

Önerilen Derin Öğrenme ve Makine Öğrenmesi Tabanlı Hibrit Model ile Çevresel Atıkların Sınıflandırılması

Elif Nur YILDIZ¹, Harun BİNGÖL^{2*}, Muhammed YILDIRIM³

^{1,2} Yazılım Mühendisliği, Mühendislik ve Doğa Bilimleri Fakültesi, Malatya Turgut Özal Üniversitesi, Malatya, Türkiye

³ Bilgisayar Mühendisliği, Mühendislik ve Doğa Bilimleri Fakültesi, Malatya Turgut Özal Üniversitesi, Malatya, Türkiye

¹elify6523@gmail.com, ²harun.bingol@ozal.edu.tr, ³muhammed.yildirim@ozal.edu.tr

(Geliş/Received: 07/01/2023;

Kabul/Accepted: 25/02/2023)

Öz: Çevre kirliliği sorunu, son zamanlarda artış gösterip hem insanlığa hem de çevreye tehdit oluşturmaktadır. Dünya genelinde çarpık kentleşme, sanayileşme ve insanların sorumsuz davranışları sonucu büyük bir atık problemi ortaya çıkmaktadır. Bu problem hayat standartlarımızı kısıtlayıp, daha sağlıklı bir ortamda yaşam sürmemize neden olmaktadır. Atıklar genellikle çöp olarak bilindiğinden geri kazanılmaya çalışılmadan ortamdaki uzaklaştırılır ve bu durumda da atığın geri dönüşüme gitmeden doğada kendi kendine çözünme süresi uzun yıllar almaktadır. Atıkların ömrünü uzatma ve ayrıştırılması ile hem çevre kirliliği azalır hemde geri dönüşüme katkı sağlayarak dünya daha yaşanılabilir bir hale gelir. Derin öğrenme modelleri ve makine öğrenme yöntemleri kullanılarak yapılan bu çalışmada çevremizi daha yaşanılabilir hale getiren ve geri dönüşüme yardımcı olan atık ayrıştırma veri seti kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Bu çalışmada yapay zeka teknikleri ile atık ayrıştırma tespitinde AlexNet, GoogLeNet, ResNet50, DenseNet201, ShuffleNet, SqueezeNet mimarileri ile sonuçlar elde edilmiştir. Sonraki aşama da derin mimarilerden elde edilen özellik haritaları destek vektör makineleri (DVM), k-en yakın komşu (KNN) ve karar ağaçlarında (KA) sınıflandırılmıştır. Mimarilerin elde ettikleri sonuçlar karşılaştırılarak bu problem için en iyi mimari seçilmiştir. Deneyler sonucunda önermiş olduğumuz hibrit model %85.94 doğruluk değeri elde etmiştir.

Anahtar kelimeler: Atık sınıflandırma, yapay zekâ, derin öğrenme, ESA, DVM.

Classification of Environmental Waste with Proposed Deep Learning and Machine Learning Based Hybrid Model

Abstract: The problem of environmental pollution has increased recently and poses a threat to both humanity and the environment. A big waste problem arises as a result of unplanned urbanization, industrialization, and irresponsible behavior of people around the world. This problem restricts our living standards and causes us to live in an unhealthy environment. Since wastes are generally known as garbage, they are removed from the environment without trying to be recovered. In this case, the self-dissolution time of the waste in nature takes many years without recycling. By prolonging the life of waste and separating it, environmental pollution is reduced and the world becomes more livable by contributing to recycling. In this study, which was carried out using deep learning models and machine learning methods, the classification process was carried out using the waste separation data set, which makes our environment more livable and helps recycling. In this study, results were obtained with AlexNet, GoogLeNet, ResNet50, DenseNet201, ShuffleNet, and SqueezeNet architectures in the detection of waste separation with artificial intelligence techniques. In the next step, feature maps obtained from deep architectures are classified in support vector machines, k-nearest neighbor, and decision trees. By comparing the results of the architectures, the best architecture was selected for this problem. As a result of the experiments, the hybrid model we proposed achieved an accuracy value of 85.94%.

Key words: Garbage classification, artificial intelligence, deep learning, CNN, SVM.

1. Giriş

Yaşam alanımız içinde çevre, hayat standartları için önemli bir faktördür. Çevrenin temiz ve ferah olması yaşam kalitemizi arttırdığı gibi insanların hayat enerjisini de arttırmaktadır. Son zamanlarda çevreye verilen zarar ile çevre kirliliği önemli bir sorun haline gelip canlıları tehlikeye sokmaktadır [1]. Dünya genelinde ormanların kesilip yerine dev binaların yapılması, sanayileşmenin hızla artmasıyla birlikte fabrika atıklarının çoğalması ve insanların bilinçsizce çevreye her türlü atığı rasgele atma alışkanlığı hem günümüzde hem de gelecekte ciddi çevresel problemlere yol açmaktadır. Bu atıklar; hava kirliliğine, bitkilerin zarar görmesine, deniz ve göllerdeki

* Sorumlu yazar: harun.bingol@ozal.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0003-1580-1372, ² 0000-0001-5071-4616, ³ 0000-0003-1866-4721

bilinçsizce atılan atıklar sonucu su kirliliğine, istenmeyen kokulara, küresel ısınma gibi önemli sorunlara yol açmaktadırlar [2]. Atıklar doğadaki canlıların yaşamını tehdit eden, yaşam sürelerini kısıtlayan, doğadan alınan verimi azaltan önemli etkidir. Atıklar rastgele ortaya atılıp, bilinçsizce hareket edildiğinde geri dönüşüme gitmeden çöp olarak adlandırıldığı için doğada çözünme süresi uzun yıllar almaktadır. Bugünün şartlarında önemli bir sorun haline gelen bu problem için geri dönüşüme elverişli olanlar farklı renk ve isimlerde ayrıştırılarak kategorisine göre içine atılır ve böylece ayrıştırılması kolaylaşarak ikincil madde haline getirilip tekrar üretime geçmektedir. Atıkların ayrışmasından sonraki süreç olan geri dönüşüm ile artık atıklar yeniden üretime geçip hem çevreye olan zararı azaltır hem de atık olan bir üründen tekrar verim almamızı sağlamaktadır. Çevredeki insanların bilinçlenip geri dönüşüme gereken özeni gösterdikten sonra doğal kaynakların tükenmesi önlenir. Toprak verimi ve canlıların yaşam kalitesi artar ve temiz bir çevreye ulaşılmış olunur. Atıkları başka şekilde değerlendirmek için yapılan bazı çalışmalardan biri de sıfır atık projesi olup, bu proje ile atıkların fayda sağlayacak başka bir ürüne dönüştürerek atıklardan elde edilen bu zararı en aza indirmek hedeflenmiştir. Sıfır atık ile amaç duyarlı tüketici modelini oluşturup bu bilinci insanlara aşılacak, aynı zamanda hem israfın önlenmesi hem ekonomik kazanç sağlanması hem de çevreyi korumak olmuştur. Çevreye zarar veren bu sorun ile baş etmek için atık ayrıştırma sonucu geri dönüşüm ya da sıfır atık projesi önemli rol oynamaktadır. Derin öğrenme özellikle görüntü işleme alanında bitkisel hastalıkların sınıflandırılmasından, insan ve hayvan hastalıklarının teşhis ve sınıflandırılmasına kadar birçok alanda etkili bir şekilde kullanılmaktadır [3-5]. Yapılan bu çalışma da 6 sınıflı bir atık veri seti kullanılmıştır. Bu veri setinde karton, bardak, metal, kâğıt, plastik ve çöp atıklarının ayrıştırılması için görüntüler bulunmaktadır. Çalışmanın ilk aşamasında farklı derin öğrenme mimarileri kullanılarak sonuçlar elde edilmiştir. İkinci aşamada ise derin mimarilerden elde edilen özellik haritaları makine öğrenme yöntemleri olan DVM, KNN ve karar ağaçları sınıflandırıcılarında sınıflandırılıp, bu sınıflandırıcılardan doğruluk değerleri ve karmaşıklık matrisleri elde edilmiştir. Derin öğrenme mimarileri kullanılarak elde edilen özellik haritası sınıflandırıcılarda sınıflandırıldıktan sonra DVM sınıflandırıcısında elde edilen değerler diğer sınıflandırıcılardan daha iyi olduğu gözlemlenmiştir.

Çalışmanın geri kalanı şu şekilde organize edilmiştir. İkinci bölümde çöplerin sınıflandırılması ile ilgili literatürde yer alan çalışmalar incelenmiştir. Veri seti, kullanılan derin mimariler ve önerilen hibrit metod üçüncü bölümde açıklanmıştır. Dördüncü bölümde deneysel sonuçlar verilmiştir. Beşinci bölümde ise sonuçlar sunulmuştur.

2. İlgili çalışmalar

Atık problemi her geçen gün daha ciddi bir problem haline gelmektedir. Bundan dolayı literatürde atıkların sınıflandırılması ile ilgili yapılmış çalışmalar bulunmaktadır.

Rabano ve arkadaşları yaptıkları çalışma da, MobileNet ile sıradan çöpleri kategorilere göre sınıflandıran bir model oluşturmak için cam, kâğıt, karton, plastik, metal ve diğer çöpler kullanılmıştır. Eğitim için “.jpg” uzantılı 2527 adet çöp görselinden oluşan bir veri seti kullanılmıştır. TensorFlow for Poets git deposu, MobileNet modelini 500 adımda yeniden eğitmek için bir çalışma dizini olarak klonlamıştır. Önerilen modelin nihai test doğruluğu %87.2 olmuştur [6].

Kang ve arkadaşları yaptıkları çalışma da çöp sınıflandırma konusunun; çevrenin korunması, kaynakların geri dönüşümü ve sosyal geçim için her zaman önemli bir konu olduğu görüşünü savunmuşlardır. Ön uç çöp toplama verimliliğini artırmak için, derin öğrenmeye dayalı otomatik bir çöp sınıflandırma sistemi önerilmiştir. İlk olarak, donanım yapısı ve mobil uygulama dahil olmak üzere çöp kutusunun genel sistemi tasarlanmıştır. İkinci olarak, önerilen çöp sınıflandırma algoritması ResNet-34 algoritmasına dayanmaktadır. Son olarak, önerilen sınıflandırma algoritmasının üstünlüğü, oluşturulan çöp verileri ile doğrulanmıştır. Önerilen algoritmanın sınıflandırma doğruluğu %1,01 artırılmıştır [7].

Meng ve Chu geri dönüşümün zaten tüm ülkeler için önemli bir çalışma olduğunu belirtmişlerdir. Geri dönüşüm için gerekli olan işler arasında çöp sınıflandırılması, uygun maliyetli geri dönüşümü sağlamak için en temel adımdır. Bu yazıda, görüntülerdeki tek bir çöp nesneyi tanımlamaya ve onu geri dönüşüm kategorilerinden birinde sınıflandırmaya çalışılmıştır. Birkaç yaklaşımı inceleyip daha sonra kapsamlı bir değerlendirme sağlanmıştır. Kullanılan modeller arasında HOG özellik çıkarma yöntemi, destek vektör makineleri (DVM), basit evrimsel sinir ağı (ESA) ve artık bloklara sahip ESA yer almaktadır. Değerlendirme sonuçlarına göre artık blokları olan veya olmayan basit ESA ağlarının, umut verici performanslar gösterdiği sonucuna varılmıştır. Derin öğrenme teknikleri sayesinde, hedef veri seti için çöp sınıflandırma sorunu etkin bir şekilde çözülebilmektedir [8].

Özkaya ve Seyfi yaptıkları bu çalışmada, görüntü sistemi ile çöpün geri dönüşümünü sağlamak için çöpe atılan çöp türlerini tespit eden bir derin öğrenme uygulaması geliştirilmeyi amaçlamışlardır. Farklı çöp türleri üzerinde birkaç sınıftan oluşan görüntü verileri ile eğitim ve test yapmışlardır. Eğitim ve test sırasında kullanılan

veri seti, çöp görüntülerden alınan orijinal verilerden oluştuğu belirtilmiştir. Derin öğrenme yapıları için kullanılan veri setinde 6 farklı sınıfa sahip toplam 2527 adet görüntü bulunmaktadır. Veri setindeki bu görüntülerin yarısı eğitim sürecinde, kalan kısmı ise test işlemi için kullanılmıştır. Ayrıca, daha yüksek doğrulukla daha kısa eğitim ve test süreçleri elde etmek için transfer öğrenimi kullanılmıştır. AlexNet, VGG16, GoogLeNet ve ResNet yapılan çalışmada kullanılan başlıca mimarilerdir. Sınıflandırıcıların performansını test etmek için, Softmax ve DVM olarak iki farklı sınıflandırıcı kullanılmaktadır. GoogLeNet+DVM ile %97.86 ile en yüksek doğrulukta 6 farklı tip çöp sınıflandırılmıştır [9].

Chen ve arkadaşları yaptıkları bu çalışma da, çöp sınıflandırma teknolojisi yalnızca atıkların zararsız bir şekilde işlenmesi ve kaynakların geri kazanılması için önemli bir temel değil, aynı zamanda sosyal gelişimin kaçınılmaz eğilimi olduğu görüşünü savunmaktadır. Mevcut çöp sınıflandırma yöntemleri, çöp toplama aşamasında manuel sınıflandırmaya dayanmaktadır. Araştırmacılar tutarlılık, kararlılık ve sıhhi koşullarda tatmin edici sonuçlara ulaşmanın zor olduğunu belirtmişlerdir. Bu nedenle bu çalışma, evsel çöpleri tanıyabilen ve geri dönüştürebilen derin öğrenmeye dayalı bir çöp sınıflandırma sistemi sunmaktadır. Yapılan çalışmada düşük doğruluk ve zayıf gerçek zamanlı performans sorunlarına odaklanarak, hafif bir çöp sınıflandırma modeli GCNet (Çöp Sınıflandırma Ağı) önerilmiştir. Deneysel sonuçlar, GCNet'in kendi kendine oluşturulan veri kümesindeki ortalama doğruluğunun %97.9 olduğunu göstermektedir [10].

Mittal ve arkadaşları yaptıkları çalışma da, temiz bir ortamın sürdürülmesinin, gelişmekte olan ülkelerde vazgeçilmez olduğu kadar oldukça da zor bir iş olduğunu belirtmişlerdir. Vatandaşlara mahallelerini takip etmeye ve raporlamaya teşvik etmek amaçlanmıştır. Kullanıcı tarafından tıklanan coğrafi etiketli bir görüntüde çöp bölgelerini algılayan ve kabaca bölümlere ayıran SpotGarbage adlı akıllı telefon uygulaması sunulmuştur. Yapılan çalışmada görüntülerdeki çöpi algılamak için tamamen evrişimli ağları kullanılmıştır. Çalışmada önerilen model, GINI veri kümesi üzerinde eğitilip, ortalama %87,69 doğruluk değerini elde ettiği belirtilmiştir [11].

Zhihong ve arkadaşları çöpleri otomatik olarak sıralayan robotik bir kavrama sistemini önerdiklerini belirtmişlerdir. Önermiş oldukları bu sistemde, sıralanan nesnelere otomatik olarak yakalamak için karmaşık arka planda hedef nesnelere tanımlanmasını ve konumlandırılmasını sağladığı ifade edilmiştir. Hedef nesnenin doğru bir şekilde tespitini sağlamak amacıyla, nesne tanıma ve poz tahmini için Bölge Önerisi Oluşturma (RPN) ve VGG-16 modelini uygulandığı belirtilmektedir. Çöpteki şişelerin ayıklanması çalışmasına ilişkin sonuçlar, önerilen sistemin çöpleri verimli bir şekilde ayıklayabildiğini göstermektedir [12].

Sidhart ve arkadaşları ESA mimarilerini kullanarak kategorilerden (plastik, kâğıt, karton, metaller) oluşan etiketlenmiş bir görüntü veri seti ile atıkların sınıflandırılması amacıyla bir model geliştirdiklerini belirtmişlerdir. Görüntüler kendi kendine öğrenen bir sinir ağı yardımıyla özelliklerine göre sınıflandırıldığı ifade edilmektedir. Yapılan çalışmada önerilen yöntemle %76'lık bir test doğruluğu elde edildiği belirtilmiştir [13].

3. Materyal ve Yöntem

Garbage Classification veri seti 6 sınıflı olup, test sonuçları Matlab ortamında alınmıştır. Modellerin eğitim boyunca epoch değeri 5, batchsize değeri 16 alınarak eğitim tamamlanmıştır. Veri setinin her sınıfındaki görüntülerin %80'i eğitim ve %20'si test için kullanılmaktadır. Modeli eğitmek için seçilen her mimarinin girdi boyutları belirlenir ve girdi boyutlarına göre eğitime başlanmış olunur. Eğitimin sonucunda doğruluk değerleri ve karmaşıklık matrisleri elde edilmektedir. Önerilen modelde ise DenseNet201 mimarisi taban olarak kullanılmış ve veri setindeki görüntülerin özellik haritaları elde edilmiştir. Elde edilen özellik haritaları DVM, KNN ve KA sınıflandırıcılarında sınıflandırılmıştır. Bu veri setindeki görüntüleri sınıflandırmak için kullanılan mimariler AlexNet, GoogLeNet, ResNet50, DenseNet201, ShuffleNet ve SqueezeNet olmuştur.

3.1. Veri seti

Yapılan çalışmada atıkları ayırtmak için kullanılan veri seti Garbage Classification veri setidir. Veri setine Kaggle web sitesinden erişilmiştir. Bu veri seti halka açık bir veri setidir [14]. Bu veri seti 6 sınıflı olup, 2527 görüntüye sahiptir. Veri setinde ayırtma yapmak için kullanılan atıklar Cardboard, Glass, Metal, Paper, Plastic ve Trash olmuştur. Her bir sınıfa ait rasgele görüntü örnekleri Şekil 1'de gösterilmektedir.



Şekil 1. Veri setinde yer alan sınıflara ait örnek görüntüler

3.2. ESA mimarileri

Bu çalışmada kullanılan ESA mimarileri; AlexNet, GoogLeNet, DenseNet201, ResNet50, ShuffleNet ve SqueezeNet olmuştur. Bu mimariler eğitildikten sonra her mimari için farklı doğruluk değerleri hesaplanır ve karmaşıklık matrisleri elde edilir.

AlexNet: Ilya Sutskever, Alex Krizhevsky ve Geoffrey Hinton tarafından sunulmuştur. AlexNet'in ilk katmanı, giriş görüntüsünü filtrelemek için kullanılır. Giriş görüntüsünün genişliği (W), yüksekliği (H) ve derinliği (D) olmalıdır, AlexNet mimarisinin girdi boyutu $227 \times 227 \times 3$ 'tür. İkinci evrişimli katmanın havuzlanmış ve normalleştirilmiş çıktısı, her biri 3×3 boyutunda 384 çekirdek ile üçüncü katmana bağlanır. Dördüncü evrişim katmanı için 3×3 boyutunda 384 çekirdek vardır ve bunlar 2 GPU'ya bölünerek her bir GPU yükü $3 \times 3 \times 192$ olacaktır. Beşinci evrişimli katman, her biri 3×3 boyutunda 256 çekirdeğe sahiptir ve bunlar 2 GPU'ya bölünecek, böylece her bir GPU yükü $3 \times 3 \times 128$ olacaktır. Üçüncü, dördüncü ve beşinci evrişim katmanlarının herhangi bir normalleştirme ve havuzlama katmanı olmadan oluşturulduğuna dikkat edilmelidir. Bu üç konvolüsyonel katmanın çıktısı, her katmanın 4096 nöron içerdiği tam bağlı 2 katmana girdi olarak iletilir [15].

GoogLeNet: %6.66 hata oranı ile 2014 yılında ILSVRC Imagenet yarışmasının kazanan modelidir. GoogLeNet ardışık bir yapıda katmanları sıralamaktan uzaklaşmıştır. GoogLeNet ağı bellek maliyetini azaltmak ve ağı ezberleme olasılığını düşürmek için çok sayıda ardışık katmanları üst üste ekleyip filtreler kullanmak yerine birbirine paralel bağlı başlangıç modülleri kullanmıştır. GoogLeNet'te 1×1 , 3×3 , 5×5 evrişim filtreleri sonra inception modülünde bu filtreler toplanarak bir sonraki katmana giriş olarak verilmektedir. Bu modül sayesinde bir nesneye ait hem genel hem de spesifik özellikler çıkartılmış olunur [16,17]. GoogLeNet mimarisinin girdi boyutu $224 \times 224 \times 3$ olarak verilmektedir.

DenseNet201: Bu mimari Huang ve arkadaşları tarafından bilgi aktarımının sağlanması için oluşturulan bir mimaridir. Bu mimaride her katman için önceki katmanların çıktıları giriş değeri olmaktadır. Densenet ağ mimarisi kaybolan gradyan problemini önemli ölçüde düşürmektedir. Densenet bu işlemi gerçekleştirebilmek için model azaltılmış parametre sayısına sahiptir [18]. DenseNet201 de 7×7 evrişim filtresi ve ardından ilk katman olarak 3×3 MaxPool, arada 3 ortalama havuz katmanı olan 196 evrişimsel katman ve 1 çıkıştan oluşan toplam 201 katmana sahiptir [19,20]. DenseNet201 mimarisine girdi boyutu $224 \times 224 \times 3$ olarak verilmektedir.

ResNet50: 2015 yılında He vd. tarafından geliştirilen bir modeldir. ResNet modeli 2015 yılında yapılan ILSVRC ImageNet yarışmasının kazananıdır. ResNet modelini kendisinden önceki modellerden ayıran farklardan en önemlisi daha derin bir yapıya sahip olmasıdır. ILSVRC 2015 yılında yapılan yarışmada %3.6 hata oranı ile birinci olmuş bir yapıdır. Toplu normalleştirmeyi ilk kullanan algoritmalarındandır. Ağ, $224 \times 224 \times 3$ boyutunda girdi görüntüleri gerektirir. 26 Milyon parametreye sahip olan bu model 152 katmandan oluşmaktadır [21].

ShuffleNet: Bu mimari, 2×2 kaydırmalı ShuffleNet birimi, birinci evrişimli katmanın çıktı özellik haritasını alır. Bu ShuffleNet birimi üç evrişimli işlem içerir, yani iki 1×1 noktasal grup evrişimi ve 3×3 derin kıvrımlardır. İlk noktasal grup evrişimini BN, relu aktivasyon fonksiyonu, kanal takip eder. Karıştırma işlemi, verimli ve basit olduğu için Relu aktivasyonu kullanılır [22]. $224 \times 224 \times 3$ boyutlu girdisi olup, 172 katmandan oluşmaktadır.

SqueezeNet: SqueezeNet'i tasarlamak için ESA bazında çeşitli stratejiler kullanılır. İlk olarak 3×3 filtreleri 1×1 filtrelerle değiştirilir, sonra giriş kanallarının sayısını 3×3 filtrelere düşürülür, son olarak ise ağı sonlarında alt örnekleme yapılır ve böylece evrişim katmanları büyük aktivasyon haritalarına sahip olur. SqueezeNet, esas olarak yalnızca 1×1 filtrelili sıkımlı evrişim katmanları olan yangın modüllerinden oluşur. Bu katmanlardan daha

sonra 1x1 ve 3x3 evrişim filtrelerinin bir karışımına sahip olan bir genişletme katmanı ile beslenir [23]. 68 katmandan oluşan bu mimari kendisine gelen görüntüleri $227 \times 227 \times 3$ boyutunda kabul etmektedir.

3.3. Makine öğrenme yöntemleri

Literatürde sıklıkla kullanılan ve yüksek doğruluk değerine ulaşan sınıflandırıcılar arasında DVM, KNN ve KA yer almaktadır.

Destek Vektör Makineleri (DVM): DVM birçok önemli ilkeyi bünyesinde barındırır ve doğrudan sınıflandırma problemini çözer. DVM iki ana fikir üzerinde yoğunlaşarak ilerlemektedir. İlk olarak, çekirdek fonksiyonları, sorunu orijinal girdi uzayından, farklı sınıflara ait eğitim örneklerinin doğrusal olarak ayrılmasının mümkün olduğu, özellik uzayı adı verilen oldukça boyutlu bir probleme dönüştürmek için kullanılır. İkinci olarak, en iyi ayırıcı hiper düzlemi bulmak için maksimum marj kavramını tanıtır [24,25].

K En Yakın Komşu (KNN): Basit uygulaması ve seçkin performansı nedeniyle veri madenciliği ve makine öğrenimi uygulamalarında sınıflandırıcı olarak yaygın olarak kullanılmaktadır. Sınıflandırma görevlerinin yanı sıra, kNN yöntemleri ayrıca regresyon ve kayıp veri ataması için de sıklıkla kullanılmaktadır [26].

Karar Ağaçları (KA): Karar ağaçları algoritması, veri madenciliği teknikleri içinde önemli bir sınıflandırma yöntemidir. Karar ağacı, kök düğümü, dalları ve yaprak düğümleri olan ağaç yapısında sınıflandırma ve regresyon modelleri oluşturur [27].

4. Deneysel Sonuçlar

Yapılan bu çalışmada literatürde kabul gören ESA mimarileri ve farklı sınıflandırıcılar kullanılarak sonuçlar alınıp, karmaşık matris elde edilmiştir. Elde edilen karmaşık matrisi ile performans değerlendirme kriterleri olan Sensitivity, Accuracy, Precision, Specifty, F-score, FDR, FNR ve FPR değerlerine ulaşılmıştır. Karmaşık matrisinde 1. Cardboard, 2. Glass, 3. Metal, 4. Paper, 5. Plastic ve 6. Trash olarak adlandırılmaktadır.

4.1. Önceden eğitilmiş ESA mimarilerinde elde edilen sonuçlar

Yapılan çalışmada kullanılan ESA mimarileri AlexNet, GoogLeNet, ResNet50, DenseNet201, ShuffleNet ve SqueezeNet olmuştur. Bu mimariler Matlab ortamında çalıştırılıp, epoch 5 ve batchsize değeri 16 alınarak, görüntülerin %80'i eğitime %20'si teste ayrılmıştır. Verilen parametreler doğrultusunda modelin eğitime işlemi tamamlanmıştır. Tablo 1'de görüldüğü üzere ESA mimarilerinden alınan doğruluk değerleri verilmiştir.

Tablo 1. ESA mimarilerinden elde edilen doğruluk değerleri

AlexNet	GoogLeNet	ResNet50	DenseNet201	ShuffleNet	SqueezeNet
%80.59	%80.0	%81,58	%85.94	%76.24	%76.83

ESA tabanlı modeller eğitildikten sonra en iyi sonuç veren mimari %85.94 doğruluk oranı ile DenseNet201 olmuştur. En düşük sonucu veren mimari ise %76.24 doğruluk oranı ile ShuffleNet olmuştur. ESA mimarileri ile modeller eğitildikten sonra elde edilen karmaşık matrisleri Tablo 2'de sunulmuştur.

Tablo 2. ESA mimarilerine ait karmaşıklık matrisleri

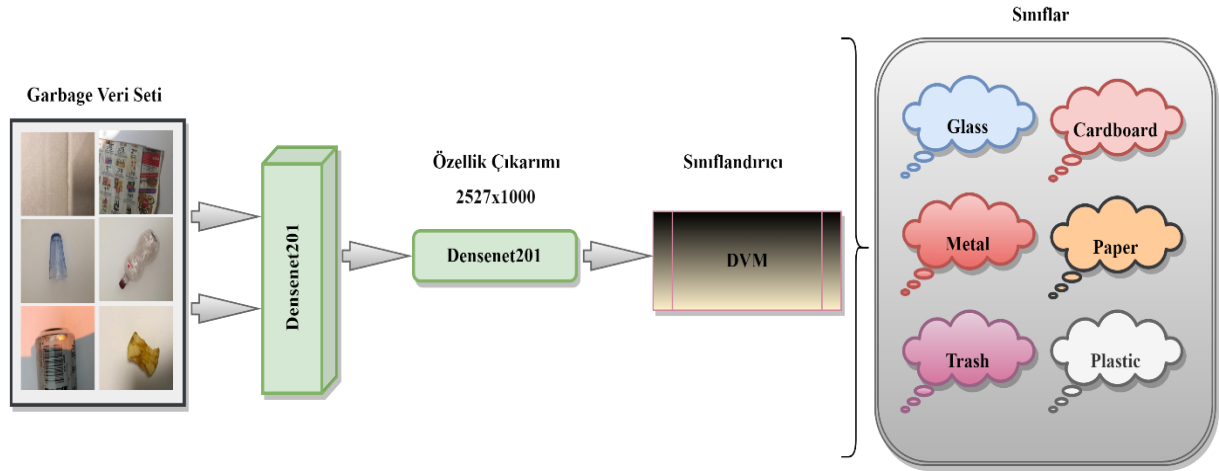
AlexNet							GoogLeNet						
1	73	2		6			1	78			3		
2		86	8		5	1	2		77	13	1	9	
3		10	69	1	1	1	3	1	4	70	3	4	
4	4	4	1	103	1	6	4	6	1	1	103	1	7
5	2	15	5	9	61	4	5	1	8	6	13	64	4
6	1	1	1	7	2	15	6	1	1	2	10	1	12
	1	2	3	4	5	6		1	2	3	4	5	6
ResNet50							DenseNet201						
1	75		1	5			1	78	1		2		
2		86	6		8		2		91	3		5	1
3		2	73		6	1	3		3	78			1
4	5	1	1	106		6	4	3		1	110		5
5	1	10	8	11	60	6	5	2	9	3	10	62	10
6	3	1	3	7	1	12	6	1		3	8		15
	1	2	3	4	5	6		1	2	3	4	5	6
ShuffleNet							SqueezeNet						
1	72			6	3		1	77			3	1	
2		83	6	2	9		2	1	77	13	1	8	
3		7	66	2	4	3	3	1	6	72	2		1
4	4	3	1	105	2	4	4	7	2	3	102		5
5	3	14	7	10	51	11	5	3	20	13	9	48	3
6	5		5	9		8	6	1		4	9	1	12
	1	2	3	4	5	6		1	2	3	4	5	6

Tablo 2 incelendiğinde derin mimariler için de elde edilen en iyi doğruluk oranı %85.94 ile DenseNet201 mimarisinde olmuştur. Kullanılan veri setinde toplam görüntü sayısı 2537'dir. Bu görüntü sayısının %20'si test için kullanılmıştır. Test için ayrılan görüntü sayısı 505 olmuştur. DenseNet201 modeli, 434 görüntüyü doğru bir şekilde sınıflandırırken, 71 görüntüyü yanlış sınıflandırmıştır. Cardboard sınıfı için toplam görüntü sayısı 403 olup, 81 görüntüsü test için kullanılmıştır. DenseNet201 modeli, bu sınıfın 78 görüntüsünü doğru sınıflandırırken, 1 tanesini glass, 2 tanesini de paper sınıfı olarak tahmin etmiştir. Glass sınıfı için toplam görüntü sayısı 501 olup, 100 görüntüsü test için kullanılmıştır. DenseNet201 modeli, bu sınıfın 91 görüntüsünü doğru sınıflandırırken, 3 tanesini metal, 5 tanesini plastic, 1 tanesini de trash sınıfı olarak tahmin etmiştir. Metal sınıfı için toplam görüntü sayısı 410 olup, 82 görüntüsü test için kullanılmıştır. DenseNet201 modeli, bu sınıfın 78 görüntüsünü doğru sınıflandırırken, 3 tanesini glass, 1 tanesini de trash sınıfı olarak tahmin etmiştir. Paper sınıfı için toplam görüntü sayısı 594 olup, 119 görüntüsü test için kullanılmıştır. DenseNet201 modeli, bu sınıfın 110 görüntüsünü doğru sınıflandırırken, 3 tanesini cardboard, 1 tanesini metal, 5 tanesini de trash sınıfı olarak tahmin etmiştir. Plastic sınıfı için toplam görüntü sayısı 482 olup, 96 görüntüsü test için kullanılmıştır. DenseNet201 modeli, bu sınıfın 62 görüntüsünü doğru sınıflandırırken, 2 tanesini cardboard, 9 tanesini glass, 3 tanesini metal, 10 tanesini paper,

10 tanesini de trash sınıfı olarak tahmin etmiştir. Trash sınıfı için toplam görüntü sayısı 137 olup, 27 görüntüsü test için kullanılmıştır. DenseNet201 modeli, bu sınıfın 15 görüntüsünü doğru sınıflandırırken, 1 tanesini cardboard, 3 tanesini metal, 8 tanesini paper sınıfı olarak tahmin etmiştir. Çalışmada kullanılan modeller arasında en düşük doğruluk değeri %76.24 ile ShuffleNet mimarisinde elde edilmiştir.

4.2. Önerilen modelde elde edilen sonuçlar

Önerilen modelde DenseNet201 mimarisi taban olarak kullanılmış ve ilgili veri setinde ki görüntülerin özellik haritaları elde edilmiştir. Elde edilen özellik haritaları DVM, KNN ve karar ağaçlarında sınıflandırılmıştır. DenseNet201DenseNet201 mimarisi taban olarak kullanılıp özellik haritaları elde edildiğinde en yüksek doğruluk değeri DVM sınıflandırıcısında elde edilmiştir. Önerilen modelde yer alan temel adımlar Şekil 2’de gösterilmiştir.



Şekil 2. Önerilen hibrit model

Farklı ESA mimarileri kullanılarak elde edilen özellik haritaları farklı sınıflandırıcılarda sınıflandırıldığında elde edilen doğru değerleri Tablo 3’te sunulmuştur.

Tablo 3. ESA Mimarileri, Sınıflandırıcı Sonuçları

ESA Mimarileri	KA	DVM	KNN
AlexNet	57.10%	80.20%	75.00%
GoogLeNet	60.50%	84.50%	78.20%
DenseNet201	66.90%	89.70%	83.40%
ResNet50	67.70%	89.60%	82.60%
ShuffleNet	61.30%	85.60%	78.90%
SqueezeNet	59.50%	85.40%	77.00%

Tablo 3’te gösterildiği gibi en yüksek doğruluk değeri, DenseNet201 mimarisi ile DVM sınıflandırıcısının birlikte oluşturmuş oldukları hibrit modelden elde edilmiştir. Bu mimarinin karmaşıklık matrisi Tablo 4’te sunulmuştur. DenseNet201 mimarisi kullanılarak elde edilen özellik haritası üç farklı sınıflandırıcıda sınıflandırıldığında en yüksek değeri %89.70 ile DVM sınıflandırıcısında elde ederken, en düşük değeri ise 66.90 ile KA sınıflandırıcısında elde etmiştir. 6 farklı ESA mimarisi taban olarak kullanılıp özellik haritası elde edildikten sonra, sınıflandırma aşamasında en başarılı sınıflandırıcının DVM olduğu görülmektedir.

Tablo 4. DenseNet201+DVM
DenseNet201+ DVM (89.70%)

1	365		2	32	4	
2		455	22	3	19	2
3		15	378	10	5	2
4	12	1	9	557	6	9
5	1	23	14	9	423	12
6	3	3	10	18	14	89
	1	2	3	4	5	6

Önerilen model 2527 görüntüden, 2267 görüntüyü doğru tahmin ederken, 260 görüntüyü ise yanlış tahmin etmiştir. Önerilen model için performans kriter sonuçları Tablo 5'te verilmiştir.

Tablo 5. Performans Kriterleri

	Acc.(%)	Spç.(%)	Sens.(%)	Pre.(%)	F1(%)	FDR(%)	FPR(%)	FNR(%)
Cardboard	97.82	98.12	95.54	90.57	92.99	0.09	0.01	0.04
Glass	96.52	97.86	91.54	90.81	91.18	0.09	0.02	0.08
Metal	96.48	98.41	86.89	92.19	89.46	0.07	0.01	0.13
Paper	95.69	98.05	88.55	93.77	91.08	0.06	0.01	0.11
Plastic	95.77	98.01	94.41	89.80	92.05	0.10	0.01	0.05
Trash	97.11	98.01	94.41	89.80	92.05	0.10	0.01	0.05

Modellerin başarısını sadece doğruluk ile ölçmek doğru olmadığından dolayı önerilen modelin başarısı farklı performans kriterleri dikkate alınarak belirlenmiştir. Tablo 5 incelendiğinde DenseNet201+DVM ile elde edilen performans kriterleri incelenmiştir ve en yüksek doğruluk %97.82 ile Cardboard sınıfında olmuştur. Yapılan çalışmada da önerilen modelin atık ayrıştırma veri setinde başarılı sonuçlar verdiği gözlemlenmiştir.

5. Sonuçlar

Çevre kirliliği doğaya hasar veren ve günümüzde yaşantımız için büyük tehdit yaratan unsurdur. Yaşam standartlarımızı kısıtlayan bu sorun çevreye bilinçsizce atılan atıkların çöp olarak tanımlanması ve doğada çözünmek için beklenilmesi sonucu oluşmuştur. Bu sorun atıkların kategorilerine göre sınıflandırılması ile çözülebilecek yöntemlerden biridir. Ayrıştırılan bu atıklar geri dönüşüme giderek tekrar üretime geçmektedir. Geri dönüşüm için yapılan bu kolaylık hem çevrenin daha yaşanılabilir bir yer haline gelmesine hem de çevre bilinci oluşturmaya yardımcı olmaktadır. Derin öğrenme son yıllarda görüntü işleme ve sınıflandırmada sağlık, endüstri, ilaç, havacılık, meteoroloji gibi birçok bilim dalında ki uygulamalarda oldukça başarılı sonuçlar üretmektedir. Yapılan çalışmada da 6 derin mimari ve farklı sınıflandırıcılar ile sonuçlar alınmıştır. Elde edilen sonuçlar karşılaştırıldığında yüksek doğruluk değeri %89.70 ile önerilen modelde elde edilmiştir.

Kaynaklar

- [1] Kaypak, Ş. (2014). Çevre Sorunlarının Çözümünde Küresel Çevre Politikaları. Muğla Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, (31), 17-34. Goldberg D.E., Holland J.H. : Genetic algorithms and machine learning. Mach Learn, 3:95–9, 1988.
- [2] Özbuğutu, E., Karahan, S., & Tan, Ç. (2014). Çevre Eğitimi ve Alternatif Yöntemler–Literatür Taraması/Environmental Education and Its Alternative Methods–A Literature Review. Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 11(25), 393-408.
- [3] Bayram, H. Y., Bingöl, H., & Alatas, B. (2022). Hybrid Deep Model for Automated Detection of Tomato Leaf Diseases. Traitement du Signal, 39(5), 1781-1787.
- [4] Eroğlu, O., & Yildirim, M. (2022). Automatic detection of eardrum otoendoscopic images in patients with otitis media using hybrid-based deep models. International Journal of Imaging Systems and Technology, 32(3), 717-727.

- [5] Yildirim, K., Yildirim, M., Eryesil, H., Talo, M., Yildirim, O., Karabatak, M., ... & Acharya, U. R. (2022). Deep learning-based PI-RADS score estimation to detect prostate cancer using multiparametric magnetic resonance imaging. *Computers and Electrical Engineering*, 102, 108275.
- [6] Rabano, S. L., Cabatuan, M. K., Sybingco, E., Dadios, E. P., & Calilung, E. J. (2018, November). Common garbage classification using mobilenet. In *2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)* (pp. 1-4). IEEE.
- [7] Kang, Z., Yang, J., Li, G., & Zhang, Z. (2020). An automatic garbage classification system based on deep learning. *IEEE Access*, 8, 140019-140029.
- [8] Meng, S., & Chu, W. T. (2020, February). A study of garbage classification with convolutional neural networks. In *2020 Indo-Taiwan 2nd International Conference on Computing, Analytics and Networks (Indo-Taiwan ICAN)* (pp. 152-157). IEEE.
- [9] Ozkaya, U., & Seyfi, L. (2019). Fine-tuning models comparisons on garbage classification for recyclability. *arXiv preprint arXiv:1908.04393*.
- [10] Chen, Z., Yang, J., Chen, L., & Jiao, H. (2022). Garbage classification system based on improved ShuffleNet v2. *Resources, Conservation and Recycling*, 178, 106090.
- [11] Mittal, G., Yagnik, K. B., Garg, M., & Krishnan, N. C. (2016, September). Spotgarbage: smartphone app to detect garbage using deep learning. In *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing* (pp. 940-945).
- [12] Zhihong, C., Hebin, Z., Yanbo, W., Binyan, L., & Yu, L. (2017, July). A vision-based robotic grasping system using deep learning for garbage sorting. In *2017 36th Chinese control conference (CCC)* (pp. 11223-11226). IEEE.
- [13] Sidharth, R., Rohit, P., Vishagan, S., Karthika, R., & Ganesan, M. (2020, June). Deep learning based smart garbage classifier for effective waste management. In *2020 5th International Conference on Communication and Electronics Systems (ICCES)* (pp. 1086-1089). IEEE.
- [14] URL1: [url:https://www.kaggle.com/datasets/asdasdasdas/garbage-classification](https://www.kaggle.com/datasets/asdasdasdas/garbage-classification), Erişim tarihi: 05/01/2023.
- [15] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- [16] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- [17] Cengil, E., Çınar, A., & Yıldırım, M. (2022). A hybrid approach for efficient multi-classification of white blood cells based on transfer learning techniques and traditional machine learning methods. *Concurrency and Computation: Practice and Experience*, 34(6), e6756.
- [18] Çetiner, H. Yaprak Hastalıklarının Sınıflandırılabilmesi İçin Önceden Eğitilmiş Ağ Tabanlı Derin Ağ Modeli. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 8(15), 442-456.
- [19] Eroglu, Y., Yildirim, K., Çınar, A., & Yildirim, M. (2021). Diagnosis and grading of vesicoureteral reflux on voiding cystourethrography images in children using a deep hybrid model. *Computer Methods and Programs in Biomedicine*, 210, 106369.
- [20] Bingol, H. (2022). Classification of OME with Eardrum Otoendoscopic Images Using Hybrid-Based Deep Models, NCA, and Gaussian Method. *Traitement du Signal*, 39(4).
- [21] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [22] Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). ShuffleNet: An extremely efficient convolutional neural network for mobile devices. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 6848-6856).
- [23] Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*.
- [24] Chorowski, J., Wang, J., & Zurada, J. M. (2014). Review and performance comparison of SVM-and ELM-based classifiers. *Neurocomputing*, 128, 507-516.
- [25] Bingol, H. (2022). NCA-based hybrid convolutional neural network model for classification of cervical cancer on gaussian-enhanced pap-smear images. *International Journal of Imaging Systems and Technology*, 32(6), 1978-1989.
- [26] Zhang, S., Li, X., Zong, M., Zhu, X., & Cheng, D. (2017). Learning k for knn classification. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 8(3), 1-19.
- [27] Gacar, B. K., & Kocakoç, İ. D. (2020). Regression analyses or decision trees?. *Manisa Celal Bayar Üniversitesi Sosyal Bilimler Dergisi*, 18(4), 251-260.