

Atıkların Transfer Öğrenme Yöntemi ile Sınıflandırılmasında Veri Artırımının Etkisi

Necdet Tuğrul Artuğ*¹ 

*¹İstanbul Üniversitesi Cerrahpaşa, Teknik Bilimler Meslek Yüksekokulu, Elektrik ve Enerji
Bölümü, Elektrik Programı , İSTANBUL

(Alınış / Received: 05.02.2025, Kabul / Accepted: 13.03.2025, Online Yayınlanma / Published Online: 30.04.2025)

Anahtar Kelimeler

Atık Ayırıştırma,
Evrişimsel Sinir Ağları,
Derin Öğrenme,
Transfer Öğrenme,
Yapay Zekâ

Öz: Atıkların sınıflandırılmasının efektif bir şekilde yapılması, küresel ısınmaya karşı alınacak önlemlerden bir tanesidir. Bu sürecin geleneksel yöntemler yerine daha pratik yöntemlerle, yani yapay zekâ aracılığıyla yapılması sürece katkı sağlayacaktır. Bu çalışmada 9 atık sınıfı içeren RealWaste veri seti kullanılarak, transfer öğrenme yoluyla sınıflandırılma işlemi gerçekleştirilmiştir. Derin öğrenme ağlarının sınıflandırma başarısının test edilmesi için dört farklı senaryo ele alınmıştır. Ayrıca veri artırımının sınıflandırma sürecine etkisi araştırılmıştır. Çalışmada AlexNet, GoogLeNet, MobileNet, ResNet serisi, VGG serisi ve Inception_v3 ağları tercih edilmiştir. Ağların son 2 katmanı eğilirken, diğer katmanları dondurulmuştur. Veri artırımı için geometrik dönüşümler tercih edilmiştir. Veri seti üzerinde ek işlemler yapılmadan en yüksek başarı %91,57 olarak ResNet50 ağıyla elde edilmiştir. Veri artırımı yapıldığında ise Inception_v3 ağıyla %99,912'lik sınıflandırma başarısı elde edilmiştir. Veri artırımının sınıflandırma başarısına pozitif etki ettiği gözlemlenmiştir.

The Effect of Data Augmentation on Classification of Wastes via Transfer Learning Method

Keywords

Waste Decomposition,
Convolutional Neural
Networks,
Deep Learning,
Transfer Learning,
Artificial Intelligence

Abstract: Effective classification of waste is one of the precautions to be taken against global warming. Carrying out this process with more practical methods instead of traditional methods, namely through artificial intelligence, will contribute to the process. In this study, classification process was conducted via transfer learning while using RealWaste dataset which contains 9 waste classes. Four different scenarios were considered to test the classification performance of the deep learning networks. Besides, the effect of data augmentation on the classification process was investigated. AlexNet, GoogLeNet, MobileNet, ResNet versions, VGG versions and Inception_v3 networks were preferred in this study. While the last 2 layers of the networks were trained, the other layers were frozen. Geometric transformations were preferred for data augmentation. The highest performance acquired without doing any additional processes on the data set was 91.57% with ResNet50 network. When data augmentation was made, 99.912% classification performance was achieved with the Inception_v3 network. It was observed that data augmentation affected the classification performance in a positive way.

*İlgili Yazar, email: tugrulartug@gmail.com

1. Giriş

Ev veya sanayi kaynaklı atıkların çöp sahalarında etkin bir şekilde ayıklanması, çevre kirliliğinin azaltılmasında önemli bir rol oynar [1, 2]. Bu sürecin düzgün şekilde yönetilmemesinin hem çevreye hem de insan sağlığına

olumsuz etkisi vardır. Atıkların ayrıştırma sürecinin etkin yapılamaması ve bekletilmesi gaz salınımına sebep olur. Bu salınım da küresel ısınmada artış ile sonuçlanır [2, 3].

Atıklar organik, inorganik ve geri dönüştürülebilir atıklar olarak 3 ana grupta toplanabileceği gibi, kendi içlerinde de alt gruplara ayrılabilir [4]. Geri dönüştürülebilir atıklara örnek olarak kâğıt, cam, plastik ve metal verilebilir. Atıkların ayrıştırılması geleneksel şekilde insan gücüyle yapılabileceği gibi, akıllı sistemler vasıtasıyla da yapılabilmektedir. Bununla ilgili yapılan çalışmalardan birinde [5] akıllı telefon vasıtasıyla atığın türünü belirlemeye yönelik bir yazılım geliştirmişlerdir. Bunun için derin öğrenmeye dayalı bir sınıflandırıcı önermişler ve hazır bir veri seti olan GINI üzerinde çalışmışlardır. Çalışma sonunda %87,69 doğruluk elde etmişlerdir.

Yapılan bir diğer çalışmada [6] Chu ve diğerleri, atıkların sınıflandırılabilmesi için çok katmanlı hibrit bir derin öğrenme mimarisi tasarlamışlardır. Evrimsel sinir ağları ile görüntülerden öznitelikler çıkartırken, çok katmanlı perseptron ile de atıkları sınıflandırmışlardır. Kendi oluşturdukları veri seti 5000 görüntüden oluşmaktadır ve atıkları geri dönüştürülebilir ve diğerleri olarak sınıflamışlardır. Sonuçta %90'ın üzerinde başarı elde etmişlerdir.

Zhang ve diğerleri [7], derin öğrenme yoluyla ResNet18 ağına kendi kendini izleme modülü entegre ederek, geri dönüştürülebilir atıkları sınıflamışlardır. Geliştirdikleri modeli TrashNet veri seti üzerinde denemişlerdir. TrashNet 6 farklı atık türüne ait görüntüleri içermektedir ve bu set üzerinde %95,87'lik bir başarı elde etmişlerdir.

Akıllı sistemlerle atık sınıflandırmasına yönelik bir çalışma da Hossen ve diğerleri [8] tarafından yapılmıştır. Bu çalışmada RWCNet adı verilen bir derin öğrenme modeli geliştirerek, TrashNet veri setini sınıflandırmaya çalışmışlardır. Önerdikleri model %95,01'lik bir başarı elde etmiştir.

Bilinen önceden eğitilmiş derin öğrenme ağlarını transfer öğrenme yoluyla kullanarak, katı atıkları sınıflandırma problemini içeren bir çalışma, Oza ve diğerleri [9] tarafından 2025 yılında yapılmıştır. Çalışmalarında hazır 3 veri setini birleştirerek kullanmışlardır. Böylece 10 farklı kategoride 30000'in üzerinde görüntü içeren bir veri seti oluşturmuşlardır. Dense-Net ve Efficient-Net ağları birleştirilerek %99,54'lük başarı elde etmişlerdir.

Mevcut çalışmanın amacı ise RealWaste [10] isimli veri seti üzerinde önceden eğitilmiş evrimsel sinir ağlarını, transfer öğrenme yöntemi vasıtasıyla kullanarak atıkları sınıflandırmak ve veri artırımının sınıflandırma başarısı üzerine etkisini araştırmaktır.

2. Materyal ve Metot

Çalışmada çeşitli atıkları içeren bir veri seti [10], transfer öğrenme yöntemi ile bilinen evrimsel sinir ağları kullanılarak sınıflandırılacaktır. Oluşturulacak senaryolar ile sınıflandırma performansı artırılmaya çalışılacak ve ağların performansları karşılaştırılacaktır. Tüm süreçler MATLAB ortamı üzerinde yürütülecektir. Ağların eğitimi işlemi için yüksek performanslı bir bilgisayar kullanılacaktır. Bilgisayarın donanımında 5,8 GHz'lık 24 çekirdekli bir işlemci, 32 GB 4800 MHz DDR5 bellek ve Nvidia RTX A4000 yongasına sahip 16 GB bellekli bir ekran kartı bulunmaktadır.

2.1. Veri seti

RealWaste [10] veri seti 524x524 çözünürlüğünde, toplam 9 farklı sınıfa ait atık görüntüsü barındırmaktadır. Bu veri setini diğerlerinden ayıran özelliği, deformasyona ve bozulmaya uğramış materyalleri de içermesidir. Atık türleri sırasıyla bitki (436), cam (420), gıda (411), kâğıt (500), karışık (495), karton (461), metal (790), plastik (921) ve tekstilden (318) oluşmaktadır. Karışık isimli kategori, net şekilde belirlenmiş olan diğer 8 kategoriye girmeyen atıklar için belirlenmiş bir sınıftır. Veri setinin düzgünce eğitim, test ve validasyon olarak ayrılabilmesi için bitki, gıda, karton, plastik ve tekstil sınıflarından sırasıyla 1, 1, 1, 1 ve 3 adet görüntü atılmış ve toplamda 4745 görüntü elde edilmiştir. Bahsedilen 9 sınıfa ait örnek görüntüler Şekil 1'de sunulmuştur. Karışık kategorisinin örnek görüntüsü bir bulaşık süngeridir.



1. Sıra: Bitki, Cam, Gıda
2. Sıra: Kağıt, Karışık, Karton
3. Sıra: Metal, Plastik, Tekstil

Şekil 1. RealWaste veri setinden 9 sınıf için örnek görüntüler

2.2. Yöntem

Çalışmada kullanılacak olan veri setinin sınıflandırılması için, önceden eğitilmiş ve bilinen evrimsel sinir ağları kullanılacaktır. Test edilecek ağlar, derinlik ve parametre bilgileri Tablo 1’de verilmiştir.

Tablo 1. Önceden eğitilmiş derin öğrenme ağları ve bilgileri

Ağ	Ağın Derinliği	Parametre Sayısı (Milyon)
AlexNet [11]	8	61
GoogLeNet [12]	22	7
MobileNet [13]	53	3,5
ResNet18 [14]	18	11,7
ResNet50 [14]	50	25,6
VGG16 [15]	16	138
VGG19 [15]	19	144
Inception_v3 [16]	48	23,9

AlexNet 2012’de ImageNet yarışmasını kazanmış olup Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilmiştir [11]. Oldukça hızlı eğitilebilen bir ağıdır. GoogLeNet ise aynı yarışmayı 2014 yılında kazanmış olup, Google mühendisleri tarafından geliştirilmiştir [12]. İlk versiyonu, nesne algılama ve görüntü sınıflandırma işlemlerini mobil cihazlarda bile yapabilecek kadar sistem dostudur. Sandler ve diğerleri tarafından geliştirilen MobileNet ise düşük sistem gereksinimleriyle mobil cihazlarda gerçek zamanlı uygulamalar geliştirmek için idealdir [13]. Bunu sağlarken, derinliği yine yüksek tutabilmiş ve performanstan ödün vermemiştir. ResNet ise eğitim sırasında yeri geldiğinde bazı katmanları atlamasına imkân veren bir mimari sunar. He ve diğerleri tarafından geliştirilen ResNet, bu mimari sayesinde daha derin ağlar oluşturabilmeyi mümkün kılmıştır [14]. ResNet ağı 2015 yılı ImageNet yarışmasını kazanmıştır. Derinlik sayısı 152’ye kadar olan modelleri mevcuttur. VGG ağının mimarisi sıralı şekilde evrim katmanları, havuzlama katmanları ve tam bağlı katmanlardan oluşur. Bu düzenli mimari yüksek parametre sayısına sahiptir ve VGG16 ile VGG19 olmak üzere iki versiyonu vardır [15]. Transfer öğrenme içeren çalışmalarda sıkça tercih edilmektedir. Inception_v3 de yine Google mühendisleri tarafından geliştirilmiştir. Kendinden önce geliştirilen GoogLeNet mimarisinin 3. versiyonudur. Bu versiyon hem derinliği hem de parametre sayısını belirgin şekilde artırarak, ağın patern tanıma yeteneğini ileri taşımıştır [16].

Yukarıda adı geçen ağların her biri için aşağıdaki ortak parametre ayarları tercih edilmiştir;

- Öğrenme oranı: 10^{-4}
- Validasyon frekansı: Her 5 iterasyonda bir
- İterasyon sayısı: 200

MATLAB ortamında her ağın son iki konvolüsyon katmanı eğitmek için açık bırakılıp, diğer katmanlar dondurulmaktadır. Ağ, en iyi doğruluk değerinin alındığı iterasyondaki ağırlık değerlerini kaydetmektedir. Bu çalışmada 4 farklı senaryo ele alınmış olup, detayları 2.4-2.7 bölümleri arasında verilmiştir.

2.3. Veri seti ön işlemleri

AlexNet için görüntüler 227x227 boyutuna, GoogLeNet, MobileNet, ResNet18, ResNet50, VGG16 ve VGG19 için 224x224 boyutuna ve Inception_v3 için 299x299 boyutuna küçültülmüştür. Veri seti %60 eğitim, %20 test ve %20 validasyon olmak üzere rastgele bölünmüştür.

Derin öğrenme çalışmalarında, veri setinde bulunan örnek sayısı sınıflandırma performansında kilit rol oynar. Örnek sayısı ne kadar yüksek olursa, ağ modelinin görüntülerden çıkarabileceği öznetelik sayısı da artar. Dolayısıyla ağın genelleme performansı da yükselir.

Veri sayısı az olduğunda, sentetik bir şekilde veri artırımı yoluna başvurulabilir. Veri artırımı yöntemleri iki ana başlıkta toplanabilir. Bunlardan ilki derin öğrenme yaklaşımını içeren nöral stil transferini (Neural style transfer - NST) ve üretken çatışmacı ağları (Generative adversarial networks – GAN) içerir [17]. Diğerleri ise görüntü üzerine manipülasyonlar yapan kaydırma, döndürme, yansıma, kesme, ölçekleme gibi geometrik dönüşümleri ve keskinleştirme, kontrast ile oynama gibi fotometrik dönüşümleri içerir [17, 18].

Sadece veri setindeki örnek sayısının az olduğu durumlarda değil, sınıflardaki örnek sayısının dengesiz olduğu durumlarda da veri artırımı performansı olumlu şekilde etkilemektedir. Yapılan bir çalışmada [17] dengesiz bir veri setine geometrik dönüşümler uygulayarak veri sayısını artırmışlar ve F1 skoru üzerinde artış kaydetmişlerdir. ImageNet veri seti üzerinde yapılan bir diğer çalışmada [18], geometrik dönüşümlerin performansa etkisinin daha fazla olduğu bulgusuna ulaşmışlardır.

Çalışmada kullanılan veri seti belli bir standartta kaydedilmiştir ve düzenli bir yapıya sahiptir. Bu bilgilere ilaveten daha önceki çalışmalarda elde edilen bulguların ışığında, veri artırımı için geometrik dönüşüm tercih edilmiştir.

Veri artırımı işleminde kullanılan geometrik dönüşümlere ait işlemler aşağıda verilmiştir;

- Döndürme: 90, 180 ve 270 derece
- Yansıma: X ve Y eksenine ayna görüntüleri

Bu işlemler sonucunda orijinal görüntüyle birlikte veri setindeki görüntü sayısı, senaryo içerisinde 6 katına çıkmaktadır.

2.4. Ham verinin sınıflandırılması (8 sınıflı)

İlk senaryoda kategorisi net bir şekilde belirli olan 8 sınıf ele alınmış ve 'karışık sınıfı' dışarıda bırakılmıştır. Görüntü sayısı 4250'dir. Yukarıdaki ayarlara göre 8 farklı ağ bu veriler ile eğitilmiş ve doğruluk, kesinlik, duyarlılık, F1 Skoru, ROC eğrisi altında kalan alan değerleri hesaplanmıştır. Ayrıca karışıklık matrisi de oluşturulmuştur.

2.5. Artırılmış verinin sınıflandırılması (8 sınıflı)

İkinci senaryoda ise 2.4'teki aynı 8 sınıflı veri setine, veri artırımı yapılmış olup tekrar aynı ağlar eğitilip test edilmiştir. Bu işlem sonunda elde edilen görüntü sayısı 25500'dür. Bir önceki bölümde bahsi geçen parametreler bu senaryo için de hesaplanmıştır.

2.6. Ham verinin sınıflandırılması (9 sınıflı)

Bu senaryoda, net bir şekilde ayrılmış kategorilerdeki sınıflardan da yeri geldiğinde bir parça içeren (Ör: Plastik içeren oyuncak) karışık sınıfı da veri setine dahil edilmiştir. Böylece veri setindeki görüntü sayısı 4745'e yükselmiştir. Ağlar tekrar eğitilip, aynı parametreler bu aşamada da hesaplanmıştır.

2.7. Artırılmış verinin sınıflandırılması (9 sınıflı)

Son senaryoda ise 2.6'daki 9 sınıflı veri setine veri artırımı yapılmıştır. Bu sayede görüntü sayısı 28470'e çıkmıştır. Veri artırımının etkisinin araştırılması istenen bu en karmaşık senaryoda, yine önceki senaryolarda adı geçen parametreler hesaplanmıştır. Karışık sınıfına ait 4 adet örnek görüntü Şekil 2'de sunulmuştur.



Şekil 2. Karışık sınıfına ait 4 adet görüntü (çubuk, kolye, toz kümesi ve sünger)

3. Bulgular

İlk senaryo (Bölüm 2.4) için elde edilen sonuçlar Tablo 2'de sunulmuştur.

Tablo 2. 8 sınıflı ham verilerin sınıflandırılma performansı

Ağ	Eğitim Başarısı	Test Başarısı	Validasyon Başarısı	Kesinlik	Duyarlılık	F1 Skoru	ROC Eğrisi Alanı
AlexNet	98,824	87,765	88,706	88,693	87,433	0,881	0,928
GoogLeNet	99,647	89,647	91,177	90,739	89,706	0,902	0,941
MobileNet	99,451	91,412	92,235	91,676	92,081	0,919	0,954
ResNet18	99,608	93,059	93,412	93,949	93,733	0,938	0,964
ResNet50	99,882	93,177	93,529	93,599	93,279	0,934	0,961
VGG16	98,745	87,882	89,177	89,533	87,815	0,887	0,930
VGG19	99,569	93,059	94,941	93,411	93,514	0,935	0,963
Inception_v3	99,529	93,765	94,471	95,039	93,366	0,942	0,962

En yüksek değer veren parametreler tablo üzerinde koyu ile gösterilmiştir. Eğitim süresi en kısa zaman alan ağ AlexNet olarak öne çıkmıştır. Diğer taraftan en kötü test başarısı da yine AlexNet ile alınmıştır (%87,765). En iyi test sonucu Inception_v3 ağıyla %93,765 olarak elde edilmiştir. Inception_v3 ağına ait karışıklık matrisi Şekil 3'te verilmiştir.

Test Başarısı %93,7647

Gerçek Sınıf	Bitki	86		1					
	Cam		78				2	4	
	Gıda	2		80					
	Kağıt				93	2	1	4	
	Karton				1	84	2	5	
	Metal		2				153	3	
	Plastik		2	1		1	10	170	
	Tekstil	1	2		2		5		53
		Bitki	Cam	Gıda	Kağıt	Karton	Metal	Plastik	Tekstil

Tahmin Edilen Sınıf


Şekil 3. Inception_v3 ağı için 8 sınıflı ham veri test performansı

Arttırılmış veri ile oluşturulan ikinci senaryoya (Bölüm 2.5) ait sonuçlar Tablo 3'te sunulmuştur.

Tablo 3. 8 sınıflı arttırılmış verilerin sınıflandırılma performansı

Ağ	Eğitim Başarısı	Test Başarısı	Validasyon Başarısı	Kesinlik	Duyarlılık	F1 Skoru	ROC Eğrisi Alanı
AlexNet	99,856	98,157	98,843	98,196	98,487	0,983	0,991
GoogLeNet	100	99,902	100	99,934	99,908	0,999	1
MobileNet	99,987	99,471	99,765	99,462	99,521	0,995	0,997
ResNet18	100	99,745	99,882	99,776	99,817	0,998	0,999
ResNet50	100	99,961	99,980	99,976	99,976	1	1
VGG16	99,987	99,039	99,235	99,196	98,960	0,991	0,994
VGG19	99,778	98,333	98,726	98,558	98,496	0,985	0,991
Inception_v3	99,994	99,902	99,980	99,934	99,943	0,999	1

Veri artırımı başarıyı tüm parametreler için yükseltmiştir. En yüksek değerler yine tabloda koyu ile belirtilmiştir. En yüksek test başarısını ResNet50 ağı vermiştir (%99,961). AlexNet ağı yine en hızlı eğitilen ağ olmakla beraber, en düşük sınıflandırma performansını %98,157 ile göstermiştir. ResNet50 ağı sonuçlarından elde edilen karşıtlık matrisi Şekil 4'te verilmiştir.



Şekil 4. ResNet50 ağı için 8 sınıflı artırılmış veri test performansı

Üçüncü senaryoda (Bölüm 2.6) karışık sınıfı da veri setine eklenmiştir. Eğitilen ağlar ile elde edilen sonuçlar Tablo 4'te paylaşılmıştır. İleriki senaryolarda AlexNet ağı, önceki iki senaryoda da (Bölüm 2.4 ve 2.5) en düşük sınıflandırma başarısını gösterdiğinden test edilmemiştir. Benzer şekilde VGG ağları da hem uzun eğitim süreleri hem de yine bahsedilen senaryolarda en iyi sonuçları vermediğinden testlere dahil edilmemişlerdir.

Tablo 4. 9 sınıflı ham verilerin sınıflandırılma performansı

Ağ	Eğitim Başarısı	Test Başarısı	Validasyon Başarısı	Kesinlik	Duyarlılık	F1 Skoru	ROC Eğrisi Alanı
GoogLeNet	99,895	87,566	87,777	88,322	87,647	0,880	0,930
MobileNet	99,895	86,934	88,514	86,973	87,819	0,874	0,931
ResNet18	99,930	90,200	91,992	90,893	90,057	0,905	0,944
ResNet50	99,860	91,570	92,624	92,326	91,869	0,921	0,954
Inception_v3	99,895	91,570	92,202	91,708	91,352	0,915	0,951

Eklenen yeni 'karışık' sınıfı, 8 sınıflı ilk senaryoya (Bölüm 2.4) kıyasla, performansı %2-3 arasında düşürmüştür. Tabloda en yüksek değerler koyu ile gösterilmiştir. Bu senaryoda en yüksek test başarısı ResNet50 ve Inception_v3 ağları ile %91,57 olarak elde edilmiştir. En hızlı eğitilen ağ ResNet18 olurken, en düşük test performansını MobileNet göstermiştir (%86,934). ResNet50 ağına ait karışıklık matrisi Şekil 5'te sunulmuştur.

Test Başarısı %91,5701

Gerçek Sınıf	Bitki	86			1				
	Cam		79				4	1	
	Gıda	3		76	1	2			
	Kagıt		1		95	2		2	
	Karışık		1	1	3	83	4	5	2
	Karton				1	87	1	3	
	Metal		2		1	4	1	147	3
	Plastik		4		1		3	14	161
	Tekstil	1	1			5		1	55
	Bitki	Cam	Gıda	Kagıt	Karışık	Karton	Metal	Plastik	Tekstil

Tahmin Edilen Sınıf


Şekil 5. ResNet50 ağı için 9 sınıflı ham veri test performansı

En karmaşık olan son senaryoya (Bölüm 2.7) ait sonuçlar Tablo 5'te sunulmuştur.


Tablo 5. 9 sınıflı artırılmış verilerin sınıflandırılma performansı

Ağ	Eğitim Başarısı	Test Başarısı	Validasyon Başarısı	Kesinlik	Duyarlılık	F1 Skoru	ROC Eğrisi Alanı
GoogLeNet	100	99,877	99,912	99,885	99,900	0,999	0,999
MobileNet	99,977	99,298	99,701	99,314	99,347	0,993	0,996
ResNet18	100	99,701	99,737	99,809	99,779	0,998	0,999
ResNet50	100	99,895	99,947	99,900	99,929	0,999	1
Inception_v3	100	99,912	99,895	99,936	99,923	0,999	1

Veri artırımı sonuçlara olumlu etki etmiştir. En yüksek değerler koyu ile gösterilmiş olup, en iyi test başarısını veren ağ Inception_v3'tür (%99,912). ResNet18 en hızlı eğitilen ağ olarak öne çıkarken, en düşük sınıflandırma performansı %99,298 ile MobileNet'e aittir. Inception_v3 ağına ait karşıtlık matrisi ve sınıflara ait ROC eğrileri sırasıyla Şekil 6 ve 7'de verilmiştir.



Şekil 6. Inception_v3 ağı için 9 sınıflı artırılmış veri test performansı



Şekil 7. Inception_v3 ağı için 9 sınıflı artırılmış veriye ait ROC eğrileri ve eğri altında kalan alan değerleri

4. Tartışma ve Sonuç

Mevcut çalışmada, bilinen önceden eğitilmiş evrişimsel sinir ağları kullanılarak, transfer öğrenme yöntemiyle atıkların sınıflandırılmasında veri artırımının etkisi araştırılmıştır. Bunun için öncelikle veri setindeki görüntüler, uygulanacak ağın girişine göre ölçeklenmişlerdir. Ağların son iki katmanı ağırlıkların ince ayarı için eğitilmiş, diğer katmanlar ise dondurulmuştur. Çalışma kapsamında 4 senaryo belirlenmiştir. İlk senaryoda açık bir şekilde birbirinden ayrılmakta olan 8 atık kategorisi sınıflandırılmıştır. İkinci senaryoda ise aynı kategorilere veri artırımı yapılmış ve sınıflandırma başarısı araştırılmıştır. Üçüncü senaryoda 9. sınıf olan 'karışık' kategorisi eklenmiş ve görüntülerde sayı artırımına gidilmeden, bu zorlaştırılmış veri setinin sınıflandırılması gerçekleştirilmiştir. Son senaryoda ise yine bu 9 kategoriye veri artırımı yapılmış ve sınıflandırma sonuçları incelenmiştir.

İlk senaryonun sonuçlarına bakıldığında, test başarısının %87,765'in altına inmediği ve en yüksek başarıyı Inception_v3 ağının %93,765 ile gösterdiği görülmektedir. Aynı ağ %95 üzeri kesinlik ve F1 skoru için 0,942 değerini vermiştir. Bu senaryo için tüm ağlar birlikte değerlendirildiğinde en iyi sınıflandırılan atık bitki, en kötü sınıflandırılan atık ise plastik olarak belirlenmiştir.

İkinci senaryoda ise veri artırımının, sınıflandırma başarısını belirgin bir şekilde artırdığı görülmektedir. Test sonuçları %98,157'un altına inmezken, en yüksek sınıflandırma başarısı %99,961 olarak ResNet50 ağı ile elde edilmiştir. Diğer tüm parametrelerde de neredeyse hep en iyi sonucu veren ResNet50 ağı, diğer ağlardan bir adım öndedir. Tüm ağlar beraber ele alındığında bitki ve gıda atıklarının en doğru şekilde sınıflandırıldığı gözlemlenirken, yine plastik atıklarının nispeten daha yanlış sınıflandırıldığı görülmüştür. Yanlış sınıflandırılan plastikler, genellikle metal olarak yanlış sınıflandırılmıştır. Her ne kadar sınıflandırılma oranı diğer atık sınıflarına göre düşük olsa da, %96,649'un altına inmemiştir. Plastik atıkların yanlış sınıflandırılmasının sebebi, zaman zaman metal gibi parlak yüzeyli olmalarından olabilir. Benzer sorunla çalışmalarında karşılaşan Younis ve Obaid [19], bu iki sınıfı ayırmada karşılaşılan zorluklara değinmişlerdir.

Üçüncü senaryo, kullanılan veri setinin kaynak çalışması olan yayın ile [20] benzer bir senaryodur. Single ve diğerleri yaptıkları çalışmada, veri setinden rastgele %10'luk kısmını test için ayırmışlardır. Kalan %90'lık veriyi de %80 eğitim ve %20 validasyon olarak ayırmışlardır. Böylece veri seti %72 eğitim, %18 validasyon ve %10 test olarak ayrılmıştır. Mevcut çalışmada ise veri setinin bölünmesi %60 eğitim, %20 test ve %20 validasyon şeklindedir. Bu çalışmada elde edilen sonuçlar ile [20] numaralı çalışmanın sonuçlarının karşılaştırması Tablo 6'da sunulmuştur. Sadece birebir uyumlu olan ağlar karşılaştırma tablosuna eklenmiştir.

Tablo 6. Üçüncü senaryonun kaynak çalışma [20] ile karşılaştırma sonuçları

Ağ	Çalışma	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
MobileNet	Single vd. [20]	88,15	89,98	85,86	0,879
	Mevcut Çalışma	86,934	86,973	87,819	0,874
Inception_v3	Single vd. [20]	89,19	91,34	87,73	0,903
	Mevcut Çalışma	91,57	91,708	91,352	0,915

Ağlara yönelik sonuçlar kendi içinde değerlendirildiğinde, Single vd. MobileNet için daha iyi sonuçlar elde etmişken, mevcut çalışma Inception_v3 için daha iyi sonuç vermiştir. Mevcut çalışmanın ikinci en iyi test performansını veren ağ Inception_v3 olsa da Single vd.'nin sonuçlarının [20] üzerine çıkmıştır. Bu çalışmanın en iyi sonucu da tesadüfi bir şekilde %91,57'dir ve ResNet50 ağına aittir. İki sonuç aynı test performansını verse de diğer parametreler ele alındığında, ResNet50 ağı bu senaryo için daha iyi sonuçlar sunmaktadır. Atık kategorilerinden en doğru sınıflandırılan, her ağ için bitki sınıfıdır. En hatalı sınıflandırılan ise beklendiği gibi karışık sınıfıdır. Ağlar içerisinde en düşük oranla doğru sınıflandırılan karışık sınıfına ait sınıflandırma başarısı %70,7'dir. En iyi genel test performansı veren ResNet50 ağında ise karışık sınıfına ait sınıflandırma performansı %83,838 olarak hesaplanmıştır.

Son senaryo, eklenen karışık sınıfı ile zorlaşan problemde, sınıflandırma performansını artırmak için planlanmıştır. Veri artırımı bu son senaryo için de sınıflandırma performansına olumlu etki yapmıştır. En düşük sınıflandırma başarısı dahi %99,298'dir. En iyi test başarısı %99,912 ile Inception_v3 ağına ait olsa da ResNet50 ağı da oldukça yakın bir performans göstermiştir. Tüm ağların performansı birlikte ele alındığında bitki ve gıda sınıfları yüksek doğrulukla sınıflandırılırken, plastik sınıfı en düşük doğrulukla sınıflandırılan atık türü olmuştur. En düşük performansı veren ağ için plastik sınıfının doğruluk değeri %99,094 olarak bulunmuştur.

Tüm senaryoların sonuçları irdelendiğinde, veri artırımının performansa olumlu etki gösterdiği görülmektedir. Yanlış sınıflandırmaların sebebi, o atık sınıfında kısmi de olsa başka sınıftan materyal içermesi olabilir. Örneğin cam kavanozların kapakları metal olabildiğinden metal sınıfında yanlış olarak sınıflanabilmektedir.

İlk iki senaryoda AlexNet en kötü sınıflandırma performansını göstermiştir. AlexNet ağına parametre sayısı test edilen ağlar arasında en yüksek 3. olsa da derinliği yeterli gelmemiş olabilir. Pekâlâ ağına derinliğinin fazla olması illa iyi sonuç verecek anlamına gelmez. Ağına organizasyonunun probleme göre uyumlu olması daha yüksek sonuç alınmasını sağlayacaktır [21].

Bu çalışmanın sonuçları tatmin edici olsa da sistemin bazı dezavantajları da bulunmaktadır. Ağına performansı görüntü kalitesine bağlıdır. Görüntülerin bir standarda uygun olarak çekilmesi önemlidir ve cisim ortaya konumlanmalıdır. Eğer öyle değilse de ağına başarımın sağlanması için cisim önışlemlerle ortalanmalı ve ağına göre görüntü ölçeklenmelidir. Ayrıca eğitim verisinde her sınıfa ait görüntü adedi dengeli olmalıdır.

Bu çalışmada kurulan ağ yapısı ile bahsi geçen sınıflardaki atıklar ayrıştırılabileceği gibi, atıklar arasında sadece ayrıştırılmak istenen bir sınıfa da odaklanılabilir. Örneğin geri dönüştürülebilir olanlar ile geri dönüştürülemeyen atıklar ayrıştırılabilir. Test edilecek görüntünün ağına hangi açıyla verileceği bilinemeyeceğinden, veri artırımında önerilen geometrik dönüşümler uygulanıp, üretilen türevleriyle beraber görüntüler ağına verilebilir. Elde edilen sonuçlar bir komiteden geçirilerek, çoğunluğun kararına göre görüntünün sınıfı tespit edilebilir. Ayrıca tüm senaryoların eğitim süreci incelendiğinde, 200 iterasyonun eğitim süresini gereksiz yere uzattığı ve yaklaşık 80 iterasyonun ağların eğitimi için yeterli olduğu görülmüştür. Ağına ayarları, en iyi doğruluk değerini verdiği iterasyondaki ağırlık değerlerini çekmek üzerine olduğundan, sonuçlar üzerine olumsuz bir etkisi olmamıştır.

Teşekkür

Bu çalışmada, İstanbul Üniversitesi-Cerrahpaşa Teknik Bilimler Meslek Yüksekokulu Müdürlüğü bünyesinde bulunan Yapay Zekâ Laboratuvarı envanterindeki bilgisayar kullanılmıştır.

Kaynakça

- [1] Baun, A., Jensen, S. D., Bjerg, P., Christensen, T. H., Nyholm, N. 2000. Toxicity of organic chemical pollution in groundwater downgradient of a landfill (Grindsted, Denmark). *Environ. Sci. Technol.*, 34, 1647–1652.
- [2] Asase, M., Yanful, E. K., Mensah, M., Stanford, J., Amponsah, S. 2009. Comparison of municipal solid waste management systems in Canada and Ghana: a case study of the cities of London, Ontario, and Kumasi, Ghana. *Waste Manag.*, 29(10), 2779-2786.
- [3] Themelis, N. J., Ulloa, P. A. 2006. Methane generation in landfills. *Renew. Energy*, 32, 1243–1257.
- [4] Hoornweg, D., Bhada-Tata, P. 2012. What a Waste: A Global Review of Solid Waste Management. Urban development series; knowledge papers, 15. <https://hdl.handle.net/10986/17388>. (Erişim Tarihi: 01.02.2025).
- [5] Mittal, G., Yagnik, K. B., Garg, M., Krishnan, N. C. 2016. Spotgarbage: smartphone app to detect garbage using deep learning. *UbiComp '16: Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, 12-16 Eylül, Hamburg, 940-945.
- [6] Chu, Y., Huang, C., Xie, X., Tan, B., Kamal, S., Xiong, X. 2018. Multilayer Hybrid Deep-Learning Method for Waste Classification and Recycling. *Comput Intell Neurosci.*, 5060857.
- [7] 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 and Recycling*, 171, 105636.
- [8] Hossen, M. M., Majid, M. E., Kashem, S. B. A., Khandakar, A., Nashbat, M., Ashraf, A., Hasan-Zia, M., Kunju, A. K. A., Kabir, S., Chowdhury, M. E. 2024. A reliable and robust deep learning model for effective recyclable waste classification. *IEEE Access*, 12, 13809-13821.
- [9] Oza, P., Agrawal, S., Kapadia, M., Raotole, O. 2025. Solid waste classification using deep neural network: A transfer learning approach. *Earth Science Informatics*, 18(2), 1-25.
- [10] Single, S., Iranmanesh, S., Raad, R. 2023. RealWaste [Dataset]. UCI Machine Learning Repository. <https://archive.ics.uci.edu/dataset/908/realwaste>. (Erişim Tarihi: 14.12.2024).
- [11] Krizhevsky, A., Sutskever, I., Hinton, G. E. 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.

- [12] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. 2015. Going deeper with convolutions. IEEE conference on computer vision and pattern recognition, 7-12 Haziran, Boston, 1-9.
- [13] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L. C. 2018. Mobilenetv2: Inverted residuals and linear bottlenecks. IEEE conference on computer vision and pattern recognition, 18-23 Haziran, Salt Lake City, 4510-4520.
- [14] He, K., Zhang, X., Ren, S., Sun, J. 2016. Deep residual learning for image recognition. IEEE conference on computer vision and pattern recognition, 27-30 Haziran, Las Vegas, 770-778.
- [15] Simonyan, K., Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. arXiv preprint, arXiv:1409.1556. <https://arxiv.org/abs/1409.1556>. (Erişim Tarihi: 01.02.2025).
- [16] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. 2016. Rethinking the inception architecture for computer vision. IEEE conference on computer vision and pattern recognition, 27-30 Haziran, Las Vegas, 2818-2826.
- [17] de la Rosa, F. L., Gómez-Sirvent, J. L., Sánchez-Reolid, R., Morales, R., Fernández-Caballero, A. 2022. Geometric transformation-based data augmentation on defect classification of segmented images of semiconductor materials using a ResNet50 convolutional neural network. Expert Systems with Applications, 206, 117731.
- [18] Shijie, J., Ping, W., Peiyi, J., Siping, H. 2017. Research on data augmentation for image classification based on convolution neural networks. 2017 Chinese Automation Congress (CAC), 20-22 Ekim, Çin, 4165-4170.
- [19] Younis, H., Obaid, M. 2024. Performance Comparison of Pretrained Deep Learning Models for Landfill Waste Classification. International Journal of Advanced Computer Science & Applications, 15(11), 689-698.
- [20] Single, S., Iranmanesh, S., Raad, R. 2023. RealWaste: A Novel Real-Life Data Set for Landfill Waste Classification Using Deep Learning. Information, 14(12), 633.
- [21] Sharma, N., Jain, V., Mishra, A. 2018. An analysis of convolutional neural networks for image classification. Procedia computer science, 132, 377-384.