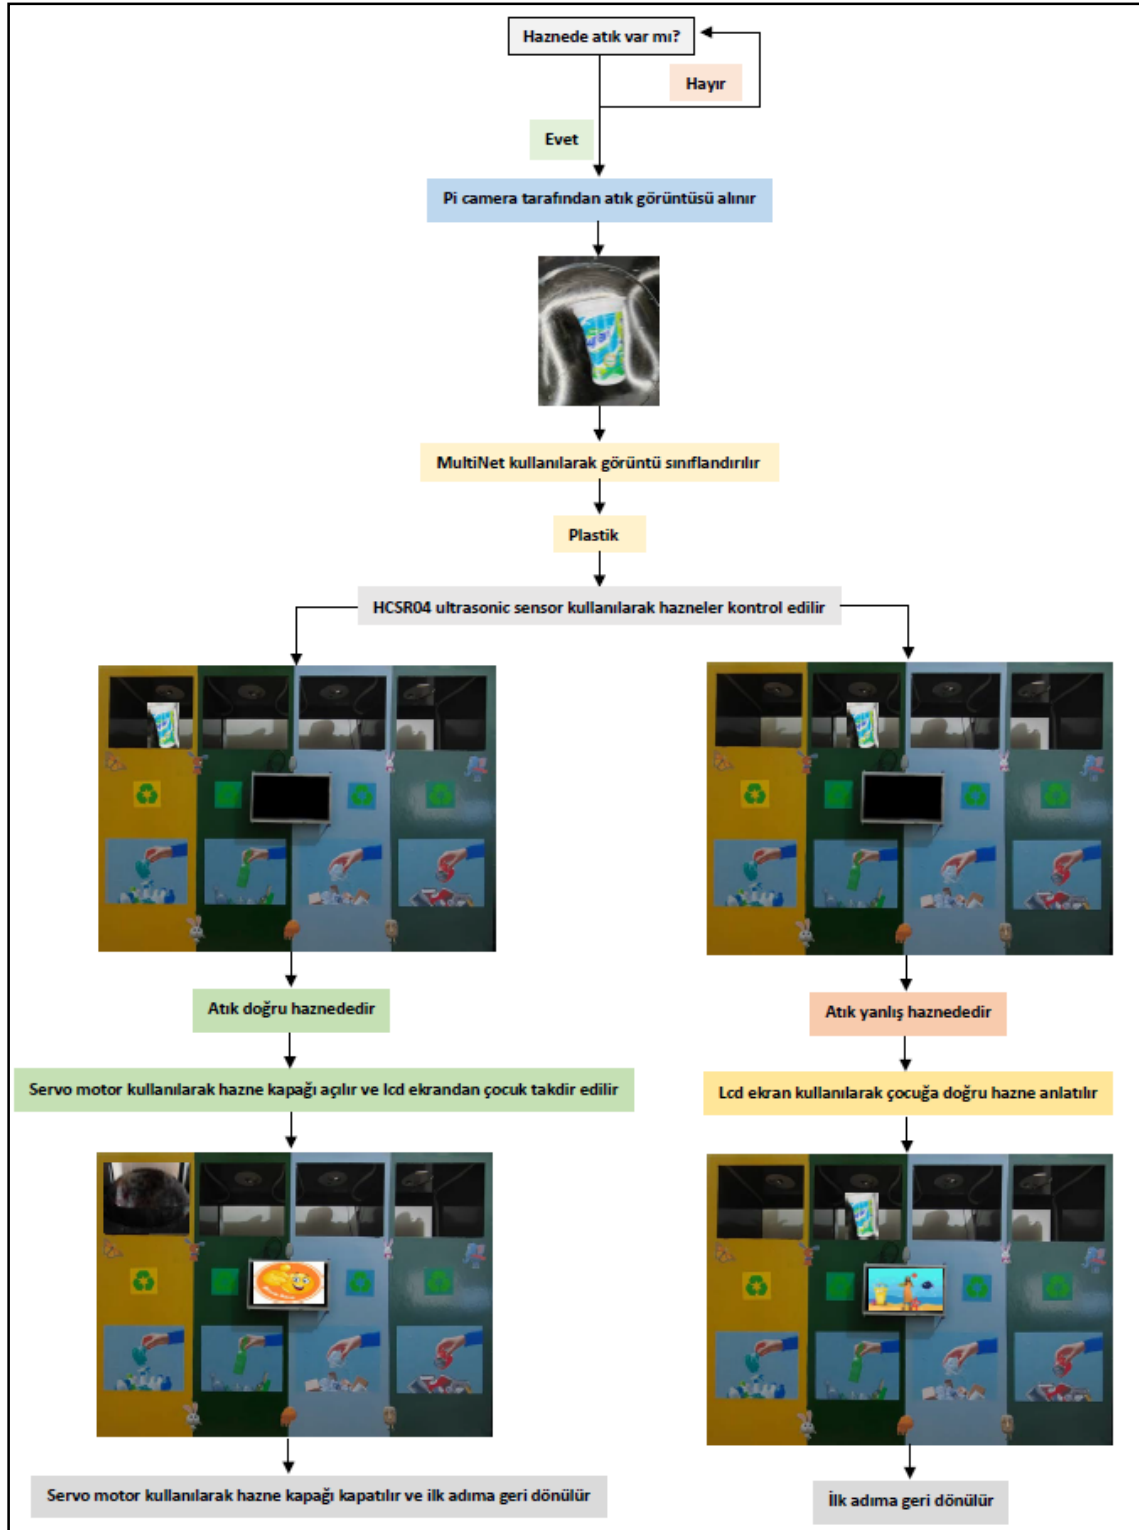


Şekil 2.15. Gömülü sisteme sahip geri dönüşüm kutusu

Geri dönüşüm kutusunun çalışma prensibi aşağıdaki gibidir:

1. Atık yanlış hazneye konulursa haznenin kapağı açılmaz ve LCD ekranda müzikli ve eğitici video içeriklerle çocuk doğru hazneye yönlendirilir.
2. Atık doğru hazneye konulursa haznenin kapağı açılarak geri dönüşüm kutusuna düşer ve çocuk LCD ekranda paylaşılabilecek alkış sesli videoyla birlikte tebrik edilir.


Böylece çocuğun elindeki atıkları yanlış hazneye atması engellenir ve doğru hazneyi bulması için eğlenceli ve eğitici videolar ile yönlendirilir. Çocuk atığı doğru hazneye attığında doğru yaptığını anlar ve övülür, böylece çocuklar atıklarını doğru haznelere atma eğiliminde olacaklardır. Sistemin çalışma prensibine ait akış diyagramı Şekil 2.16'da verilmiştir.



Şekil 2.16. Geri dönüşüm kutusunun çalışma prensibi

2.8. Raspberry Pi 4B'nin Kurulumu ve Kullanılan Tüm Kodlar

Gömülü sistemde sistemi kontrol edecek işlemci olarak Raspberry Pi 4B (8 GB RAM) kullanılmaktadır. Raspberry Pi'nin pinleri ve hangi amaçla kullanılabileceği Şekil 2.17'de yer almaktadır [55].



Şekil 2.17. Raspberry Pi'nin pin dizilimi

Raspberry Pi'nin gücü prizden, motorlar ve sensörler gibi diğer elektronik ekipmanların gücü ise Raspberry Pi üzerindeki pinlerden sağlanmaktadır. Geri dönüşüm kutusundaki ekipmanların hangi pinleri kullanarak kontrol edildikleri Şekil 2.18'de bulunmaktadır.

Boş	1	2	5 Volt
Boş	3	4	5 Volt
Boş	5	6	Toprak pini
Boş	7	8	5 numaralı hr-sc04 ECHO pini
Toprak pini	9	10	6 numaralı hr-sc04 ECHO pini
5 numaralı hr-sc04 TRIG pini	11	12	1 numaralı hr-sc04 ECHO pini
6 numaralı hr-sc04 TRIG pini	13	14	Toprak pini
7 numaralı hr-sc04 TRIG pini	15	16	2 numaralı hr-sc04 ECHO pini
Toprak pini	17	18	3 numaralı hr-sc04 ECHO pini
8 numaralı hr-sc04 TRIG pini	19	20	Toprak pini
Boş	21	22	4 numaralı hr-sc04 ECHO pini
Boş	23	24	7 numaralı hr-sc04 ECHO pini
Toprak pini	25	26	8 numaralı hr-sc04 ECHO pini
Boş	27	28	Boş
1 numaralı hr-sc04 TRIG pini	29	30	Toprak pini
2 numaralı hr-sc04 TRIG pini	31	32	1 numaralı motor pini
3 numaralı hr-sc04 TRIG pini	33	34	Toprak pini
Boş	35	36	2 numaralı motor pini
4 numaralı hr-sc04 TRIG pini	37	38	3 numaralı motor pini
Toprak pini	39	40	4 numaralı motor pini


Şekil 2.18. Tez çalışmasında Raspberry üzerinde kullanılan pinler

Raspberry Pi için optimize edilmiş olan Raspberry Pi OS (Raspbian) işletim sistemi Debian'a dayalı bir işletim sistemidir [56]. Raspberry Pi işletim sistemini kurabilmek için Micro SD Kart üzerine Raspberry Pi Imager yazılımı sayesinde ilk kurulum gerçekleştirilir. Şekil 2.19'da verilen arayüzdeki işletim sistemi (operating system) kısmından Raspberry Pi OS (32-bit) seçilir ve depolama (storage) kısmında da Micro SD kart bulunarak Write (Yaz) butonuna tıklanır. Bu işletim sisteminin 64 biti de mevcuttur fakat henüz gelişmekte olduğundan tüm fonksiyonlar tam olarak çalışmamaktadır (Örneğin kamera).



Şekil 2.19. Raspberry Pi imager arayüzü

Yazma işlemi tamamlandıktan sonra Micro SD kart Raspberry Pi'ye takılır. Güç kabloları da takıldıktan sonra HDMI çıkışından alınan görüntü sayesinde kurulum aşamaları gerçekleştirilir. İlk açıldığında Şekil 2.20'deki gibi bir ekran elde edilir. Kullanılacak saat dilimi ve dil seçilir ve internet bağlantısı yapılarak ilk kurulum tamamlanır.



Şekil 2.20. Raspberry Pi kurulum ekranı

Raspberry Pi’de Python yazılımı otomatik olarak 2,7’lik versiyonla gelmektedir. Python 3,7’yi kurmak için 2,7’lik versiyon kaldırılmalı ve sonrasında 3,7’lik versiyon kurulmalıdır. Şekil 2.21’deki kodlar sayesinde bu işlemler yapılmıştır [57].

```
>sudo apt-get remove python2.7

>sudo apt-get update

>sudo apt-get install -y build-essential tk-dev libncurses5-dev libncursesw5-dev
libreadline6-dev libdb5.3-dev libgdbm-dev libsqlite3-dev libssl-dev libbz2-dev libexpat1-
dev liblzma-dev zlib1g-dev libffi-dev

>wget https://www.python.org/ftp/python/3.7.0/Python-3.7.0.tgz

>sudo tar xzf Python-3.7.0.tgz

>cd Python-3.7.0

>sudo ./configure

>sudo make -j 4

>sudo make altinstall
```

Şekil 2.21. Python 3,7 versiyonunun kurulumu için kullanılan kodlar

Python3,7’nin varsayılan olarak çağrılabilmesi için “vim ~/.bashrc” kodu cmd ekrana girilir ve açılan dosyaya “alias python='/usr/local/bin/python3.7'” satırı yazılıp kaydedilir. Sonrasında komut satırında “source ~/.bashrc” yazılarak kurulum tamamlanmış olur.

Python üzerinden Raspberry Pi’nin pinlerini kullanabilmek ve geri dönüşüm kutusunu kontrol edecek kütüphanelerin kurulabilmesi için komut ekranından kurulum yapılması gerekir. Fakat birçok kütüphaneyi tek tek kurmak zor olacağı için daha basit bir yöntem bulunmaktadır. Raspberry Pi içerisinde Thonny Python IDE arayüzü yeni başlayanlar için kolay bir arayüz olarak kullanılabilir. Bu arayüzde üst çubukta bulunan tools seçeneğinin altında library sekmesi bulunmaktadır. Açılacak sayfada kurulmak istenen kütüphane arattırılır ve indir butonuna tıklanarak doğrudan kütüphane ekleme işlemi yapılabilir.

Bu çalışmada kullanılan bazı kütüphaneleri eklemek için gereken kod Şekil 2.22’de verilmiştir [58]. Bu kodda import komutuyla eklenmek istenen kütüphanenin ismi girilir. RPi.GPIO komutu sayesinde Raspberry Pi üzerindeki pinlerin doğrudan numaralarının

kullanılacağı belirtilir. Sleep kütüphanesi sayesinde bir komuttan sonra beklenmek istenen süreye göre `time.sleep(saniye)` komutu kullanılmaktadır. Video oynatabilmek için `vlc` kütüphanesinin de eklenmesi gerekmektedir.

```
from time import sleep
from lobe import ImageModel
import RPi.GPIO as GPIO
import time
import vlc
import subprocess
import os
import numpy as np
```

Şekil 2.22. Python'a kütüphane eklenmesi için kullanılan kodlar

Şekil 2.23'teki kodların herhangi bir Python kodu içerisinde kullanılması zorunludur aksi takdirde hata uyarılarıyla karşılaşılabilir.

```
GPIO.setwarnings ( False )# Şimdilik uyarıyı yoksay
GPIO.setmode(GPIO.BOARD)# Fiziksel pin numaralandırmasını kullanın
```

Şekil 2.23. Python kodlarında kullanılması zorunlu olan kodlar

Hazne kapaklarını açıp kapatabilmek için kullanılacak servo motorların kontrolünü sağlayacak kodlar Şekil 2.24'teki gibidir [58]. Servo motor 1 için 32 nolu pin, servo motor 2 için 36 nolu pin, servo motor 3 için 38 nolu pin, servo motor 4 için 40 nolu pinden çıkış alınacağı bu şekilde tanımlanmıştır. `GPIO.PWM(32, 50)` gibi her satırda bulunan 50'nin anlamı PWM periodunun 50 Hz olacağı (yaklaşık olarak 20 mili saniye) belirtilmektedir. `GPIO.OUT` komutu ile belirtilen pinden çıkış alınır.

```
GPIO.setup(32,GPIO.OUT)
servo1 = GPIO.PWM(32,50) # pin 11 for servol
GPIO.setup(36,GPIO.OUT)
servo2 = GPIO.PWM(36,50) # pin 12 for servo2
GPIO.setup(38,GPIO.OUT)
servo3 = GPIO.PWM(38,50) # pin 12 for servo3
GPIO.setup(40,GPIO.OUT)
servo4 = GPIO.PWM(40,50) # pin 12 for servo4
```

Şekil 2.24. Servo motor pinlerinin tanımlanmasını sağlayan kodlar

Atık koyulduğunu tespit edebilmek yâda haznelerin dolup dolmadığını anlayabilmek için kullanılacak olan ultrasonik mesafe sensörlerinin kontrolünü sağlayacak kodlar Şekil

2.25'teki gibidir [58]. Örnek olarak TRIG1 29 nolu pinden çıkış verecek olup ECHO1 12 nolu pinden girdi alacaktır. Trig sayesinde sensörden dalga gönderilirken yansıma sonucunda dalganın geri dönüşü Echo üzerinden olmaktadır ve böylece nesne ile mesafe ölçülebilmektedir.

```
TRIG1 = 29
ECHO1 = 12
GPIO.setup(TRIG1,GPIO.OUT)
GPIO.setup(ECHO1,GPIO.IN)
TRIG2 = 31
ECHO2 = 16
GPIO.setup(TRIG2,GPIO.OUT)
GPIO.setup(ECHO2,GPIO.IN)
TRIG3 = 33
ECHO3 = 18
GPIO.setup(TRIG3,GPIO.OUT)
GPIO.setup(ECHO3,GPIO.IN)
TRIG4 = 37
ECHO4 = 22
GPIO.setup(TRIG4,GPIO.OUT)
GPIO.setup(ECHO4,GPIO.IN)
TRIG5 = 11
ECHO5 = 8
GPIO.setup(TRIG5,GPIO.OUT)
GPIO.setup(ECHO5,GPIO.IN)
TRIG6 = 13
ECHO6 = 10
GPIO.setup(TRIG6,GPIO.OUT)
GPIO.setup(ECHO6,GPIO.IN)
TRIG7 = 15
ECHO7 = 24
GPIO.setup(TRIG7,GPIO.OUT)
GPIO.setup(ECHO7,GPIO.IN)
TRIG8 = 19
ECHO8 = 26
GPIO.setup(TRIG8,GPIO.OUT)
GPIO.setup(ECHO8,GPIO.IN)
```

Şekil 2.25. Mesafe sensörlerini kontrol etmek için pinleri tanımlayan kodlar

“Model = ImageModel.load(‘/home/onur/Desktop/Lobe’)” komutu kullanılarak parantez içerisindeki adreste bulunan klasörde yer alan ve MultiNet modelinden elde edilen ağırlıkların Tensor Flow Lite ortamında elde edildiği dosya bulunmaktadır. Bu dosya kullanılarak görüntülerin sınıflandırılması yapılmaktadır. Tensor Flow Lite ortamı boyutunun az olması ve daha hızlı çalışmasını sağlamak için tercih edilmiştir.


Pin tanımlamaları yapıldıktan sonra while döngüsü içerisinde yer alan Şekil 2.26’daki kodlarla birlikte sistem tekrar durduruluncaya kadar çalışmaya başlayacaktır. Exec(open (distance1.py).read()) komutuyla “distance1.py” olarak kaydedilen ayrı bir kod çalıştırılacaktır. Distance1 plastik atık, distance2 cam atık, distance3 kâğıt atık, distance4 metal atık koyulup koyulmadığını kontrol eder. Distance5 plastik atık haznesinin, distance6

cam atık haznesinin, distance7 kâğıt atık haznesinin, distance8 metal atık haznesinin dolup dolmadığını anlayabilmek için mesafe ölçme komutu olarak kullanılmıştır.

```
while True:
    exec(open("distance1.py").read())
    time.sleep(0.1)
    exec(open("distance2.py").read())
    time.sleep(0.1)
    exec(open("distance3.py").read())
    time.sleep(0.1)
    exec(open("distance4.py").read())
    time.sleep(0.1)
    exec(open("distance5.py").read())
    time.sleep(0.1)
    exec(open("distance6.py").read())
    time.sleep(0.1)
    exec(open("distance7.py").read())
    time.sleep(0.1)
    exec(open("distance8.py").read())
    time.sleep(0.1)
```

Şekil 2.26. Mesafelerin sürekli olarak kontrol edilmesini sağlayan kodlar

Örnek olarak distance1.py ve distance5.py kodunun içeriği Şekil 2.27 ve Şekil 2.28’de paylaşılmıştır. Mesafenin kaç cm olduğunda atık var/yok olduğunu yâda poşetin dolu/boş olduğunu anlayabilmek için if döngüsünden faydalanılmıştır.



```

distance1.py - C:\Users\User\Desktop\Raspberry pi kodları\distance1.py
File Edit Format Run Options Window Help

import RPi.GPIO as GPIO
import time

GPIO.setmode(GPIO.BOARD)
GPIO.setwarnings(False)

TRIG1 = 29
ECHO1 = 12
GPIO.setup(TRIG1,GPIO.OUT)
GPIO.setup(ECHO1,GPIO.IN)

GPIO.output(TRIG1, True)

time.sleep(0.00001)
GPIO.output(TRIG1, False)

while GPIO.input(ECHO1)==0:
    pulse_start1 = time.time()

while GPIO.input(ECHO1)==1:
    pulse_end1 = time.time()


pulse_duration1 = pulse_end1 - pulse_start1
distance1 = pulse_duration1 * 17150
distance1 = round(distance1, 2)

time.sleep(0.1)

if distance1 > 2 and distance1 < 20:
    print("1'de atık var:",distance1 - 0.5,"cm")
else:
    print("1'de atık yok:",distance1 - 0.5,"cm")

```

Şekil 2.27. Mesafe sensörlerinin atık konulduğunun tespitini sağlayan kodlar



```

distance5.py - C:\Users\User\Desktop\Raspberry pi kodları\distance5.py (3.
File Edit Format Run Options Window Help
import RPi.GPIO as GPIO
import time

GPIO.setmode(GPIO.BOARD)
GPIO.setwarnings(False)

TRIG5 = 11
ECHO5 = 8
GPIO.setup(TRIG5,GPIO.OUT)
GPIO.setup(ECHO5,GPIO.IN)

GPIO.output(TRIG5, True)

time.sleep(0.00001)
GPIO.output(TRIG5, False)

while GPIO.input(ECHO5)==0:
    pulse_start5 = time.time()

while GPIO.input(ECHO5)==1:
    pulse_end5 = time.time()

pulse_duration5 = pulse_end5 - pulse_start5
distance5 = pulse_duration5 * 17150
distance5 = round(distance5, 2)

time.sleep(0.1)

if distance5 > 2 and distance5 < 25:
    print("1'deki poşet dolu:",distance5 - 0.5,"cm")
else:
    print("1'deki poşet boş:",distance5 - 0.5,"cm")

```

Şekil 2.28. Mesafe sensörlerinin haznelerin dolduğunun tespiti sağlayan kodlar


Yukarıdaki mesafe kodları sayesinde while döngüsü içerisinde sürekli olarak mesafe ölçüm işlemleri yapılmaktadır. Eğer distance1'den gelen ölçüme göre hazneye atık koyulduğu tespit edilirse Şekil 29'daki kodlar sayesinde atığın görüntüsü alınıp derin sinir ağına girdi olarak kullanılmaktadır. Sonrasında atığın sınıfı "result1 = model.predict_from_file()" ve "label1 = result1.prediction" komutlarıyla tespit edilmektedir. Mesafe sensörü sayesinde plastik tarafına konulduğu bilinen atığın sınıf etiketiyle uyuşup uyuşmadığı ve böylece atığın doğru tarafa konulup konulmadığı tespit edilmektedir. Atık doğru tarafa konulduysa if komutuyla birlikte servo motor çalıştırılacak ve alkış sesli video ekrana gelecektir. Atık yanlış tarafa konulduğunda ilgili hazneye hangi atık türünü konması gerektiğini anlatan video ekrana gelecektir. Örnek olarak plastik haznesini kontrol eden kodlar aşağıdaki Şekil 2.29'da paylaşılmıştır. Servo1.ChangeDutyCycle() komutlarıyla birlikte önce 90 derecelik

servo motor dönüşü yapılarak hazne kapağı açılmakta ve 3 saniyelik duraklama sonrasında geriye doğru 90 derecelik motor dönüşü yapılarak hazne kapağı kapatılmaktadır.

```
elif distancel < 20:
    print('plastikte atık var:')
    subprocess.call("/home/onur/RaspberryPi/init_camera1.sh", shell=True)
    time.sleep(0.1)
    result1 = model.predict_from_file('/home/onur/RaspberryPi/capture_1.jpg')
    labell = result1.prediction
    print(labell)
    if labell == "PLAST":
        exec(open("odul_video.py").read())
        servol.start(0)
        servol.ChangeDutyCycle(2)
        time.sleep(1)
        servol.ChangeDutyCycle(0)
        time.sleep(3)
        servol.ChangeDutyCycle(7)
        time.sleep(1)
        servol.stop(0)
    else:
        exec(open("plastik_egitici_video.py").read())
```

Şekil 2.29. Atık sınıflandırılmasını ve servo motorları kontrol etmeyi sağlayan kodlar


Subprocess.call() komutuyla çağrılan “init_camera1.sh” komutu sayesinde kamera çoklayıcı modül üzerinden 1 numaralı kamera çalıştırılmaktadır. Kamera çoklayıcı modül üzerindeki tüm pinler Raspberry üzerindeki pinlere bağlanmıştır. Bu kodun içeriği Şekil 2.30’da paylaşılmıştır. Bu kod içerisinde de ayrıca başka bir kod olan “AdapterTestDemo1.py” isimli kod çağrılmaktadır ve Şekil 2.31’de paylaşılan bu kod sayesinde kamera tarafından atığın görüntüsü alınıp capture komutuyla derin sinir ağına girdi olarak kullanılmak üzere kaydedilmektedir. Kamera çoklayıcı modülü uygun şekilde Raspberry Pi’ye kurup kullanabilmek için modülü üreten firma tarafından hazırlanan adımlar sırasıyla yapılmıştır [53].



```
*init_camera1.sh - Not Defteri
Dosya Düzen Biçim Görünüm Yardım

i2cdetect -y 1
i2cset -y 1 0x70 0x00 0x04
if [ -c "/dev/video0" ]; then
sudo python AdapterTestDemo1.py
else
echo "Can't find video0 device, please check the hardware connection! "
```

Şekil 2.30. Kameraların çalışması için kullanılan kod



```

AdapterTestDemo1.py - C:\Users\User\Desktop\Raspberry pi kodları\AdapterTestDemo1.py
File Edit Format Run Options Window Help

import RPi.GPIO as gp
import os

gp.setwarnings(False)
gp.setmode(gp.BOARD)

gp.setup(7, gp.OUT)
gp.setup(11, gp.OUT)
gp.setup(12, gp.OUT)

def main():
    print('Start testing the camera A')
    i2c = "i2cset -y 1 0x70 0x00 0x04"
    os.system(i2c)
    gp.output(7, False)
    gp.output(11, False)
    gp.output(12, True)
    capture(1)

def capture(cam):
    cmd = "libcamera-still -o capture_%d.jpg" % cam
    os.system(cmd)


if __name__ == "__main__":
    main()

    gp.output(7, False)
    gp.output(11, False)
    gp.output(12, True)

```

Şekil 2.31. Kameralardan atık görüntüsü alan ve kaydedilmesini sağlayan kodlar

Eğitici videoların LCD ekranda gösterilmesini sağlayan örnek kodlar Şekil 2.32 ve Şekil 2.33'te verilmiştir. Video oynatıcı olarak VLC media player kullanılmakta olup “random.choice” komutu sayesinde belirtilen klasör içerisinde bulunan videolardan biri oynatılmaktadır. Böylece sürekli aynı video yerine çocukların sıkılmasını önlemek için birçok farklı eğitici video paylaşılabilmektedir.




```

import RPi.GPIO as GPIO
from time import sleep
import vlc
import glob
import subprocess
from random import choice
import random
import os
import sys

random_file = random.choice(os.listdir("/home/onur/Videolar/yanlis_sesi"))
video_path = '/home/onur/Videolar/yanlis_sesi/' + random_file
Media = vlc.MediaPlayer(video_path)
Media.play()
sleep(3)
Media.stop()
random_file = random.choice(os.listdir("/home/onur/Videolar/plastik_egitici_videolar"))
video_path = '/home/onur/Videolar/plastik_egitici_videolar/' + random_file
Media = vlc.MediaPlayer(video_path)
Media.play()
sleep(17)
Media.stop()

```

Şekil 2.32. Eğitici videonun oynatılması için kullanılan kodlar



```

import RPi.GPIO as GPIO
from time import sleep
import vlc
import glob
import subprocess
from random import choice
import random
import os
import sys

random_file = random.choice(os.listdir("/home/onur/Videolar/odul_videolar"))
video_path = '/home/onur/Videolar/odul_videolar/' + random_file
Media = vlc.MediaPlayer(video_path)
Media.play()
sleep(5)
Media.stop()

```

Şekil 2.33. Doğru tercih sonrasında video oynatılmasını sağlayan kodlar

Daha sonra haznenin dolup dolmadığını anlamak için sürekli olarak ölçüm yapan mesafe sensörlerinden gelen bilgilere göre hazne dolduğunda sesli olarak hangi haznenin dolduğu söylenmektedir. Bu işlemi yapan kodlar Şekil 2.34’de verilmiştir. Bu kodlardan da görüleceği üzere mesafe 25 cm’in altına indiğinde hazne doldu anlamına gelmektedir.

```

if distance5 < 25:
    Media = vlc.MediaPlayer("/home/onur/Videolar/plastik_dolu")
    Media.play()
    sleep(3)
    Media.stop()
elif distance6 < 25:
    Media = vlc.MediaPlayer("/home/onur/Videolar/cam_dolu")
    Media.play()
    sleep(3)
    Media.stop()
elif distance7 < 25:
    Media = vlc.MediaPlayer("/home/onur/Videolar/kagit_dolu")
    Media.play()
    sleep(3)
    Media.stop()
elif distance8 < 25:
    Media = vlc.MediaPlayer("/home/onur/Videolar/metal_dolu")
    Media.play()
    sleep(3)
    Media.stop()

```


Şekil 2.34. Atık haznelerinin dolduğunu tespit edebilmek için kullanılan kodlar

Tüm bu kodlar bir klasörde toplanarak sadece “MAINCODE.py” kodunun çalıştırılmasıyla tüm sistemin çalışması sağlanabilmektedir. Tüm sistemi kontrol eden kodlar ve bu kodların bir klasörde toplanması Şekil 2.35’te gösterilmiştir.

	AdapterTestDemo1	17.06.2023 23:40	Python File	1 KB
	AdapterTestDemo2	17.06.2023 23:40	Python File	1 KB
	AdapterTestDemo3	17.06.2023 23:40	Python File	1 KB
	AdapterTestDemo4	17.06.2023 23:40	Python File	1 KB
	cam_egitici_video	17.06.2023 23:40	Python File	1 KB
	distance1	17.06.2023 23:40	Python File	1 KB
	distance2	17.06.2023 23:40	Python File	1 KB
	distance3	17.06.2023 23:40	Python File	1 KB
	distance4	17.06.2023 23:40	Python File	1 KB
	distance5	17.06.2023 23:40	Python File	1 KB
	distance6	17.06.2023 23:40	Python File	1 KB
	distance7	17.06.2023 23:40	Python File	1 KB
	distance8	17.06.2023 23:40	Python File	1 KB
	egitici_video	17.06.2023 23:41	Python File	1 KB
	init_camera1.sh	17.06.2023 23:40	SH Dosyası	1 KB
	init_camera2.sh	17.06.2023 23:41	SH Dosyası	1 KB
	init_camera3.sh	17.06.2023 23:41	SH Dosyası	1 KB
	init_camera4.sh	17.06.2023 23:41	SH Dosyası	1 KB
	kagit_egitici_video	17.06.2023 23:41	Python File	1 KB
	MAINCODE	17.06.2023 23:41	Python File	6 KB
	metal_egitici_video	17.06.2023 23:41	Python File	1 KB
	odul_video	17.06.2023 23:41	Python File	1 KB
	plastik_egitici_video	17.06.2023 23:41	Python File	1 KB
	previewOpencv	17.06.2023 23:41	Python File	4 KB

Şekil 2.35. Tüm sistemi kontrol eden kodlar ve bir klasörde toplanması


Raspberry Pi üzerinde yapılan tüm bağlantıların son hali, geri dönüşüm kutusunun içi ve kamera ve atık algılamak için kullanılan mesafe sensörü sırasıyla Şekil 2.36, Şekil 2.37, Şekil 2.38’de verilmiştir.



Şekil 2.36. Raspberry Pi'ye yapılan tüm bağlantılar



Şekil 2.37. Geri dönüşüm kutusunun içerisinde son hali



Şekil 2.38. Kamera ve atık algılamak için kullanılan mesafe sensörü

3. DENEYSEL SONUÇLAR

MultiNet modeli, açık kaynak kitaplığı olan Keras kullanılarak uygulanmıştır. Tüm eğitim ve test süreçleri Google Colab, 12 GB GDDR5 RAM'e sahip Tesla K80 GPU, 2,2 GHz'de iki çekirdekli Intel Xeon işlemciler ve toplam 15 GB RAM üzerinde gerçekleştirilmiştir.


MultiNet modelinin hangi katmanlardan oluştuğu ve parametre sayısının katmanlara göre dağılımı aşağıdaki Şekil 3.1'deki gibidir.

Model: "model"			
Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	[(None, 224, 224, 3)]	0	[]
densenet201 (Functional)	(None, 7, 7, 1920)	18321984	['input_1[0][0]']
NASNet (Functional)	(None, 7, 7, 1056)	4269716	['input_1[0][0]']
vgg16 (Functional)	(None, 7, 7, 512)	14714688	['input_1[0][0]']
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1920)	0	['densenet201[0][0]']
global_average_pooling2d_1 (GlobalAveragePooling2D)	(None, 1056)	0	['NASNet[0][0]']
global_average_pooling2d_2 (GlobalAveragePooling2D)	(None, 512)	0	['vgg16[0][0]']
concatenate_4 (Concatenate)	(None, 3488)	0	['global_average_pooling2d[0][0]', 'global_average_pooling2d_1[0][0]', 'global_average_pooling2d_2[0][0]']
dropout (Dropout)	(None, 3488)	0	['concatenate_4[0][0]']
batch_normalization (BatchNormalization)	(None, 3488)	13952	['dropout[0][0]']
dense (Dense)	(None, 128)	446592	['batch_normalization[0][0]']
dropout_1 (Dropout)	(None, 128)	0	['dense[0][0]']
batch_normalization_1 (BatchNormalization)	(None, 128)	512	['dropout_1[0][0]']
dense_1 (Dense)	(None, 4)	516	['batch_normalization_1[0][0]']
Total params: 37,767,960			
Trainable params: 37,494,934			
Non-trainable params: 273,026			

Şekil 3.1. Multinet modelinin katmanları ve parametre sayıları

MultiNet derin sinir ağı yapısı ile eğitim sırasında elde edilen eğitim ve doğrulama verilerinin doğruluk ve kayıp grafikleri Şekil 3.2'de verilmektedir. Sistemde kullanılan

görüntü sayısı sınırlı olduğu için 200 epoch'a kadar ağ eğitimi gerçekleştirilmiş ve 165. epoch'ta %96'lık doğruluk elde edilmiştir. Tüm ağın eğitimi yaklaşık 45 dakika sürmüştür. Ağın ortalama eğitim doğruluğu %94, ortalama doğrulama doğruluğu %65 olmuştur. Kayıp fonksiyon eğrisinde de görüldüğü gibi eğitim kayıp değeri sıfıra yakındır. Bu çalışma çok sınıflı sınıflandırmaya dayandığından, kayıp fonksiyonu olarak kategorik çapraz entropi (categorical cross entropy) kullanılmıştır.



Şekil 3.2. MultiNet eğitim ve doğrulama doğrulukları, eğitim ve doğrulama kayıpları


Kayıp fonksiyonunun seçimi derin sinir ağının katmanlarındaki çıktıları etkilediği için probleme en uygun olanı tercih edilmelidir. Bu fonksiyon etiketler ve tahminler arasındaki çapraz entropi kaybını hesaplamaktadır. İki veya daha fazla etiket sınıfı olduğunda çapraz entropi kaybı fonksiyonu kullanılmalıdır. Binary çapraz entropi fonksiyonu da bulunmaktadır fakat bu fonksiyonun sadece 2 etiket sınıfı olduğunda kullanılması uygundur [59]. Bu tez çalışmasında en uygun kayıp fonksiyonu olarak kategorik çapraz entropi kullanılmıştır.

Model veri setinin bir kısmıyla eğitilirken başka bir kısmıyla da eğitilmiş model değerlendirilmektedir. Fakat modelin eğitilmesi ve test edilmesi sırasında veri seti bölünmüş olmasına rağmen verinin dağılımına bağlı olarak bazı sapmalar ve hatalar meydana gelebilmektedir. K-kat çapraz doğrulama yöntemi sapmaları ve hataları minimum seviyeye getirebilmek için kullanılmıştır. Veri seti, belirlenen k sayısına göre eşit parçalara bölünmektedir ve her bir parça eğitim ve test etmek için kullanılmaktadır. Seçilen k sayısı model performansını etkilemektedir. Daha yüksek doğruluk değerleri k parametresinin doğru seçilmesiyle elde edilmektedir.

Genellikle 5 ya da 10 olarak seçilen k değerini seçmek için belirli bir kural yoktur. Bu çalışmada k değerleri 2'den 10'a kadar olacak şekilde değerlendirilmiştir. Atıkları sınıflandırmak için kullanılan MultiNet modelinin çapraz doğrulama deney sonuçlarına göre en iyi doğruluk 0,9777 olarak ve en düşük kayıp değeri 0,0155 olarak 7-kat çapraz doğrulama ile elde edilmiştir. Çizelge 3.1 ve Şekil 3.3'de farklı k değerleri için elde edilen doğruluk ve kayıp değerleri verilmiştir. Bu sonuçlara göre ortalama model performansının 0,9412 olduğu görülmektedir.

Çizelge 1.1. K-kat çapraz doğrulama sonuçları

K-Katlar	2-Kat	3-Kat	4-Kat	5-Kat	6-Kat	7-Kat	8-Kat	9-Kat	10-Kat	Averaj
Doğruluk değerleri	0,9111	0,9388	0,9044	0,9444	0,9722	0,9777	0,9497	0,9286	0,9441	0,9412
Kayıp değerleri	0,0823	0,0595	0,0851	0,0472	0,0228	0,0155	0,0393	0,0658	0,0409	0,0509



Şekil 3.3. K-kat çapraz doğrulama sonuçlarının grafiği

Çizelge 3.2'de eğitim sırasında kullanılan parametrelerin değerleri verilmiştir.

Çizelge 3.2. Eğitim parametreleri

Parametreler	Değer
Optimize etme yöntemi	adam
Öğrenme oranı	.0001
Kayıp fonksiyonu	Categorical_crossentropy
Metrikler	Doğruluk (accuracy)
Batch boyutu	32
Epochs	200

Derin sinir ağlarında hata oranını en aza indirmek için sıklıkla kullanılan 6 adet optimizasyon yöntemi bulunmaktadır. Bunlar SGD, Momentum, Adagrad, RMSProp, Adadelta ve Adam yöntemleridir. Bu tez çalışmasında en iyi optimizasyon Adam yöntemiyle elde edilmiştir. Adam yöntemi, RMSProp ve momentum yöntemlerinin avantajlı yönlerinin birleştirilmesi ile önerilen gradient descent algoritmasıdır. Adam optimizasyon yöntemiyle ilgili denklemler Eş. 3.1, Eş. 3.2, Eş. 3.3, Eş. 3.4 ve Eş. 3.5'deki gibidir. Mevcut gradient ($\partial L / \partial w_t$), öğrenme katsayısı (α), mevcut ağırlık (w_t), V_t geçmiş degradelerin karelerinin toplamı (başlangıçta sıfırdır), β hareketli ortalama parametresi (0,95), ϵ küçük bir pozitif sabit (10^{-8}) ve S_t mevcut gradyanların toplamıdır (başlangıçta sıfırdır) [60].

$$w_{t+1} = w_t - \frac{\alpha}{\sqrt{\hat{s}_t + \epsilon}} \cdot \hat{v}_t \quad (3.1)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_1^t} \quad (3.2)$$

$$\hat{s}_t = \frac{s_t}{1 - \beta_2^t} \quad (3.3)$$

$$v_t = \beta_1 v_{t-1} + (1 - \beta_1) \frac{\partial L}{\partial w_t} \quad (3.4)$$

$$s_t = \beta_2 s_{t-1} + (1 - \beta_2) \left[\frac{\partial L}{\partial w_t} \right]^2 \quad (3.5)$$

DenseNet-201, NasNetMobile, VGG-16, MobileNet, ResNet50, Xception olmak üzere 6 farklı transfer öğrenme yöntemleri kullanılarak elde edilen sonuçlar ile bu çalışmada kullanılan MultiNet ağının karşılaştırma sonuçları Çizelge 5'te verilmektedir. Tüm çalışmalarda "adam" optimize etme yöntemi kullanılmıştır ve epoch sayısı tümü için 200'dür. Çizelge 3.3'ten de görülebileceği gibi DenseNet-201 en iyi test doğruluğuna

sahiptir. 7-kat çapraz doğrulamalı MultiNet 0,98 ile DenseNet-201'e en yakın test sonucunu verirken, ResNet-50 0,96 ile en iyi üçüncü doğruluk sonucuna sahiptir.

Çizelge 3.3. 6 farklı önceden eğitilmiş model kullanılarak elde edilen sonuçlar

Model	Atık Kategorisi	Test Doğruluğu	Ortalama Skor
DenseNet-201	Kâğıt	0,99	0,99
	Cam	1,0	
	Plastik	0,98	
	Metal	1,0	
NasNetMobile	Kâğıt	0,92	0,89
	Cam	0,86	
	Plastik	0,91	
	Metal	0,9	
VGG-16	Kâğıt	0,91	0,93
	Cam	0,96	
	Plastik	0,96	
	Metal	0,92	
MobileNet	Kâğıt	0,94	0,92
	Cam	0,89	
	Plastik	0,92	
	Metal	0,95	
ResNet-50	Kâğıt	0,98	0,96
	Cam	0,96	
	Plastik	0,94	
	Metal	0,98	
MultiNet	Kâğıt	0,98	0,98
	Cam	0,96	
	Plastik	0,97	
	Metal	0,99	

Ağ eğitimi yapıldıktan sonra test veri setinden doğru ve yanlış olarak sınıflandırılan örnek görüntüler Şekil 3.4'de yer almaktadır.



Şekil 3.4. Test görüntülerinden doğru ve yanlış sınıflandırılan örnekler

4. TARTIŞMA

Bu bölümde geri dönüşüm kutusunun nihai halinin her açıdan değerlendirilmesi ve geri dönüşüm kutusunun daha iyi performans vermesini sağlayacak şeyler konular üzerinde durulmuştur.

Veri setinde bulunan görüntüler ana sınıfında çocukların kullanabileceği eşyalardan oluştuğu için veri sayısı sınırlı olmuştur. Günlük hayatta kullanılan verilerin de veri setine eklenmesi her ne kadar anasınıflarında kullanılmayacak olsa bile ağı eğitimi için daha yüksek doğrulukta sonuçlar elde edilebilmesine olanak sağlayacaktır. MultiNet modeli hastalıkları sınıflandırma işleminde kullanılırken çok yüksek sayıda veri içeren veri setlerinde başarılı olmuştur.

Veri setini oluşturan atık görüntüleri elde edilirken hazne kapakları siyaha boyanmıştır. Fakat atığın görüntüsünü daha net alabilmek ve ortam ışığının görüntü kalitesini bozmasını engellemek için kullanılan şerit ledin atık görüntülerinde hazne kapağından yansıdığı görülmektedir. Bu durum görüntüyü sınıflandırırken gürültü etkisi yaratmakta ve atık türünü tespit etmekte derin sinir ağının işini zorlaştırmaktadır. Bu nedenle hazne kapaklarının beyaza boyanması ile daha iyi sınıflandırma sonuçlarının elde edilebileceği ve derin sinir ağının hata yapma riskinin azalacağı ön görülmektedir.


Geri dönüşüm kutusu test edilirken kamera çoklayıcı modül nedeniyle atık görüntülerini alırken zaman kaybının olduğu fark edilmiştir. Her bir Raspberry Pi üzerinde 1 adet kamera çıkışı olduğundan dolayı her hazne için farklı Raspberry Pi kullanılması atık görüntüsünün alınma hızını büyük ölçüde arttıracaktır ve daha verimli çalışan bir sistem olacaktır. Fakat bu durumda maliyet artacağı için eğer çok hızlı bir çalışma gerekmiyorsa (2 saniye fark) kamera çoklayıcı modül de kullanılabilir.

Geri dönüşüm kutusu üzerinde kamera ve mesafe ölçen sensörlerin kullanıldığı delikler mevcuttur. Bu delikler nedeniyle mesafe sensörü biraz arkada kalmakta ve atık koyulup koyulmadığını tespit ederken bazen geç kalmaktadır. Bu problemin önüne geçebilmek için atık koyulurken eli algılayabilecek şekilde sensörlerin en öne yerleştirilmesi atığın çok daha erken algılanmasına olanak tanıyacaktır.

Servo motorların bağlantıları yapılırken güç beslemesini doğrudan Raspberry Pi'den olacak şekilde yapılmamıştır. Çünkü Raspberry Pi'ye zarar verme ve hatta yakma olasılığı nedeniyle tedbir amaçlı olarak dışardan 5 volt DC ile beslenmesi yeterli olacaktır. Mesafe ölçen sensörlerin ise güç bağlantıları doğrudan Raspberry Pi'den alınmış olup 8 adet sensörü de başarılı bir şekilde besleyebildiği görülmüştür.

Geri dönüşüm kutusunun 1,5 mm siyah sacdan değil de plastik profilden yapılması yada daha ince bir sacdan yapılması çok daha hafif olmasını sağlayacak ve taşınmasını kolaylaştıracaktır. Ayrıca kapakların ağır olması servo motorların bazen zorlanmasına sebep olmuştur.

MultiNet ağının eğitimi yapılırken bazı problemlerle karşılaşmıştır ve ağın Şekil 4.1'deki gibi aşırı öğrenme problemiyle (overfitting) karşılaşmıştır. Bu problemin çözülebilmesi için başlangıçta 0,2 olan dropout değerleri 0,4'e çıkarılmıştır. Aynı zamanda batch size 1 iken 32'ye çıkarılmıştır. Bu değişiklikler sonucunda eğitim doğruluğunun doğrulama doğruluğundan daha yüksek olmasını sağlamıştır.



Şekil 39. Aşırı öğrenme durumunda ortaya çıkan doğruluk ve kayıp grafiği

Geri dönüştürülebilir atıkların sınıflandırılması ile ilgili literatürde yer alan bazı çalışmalar TrashNet veri seti kullanılarak model eğitimi gerçekleştirmişlerdir [31, 33, 34]. Literatürdeki çalışmalarla bu çalışmada kullanılan MultiNet modelinin performansını kıyaslayabilmek için bu çalışmada özel olarak hazırlanan veri setinin yanı sıra TrashNet veri seti ile de atık görüntüleri sınıflandırılmıştır. Elde edilen sonuçların karşılaştırılması Çizelge 4.1'de verilmiştir. Kullanılan veri setleri aynı olsa bile veri arttırma yöntemlerinin farklı olması test doğruluklarının farklı olmasına sebep olan en büyük etmenlerden biridir.

Çizelge 4.1. MultiNet modelinin diğer yöntemlerle karşılaştırılması

Model	Veri seti	Sınıf Sayısı	Test Doğruluğu
RecycleNet (4 DenseNet121 Blocks), [31], 2018	TrashNet (2527 görüntü), [61]	6 (Kâğıt, cam, plastik, metal, karton, atık)	0,81
DenseNet-121 + fully connected layers were optimized by Genetic Algorithm, [33], 2021	TrashNet (2527 görüntü), [61]	6 (Kâğıt, cam, plastik, metal, karton, atık)	0,99
ResNet-18 + Self-monitoring module, [34], 2021	TrashNet (2527 görüntü), [61]	6 (Kâğıt, cam, plastik, metal, karton, atık)	0,95
DenseNet-201 + NasNetMobile + VGG-16 + Fine-tuned (Önerilen)	TrashNet (2527 görüntü), [61]	6 (Kâğıt, cam, plastik, metal, karton, atık)	0,95

Çizelge 4.1’de verilen ve 2018 yılında gerçekleştirilen RecycleNet adlı çalışmada TrashNet veri seti kullanılmış ve 4 DenseNet-121 bloğundan oluşan yapı kullanılarak atık görüntülerinin sınıflandırılması için %81 doğruluk elde edilmiştir [31]. 2021 yılında yapılan çalışmada TrashNet veri seti kullanılmış ve DenseNet121'deki tam bağlı katman, genetik bir algoritma kullanılarak optimize edilerek %99'luk bir doğruluğa ulaşılmıştır [33]. 2021’de yapılan ve TrashNet veri setinin kullanıldığı başka bir çalışmada, ResNet18 modeline bir kendi kendini izleme modülü ekleyerek %95 doğruluk elde edilmiştir [34]. Bu tez çalışmasında MultiNet modelinin TrashNet veri seti üzerindeki performansı %95 olarak bulunmuştur. MultiNet modeli çocuklara geri dönüşüm bilincini kazandırmak için tasarlanacak geri dönüşüm kutusunda kullanmak için yeterli bir derin sinir ağı olduğu bu sonuçlardan da anlaşılmaktadır. Çizelge 4.1’de görüleceği gibi, DenseNet-121 + genetik algoritma yöntemi en iyi performansı gösterirken, MultiNet modeli de ikinci en yüksek test doğruluğunu paylaşarak iyi bir performans sergilemiştir.

Zaten iyi bir sınıflandırma yeteneğine sahip olan DenseNet-121’in genetik algoritma ile birlikte kullanılması en yüksek doğruluk sonucunu vermiştir. Genetik algoritmanın model performansını nasıl daha iyi hale getirdiği araştırılmıştır. Genetik algoritmanın nöron sayısını ve tam bağlı katmanın (fully-connected-layer) dropout değerlerini optimize ettiği görülmüştür. Bu optimize etme yöntemi sayesinde konvolüsyon katmanındaki görüntünün özelliklerinin daha verimli şekilde elde edilmesini sağlamaktadır. Genetik algoritma tam

bağlı katmanın (fully-connected-layer) yüksek parametrelerine en iyi şekilde ince ayar yapmak için kullanılabileceği görülmektedir. Bu tez çalışmasında ince ayar yapmak için dropout katmanları, batch normalizasyon katmanları ve dense katmanları kullanılmaktadır.



5. SONUÇ VE ÖNERİLER

Bu çalışmada anaokulu ve ilkokulda çocuklara verilen geri dönüşüm eğitimi ile ilgili çalışmalar incelenmiş ve gömülü derin öğrenme sistemine sahip bir geri dönüşüm kutusu önerilmiştir. Geri dönüştürülebilir atıkların sınıflandırılmasında daha önce atık sınıflandırmasında kullanılmayan MultiNet derin sinir ağı kullanılmıştır. MultiNet, DenseNet-201, NasNetMobile ve VGG-16 olmak üzere önceden eğitilmiş 3 CNN modelinden oluşmaktadır. Bu modeli eğitmek için çocukların okulda kullandıkları plastik, cam, metal ve kâğıt atıklarının görüntülerinden oluşan özel bir veri seti oluşturulmuştur. Ağın ortalama sınıflama doğruluğu 7-kat çapraz doğrulama yöntemiyle %98 olmuştur. Bu çalışmada çocuklara geri dönüşüm konusunda farkındalık kazandırılması amaçlanmaktadır. Tasarlanan geri dönüşüm kutusu, çocukların gözetim altında olmasa bile yanlış hazneye atık atmalarına izin vermemekte, onlara atık türünü öğretmekte ve doğru seçim yaptıklarında onları mutlu etmektedir.

Tartışma bölümünde bahsedildiği gibi geri dönüşüm kutusunun performansını arttıracak çeşitli yaklaşımlar uygulanabilir. Hazne kapaklarının beyaza boyanması sonucunda atık sınıflandırma işleminin daha başarılı yapılacağı test edilerek belirlenmiştir. Geri dönüşüm kutusu çok daha hafif ve dayanıklı malzemeden tasarlansaydı taşınması çok daha kolay olabilirdi. Hazne kapaklarını görerek atık bırakıldığını tespit eden sensörlerin hareketi çok daha hızlı algılayabilmesi için kamera yanında değil de daha öne getirilmesi gerektiği tespit edilmiştir.

Çocukların bilişim çağında olduğu günümüzde, onları daha iyi eğitebilmek için derin sinir ağından faydalanmak oldukça etkili bir yöntemdir. Çocuklar doğru bir davranış gösterdiklerinde takdir edildikleri zaman aynı davranışı devam ettirmek istemektedirler. Bu tez çalışmasında önerilen akıllı geri dönüşüm kutusu ile hem çocuklara atıkları sınıfına uygun doğru hazneye atmaları için alışkanlık kazandırılacak hem de atık türleri öğretilmiş olacaktır. Bu çalışmadan alınacak ilham sonucunda ileride çok daha iyi çalışmaların ortaya çıkacağı ve bu tez çalışmasının literatüre faydalı olacağı düşünülmektedir.

İleriye yönelik bir çalışma olarak, çocukların geri dönüşümdeki başarılarını takip etmek için geri dönüşüm kutusunu kullandıklarında yüzlerinin tanınması ve kaydedilmesi planlanmaktadır. Atıkları geri dönüşüm kutusuna atarken yaptığı her doğru seçim için çocuğa +1 puan verilecektir. Her ayın sonunda en yüksek puanı alan çocuk, ayın en çevreye duyarlı çocuğu olarak ilan edilecektir. Bu yöntemle çocuklara geri dönüşüm eğitimi vermek daha kolay ve verimli olurken aynı zamanda çocuklar öğrenmeye daha istekli olacaklardır.



KAYNAKLAR

1. Şahin, S. (2016). Expressing the Changing World Population Structure with Visual Materials: Rethinking the Population Pyramids. *TÜCAUM International Geography Symposium*, 12, 434.
2. Purkayastha, D., Chakrabarti, S. (2014). Risk Assessment of Hapania Dumping Yard Using Integrated Risk Based Approach. *An International Peer Review E-3 Journal of Sciences*, 4, 2717-2727.
3. İnternet: Simmons, A. M. (2016). The World's Trash Crisis, And Why Many Americans Are Oblivious. URL: <https://www.latimes.com/world/global-development/la-fg-global-trash-20160422-20160421-snap-htlstory.html>, Son Erişim Tarihi: 12.03.2023.
4. İnternet: Disappearance Times of Wastes. (2023). URL: <https://www.cevremuhendisligi.org/index.php/cevre-aktuel/atiklarin-dogada-yok-olma-sureleri>, Son Erişim Tarihi: 01.06.2023.
5. İnternet: Deniz Canlıları Neden Plastiği Gıda Sanıp Yiyor?. (2018). URL: <https://www.bbc.com/turkce/haberler-dunya-45507225>, Son erişim tarihi: 12.03.2023.
6. İnternet: Türkiye'nin Ham Madde İthalatı. (2018). URL: <https://www.istka.org.tr/media/131269/t%C3%BCrkiye-nin-ham-madde-%C4%B0thalat%C4%B1.pdf>, Son erişim tarihi: 12.03.2023.
7. İnternet: Avrupa Türkiye'nin 3 Katı Plastik Atık İthal Ediyor. (2021). URL: <https://www.bloomberght.com/avrupa-turkiyenin-3-kati-plastik-atik-ithal-edip-hammadde-yapiyor-2284126>, Son erişim tarihi: 01.06.2023.
8. İnternet: Atık Yönetimi Piramidi. (2014). URL: <http://www.pagcev.org/geri-donusum>, Son erişim tarihi: 12.03.2023.
9. İnternet: The Economic Benefits of Recycling and Waste Reduction – Waste Wise Case Studies from the Private and Public Sectors. (2013). URL: <https://www.nj.gov/dep/dshw/recycling/wastewise/njwwcasestudy.pdf>, Son erişim tarihi: 12.03.2023.
10. İnternet: Atıkların Geri Dönüşümü Geçen Yıl Ekonomiye 2.2 Milyar Liralık Katkı Sağladı. (2021). URL: <https://www.hurriyet.com.tr/ekonomi/atiklarin-geri-donusumu-gecen-yil-ekonomiye-2-2-milyar-liralik-katki-sagladi-41772555>, Son erişim tarihi: 12.03.2023.
11. İnternet: Ülkemde Sıfır Atık. (2018). URL: <https://sifiratik.meb.gov.tr/>, Son erişim tarihi: 12.03.2023.
12. İnternet: Figure 2: MSW Treatment Method Shares For E.U. Countries, Switzerland, Norway, and Iceland as of 2018. (2020). URL: <https://www.wtert.net/paper/4308/Waste-Management-in-EU-Asia-and-Turkey.html>, Son erişim tarihi: 12.03.2023.

13. İnternet: Figure 5: MSW Management By Treatment Methods in Time For Turkey. (2020). URL: <https://www.wtert.net/paper/4308/Waste-Management-in-EU-Asia-and-Turkey.html>, Son erişim tarihi: 12.03.2023.
14. Rai, R. K., Neupane, S., Bhattarai, D. (2019). Designing solid waste collection strategy in small town of developing countries using choice experiment. *Journal of Urban Management*, 8, 386-395.
15. Raptopoulos, F., Papadopoulos, G., Mavrakakis, N., Maniadakis, M., Koskinopoulou, M. (2021). Robotic Waste Sorting Technology. *IEEE Robotics & Automation Magazine*, 1, 50-60.
16. İnternet: Cho R. Recycling in the US Is Broken. How Do We Fix It?. (2020). URL: <https://news.climate.columbia.edu/2020/03/13/fix-recycling-america/>, Son Erişim Tarihi: 12.03.2023.
17. Durant, D., Lucas, A. (2018). Manufacturing a Better Planet: Challenges Arising from the Gap between the Best Intentions and Social Realities. *Recycling*, 3, 17.
18. Sheng, T. J., Islam, M. T., Misran, N., Baharuddin, M. H., Arshad, H., Islam, M. S., Chowdhury, M. E. H., Rmili, H., Islam, M. D. R. (2020). An Internet of Things Based Smart Waste Management System Using LoRa and Tensorflow Deep Learning Model. *IEEE Access*, 8, 148793-148811.
19. İnternet: Smart Waste Management. (2023). URL: <http://ecubelabs.com/>, Son Erişim Tarihi: 12.05.2023.
20. Tuna Oran, N., Çeber Turfan, E., Çakır Koçak, Y. (2016). Waste Separation, Social Responsibility and Environmental Awareness Training. *Jaren*, 2, 97-102.
21. Maddox, P., Doran, C., Williams, I. D., Kus, M. (2011). The role of intergenerational influence in waste education programmes: The THAW project. *Waste Manage*, 31(12), 2590-2600.
22. Deng, J., Tang, J., Lu, C., Han, B., Liu, P. (2022). Commitment and intergenerational influence: A field study on the role of children in promoting recycling in the family. *Resources, Conservation & Recycling*, 185, 106403.
23. İnternet: Zero Waste in My Country. (2018). URL: <https://sifiratik.meb.gov.tr/>, Son Erişim Tarihi: 12.03.2023.
24. Sufia, R., Arisona, R. D. (2021). Introducing environmental education to early children through 3R activities (an effort for Indonesia free trash). *IOP Conference Series: Earth and Environmental Science*, 747, 012030.
25. Mostowfi, S., Mamaghani, N. K., Khorramar, M. (2016). Designing Playful Learning by Using Educational Board Game for Children In The Age Range of 7-12: (A Case Study: Recycling and Waste Separation Education Board Game). *International Journal of Environmental & Science Education*, 11, 5453-5476.
26. İnternet: Recycle2-Symbol. (2018). URL: <https://okuloncesi.eba.gov.tr/activity/151>, Son Erişim Tarihi: 12.03.2023.

27. İnternet: Recycling1-Waste Hunters. (2018). URL: <https://okuloncesi.eba.gov.tr/activity/138>, Son Erişim Tarihi: 12.03.2023.
28. Arnett, M., Luo, Z., Paladugula, P. K., Cardenas, I. S., Kim, J. H. (2020). Robots Teaching Recycling: Towards Improving Environmental Literacy of Children. *ACM/IEEE International Conference on Human-Robot Interaction*, 615-616.
29. Madyal, J., Platte, L., Arndt, J., Spangenberg, M., Zähl, K. (2020). MoBi – An Interactive Classroom Robot Helping Children to Separate Waste. *ACM/IEEE International Conference on Human-Robot Interaction*, 629-630.
30. Rossano, V., Macchiarulo, N., Errico, F. D., Carolis, B. D. (2019). Investigating the Social Robots' Role in Improving Children Attitudes toward Recycling. The case of PeppeRecycle. *10th IEEE International Conference on Cognitive Infocommunications (CogInfoCom)*, 10, 301-306.
31. Bircanoğlu, C., Atay, M., Beşer, F., Genç, Ö., Kızrak, M. A. (2018). RecycleNet: IntelligentWaste Sorting Using Deep Neural Networks. *In Proceedings of the 2018 Innovations in Intelligent Systems and Applications (INISTA)*, 1, 1-7.
32. Ahmad, K., Khan, K., Al-Fuqaha, A. (2020). Intelligent Fusion of Deep Features for Improved Waste Classification. *IEEE Access*, 8, 96495-96504.
33. Mao, W. L., Chen, W. C., Wang, C. T., Lin, Y. H. (2021). Recycling waste classification using optimized convolutional neural network. *Resources, Conservation & Recycling*, 164, 105132.
34. 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 & Recycling*, 171, 105636.
35. Gulbe, A., Altikat, S., Altikat, A. (2021). Intelligent solid waste classification using deep convolutional neural networks. *International Journal of Environmental Science and Technology*, 1, 1-8.
36. Hassan, H., Saad, F., Raklan, M. S. M. (2018). *A Low-Cost Automated Sorting Recycle Bin powered by Arduino Microcontroller*. IEEE Conference on Systems, Process and Control (ICSPC 2018), Shah Alam, 182-186, 8704146.
37. Makhseed, M., Salam, F. A., El-Aswad, S., Esmaeili, S. E. (2021). *Design and Assembly of A Smart Recycling Bin*. HORA 2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications, Online, Proceedings, 2021.
38. Wahyutama, A. B., Hwang, M. (2022). YOLO-Based Object Detection for Separate Collection of Recyclables and Capacity Monitoring of Trash Bins. *Electronics Switzerland*, 11(9), 1323.
39. Rahman, M. W., Islam, R., Hasan, A., Bithi, N. I., Hasan, M. M., Rahman, M. M. (2022). Intelligent waste management system using deep learning with IoT. *Journal of King Saud University - Computer and Information Sciences*, 34(5), 2072–2087.

40. Khan, S. I., Shahrior, A., Karim, R., Hasan, M., Rahman, A. (2022). MultiNet: A deep neural network approach for detecting breast cancer through multi-scale feature fusion. *Journal of King Saud University-Computer and Information Sciences*, 34, 6217-6228.
41. Al Fryan, L. H., Shomo, M. I., Alazzam, M. B. (2023). Application of Deep Learning System Technology in Identification of Women's Breast Cancer. *Medicina (Lithuania)*, 59(3), 487.
42. Diao, S., Luo, W., Hou, J., Lambo, R., Al-Kuhali, H. A., Zhao, H., Tian, Y., Xie, Y., Zaki, N., Qin, W. (2023). Deep Multi-Magnification Similarity Learning for Histopathological Image Classification. *IEEE Journal of Biomedical and Health Informatics*, 27(3), 1535–1545.
43. Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. (2017). *Densely connected convolutional networks*. Proceedings of the IEEE conference on computer vision and pattern recognition, Honolulu, 4700–4708.
44. Hao, W., Zhang, Z. (2019). Spatiotemporal distilled dense-connectivity network for video action recognition. *Pattern Recognition*, 92, 13–24.
45. Türk, F., Kökver, Y. (2022). Application with deep learning models for COVID-19 diagnosis. *Sakarya University Journal of Computer And Information Sciences*, 5(2), 169-180.
46. Zoph, B., Vasudevan, V., Shlens, J., Le, Q. V. (2018). *Learning transferable architectures for scalable image recognition*. Proceedings of the IEEE conference on computer vision and pattern recognition, Salt Lake City, 8697–8710.
47. Saxen, F., Werner, P., Handrich, S., Othman, E., Dinges, L., Al-Hamadi, A. (2019). *Face attribute detection with mobilenetv2 and nasnet-mobile*. 11th International Symposium on Image and Signal Processing and Analysis (ISPA), Dubrovnik, 176–180.
48. Simonyan, K., Zisserman, A. (2015). *Very deep convolutional networks for large-scale image recognition*. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, San Diego, 1-14.
49. Özkaraca, O., Bagriacık, O. I., Gürüler, H., Khan, F., Hussain, J., Khan, J., Laila, U. (2023). Multiple Brain Tumor Classification with Dense CNN Architecture Using Brain MRI Images. *Life*, 13, 349.
50. Scherer, D., Müller, A., Behnke, S., (2010). *Evaluation of pooling operations in convolutional architectures for object recognition*. International conference on artificial neural networks, Springer, Thessaloniki, 92–101.
51. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15, 1929–1958.
52. İnternet: Raspberry Pi ile Servo Motor Kontrolü. (2020). URL: <https://www.hayatimadokun.com/post/raspberry-pi-ile-servo-motor-kontrol%C3%BC>, Son Erişim Tarihi: 01.06.2023.

53. İnternet: Multi-Camera Array Introduction. (2022). URL: <https://docs.arducam.com/Raspberry-Pi-Camera/Multi-Camera-CamArray/Multi-Camera-CamArray/>, Son Erişim Tarihi: 01.06.2023.
54. İnternet: Using a Raspberry Pi distance sensor (ultrasonic sensor HC-SR04). (2017). URL: <https://tutorials-raspberrypi.com/raspberry-pi-ultrasonic-sensor-hc-sr04/>, Son Erişim Tarihi: 01.06.2023.
55. İnternet: Raspberry Pinout. (2023). URL: <https://pinout.xyz/>, Son Erişim Tarihi: 12.03.2023.
56. İnternet: Debian. (2021). URL: <https://raspi.debian.net/>, Son Erişim Tarihi: 26.07.2023.
57. İnternet: Getting started. (2021). URL: <https://www.raspberrypi.com/documentation/computers/getting-started.html>, Son Erişim Tarihi: 01.06.2023.
58. İnternet: Make a Pi Trash Classifier with ML!. (2020). URL: <https://www.hackster.io/jenfoxbot/make-a-pi-trash-classifier-with-ml-e037a6>, Son Erişim Tarihi: 01.06.2023.
59. İnternet: Keras Loss Fonksiyonları. (2021). URL: <https://medium.com/operations-management-t%C3%BCrkiye/keras-loss-fonksiyonlar%C4%B1-2955e86a9e07>, Son Erişim Tarihi: 01.06.2023.
60. Seyyarer, E., Ayata, F., Uçkan, T., Karci, A. (2020). Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması Ve Kiyaslanması. *Anatolian Journal of Computer Sciences*, 5, 2, 90-98.
61. İnternet: Trashnet veri seti. (2017). URL: <https://github.com/garyhung/trashnet>, Son Erişim Tarihi: 01.06.2023.





Gazili olmak ayrıcalıktır