

DERİN ÖĞRENME İLE ÇEVRESEL ATIKLARIN SINIFLANDIRILMASINA DAYALI AKILLI ÇÖP KONTEYNERİ TASARIMI VE PROTOTİPİNİN GELİŞTİRİLMESİ

Mehmet Umut SALUR^{1*}, Nermin ELMAS², Aybuke Nur KOÇAK³, Melike KAYMAZ⁴

^{1,2,3,4} Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Gaziantep, 27470, Türkiye

Geliş Tarihi/Received Date: 28.09.2024 Kabul Tarihi/Accepted Date: 22.12.2024 DOI:10.54365/adyumbd.1557588

ÖZET

Günümüzde dünya nüfusunun artışıyla birlikte kentlerde ve sanayide yüksek oranda doğal kaynak kullanılmaktadır. Bu kaynak kullanımı, beraberinde tonlarca çevresel atığın oluşmasına neden olmaktadır. Bu kirlilik, gelecek nesiller için sürdürülebilir dünyanın varlığı konusunda ciddi tehdit oluşturmaktadır. Günümüz teknolojisiyle çevresel atıkların yönetimi için derin öğrenme ve görüntü işleme tabanlı çözümleri geliştirmek mümkündür. Bu çalışmada çevresel atıklardan geri dönüşümü mümkün olanların (kağıt, plastik, metal ve cam) yerinde ve otomatik bir şekilde sınıflandırılması ve ayrıştırılması için görüntü işleme ve Raspberry Pi tabanlı akıllı çöp konteyneri prototipi gerçekleştirilmiştir. Akıllı çöp konteynerine bırakılan bir atık; i- hareket algılama sensörüyle fark edilmekte, ii- atığın fotoğrafı çekilmekte, iii- çekilen fotoğraf derin öğrenmeyle sınıflandırılmakta, iv- atığın sınıfı belirlendikten sonra adım motoru yardımıyla çöp konteynerin içindeki ilgili bölüme taşımaktadır. Bu yönüyle insan müdahalesi olamadan dönüştürülebilen çevresel atıklar yerinde ve otomatik bir şekilde ayrıştırılmaktadır. Akıllı çöp konteyneri, çevresel atıkların geri dönüşüme kazandırılması ve yönetilmesi sürecini hem maliyet hem de insan iş gücü açısından iyileştirme potansiyeline sahiptir.

Anahtar Kelimeler: Çevresel Atıkların Sınıflandırılması, Derin Öğrenme, Raspberry Pi, Görüntü İşleme

DESIGN AND PROTOTYPE DEVELOPMENT OF A SMART GARBAGE CONTAINER BASED ON ENVIRONMENTAL WASTE CLASSIFICATION USING DEEP LEARNING

ABSTRACT

Today, with the population increase in the world, natural resources are used at a high rate in cities and industry. This resource use causes the formation of tonnes of environmental waste. This pollution poses a serious threat to the existence of a sustainable world for future generations. Today, it is possible to develop deep learning and image processing based solutions for environmental waste management. In this study, an image processing and Raspberry Pi based smart garbage container prototype has been realised for on-site and automatic classification and sorting of recyclable environmental wastes (paper, plastic, metal and glass). A waste left in the smart waste container is i- motion detected by a motion detection sensor, ii- image of the waste is taken, iii- image is classified by deep learning, iv- after the class of the waste is determined, it is moved to the relevant section in the waste container with the help of a stepper motor. This approach ensures that recyclable environmental waste is separated automatically without human intervention. The smart waste container has the potential to improve the recycling and management of environmental waste, offering benefits in terms of cost-efficiency and reduced human labor requirements.

Keywords: Classification of Environmental Waste, Deep Learning, Raspberry Pi, Image Processing

* e-posta¹: mehmetumut.salur@gibtu.edu.tr ORCID ID: <https://orcid.org/0000-0003-0296-6266> (Sorumlu Yazar)
e-posta²: nerminelmas02@gmail.com ORCID ID: <https://orcid.org/0009-0004-5617-6344>
e-posta³: aybukekck001@gmail.com ORCID ID: <https://orcid.org/0009-0005-2467-4477>
e-posta⁴: melikekaymaz0@gmail.com ORCID ID: <https://orcid.org/0009-0007-6142-2978>

1. Giriş

Her yıl milyarlarca tona ulaşan çevresel atıklar geri dönüştürülemeden doğada tehdit unsuru olarak dünya iklimi ve yaşam alanlarını olumsuz etkilemektedir. Sürdürülebilir bir yaşam ve çevre için öncelikli hedef, çevresel atık oluşumunu en aza indirmektir. İkinci bir çözüm ise, oluşan atıkların geri dönüşüm yoluyla doğadan temizlenmesi ve yeniden kullanıma kazandırılmasıdır. Bu kapsamda, çevresel atıkların geri dönüştürülmesi ülkemizde ve dünyada yeni politikalara ve teknolojilere açık bir araştırma alanıdır. Dünya nüfusunun her geçen yıl büyümesi bu alandaki araştırmalara olan ilgiyi de beraberinde getirmektedir. Gelecek kuşaklara daha sürdürülebilir bir dünya mirası bırakmak için çevresel atıkların geri dönüştürülmesi büyük önem taşımaktadır [1]. Çevresel atıkların sınıflandırılması ve geri dönüştürülebilir atıkların daha hızlı bir şekilde doğaya kazandırılması, sürdürülebilir bir gelecek için temel oluşturmaktadır. Ayrıca, ham madde üretiminin düşmesi enerji tasarrufu sağlamak ve doğal kaynakların korunmasına yardımcı olmaktadır. Geleneksel yöntemlerle çevresel atıkların toplanması ve ayrıştırılması süreci, manuel işlemlerle zaman alıcı bir süreçtir [2]. Ancak, günümüzde gelişen teknolojiyle Raspberry Pi gibi mikrobilgisayarlar ve derin öğrenme algoritmaları bu süreci hızlandırmak ve optimize etmek için önemli bir potansiyel sunmaktadır.

Günümüzde çevresel atıklar günlük periyotlarla çöp araçları tarafından toplanmakta ve çöp ayrıştırma merkezlerinde manuel yöntemlerle ayrıştırıldıktan sonra bir kısmı geri dönüşüme tabi tutulmaktadır. Ancak bu yöntem maliyet, zaman, süreç ve insan gücü açısından yüksek maliyetler gerektirmektedir. Bu çalışmada çevresel atıkların çöp toplama merkezlerine taşınmadan yerinde ayrıştırılması problemi için derin öğrenme ve Raspberry Pi tabanlı akıllı çöp konteyneri tasarımının gerçekleştirilmesi ele alınmıştır. Sistem prototipinin geliştirilmesiyle çevresel atıkların yönetimi hem maliyet hem de insan gücü açısından iyileştirilmiştir. Akıllı çöp konteyneri tasarımıyla çevresel atıklar çöp konteynerine bırakıldıktan sonra otomatik bir şekilde sınıflandırılmakta ve ilgili kategorileri (kağıt, metal, plastik vb.) temsil eden bölümlerde biriktirmektedir. Bunun sonucunda çöplerin toplanmasından sonra her kategori doğrudan çevresel atık geri dönüşüm merkezlerinde yeniden dönüştürülebilecektir. Bu şekilde çevresel atıkların yönetimi ve işletilmesi süreci iyileştirilmiş ve geliştirilmiştir. Bu da sürdürülebilir bir dünya ve dünyada yaşam çeşitliliği açısından önem arz etmektedir. Çevresel atıkların görüntü işleme yöntemleriyle sınıflandırılması son yıllarda önemli araştırma alanlarından biri olmuştur [1-3]. Görüntü işleme tabanlı ve entegre sistem olarak geri dönüştürülebilir nesnelere sınıflandıran ve nesneye göre kullanıcı bakiyesini arttıran sistem gerçekleştirilmiştir [4].

Bu çalışmada derin öğrenme ve Raspberry Pi tabanlı sistem bileşenlerinden oluşan akıllı çöp konteyneri tasarımı ve gerçekleştirilmesi yapılmıştır. Akıllı çöp konteyneri tasarımında çöpler tek bir noktadan konteynerin içine bırakılıp sistem tarafından otomatik bir şekilde sınıflandırıldıktan sonra ilgili kategoriye ait bölüme taşınmaktadır. Akıllı konteyner tasarımı bu yönüyle mevcut çözümlerden ayrılmaktadır. Akıllı konteyneri sistemi tasarımı görüntü işleme, derin öğrenme ve nesnelere interneti konseptinde otomatik bir şekilde çöpleri ayrıştırmaktadır. Derin öğrenme ve Raspberry Pi'nin birleşimi, daha hızlı, doğru ve ekonomik bir atık sınıflandırma sistemi sunmaktadır. Sürdürülebilir bir gelecek için çevresel atıkların geri dönüştürülmesinde önemli bir adım olarak değerlendirilebilir. Çalışmanın katkıları aşağıda sunulmuştur:

- Çevresel atıkların sınıflandırılmasında ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modelleri üzerinde ince-ayar (fine-tuning) yapılmış ve bu yöntemle literatürdeki çalışmalara kıyasla daha yüksek başarı oranları elde edilmiştir.
- Çevresel atıkların yerinde ayrıştırılması için yeni bir akıllı çöp konteyneri tasarımı gerçekleştirilmiştir.
- Raspberry Pi kullanılarak çevresel atıkların görüntülerinin alınması, sınıflandırılması ve ayrıştırılmasını sağlayan sistem geliştirilmiştir.

Çalışmanın ikinci bölümünde ilgili çalışmalar, üçüncü bölümünde materyal ve metot, dördüncü bölümde deneysel sonuçlar ve tartışma ve son bölümde ise çalışmanın sonucu sunulmuştur.

2. İlgili Çalışmalar

Son yıllarda derin öğrenme, görüntü işleme ve sınıflandırma alanlarında sağlık, tarım, ilaç, havacılık, güvenlik ve otonom araçlar gibi pek çok bilim dalında oldukça başarılı sonuçlar sağlamaktadır [3]. Ahmed ve ark., çevresel atıkları sınıflandırmak için CNN (Convolutional Neural Network) mimarileri olan DenseNet169, MobileNetV2 ve ResNet50V2 modellerini kullanmış; bu modellerle sırasıyla %94,40, %97,60 ve %98,95 doğruluk oranlarına ulaşmışlardır [5].

Yıldız ve ark., atıkları sınıflandırmak için CNN mimarileri olan AlexNet, GoogLeNet, ResNet50, DenseNet201, ShuffleNet ve SqueezeNet kullanmışlardır [3]. DenseNet201 mimarisi kullanılarak özellik haritaları elde edilmiştir ve bu haritalar SVM (Support Vector Machine), KNN (K-Nearest Neighbors) ve DT (Decision Trees) algoritmalarına giriş olarak verilmiştir. DenseNet201 mimarisinin SVM, DT ve KNN sınıflandırıcılar ile hibritlenmesi sonucunda sırasıyla 89.70%, 66.90% ve 83.40% doğruluk elde edildiği görülmüştür. Elde edilen özellik haritaları, SVM sınıflandırıcısında en yüksek doğruluğu elde ettiğini göstermiştir. Ayrıca modellerin başarısını yalnızca doğrulukla değerlendirmek yeterli olmadığından, önerilen yöntemin etkinliği, farklı performans metrikleri kullanılarak da belirlenmiştir. DenseNet201+SVM modelinin performansı değerlendirilmiş ve en yüksek doğruluk oranı %97.82 olarak karton sınıfında, en düşük ise %95.69 ile kâğıt sınıfında elde edilmiştir.

Tatke ve ark., derin sinir ağları ve bilgisayarlı görme gibi teknolojilerin kullanımıyla atıkların sınıflandırma sürecini daha etkili hale gelmesi adına derin öğrenme modellerini karşılaştırarak analiz etmiştir [6]. Araştırmada CNN, ResNet50, VGG16 gibi modeller test edilmiştir. Model eğitimi için güçlü TensorFlow kütüphanesinin kullanılması, modellerin sağlam ve doğru sonuçlar vermesine ve minimal hata oranına sahip olmasına ek bir avantaj sağlamıştır. Bu modellerin sonuçlarının karşılaştırmalı analizinden ResNet50'nin en iyi performansı sunduğu ve bu konuyla ilgili uygulama odaklı bir yaklaşım için kolayca uygulanabileceği sonucuna varılmıştır. Modelin yüksek doğruluk göstermesinde, ResNet50'nin öğrenilebilir parametre sayısı ve atlamalı bağlantıların, eğitim sırasında gradyanlar üzerinde daha tutarlı bir geriye yayılma sağlaması olduğu vurgulanmıştır.

Alsubaei ve ark., akıllı şehirlerin hızlı kentleşmesi, atıkların etkili geri dönüşümü için akıllı ve otomatik atık yönetim tekniklerinin tasarlanmasına dair araştırmalar yapmıştır [7]. Önerilen DLSODC-GWM tekniği, akıllı atık yönetim sistemlerini desteklemek amacıyla küçük çöp atık nesnelerinin tespiti ve sınıflandırılmasına odaklanmaktadır. Bu teknik, nesne tespiti ve sınıflandırma olmak üzere iki ana süreçten oluşmaktadır. Nesne tespiti için IRD modelinin hiperparametrelerinin AOA (Arithmetic Optimization Algorithm) ile optimal olarak seçildiği geliştirilmiş bir RefineDet (IRD) modeli uygulanmıştır. Ardından, atık nesnelerin çeşitli sınıflara ayrılması için fonksiyonel bağlantı sinir ağı (FLNN) kullanılmıştır. Atık sınıflandırması için IRD ve AOA tabanlı hiperparametre ayarının yeniliği çalışmanın özgünlüğünü vurgulamaktadır. DLSODC-GWM tekniğinin performansı, referans veri kümeleriyle doğrulanmış ve deneysel sonuçlar, mevcut yöntemlerle karşılaştırıldığında DLSODC-GWM'nin %98,61'e varan doğruluk oranıyla üstün performans sergilediğini göstermiştir.

Varol ve ark., araştırmalarında atık görüntülerini sınıflandırmak amacıyla, açık erişimli Garbage Classification veri setini çalışmaya uygun hale getirip kullanmışlardır [2]. Deneysel süreçlerde özellik çıkarımı için CNN mimarilerinden DarkNet-19 modeli tercih edilmiştir. Performans, çeşitli metriklerle ölçülmüş ve %96'lara varan doğruluk değerleri elde edilmiştir.

Kang ve ark., görüntü sınıflandırma algoritmalarının evrimini ve derin öğrenme teknolojisinin uygulanmasını ele almıştır [8]. Son teknoloji algoritmalar olan AlexNet, VGG, Inception ve ResNet üzerinde araştırmalar yapılmıştır. ResNet-34 ve ResNet-152 modelleri, doğruluk ve kayıp açısından başarılı sonuçlar vermiştir. Ancak, hesaplama hızının azalması nedeniyle temel model olarak ResNet-34 tercih edilmiştir. ResNet-34 modeli üç farklı şekilde modifiye edilmiştir: çoklu özellik füzyonu, artık

birimlerin özelliklerinin yeniden kullanımı ve aktivasyon fonksiyonunun optimizasyonu. Her bir değişiklik, çevresel atık veri seti üzerinde test edilmiş ve orijinal ResNet-34'e kıyasla daha yüksek bir doğruluk elde edilmiştir. Modifikasyonları birleştiren tüm ResNet-34 verilerinin, en yüksek doğruluğa sahip olduğu görülmüştür. Önerilen algoritma ve donanım ile otomatik bir çöp sınıflandırma sistemi entegre edilmiştir. Bu sistem %99,96 kadar bir sınıflandırma doğruluğuna ve ortalama 0,95 saniyelik bir sınıflandırma döngüsüne sahiptir. Sürücü ve ark. önceden eğitilen modeller ile atıkları otomatik olarak sınıflandırmayı amaçlamışlardır. Modeller arasında Resnet50-V2 modeli %97,07 başarıyla öne çıkmıştır [9].

Keskin ve ark., sınıflandırma problemi için CNN mimarilerini kullanarak modellerin doğruluk oranlarını karşılaştırmış ve ResNet101, ConvNeXt ve DenseNet121 ile yapılan analizlerde, ResNet101'in doğruluk açısından diğer mimarilere kıyasla daha üstün bir performans sergilediğini tespit etmişlerdir [10]. Resnet101, %97,72 doğruluk oranıyla en başarılı model olarak öne çıkmıştır. Çalışmada ResNet101'in daha derin yapısı ve sıçrama bağlantıları sayesinde diğer modellere kıyasla daha yüksek doğruluk ve verimlilik sağladığını ortaya koymuştur.

Zhou ve ark., derin öğrenme tabanlı otomatik çöp tanıma ve sınıflandırma sistemi geliştirmiştir [11]. Çalışma, ResNet50, YOLOv5 ve zayıf denetimli CNN algoritmalarını entegre ederek çevresel atık yönetimi için yüksek doğruluk ve verimlilik sağlayan bir yaklaşım önermektedir. HGI-30 ve TrashNet gibi veri setleri üzerinde yapılan deneylerde önerilen model, geleneksel yöntemlere kıyasla doğruluk (%97,02), F1 skoru (%91,87) ve AUC (%91,22) metriklerinde üstün performans sergilemiştir. Sistem, şehirlerin sürdürülebilir gelişimine destek olmak amacıyla nesnelerin interneti (IoT) teknolojileriyle de entegre edilmiştir.

Wu ve ark., ev ortamında çöp tespiti ve sınıflandırması için görsel sahne anlama temelli bir yöntem önermiştir [12]. Çalışmada, YOLOv5m modeline ESA (Efficient Spatial Attention) mekanizması entegre edilerek YOLOv5m-Attention-KG modeli geliştirilmiştir. Bu model, bilgi grafikleri ile birleştirilerek nesne özelliklerinin daha etkili bir şekilde analiz edilmesini sağlamıştır. Model, 15.000 görüntüden oluşan veri seti üzerinde eğitilmiş ve %73,2 mAP ve 28 FPS performans göstermiştir. Sistem, ev hizmet robotları gibi uç cihazlarda gerçek zamanlı algılama ve sınıflandırma sağlayarak enerji tüketimini azaltmak ve sınıflandırma sürecini otomatikleştirmek için sunulmuştur.

Chen ve ark., atık sınıflandırma yöntemlerinde derin öğrenme teknolojisinin uygulamasını incelemiş ve ShuffleNetV2 modelini temel alarak GCNet adlı bir sınıflandırma modeli geliştirmiştir [13]. ShuffleNetV2, paralel karışık dikkat mekanizması (PMAM), FReLU aktivasyon fonksiyonu ve transfer öğrenme ile iyileştirilmiştir. PMAM, modelin boyutsal ve kanal özelliklerini güçlendirirken, FReLU aktivasyon fonksiyonu piksel seviyesinde uzamsal modelleme sağlayarak doğruluk performansını artırmıştır. GCNet modeli, yazarların kendi oluşturduğu 4.256 görüntüden oluşan veri seti üzerinde test edilmiş ve %97,9 doğruluk oranına ulaşmıştır. Ayrıca, model yalnızca 1.3M parametreye sahiptir ve Raspberry Pi 4B üzerinde 105 ms tekil çıkarım süresi ile çalışmaktadır. Yapılan modifikasyonlar sonucunda, GCNet'in ShuffleNet v2'den %4,5 daha yüksek doğruluk elde ettiği görülmüştür.

Fan ve ark., ev ortamında atık sınıflandırması için Raspberry Pi tabanlı akıllı bir çöp konteyneri tasarlamış ve geliştirmiştir [14]. Çalışmada, EfficientNetB2 modeli, paralel karışık dikkat mekanizması (PMAM) ve arka plan gürültü giderme algoritması ile modifiye edilmiştir. EfficientNetB2 modeli, son havuzlama katmanından önce PMAM ile güçlendirilmiş ve görüntü işleme sırasında arka planın etkisini azaltmak için özel bir ön işleme algoritması uygulanmıştır. Model, günlük ev atıklarının dört kategoride sınıflandırılmasını sağlamıştır: geri dönüştürülebilir, mutfak, tehlikeli ve diğer atıklar. Toplamda 14.802 görüntü içeren bir veri setinde %93,38 doğruluk oranı elde edilmiştir. Sistem, düşük maliyetli bir donanım olan Raspberry Pi 4B üzerine entegre edilmiştir. Bu sistem, günlük atık yönetimi için uygun maliyetli ve etkili bir çözüm sunarak, akıllı ev uygulamaları ve geri dönüşüm süreçlerinde kullanılabilir hale getirilmiştir.


Jin ve ark., atık tespiti ve sınıflandırması için derin öğrenme tabanlı bir makine görüş sistemi geliştirmiştir [15]. Çalışmada MobileNetV2 modeli temel alınarak dikkat mekanizmaları (CBAM) ve

PCA ile modifiye edilmiştir. MobileNetV2 modeli üç farklı şekilde optimize edilmiştir: dikkat mekanizmaları ile özellik çıkarımının iyileştirilmesi, PCA ile parametre sayısının azaltılması ve aktarım öğrenmesi ile modelin genelleme kabiliyetinin artırılması. Her bir iyileştirme, Huawei Cloud veri seti üzerinde test edilmiş ve %90,7 gibi yüksek bir doğruluk oranına ulaşılmıştır. Önerilen model ve sistem, taşınabilir bir cihazda (Raspberry Pi 4B) uygulanmış ve otomatik bir çöp sınıflandırma cihazı olarak entegre edilmiştir.

Literatürdeki çalışmalar atık çöplerin sınıflandırılmasında derin öğrenme modellerin performansını artıracak parametre optimizasyonu, katman ve hiperparametre sayısı belirleme, dikkat mekanizması kullanma ve son teknoloji modellerini geliştirme konularına yoğunlaşmıştır. Bu çalışmada derin öğrenme modellerinin veri kümesine uyumunu sağlamak için son teknoloji modellerinin ince-ayarları (fine-tuning) yapılmıştır. Son yıllarda nesnenelerin interneti konseptinde çalışan çevresel atıkları sınıflandıran akıllı cihazların geliştirilmesi ve üretilmesi literatürde çalışılan güncel konular arasında yer almaktadır. Bu sistemler genellikle Raspberry Pi gibi ucuz ve düşük donanım kaynaklarına sahip küçük entegreler üzerinde geliştirilmektedir. Bu çalışmada çevresel atıkların sınıflandırılmasında Raspberry Pi üzerinde çalışacak bir akıllı çöp konteyneri sistemi tasarımı ve gerçekleştirilmesi yapılmıştır. Literatürde önerilen sistemlere göre bu çalışmada önerilen sistemin bazı farklılıkları bulunmaktadır. Bunların başında önerilen sistemin hem ev hem de dış ortam için kolaylıkla ürüne dönüştürülebilir yapıda olması gelmektedir. Ayrıca önerilen sistemde çevresel atığın taşınması ve ilgili bölüme bırakılması adım motoru gibi düşük maliyetli bir mekanizmayla gerçekleştirilmektedir.

3. Materyal ve Metod

Akıllı çöp konteyneri prototipi için geliştirilen yöntemin temel aşamalarının genel şeması Şekil 1’de verilmiştir. Bu çalışmada temel de dört aşama bulunmaktadır. Bu aşamalar çöp konteyneri tasarımı, sistem bileşenlerinin kurulumu, çevresel atıkların derin öğrenmeyle sınıflandırılması ve sistem entegrasyonu ve testlerinin yapılması şeklindedir.



Şekil 1. Önerilen yöntem; çevresel atıkları sınıflandırmanın temel aşamaları

Akıllı çöp konteyneri sistemindeki amaç insan müdahalesi olmadan çevresel atıkların derin öğrenme ve bilgisayarlı görü teknolojileri sayesinde yerinde otomatik bir şekilde sınıflandırılmasıdır. Birinci aşamada çöp konteyneri tasarımı gerçekleştirilmiştir. Konteyner üzerinde Raspberry Pi kurulumu ve tasarıma yerleştirilmesi yanında kamera, hareket algılama sensörü ve çevresel atıkları ilgili bölüme taşıyan hareketli ray sistemi bulunmaktadır. Bu aşamada, bu devrelerin konteyner üzerindeki yerleri, konteynerin büyüklüğü vb. tasarımlar gerçekleştirilmiştir.

İkinci aşamada akıllı çöp konteyneri için sistem bileşenlerinin kurulumu gerçekleştirilmiştir. Bu aşamada i- Raspberry Pi işletim sisteminin versiyon olarak en güncel hali olan Raspberry Pi OS kurulumu, ii- derin öğrenme kütüphanelerinden Tensorflow ve Keras kurulumu, iii- hareketi algılayan sensörün yerleştirilmesi ve sensörü kontrol eden uygulamaların geliştirilmesi, iv- hareketli atık çöp plakasının yerleştirilmesi, adım motoru kurulumu ve hareketi gerçekleştiren uygulamaların geliştirilmesi, v- kamera sisteminin entegrasyonu işlemleri gerçekleştirilmiştir.

Üçüncü aşamada Raspberry Pi ile çevresel atıklar derin öğrenme modelleriyle sınıflandırılmıştır. Sınıflandırma işlemi için literatürde görüntü işleme alanında yüksek performans sağlayan DenseNet201, Inception-V3, ResNet50, VGG16 ve DenseNet169 modelleri kullanılmıştır. Bu modellerin performansını arttırmak ve veri kümesine uyumunu sağlamak adına ince-ayar (fine-tuning) yapılmıştır. Bu kapsamda modellere ek eğitilebilir katmanlar eklenmiş ve performans testleri yapılmıştır. Derin öğrenme modelleri yardımıyla çöp konteynerine atılan atıkların sınıfları cam, metal, kağıt ve plastik olarak tahmin etmiştir. Bu modellerin literatürdeki çevresel atık veri kümeleri üzerindeki performansları araştırılmıştır. Bu araştırma sonucunda en iyi başarıyı gösteren model Raspberry Pi üzerinde akıllı çöp konteynerinin sınıflandırıcı metodu olmuştur. Belirlenen bu model yardımıyla atılan atıkların sınıfları belirlendikten sonra hareketli ray sistemi atığı, ilgili atık bölümüne hareket ederek götürmüştür.

Dördüncü aşamada bir bütün olarak sistemin entegrasyonu yapılmış ve örnek senaryolar doğrultusunda akıllı çöp konteynerinin performansı değerlendirilmiştir. Sistemin çalışmasını sağlayan bir bütün yazılım geliştirmesi ve modülleri entegrasyonu bu aşamada gerçekleştirilmiştir. Kamera görüntülerinin algılanması uygulaması, hareket sensörü uygulaması, hareketli ray sistemini kontrol uygulaması ve üçüncü aşamada geliştirilen derin öğrenme sınıflandırma uygulamaları bu aşamada birleştirilerek akıllı çöp konteyneri yazılımı Raspberry Pi üzerinde çalıştırılmıştır.

3.1. Akıllı Çöp Konteyneri Tasarımı

Çevresel atık çeşitleri için ayrılmış dört bölmeden oluşan çöp konteyneri tasarımı Şekil 2’de verilmiştir. Bir çevresel atık çöp konteynerine hareketli plaka üzerine bırakıldıktan sonra; i- sensör çevresel atığı fark edip kamera yardımıyla görüntüsünü almakta, ii- derin öğrenme modeliyle sınıflandırılmakta, iii- hareketli plaka adım motoru yardımıyla ray üzerinde hareket ederek çöpi ilgili bölüme taşımaktadır. Hareketli atık taşıyıcı plaka ilgili kategori üzerine geldikten sonra çöpi bu alandan aşağıya atılması planlanmıştır. Ancak hareketli atık taşıyıcı plakanın açılır kapanır şekilde tasarlanması ele alınmamıştır. Atık kutularının üst bölmesindeki kutu içerisinde tüm donanım ekipmanları bulunmaktadır (Raspberry Pi, kamera, sensörler, motorlar, kablolar, ray sistemi). Oluşturulan prototip konteyner, kartondan tasarlanmıştır.



Şekil 2. Akıllı çöp konteyneri bileşenleri

Şekil 3’te çöp konteyneri üzerinde çalışan hareketli ray sisteminin tasarımı verilmiştir. Atık konteynerine atıldıktan sonra Şekil 3’teki görüldüğü gibi hareketli atık taşıyıcı plaka üzerine düşmektedir.

Plaka ileri-geri olacak şekilde adım motor yardımıyla iki yönlü hareket etmektedir. Ray sisteminin hareketi adım motor ile sağlanmıştır. Ray tasarımı ve ray hareket yolunun tasarımında ipler ve çubuklar kullanılmıştır.



Şekil 3. Hareketli ray tasarımı

3.2. Sistem Bileşenlerinin Kurulumu ve Entegrasyonu

Çöp görüntülerinin sınıflandırılması ve çöp taşıyıcı ray sisteminin kontrol edilmesi işlemleri tasarlanan prototip üzerine yerleştirilen Raspberry Pi 4 Model B yardımıyla gerçekleştirilmiştir. Raspberry Pi, tek bir kart üzerine inşa edilmiş kompakt bir küçük bilgisayardır. Bir bilgisayarın ihtiyaç duyduğu işlemci, RAM, giriş/çıkış portları gibi tüm bileşenler, bu tek devre kartında bir araya getirilmiştir.

Raspberry Pi Kamera Modülü 3, Raspberry Pi kamera serisinin en yaygın kamera parçasıdır. Raspberry Pi'den adım motoru kontrolünü sağlamak için motor sürücü devresi olarak ULN2003A kullanılmıştır. Atık konteynere atıldığında Raspberry Pi Kamera Modülünün fotoğrafı çekebilmesi için Hc-sr501 ayarlanabilir hareket algılama sensörü aracılığıyla tespit edilmektedir. Adım motorlar adım adım döndürülebilen çok hassas konum kontrol imkanı sağlayan motorlardır. Hareketli plakanın çöp bölümleri arasında hareketi için adım motor kullanılmıştır. BreadBoard devrelerimizi birbirine lehimlemeden kurmamıza, test yapmamıza ve devreyi kontrol ederek bir hata olup olmadığını anlamamıza olanak sağlamaktadır. Hareketli ray sisteminin kontrolü için kullanılan modüller Şekil 4'te verilmiştir.




a-) Raspberry Pi 4 Model B



b-) 28 BYJ-48 Redüktörlü Adım Motoru



c-) ULN2003A Adım Motor Sürücü Kartı



d-) HC-SR501 Ayarlanabilir IR Hareket Algılama Sensörü




e-) Raspberry Pi Kamera Modülü 3

Şekil 4. Sistem bileşenleri

16 GB büyüklüğünde bir SD kartına Raspberry Pi'nin kendi işletim sisteminin kurulumu yapılmıştır. Bu kurulumdan sonra Şekil 5'te şeması gösterilen bağlantılar gerçekleştirilerek devre tamamlanmıştır. Adım motorun dönme sayısı ve dönme hızı oluşturmuş ray prototipinin şekline ve uzunluğuna göre belirlenmiştir. Adım motoru sayesinde hareketli atık taşıyıcı plaka ilgili atığın hizasına getirilmiştir. Akıllı çöp konteyneri bileşenleri tasarlanan prototip üzerine yerleştirilmiştir.

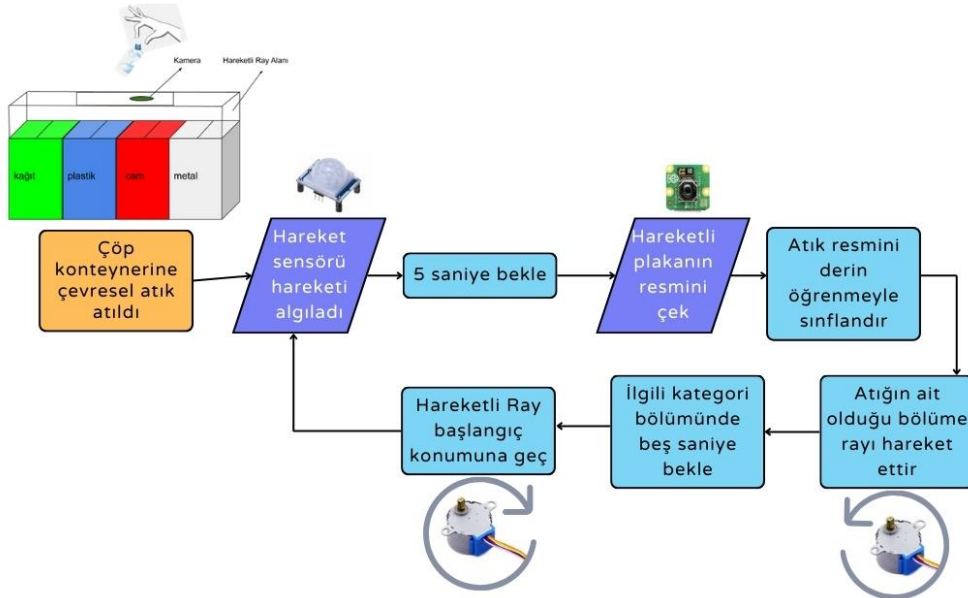
Raspberry Pi kartında derin öğrenme modellerinin çalıştırılabilmesi için TensorFlow Lite kurulumu yapılmıştır. TensorFlow, Google Beyin ekibi tarafından makine öğrenmesi algoritmalarının uygulanması amacıyla geliştirilmiş bir yazılım çatısıdır [16]. TensorFlow temelde derin öğrenme

ağlarının kullanımını desteklemek için geliştirilmiştir. TensorFlow'un yanında Keras yazılım çatısı kullanılmıştır. Keras yardımıyla aynı uygulama içerisinde hem yinelemeli hem de evrişimsel sinir ağı modeli tanımlanabilmektedir. Modüler bir yapı sağladığından her ağ katmanının özellikleri kolayca belirlenebilmektedir. Yani maliyet fonksiyonlar, aktivasyon fonksiyonları, iyileştirme yöntemleri, seyreltme (Dropout) gibi model için önem arz eden parametreler birer satırla belirlenmektedir [17].



Şekil 5. Devre bağlantı şeması

Derin öğrenme modelinin literatürdeki veri seti üzerindeki eğitimi tamamlandıktan sonra kameradan alınan görüntülerin sınıfının tahmin edilmesi için Raspberry Pi'ye yüklenmiştir. Modelin sınıflandırma sonucuna göre adım motoru yardımıyla çevresel atığın ilgili bölmeye götürülmesi sağlanmıştır. Gerçek sistem testinde fiziksel atıklar yerine fiziksel atıkların fotoğrafları çöp konteynerine bırakılmıştır. Çevresel atıkların çöp konteynerine bırakılmasıyla, hareket sensörü algılama yapmakta ve akıllı çöp konteyneri için geliştirilen sistem çalışmaya başlamaktadır. Hareketin algılanmasından beş saniye sonra sistemdeki kamera aracılığıyla fotoğraf çekilmiştir. Akıllı çöp konteynerinin örnek bir senaryosunda yapılan işlemlerin akış şeması Şekil 6'da verilmiştir.




Şekil 6. Akıllı çöp konteyneri çalışmasının akış şeması

3.3. Çevresel Atıkların Derin Öğrenmeyle Sınıflandırılması

Çevresel atıkların sınıflandırılması aşamasında derin öğrenme yöntemleri kullanılmıştır. Derin öğrenme, yapay sinir ağlarının etkili ve verimli bir versiyonudur [18]. Yapay sinir ağlarıyla yapılan öğrenme işlemini yüksek katman sayısına sahip modellerle gerçekleştirme işlemi günümüzde kaba bir tanımla derin öğrenme olarak ifade edilmektedir [19]. Derin öğrenme algoritmaları veri kümesi içerisinde öznelik çıkarımını otomatik olarak gerçekleştirmektedir. CNN modeli, derin öğrenmenin en önemli mimarilerinden biridir. Genellikle görüntü sınıflandırma amacıyla kullanılan CNN modelinin, girişi bir görüntü olurken, çıkışı ise görüntünün sınıf etiket değeridir.

Görüntü verilerini giriş olarak alan ve görüntünün sınıfını tespit etmeye çalışan bir CNN modelinin katmanlar arasındaki ilişkilerini belirten şema Şekil 7'de verilmiştir. CNN'de çeşitli filtreler yardımıyla görüntüden öznelik çıkarımı işlemi evrişim katmanında yapılmaktadır. Evrişim katmanından elde edilen özneliklerin doğrusal olmamasının sağlanması için genellikle evrişim katmanı ile havuzlama katmanı arasında ReLU (Rectified Linear Units) aktivasyon fonksiyonu uygulanmaktadır [20]. Havuzlama katmanında ise elde edilen bu özellik haritalarının boyutları düşürülmektedir. CNN'nin son katmanı ise tam bağlı katmandır.



Şekil 7. Görüntü sınıflandırma için genel CNN katmanları görünümü

Çevresel atıkların sınıflandırmasında ve sistemin testlerinin yapılması aşamasında görüntü sınıflandırmada çokça tercih edilen ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modelleri üzerinde performans araştırmaları yapılmıştır. Bu beş model arasında en iyi başarıyı elde edilen model sistemin sınıflandırıcı modeli olarak seçilip entegrasyonu yapılmıştır.

ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 görsel tanıma ve sınıflandırma için kullanılan CNN modelleridir. DenseNet201 ve DenseNet169 "yoğun bağlantılar" olarak bilinen yapıyı kullanmaktadır. Yoğun bağlantılar, her katmanın kendinden önceki tüm katmanların çıktılarına bağlandığı anlamındadır. Bu, bilgi akışını artırır, parametre sayısını azaltır ve gradyanın daha iyi aktarılmasını sağlamaktadır. DenseNet169 ise 169 katmandan oluşan bir modelken, DenseNet201 201 katmandan oluşan bir modeldir [21]. ResNet50 "geri kalan bağlantılar" olarak bilinen bir yapıdadır. Bu daha derin ağların eğitimini kolaylaştırır ve aşırı öğrenmeyi azaltmaktadır. ResNet50, 50 katmandan oluşan bir başka CNN modelidir. ResNet modelinin diğer modellerden ayırt edici özelliği, daha derin bir yapıya sahip olmasıdır. 2015 yılındaki ILSVRC yarışmasında %3.6 hata oranıyla birinci olmuştur [22].


VGG16, 2014 yılında Simonyan ve Zisserman tarafından geliştirilmiş derin öğrenme modelidir. Modelin 16 katmanlı olduğunu belirtmek için VGG16 olarak isimlendirilmiştir. VGG16 modelinde 138 milyondan fazla parametre bulunmaktadır [23].

Inception modeli Szegedy ve ark. tarafından 2015 yılında geliştirilmiştir. Inception-V3 modeli Inception-V1 ve Inception-V2 modelinin iyileştirilmesiyle oluşturulmuştur. Inception-V3 modelinde 24 milyon parametre bulunmaktadır [23]. Inception modeli, evrişim katmanındaki filtreleme ve havuzlama işlemlerinin eş zamanlı olarak yapılmasını sağlamıştır [24]. Çevresel atıkların sınıflandırılmasında bu

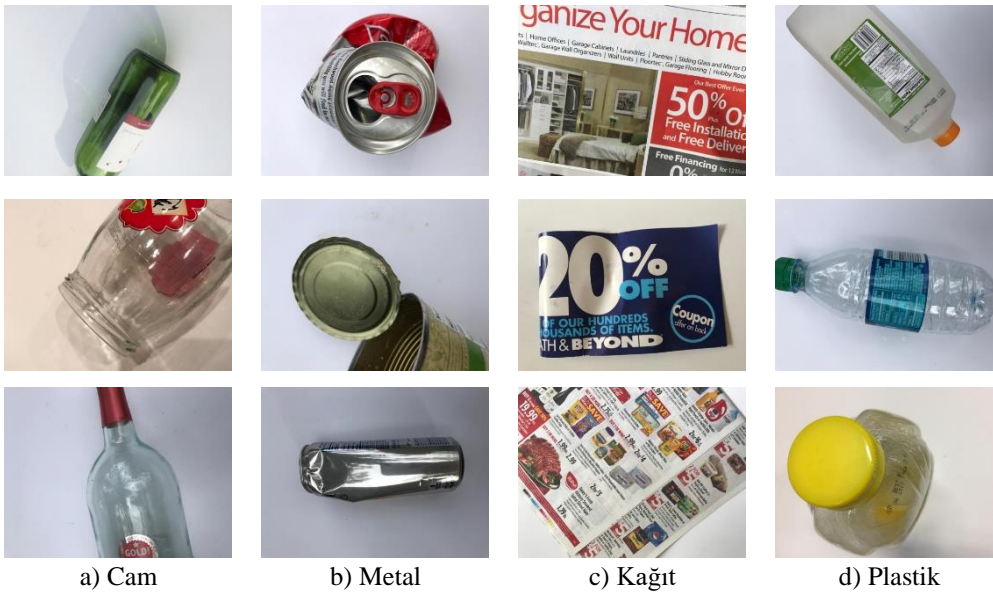
modeller referans alınmış ve veri kümesi üzerinde ince-ayar (fine-tuning) ve parametre optimizasyonu yapılmıştır.

3.3.1 Veri Kümesi

Sistemin ön testlerinin yapılmasında ve derin öğrenme modellerinin performans araştırması aşamasında Garbage Classification veri seti kullanılmıştır [25]. Bu veri seti 2021 yılında yayınlanmış ve literatürde sıklıkla kullanılan bir kıyaslama veri setidir. Veri seti güvenilir bir kaynak olan Kaggle platformundan erişildiği için, verilerin doğru etiketlendiği kabul edilmiştir. Toplamda 2527 görüntüden oluşan bu veri seti, 6 farklı sınıfa ayrılmıştır. Ancak bu çalışmada 4 sınıfa ait (Cam, Metal, Kağıt ve Plastik) 1947 adet görüntü kullanılmıştır. Bunların %80 (1589) eğitim, %20 (398) ise test aşamasında kullanılmıştır. Şekil 8’de sınıf bazlı görüntü sayıları test ve eğitim olarak yer almaktadır. Ayrıca Şekil 9’da her sınıfa ait üç adet örnek görüntü verilmiştir.



Şekil 8. Veri kümesinin sınıf bazlı görüntü sayıları



Şekil 9. Veri kümesi örnek görüntüleri; a) Cam, b) Metal, c) Kağıt ve d) Plastik

3.3.2 Model Performans Değerlendirme Ölçütleri

Her bir çevresel atık görüntüsünün plastik, metal, kağıt ve cam olarak sınıflandırılması aşamasında algoritmanın başarımları için literatürdeki metrikler kullanılmıştır. Bu metrikler; doğruluk (Denklem 1), hassasiyet (Denklem 2), duyarlılık (Denklem 3) ve F-ölçütü (Denklem 4) şeklindedir. Bu ölçütlerin hesaplanmasında karmaşıklık matrisi kullanılmaktadır. Şekil 10'da karmaşıklık matrisinin görseli verilmiştir.

Tahmin Edilen	Pozitif	TP	FP
	Negatif	FN	TN
		Pozitif	Negatif
		Gerçek	

Şekil 10. Karmaşıklık matrisi

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Hassasiyet (Precision)} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP + FP} \quad (3)$$

$$F - \text{ölçütü (F - measure)} = 2 * \left(\frac{\text{hassasiyet} * \text{duyarlılık}}{\text{hassasiyet} + \text{duyarlılık}} \right) \quad (4)$$

4. Deneysel Sonuçlar ve Tartışma

Raspberry Pi üzerinde derin öğrenme modellerinin eğitilmesi ve test edilmesi için derin öğrenme kütüphanelerinden Tensorflow ve Keras kullanılmıştır. Raspberry Pi üzerine ise Tensorflow Lite kurulumu gerçekleştirilmiştir. Bu kurulum ile hali hazırda eğitilmiş olan derin öğrenme modelleri çalıştırılmıştır. Eğitilmiş olan .h5 uzantılı model dosyaları öncesinde Google Colab ortamında .tflite olarak dönüştürülmüştür. Bu dönüşümün yapılmasının nedeni Keras'ın tflite içerisinde kullanılmamasından kaynaklanmaktadır. Sonrasında Raspberry Pi üzerinde .tflite uzantılı dosya kullanılarak sınıflandırılma gerçekleştirilmiştir.

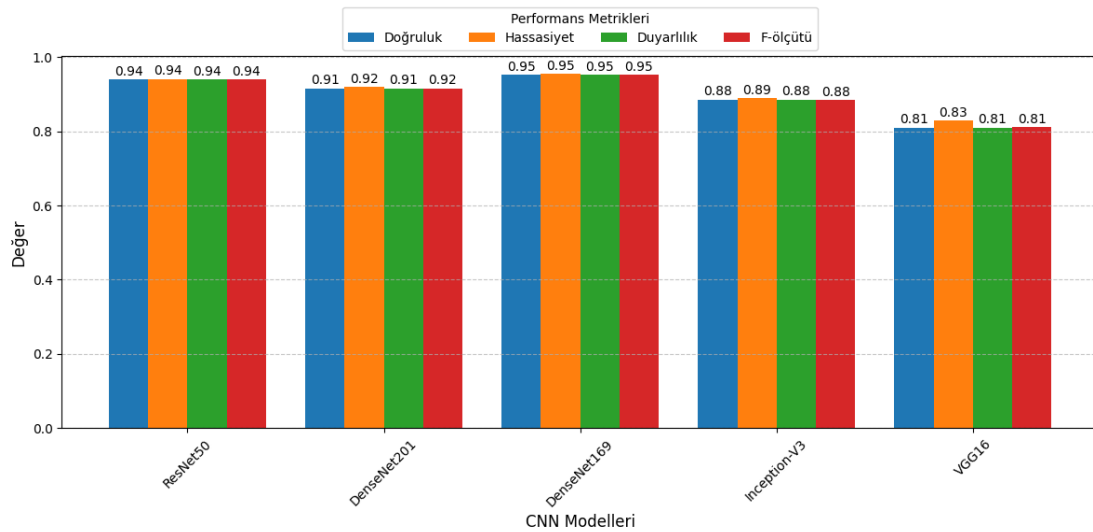
Çevresel atıkların sınıflandırılmasında ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modelleri kullanılmıştır. Modellerin ince-ayar (fine-tuning) ve parametre optimizasyonu süreçleri, doğruluk ve genel başarı metriklerini artırmak amacıyla dikkatlice tasarlanmıştır. Bu süreçte, temel olarak transfer öğrenme kullanılmış ve modeller, önceden ImageNet veri seti üzerinde eğitilmiş ağırlıklarla başlatılmıştır. İnce-ayar sürecinde, yalnızca son katmanlar yeniden eğitilmiş, böylece hesaplama maliyeti azaltılmış ve eğitim sürecinin daha hızlı olması sağlanmıştır. Her modelin sonuna eğitilebilir tam bağlı katman ve havuzlanma katmanları eklenmiştir. Tam bağlı katmandaki nöron sayısı 1024, 512, 256, 128, 64 ve 32 olacak şekilde deneyler gerçekleştirilmiştir. Model performansı doğrulama

veri seti üzerinde test edilerek, her model için en iyi hiperparametreler seçilmiştir. Tüm modellerin ince-ayar sırasında doğrulama kaybı (validation loss) göz önünde bulundurulmuş ve erken durdurma (early stopping) tekniği kullanılarak aşırı öğrenme (overfitting) önlenmiştir. Sınıflandırmada her model için ince-ayar (fine-tuning) ve parametre optimizasyonu yapılmış olup yapılan değişiklikler aşağıdaki gibidir:

- **ResNet50:** Bu model için iki boyutlu ortalama havuzlama katmanı kullanılarak, modelin çıkışındaki özellik haritalarının her bir kanalının ortalaması alınmıştır. Bu işlem, yüksek düzeyde özetlenmiş bir özellik vektörü oluşturur ve modelin daha genel özellikleri öğrenmesini sağlar. Bu özetlenmiş özellik vektöründen sonra, 256 nöronlu oluşan bir Dense katmanı eklenmiştir. Bu katman, ReLU aktivasyon fonksiyonunu kullanarak modelin daha karmaşık ilişkileri öğrenmesini sağlamıştır ve gizli katman aracılığıyla yüksek düzeyde özellikler çıkarmıştır. Aşırı uyumu önlemek amacıyla, Dropout katmanı eklenmiş ve burada nöronların %50'si rastgele devre dışı bırakılmıştır. Bu, modelin genelleme yeteneğini artırarak, eğitim verisine aşırı uyum sağlamasını önlemiştir. Dört sınıfa karşılık gelen birimlerden oluşan bir Dense çıkış katmanı eklenmiş ve softmax aktivasyon fonksiyonu kullanılmıştır. Bu katman, her bir sınıf için olasılık değerleri üretmiş ve çok sınıflı sınıflandırma problemlerinde kullanılacak nihai tahminleri sağlamıştır.
- **DenseNet201:** Bu model için iki boyutlu ortalama havuzlama katmanı kullanılarak özellik haritalarının boyutu küçültülmüştür. Ardından, 256 nöronlu ve 'relu' aktivasyon fonksiyonuna sahip tam bağlantılı bir katman olan *Dense(256, kernel_regularizer=l2(0.001))* katmanı eklenmiştir. Bu katmanı, aktivasyonları normalize eden *BatchNormalization()* ve aşırı uyumu önlemek için nöronların %50'sini devre dışı bırakan *Dropout(0.5)* katmanları izlemiştir. Daha sonra, 256 nöronlu bir tam bağlantılı katman olan *Dense(256, activation='relu', kernel_regularizer=l2(0.001))* ve yine %50 dropout katmanı aşırı uyumu önlemek için eklenmiştir. Dört sınıfa karşılık gelen birimlerden oluşan bir Dense çıkış katmanı eklenmiş ve softmax aktivasyon fonksiyonu kullanılmıştır.
- **DenseNet169:** Bu model için *GlobalAveragePooling2D()* katmanı kullanılarak özellik haritalarının boyutu küçültülmüştür. Sonrasında 32 nöronlu oluşan bir tam bağlı (Dense) katman eklenmiştir.
- **Inception-V3:** Bu model için *GlobalAveragePooling2D()* katmanı eklenmiştir. Ardından, 512 nöronlu ve 'relu' aktivasyon fonksiyonuna sahip bir tam bağlantılı Dense katmanı eklenmiştir. Bu katmanı, modelin genelleme kabiliyetini artırmak için nöronların %50'sini devre dışı bırakan *Dropout(0.5)* katmanı izlemiştir. Son olarak, dört sınıflı bir sınıflandırma için *Dense(len(classes_dict), activation='softmax')(x)* kullanılmıştır.
- **VGG16:** Bu modelde hiper parametre olarak 512 nöronlu ve 'relu' aktivasyon fonksiyonuna sahip tam bağlantılı bir katman olan *Dense(512, kernel_regularizer=l2(0.001))* iki adet katman eklenmiştir. Dense katmanının *kernel_regularizer=l2(0.001)* oranı ile ağırlıkların aşırı büyümesini sınırlayarak aşırı uyumu önlemeye yardımcı olmuştur. *BatchNormalization* katmanı ile her bir özellik vektörünü normalleştirilmiştir. Normalizasyon, eğitim sürecini hızlandırmış ve modelin performansını arttırmıştır.

ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modelleri ile deneyler yapılmıştır. Çalışılan tüm modellerin eğitimi yüz iterasyonda tamamlanmıştır. Tüm modellerde eğitim sırasında aynı veri seti kullanılarak karşılaştırma yapılmıştır. Kullanılan veri seti %80 eğitim, %20 test olarak ayrılmıştır. ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modellerinin testinde doğruluk, hassasiyet, duyarlılık ve F-ölçütü metrik sonuçları Şekil 11'de sunulmuştur. Beş

modelin doğrulama doğruluk değerleri ResNet50 %94, DenseNet201 %91, DenseNet169 %95, InceptionNet %88 ve VGG16 ise %81 olarak elde edilmiştir. Modeller arasında DenseNet169, dört metrikte de en yüksek performansı göstererek (%95,22 doğruluk, %95,45 hassasiyet, %95,22 duyarlılık ve %95,21 F-ölçütü) genel olarak en iyi model olmuştur. Bu üstünlük, DenseNet169'un yoğun bağlantı yapısının, özelliklerin yeniden kullanımını kolaylaştırması ve gradyanların daha verimli bir şekilde akmasını sağlamasından kaynaklanmaktadır. ResNet50, %93,97 doğruluk ve diğer metriklerdeki dengeli sonuçlarıyla iyi bir performans sergilemiş; sıçrama bağlantıları sayesinde daha derin bir ağ olmasına rağmen gradyan kaybını engelleyerek yüksek doğruluk sağlamıştır. Ancak, DenseNet169'un daha küçük ancak optimize edilmiş bir model olması onu ResNet50'nin önüne geçirmiştir. DenseNet201, %91,45 doğruluk ve benzer seviyelerdeki diğer metriklerle DenseNet169'un gerisinde kalmıştır. Bunun nedeni, daha derin bir yapı olmasına rağmen ek derinliğin modelin genelleme kabiliyetine katkı sağlayamaması ve hesaplama yükünü artırması olabilir. Inception-V3, %88,44 doğruluk ile ortalama bir performans göstermiştir. Modelin çok ölçekli özellik çıkarımı yapısı avantaj sağlasa da daha modern modellerin sunduğu yoğun bağlantılar ve sıçrama mekanizmalarının eksikliği performansını sınırlamıştır. Ayrıca Inception-V3 modelinin eğitim ve test aşamalarındaki performansı arasında %8'e yakın bir fark olduğu görülmüştür. Bu modelin eğitim ve test aşamalarındaki doğruluk değerleri arasındaki başarımlar diğer modellere göre daha yüksektir. Bu nedenle bu modelin eğitim aşamasında aşırı uyum (overfitting) olduğu söylenebilir. Son olarak, VGG16, %80,90 doğruluk ile en düşük performansı göstermiştir. Bu modelin sınırlı özellik çıkarımı yapısı ve yüksek parametre sayısı, modern modellerle karşılaştırıldığında düşük bir doğrulukla sonuçlanmıştır.




Şekil 11. Derin öğrenme modellerinin başarımlar metrikleri

DenseNet169'un diğer modellerden daha başarılı olmasının nedenleri arasında yoğun bağlantı (dense connectivity) yapısının olduğunu söylemek mümkündür. Bu mimari, her katmanın kendisinden önceki tüm katmanların çıktısını giriş olarak kullanmasını sağlayarak bilgi kaybını önlemekte ve özelliklerin yeniden kullanılmasını sağlamaktadır. Bu modelin gradyanların akışı iyileştirilir ve eğitilebilirliği artırılır. Ayrıca, DenseNet169 daha az parametreyle çalışarak aşırı öğrenme riskini azaltmış ve veri setinde genelleme yapabilme kabiliyetini güçlendirmiştir. DenseNet169'un optimize edilmiş derinliği, DenseNet201 gibi daha derin modellere kıyasla hesaplama verimliliğini korurken yüksek performans sunmasına olanak tanımıştır. Ayrıca DenseNet169 için yapılan ince-ayarda modelin sonuna 32 nöronlu tam bağlı katman eklenmiştir. Diğer modellere göre daha az sayıda nöronla yüksek başarımlar elde edilmiştir.

Şekil 12'de modellerin eğitim ve test aşamalarındaki doğruluk ve hata eğrileri verilmiştir. Şekil 12 a ve b'de eğitim ve doğrulama aşamalarındaki doğruluk değerlerinin eğrileri verilmiştir. Diğer taraftan




c ve d’de ise eğitim ve doğrulama aşamasındaki hata eğrileri verilmiştir. Modellerin eğitim ve test aşamaları için 100 iterasyon olacak şekilde erken durdurma (early stopping) mekanizmasıyla eğitimi ve testi yapılmıştır. Şekil 12’deki eğrilere bakıldığında modellerin 25 iterasyon sonrasında en düşük hata değerine eriştikleri görülmektedir. Modellerden en hızlı yakınsayan modelin DenseNet169 olduğu görülmektedir.



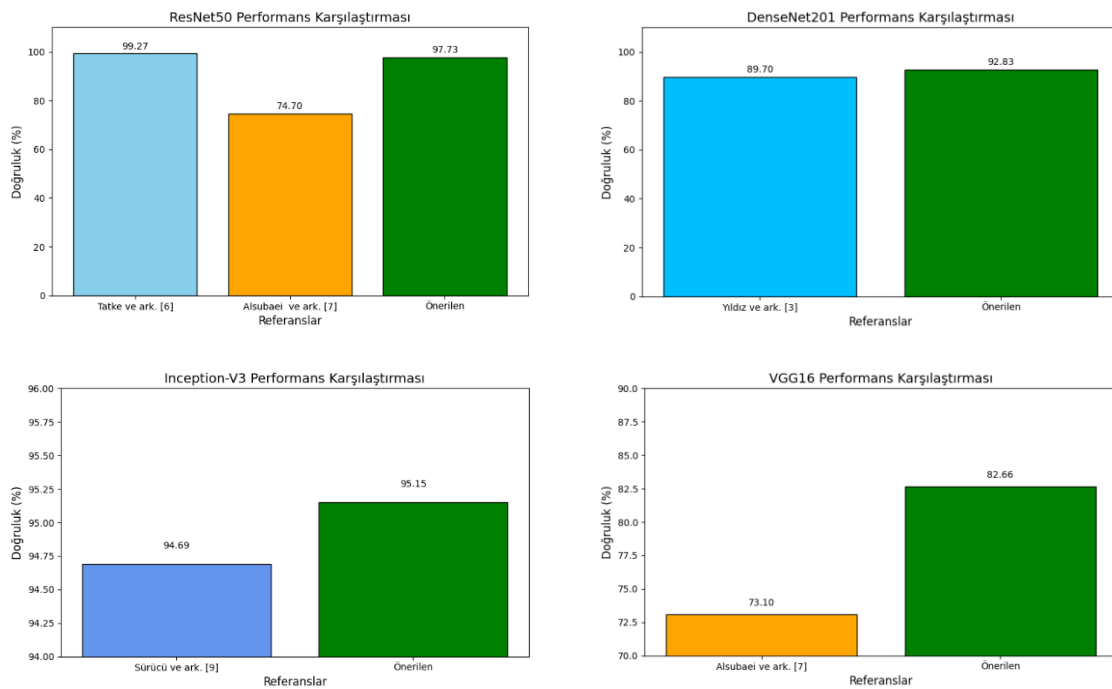
Şekil 12. Derin öğrenme modellerinin eğitim ve test aşamasındaki doğruluk ve hata eğrileri

Modellerin eğitimleri tamamlandıktan sonra yeni görüntülerle modellerin tahmin ve güven değerleri incelenmiştir. Yapılan bu testlerden bazı örneklerin sonuçları Çizelge 1’de verilmiştir. Çizelge 1’deki örneklere bakıldığında DenseNet201 ve VGG16 modellerinin bazı örnekleri yanlış sınıflandırdığı (kalın olarak vurgulanmıştır) görülmektedir.

Çizelge 1. Modellerin bazı örneklerdeki sınıflandırma sonuçları.

Giriş Görüntüsü	Kağıt		Plastik		Cam	
	Tahmin	Güven	Tahmin	Güven	Tahmin	Güven
	ResNet50	Kağıt	0,99	DenseNet201	Metal	0,86
	Inception-V3	Kağıt	0,63	DenseNet169	Plastik	1,0
	VGG16	Plastik	0,86	Inception-V3	Plastik	0,99
	ResNet50	Kağıt	0,99	DenseNet201	Plastik	0,97
	DenseNet169	Kağıt	0,86	Inception-V3	Plastik	0,99
	VGG16	Plastik	0,86	DenseNet169	Plastik	1,0
	ResNet50	Kağıt	0,99	Inception-V3	Cam	0,88
	DenseNet201	Metal	0,86	VGG16	Cam	0,99
	DenseNet169	Kağıt	0,86	ResNet50	Cam	0,99
	Inception-V3	Kağıt	0,63	DenseNet201	Cam	0,94
	VGG16	Plastik	0,86	DenseNet169	Cam	0,93
	ResNet50	Kağıt	0,99	Inception-V3	Cam	0,88
	DenseNet201	Metal	0,86	VGG16	Cam	0,99
	DenseNet169	Kağıt	0,86	ResNet50	Cam	0,99
	Inception-V3	Kağıt	0,63	DenseNet201	Cam	0,94
	VGG16	Plastik	0,86	DenseNet169	Cam	0,93

Bu çalışmada kullanılan modellerin eğitim aşamasındaki doğruluk değerlerinin aynı veri kümesi üzerinde gerçekleştirilen önceki çalışmalarla kıyaslanması Şekil 13'te yapılmıştır. İnce-ayar ve parametreleri belirlenen modellerin performanslarının önceki çalışmalarla karşılaştırıldığında genel olarak daha yüksek doğruluk oranlarına ulaştığını göstermektedir. ResNet50 modeli, %97.73 doğruluk ile Alsubaei ve ark.'nın (%74.70) çalışmasından belirgin şekilde üstün performans sergilemiş, ancak Takke ve ark.'nın (%99.27) elde ettiği doğruluğun biraz gerisinde kalmıştır. DenseNet201 modeli ise Yıldız ve ark.'nın %89.70'lik sonucuna kıyasla %92.83 doğruluk oranı ile daha iyi bir başarı göstermiştir. Inception-V3 modeli için önerilen yöntem %95.15 doğruluk ile Sürücü ve ark.'nın %94.69'luk çalışmasını az bir farkla geride bırakmıştır. Son olarak, VGG16 modeli %82.66 doğruluk ile Alsubaei ve ark.'nın %73.10'luk sonucuna göre kayda değer bir gelişim sağlamıştır. Bu sonuçlar, önerilen yöntemlerin ince-ayar ve optimizasyon süreçleri sayesinde daha başarılı sınıflandırma performansı sergilediğini açıkça ortaya koymaktadır.



Şekil 13. İnce-ayarı yapılan modellerin performanslarının önceki çalışmalarla kıyaslanması

5. Sonuç

Oluşan nüfus yoğunluğuna bağlı olarak kaynak kullanımının artması sonucunda oluşan atık miktarının oldukça artması sürdürülebilir bir dünya ve yaşam için büyük bir risk oluşturmaktadır. Bu çalışma da ise geri dönüştürülebilir atıkların daha sürdürülebilir bir dünya ve yaşam için yerinde ve otomatik olarak ayrıştırılmasını gerçekleştiren akıllı çöp konteyneri prototipi oluşturulmuştur. Önerilen akıllı çöp konteyneri içerisine bırakılan çevresel atığı fark etmekte, sınıflandırmakta ve kategorisine otomatik bir şekilde taşımaktadır. Böylece çevresel atıkların yerinde ve tam zamanında ayrıştırılmasını sağlayarak çevresel atıkların ayrıştırılması için mevcut kullanılan maliyetleri düşürmektedir.

Önerilen akıllı çöp konteyneri donanımsal olarak Raspberry Pi 4 model B, 28 BYJ-48 redüktörlü adım motoru, ULN2003A adım motor sürücü kartı, HC-SR501 ayarlanabilir hareket algılama sensörü, Raspberry Pi kamerası kullanılmıştır. Raspberry Pi üzerinde atıkları sınıflandırmak için Resnet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 derin öğrenme modelleri ile eğitimler

yapılmıştır. Her model için ince-ayar gerçekleştirilmiş olup, çevresel atıkların sınıflandırmasında modellerin başarımları arttırılmıştır. Eğitim ve test aşamalarından sonra modellerden elde edilen doğruluk başarımları karşılaştırılmıştır. En yüksek doğruluğa sahip olan modelin DenseNet169 olduğu görülmüştür. Sonuç olarak DenseNet169 en iyi sınıflandırma yapan derin öğrenme modeli olduğundan akıllı çöp konteyneri sistemi için bu model kullanılmıştır. Gelecekteki araştırmanın bir parçası olan bu çalışmanın sonuçlarına bakılarak, atık artışıdaki miktarın ve taşıdığı risklerin önüne geçilebilmesi için hazırlanmış olduğumuz bu prototip çalışmasının ilerleyen çalışmalarda ürüne dönüştürülerek kullanıma sunulmasını planlanmaktadır.

Teşekkür

Bu çalışma TÜBİTAK tarafından 1919B012302200 numaralı projeyle desteklenmiştir.

Katkı Beyanı

Makaledeki akıllı çöp konteynerinin geliştirilmesi fikri, araştırma metodolojisinin oluşturulması, makalenin yazımı aşamalarında Mehmet Umut Salur, makaledeki donanımsal bileşenlerin kurulumu ve gerekli yazılımların kurulması aşamasında Nermin Elmas ve Aybuke Nur Koçak, makalenin yazılması ve derin öğrenme modellerinin eğitim ve test aşamalarında Mehmet Umut Salur, Nermin Elmas, Aybuke Nur Koçak ve Melike Kaymaz katkı sunmuştur.

Çıkar Çatışması Beyanı

Makalenin yazar/yazarları, çalışma kapsamında herhangi bir kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] Bobulski J, Kubanek M. Deep learning for plastic waste classification system. *Applied Computational Intelligence and Soft Computing* 2021;2021(1):6626948.
- [2] Varol Varol S, Hark C, Kızılluluk S. Geri dönüştürülebilir atıkların sınıflandırılması. In: 6th International Artificial Intelligence & Data Processing Symposium, Malatya, Türkiye; 2022.
- [3] Yıldız EN, Bingöl H, Yıldırım M. Önerilen derin öğrenme ve makine öğrenmesi tabanlı hibrit model ile çevresel atıkların sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 2023;35(1):353-361.
- [4] Sağlam A, Taş M, Baykan N. Geri dönüştürülebilir atıkların materyallerine göre sınıflandırılması için raspberry pi tabanlı donanım geliştirilmesi. *Avrupa Bilim ve Teknoloji Dergisi* 2020;30-38.
- [5] Ahmed MIB, Alotaibi RB, Al-Qahtani RA, Al-Qahtani RS, Al-Hetela SS, Al-Matar KA, Al-Saqer NK, Rahman A, Sarairoh L, Youldash M, Krishnasamy G. Deep learning approach to recyclable products classification: towards sustainable waste management. *Sustainability* 2023;15(14):11138.
- [6] Tatke A, Patil M, Khot A, Karad's PJV. Hybrid approach of garbage classification using computer vision and deep learning. *International Journal of Engineering Applied Sciences and Technology* 2021;5(10):208-213.
- [7] Alsubaei FS, Al-Wesabi FN, Hilal AM. Deep learning-based small object detection and classification model for garbage waste management in smart cities and iot environment. *Applied Sciences* 2022;12(5):2281.
- [8] Kang Z, Yang J, Li G, Zhang Z. An automatic garbage classification system based on deep learning. *IEEE Access* 2020;8:140019-140029.

- [9] Sürücü S, Ecemiş İN. Garbage classification using pre-trained models. *European Journal of Science and Technology* 2022;(36):73-77.
- [10] Keskin S, Sevli O, Okatan E. Comparative analysis of the classification of recyclable wastes. *Journal of Scientific Reports-A* 2023;(055):70-79.
- [11] Zhou Y, Wang Z, Zheng S, Zhou L, Dai L, Luo H, Zhang Z, Sui M. Optimization of automated garbage recognition model based on resnet-50 and weakly supervised cnn for sustainable urban development. *Alexandria Engineering Journal* 2024;(108):415-427.
- [12] Wu Y, Shen X, Liu Q, Xiao F, Li C. A garbage detection and classification method based on visual scene understanding in the home environment. *Complexity* 2021;2021(1):1055604.
- [13] Chen Z, Yang J, Chen L, Jiao H. Garbage classification system based on improved ShuffleNet v2. *Resources, Conservation and Recycling* 2022;(178):106090.
- [14] Fan H, Dong Q, Guo N, Xue J, Zhang R, Wang H, Shi M. Raspberry pi-based design of intelligent household classified garbage bin. *Internet of Things* 2023;(24):100987.
- [15] Jin S, Yang Z, Królczyk G, Liu X, Gardoni P, Li Z. Garbage detection and classification using a new deep learning-based machine vision system as a tool for sustainable waste recycling. *Waste Management* 2023;(162):123-130.
- [16] Tensorflow: large-Scale machine learning on heterogeneous distributed systems. <https://arxiv.org/abs/1603.04467> (Erişim tarihi: 10.09.2024).
- [17] Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research* 2014;15(1):1929-1958.
- [18] Chollet F. *Deep learning with Python*, Shelter Island: Manning Publications; 2021.
- [19] LeCun Y, Bengio Y, Hinton G. Deep learning, *Nature* 2015;521(7553):436-444.
- [20] Machine Learning vs. Deep Learning. <https://lawtomated.com/a-i-technical-machine-vs-deep-learning/> (Erişim tarihi: 20.09.2024).
- [21] Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. Going deeper with convolutions. In: *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition*, Boston, MA, USA; 2015.
- [22] Zhang X, Zhou X, Lin M, Sun J. ShuffleNet: An extremely efficient convolutional neural network for mobile devices. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, Utah, ABD; 2018.
- [23] Güneş E. Derin öğrenme yaklaşımı ile fındık meyvesinin sınıflandırılması. Yüksek Lisans Tezi. İstanbul: Marmara Üniversitesi; 2022.
- [24] Dandıl E, Karaca S. MR spektroskopisi sinyalleri kullanılarak LSTM derin sinir ağı ile beyinde sahte tümörlerin tespiti. *Avrupa Bilim ve Teknoloji Dergisi* 2020;2:426-433.
- [25] Garbage Classification. <https://www.kaggle.com/datasets/asdasdasdas/garbage-classification> (Erişim tarihi: 01.08.2024).