



# Çiçek Görüntü Sınıflandırılmasında Ön Eğitimli Evrişimsel Sinir Ağlarının Performans Karşılaştırması

Ipek Atik<sup>1\*</sup>

<sup>1</sup>\*Faculty of Engineering and Natural Sciences, Department of Electrical and Electronics Engineering, Gaziantep Islam Science and Technology University, Gaziantep, Turkey (ORCID: 0000-0002-9761-1347), [ipek.atik@gibtu.edu.tr](mailto:ipek.atik@gibtu.edu.tr)

(İlk Geliş Tarihi 2 Mart 2022 ve Kabul Tarihi 26 Mart 2022)

(DOI: 10.31590/ejosat.1082023)

**ATIF/REFERENCE:** Atik I., (2022). Çiçek Görüntü Sınıflandırılmasında Ön Eğitimli Evrişimsel Sinir Ağlarının Performans Karşılaştırması. *Avrupa Bilim ve Teknoloji Dergisi*, (35), 315-321.

## Öz

Çiçek sınıflandırması botanikten, ekolojik çalışmalara kadar birçok alan için önemlidir. Çiçek görüntülerinin net şekilde belirgin olmaması, yaprakların, dalların görüntüyü kapatması ve benzer özellikte çiçeklerin çok olması sınıflandırma çalışmalarında rastlanan zorluklardandır. Çalışmada internette alınan 3670 çiçekten oluşan veri seti kullanılarak sınıflandırma çalışması yapılmıştır. Son dönemde görüntü sınıflandırma çalışmalarında derin öğrenme yöntemleri kullanılarak oldukça başarılı sonuçlara ulaşılmaktadır. Bu çalışmada derin öğrenme modellerinden ön eğitimli Evrişimsel Sinir Ağları (ESA) AlexNet, GoogLeNet, SqueezeNet, ShuffleNet ve Resnet-18 ile sınıflandırma çalışması yapılarak performansları karşılaştırmalı olarak irdelenmiştir. Karşılaştırma neticesinde en başarılı sonuca %97.26 doğruluk oranına sahip olan GoogLeNet ile ulaşılmıştır. Diğer modeller için elde edilen doğruluk oranları sırasıyla ShuffleNet, SqueezeNet, ResNet-18 ve AlexNet için %97.23, %92.84, %91.42, %89.05'tir. Çalışmada GoogLeNet modeli bu çalışmadaki modellerin yanı sıra aynı veri seti ile yapılan diğer çalışmalar içinde en yüksek başarıya ulaşan model olmuştur.

**Anahtar Kelimeler:** Derin Öğrenme, Sınıflandırma, Evrişimsel Sinir Ağları, çiçek, GoogLeNet

## Performance Comparison of Pre-Trained Convolutional Neural Networks in Flower Image Classification

### Abstract

Flower classification is important for many fields, from botanics to ecological studies. The difficulties encountered in classification studies are that flower images are not evident, leaves and branches obscure the image, and many flowers have similar characteristics. The study classification study was carried out using the data set consisting of 3670 flowers taken from the internet. Recently, very successful results have been achieved using deep learning methods in image classification studies. This study examined the performances of the deep learning models comparatively by making a classification study with the pre-trained Convolutional Neural Networks (CNN) AlexNet, GoogLeNet, SqueezeNet, ShuffleNet, and Resnet-18. As a result of the comparison, the most successful result was obtained with GoogLeNet, an accuracy rate of 97.26%. The accuracy rate was calculated as 97.23%, 92.84%, 91.42%, 89.05% for ShuffleNet, SqueezeNet, ResNet-18 and AlexNet, respectively. In addition to the models in this study, the GoogLeNet model was the model that achieved the highest success among other studies conducted with the same data set.

**Keywords:** Deep Learning, Classification, Convolutional Neural Networks, flower, GoogLeNet

\*Sorumlu Yazar: [ipek.atik@gibtu.edu.tr](mailto:ipek.atik@gibtu.edu.tr)

## 1. Giriş

Çiçekler yüzbinlerce türü bulunan bir bitki türüdür. Çiçekler sağlık, endüstri, kozmetik alanlar gibi birçok alanda yaygın olarak kullanılmaktadır. Çiçek türlerinin belirlenmesi, nesilden nesile sağlıklı şekilde aktarılabilmesi tüm canlılar ve ekolojik düzenin korunması açısından da oldukça önemlidir. Çiçek türlerinin belirlenmesinde her çiçek için ona özgü biçim ve özelliklerin belirlenmesi gerekir. Bu şekilde gruplandırılabilir ve sınıflandırması yapılabilir. Çiçek sınıflandırmada 18. yy'da Carl Linnaeus tarafından önerilen sistem şuanda da halen kullanılmaktadır (Coşkun & Demirhan, 2022; Hiary, Saadeh, Saadeh, & Yaqub, 2018). Çiçek özelliklerinin belirlenmesi oldukça zahmetli ve zaman alan bir işlemdir. Bu sebeple bilgisayar ortamında sınıflandırılması ve gruplanması birçok kolaylık sağlamaktadır (Aydın, 2018; Potur & Erginel, 2021; Sağlam, Melike, & Baykan, 2020). Bu alanda özellikle derin öğrenme yöntemleri ile başarılı sonuçlara ulaşılmaktadır. Çiçek görüntü sınıflandırma alanında birçok çalışma yapılmıştır.

Nilsback ve Zisserman'ın (Maria-Elena Nilsback & Zisserman, 2010) çalışmasında çiçek sınıflandırmada ilk olarak ön ve arka planı birbirinden ayıran, ikinci aşamada ise çiçek taç yapısını belirleyen model geliştirmiştir. Çalışmada iki basamaklı segmentasyon yöntemi kullanılmıştır. Das ve Riseman (Das, Manmatha, & Riseman, 1999), çalışmasında çiçek dokusu renk dağılımını inceleyerek aynı tür çiçeğin farklı renk ve dokularda olabileceğini göstermiştir. Nilsback ve Zisserman (M.-E. Nilsback & Zisserman, 2006) 2006 yılında yaptığı çalışmada çiçek görüntülerinin renk, şekil ve doku özelliklerini HSV renk uzayında kelimeye dönüştürerek bir sınıflandırma çalışması yapmıştır. Tseng ve Su (Tseng, Wang, & Su, 2005) renk kümelemesi ve uzamsal bilgi özellikleri ile çok seviyeli ilişkilendirme kuralları kullanarak yeni bir görüntü sınıflandırma yöntemi önermişlerdir. Cho ve Lim (Cho & Lim, 2006), çiçeklerin hem renk hem de şekil özelliklerini kullanarak kümeleme yöntemi geliştirmiştir. Nilsback ve Zisserman (Maria-Elena Nilsback & Zisserman, 2008) bir diğer çalışmasında geniş ölçekli çiçek veri setleri üzerinde çalışmışlardır. Her biri 40 ila 250 örnek içeren 103 sınıflı bir veri kümesini SVM yöntemi ile sınıflandırıp %72,8 doğruluk oranı elde etmişlerdir. Guru ve diğ. (Guru, Kumar, & Shantharamu, 2010), KNN sınıflandırıcısını kullanarak çiçekler için otomatik bir sınıflandırma modeli geliştirmiştir. Mukane ve diğ. (Shailendrakumar, Sachin, & Dattatraya, 2011), bulanık mantık sınıflandırıcı yöntemi kullanmıştır. Liu ve diğ. (Liu, Tang, Zhou, Meng, & Dong, 2016), çiçek sınıflandırmasında evrimsel sinir ağını

kullanmışlardır. Kendi veri kümelerinde %76.54 başarımlarına, Oxford-102 Flowers veri kümesinde ise %84.02 başarıya ulaşmışlardır. Xia ve Xu (Xia, Xu, & Nan, 2017), çiçeklerin sınıflandırılmasında GoogLeNet'i inception-v3 modülüyle kullanmış ve Oxford 17 Flowers için %95, Oxford 102 Flowers isimli veri kümesi için %94 doğruluk oranlarını elde etmişlerdir. Wu ve diğ. (Wu, Qin, Pan, & Yuan, 2018), Oxford-17 ve Oxford-102 çiçek veri kümesi için VGG-16, VGG-19, Inception-v3 ve ResNet50 modelleri ile sınıflandırma çalışması yapmıştır. Oxford-17 için %95.29, Oxford-102 için %96.57 doğruluk elde etmiştir. Sınıflandırma çalışmalarında uygulanan yöntemler model ve veri setine göre başarı oranında farklılık göstermektedir (Toğaçar, Ergen, & Cömert, 2019).

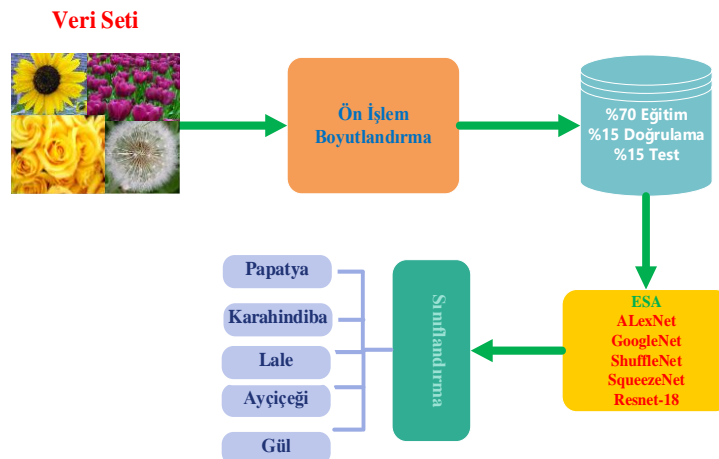
Çalışmada veri seri için ön eğitilmiş evrimsel sinir ağırları kullanılarak sınıflandırma çalışması yapılacak ve performansları karşılaştırılacaktır. Çalışmanın önemi;

- Çiçeklerin doğru ve hızlı bir şekilde sınıflandırılması ekolojiden, endüstriye, sağlığa kadar birçok alanda fayda sağlayacaktır,
- Ayrıca ekolojik dengenin bozulmaması ve bazı çiçek türlerinin tespit edilip yok olmaması açısından önemlidir,
- Çalışmada bulunan analiz sonuçları literatürdeki birçok çalışmadan daha yüksek başarı oranına sahiptir. Çalışma bu yönü ile yenilikçi bir yaklaşım sunmaktadır.
- Çalışmanın ön eğitilmiş ağların çiçek sınıflandırma alanındaki literatüre katkı sağlaması hedeflenmiştir.

Çalışmanın ikinci bölümünde materyal ve metod kısmında önerilen sınıflandırma yöntemi, veri seti, kullanılan ön eğitilmiş sinir ağırları ve modellerin performans ölçüt parametreleri hakkında bilgi verilmiştir. Çalışmanın üçüncü kısmında deneysel analiz sonuçlarına yer verilmiştir. Dördüncü bölümde tartışma kısmında literatürdeki çalışmaların başarı ölçütleri ile karşılaştırma yapılmıştır. Son olarak beşinci sonuç bölümünde çalışmanın sonuçları özetlenmiştir.

## 2. Materyal ve Metod

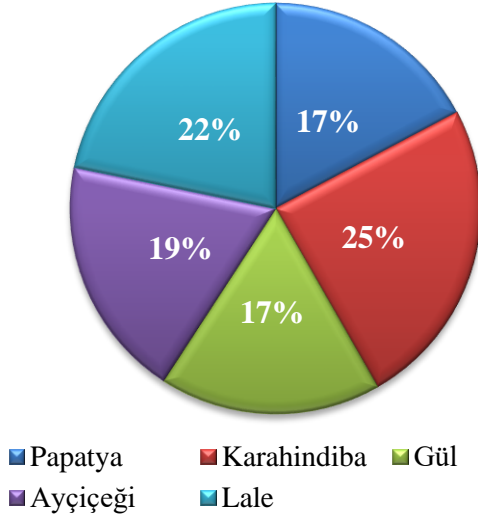
Çalışmada çiçek görüntü sınıflandırma çalışması yapılmıştır. Çalışmada ön eğitilmiş evrimsel sinir ağırları kullanılmıştır. Çalışmada bu bölümde öncelikle veri seti hakkında bilgi verilmiştir. Daha sonra ön eğitilmiş evrimsel sinir ağırları açıklanmış ve performans ölçütlerinin matematiksel eşitlikleri gösterilmiştir. Çalışmada kullanılan yöntemle ait akış diyagramı Şekil 1'de verildiği gibidir.



Şekil 1. Görüntü sınıflandırma akış diyagramı (Figure 1. Image classification flowchart).

## 2.1. Veri Seti

Veri seti erişime açık veri tabanında alınan toplam 3670 adet görüntüden oluşmaktadır (Kaggle, 2021). Bu veri setinde papatya, karahindiba, gül, ayçiçeği ve lale olmak üzere toplamda beş sınıf bulunmaktadır. Bu sınıflardan papatyada 633, karahindiba 898, gül de 641, ayçiçeğinde 699 ve lale sınıfında 799 adet görüntü bulunmaktadır. Veri setindeki çiçeklerin sınıflara göre yüzdelik dağılımı Şekil 2’de verildiği gibidir.



Şekil 2. Veri setinde sınıfların yüzdelik dağılımı  
(Figure 2. Percentage distribution of classes in the data set)  
(Kaggle, 2021).

## 2.2. Ön Eğitimli Evrimsel Sinir Ağı Modelleri

Çalışmada ön eğitimli ESA modellerinden en çok tercih edilen modeller olan AlexNet, GoogLeNet, ShuffleNet,

SqueezeNet ve Resnet-18 modelleri kullanılmıştır (Narayanan, Ali, & Hardie, 2019). AlexNet modeli giriş katmanı, 5 adet konvolüsyon katmanı, 3 adet havuzlama katmanı, 2 adet ezberleme katmanı, 3 adet tam bağlı katman, 7 adet ReLu katmanı, 2 adet normalizasyon katmanı ve sınıflandırma(çıkış) katmanı olmak üzere toplam 25 katmandan oluşur. Giriş katmanında yer alacak olan görüntü 227x227x3 boyutlarındadır (Krizhevsky, Sutskever, & Hinton, 2012). GoogLeNet modeli konvolüsyon katmanı, havuzlama katmanı, sınıflandırma katmanı, tam bağlantı katmanı, giriş katmanı ve çıkış katmanı gibi 144 katman bulunmaktadır. Girdi katmanında yer alacak görüntü 224x224x3 boyutundadır. Konvolüsyon katmanında 1x1, 3x3 ve 5x5 boyutunda filtreler vardır. 3x3 boyutunda havuzlama ve aktivasyon için doğrusal aktivasyon kullanılmaktadır (Atik, n.d.; Sarıgül, Ozyildirim, & Avcı, 2019). SqueezeNet modelinde bağımsız bir konvolüsyon tabakası, sekiz ateşleme modülü ve son konvolüsyon tabakası bulunmaktadır. (Acikgoz, 2022)(Hiary et al., 2018). ShuffleNet modeli diğer ESA mimarilerinden daha basit bir yapıya sahiptir. Parametre sayısının az olması ile de karmaşıklık daha azdır. (Zhang, Zhou, Lin, & Sun, 2017). ResNet mimarisi diğer derin öğrenme yöntemlerinden daha fazla katmana sahiptir. Microsoft ResNet mimarisinde iki ReLu ile doğrusal katman arasında bir kez kalıntı değeri (Residual Value) beslenen bir bloktan (Residual Block) oluşur. Toplam 72 katmandan içermektedir (Szegedy, Ioffe, Vanhoucke, & Alemi, 2017).

## 2.3 Performans Ölçüt Parametreleri

Model başarımını değerlendirirken kullanılan temel kavramlar doğruluk oranı, kesinlik, hassasiyet, duyarlılık ve F-skoru ölçütleri kullanılmıştır. Sınıflandırma çalışmalarında modelin başarısı doğru sınıftaki ve yanlış sınıfa atılan örnek sayılarıyla ilişkilidir. Bu atılan örnek sayıları doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP), yanlış negatif (YN) olarak ifade edilmektedir. Bu ifadelerle göre hesaplanan performans ölçüt eşitlikleri Tablo 1’de verilmiştir (Coşkun & Demirhan, 2022).

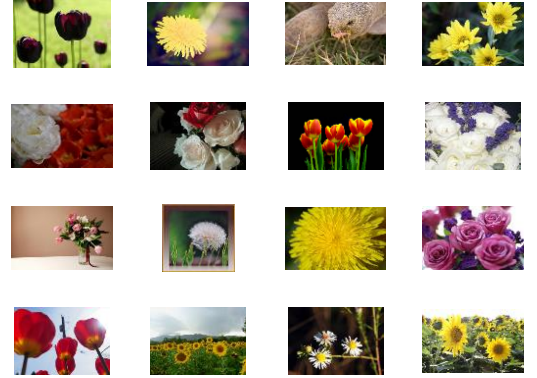
Tablo 1. Model başarımını değerlendirirken kullanılan temel kavramlar ve eşitlikleri (Table 1. Basic concepts and equations are used in evaluating model performance) (Hiary et al., 2018; Wu et al., 2018).

Ölçüt	Eşitlik	Açıklama
Doğruluk Oranı	$\frac{DP + DN}{DP + YP + YN + DN}$	Doğruluk oranı, doğru sınıflandırılmış örnek sayısının, toplam örnek sayısına oranıdır.
Duyarlılık	$\frac{DP}{DP + YN}$	Doğru sınıflandırılmış pozitif örnek sayısının toplam pozitif örnek sayısına oranıdır.
Hassasiyet	$\frac{DP}{YP + DP}$	Hassasiyet, doğru pozitif tahminlerin, pozitif tahminlere oranıdır.
F-skor	$\frac{2 * DP}{2 * DP + YP + YN}$	Kesinlik ve duyarlılığın harmonik ortalamasıdır.

### 3. Deneysel Bulgular

Çalışmada beş farklı sınıfta bulunan toplam 3670 çiçeğin sınıflandırma çalışması yapılmıştır. Veri setinde her sınıfta farklı sayıda çiçek vardır. Çiçek görüntüleri çözünürlüğü 134×240 piksel ile 1024×198 piksel arasında değişmektedir. Ön eğitilmiş derin öğrenme algoritmalarında kullanılmak için 224×224 ve 227×227 boyutlarına indirgenmiştir. Bu görüntülerin %70 eğitim için %15 doğrulama ve %15 test için kullanılmıştır. Doğru performans belirleyebilmek için tüm sınıflardaki çiçek sayısı en az çiçek içeren sınıftaki çiçek sayısı baz alınmıştır. Çalışmada kullanılan veri setinde en az çiçek içeren sınıf 633 ile papatya sınıfıdır. Diğer sınıflardaki çiçek sayısı da 633 olacak şekilde rastgele seçilmiştir. Kullanılan bilgisayar sisteminde i7-10750 H CPU @2.60 GHz, NVIDIA Quadro P620 GPU, and 16 GB RAM memory özelliklerine sahip donanım bulunmaktadır. Uygulama için MatLab derin öğrenme algoritmalarından faydalanılmıştır. Sınıflandırma çalışmasında AlexNet, GoogLeNet, ShuffleNet, SqueezeNet ve ResNet-18 derin öğrenme algoritmaları kullanılmıştır. Sınıflandırma için kullanılan örnek görüntüler Şekil 3’de görüldüğü gibidir. Ayrıca, ESA modelleri ile yapılan eğitim ve test süresince kullanılan parametreler Tablo 2’de verilmiştir. Analizlerin eğitim süreleri de özellikle daha büyük ölçekli çalışmalar için önemli bir kriterdir. Bu sebeple analizlerde derin öğrenme modellerinin


analiz süreleri de incelenmiştir. Analizlerde en kısa sürede tamamlanan derin öğrenme modeli AlexNet iken en uzun süren model çok katmanlı da içermesinden dolayı ResNet-18 modeli olmuştur. Tüm modellere ait analiz süreleri Şekil 4’de görülmektedir



Şekil 3. Sınıflandırma yapılan veri seti görüntüleri (Figure 3. Classified data set images) (Kaggle, 2021).

Tablo 2. ESA modellerinde kullanılan eğitim parametreleri ( Table 2. Training parameters used in ESA models).

Parametre	Değer
Mini topluluk boyutu	16
Maksimum dönem	100
Başlangıç öğrenme oranı	1e-4
Optimize yöntemi	sgdm




Şekil 4. Modellerde ait analiz süreleri (Figure 4. Analysis times of the models).

Şekil 4’den görüldüğü üzere analiz süreleri AlexNet, SqueezeNet, ShuffleNet, GoogLeNet ve ResNet-18 için sırasıyla 20dk, 22dk, 45dk, 75dk ve 190dk olmuştur. Kullanılan veri setinin boyutuna göre analiz süresi değişiklik gösterecektir. Çalışmada analiz yapılan her model için hata matrisleri oluşturulmuştur. Şekil 5’de AlexNet, GoogLeNet, ShuffleNet,

SqueezeNet ve ResNet-18 modelleri analiz sonuçlarına ait sınıflandırma hata matrisleri verilmiştir. Çalışmada kullanılan modellerin başarı oranını belirlemek için performans ölçütleri doğruluk oranı, hassasiyet, duyarlılık ve F-skor değerleri hesaplanmıştır. Hesaplama neticesinde elde edilen sonuçlar Tablo 3’de özetlenmiştir.

Tablo 3. ESA modelleri performans sonuçları (Table 3. Performance results of ESA models).

Model	Doğruluk (%)	Hassasiyet	Duyarlılık	F-Score
AlexNet	89.05	0.891	0.891	0.891
GoogLeNet	97.26	0.974	0.974	0.974
ShuffleNet	97.23	0.972	0.972	0.972
SqueezeNet	92.84	0.930	0.926	0.926
ResNet 18	91.42	0.916	0.914	0.912



Şekil 5. Eğitilmiş sinir ağı modellerinin hata matrisleri (Figure 5. Error matrices of the trained neural network models).

Şekil 5'te analiz sonuçlarına ait hata matrislerinde yatay eksen tahmin dikey eksen gerçek değerleri ifade eder. Gül, karahindiba, gül, ayçiçeği ve lale veri setindeki sınıfları temsil eder. Her bir modelin ismi başlıklarda belirtilmiştir. Örneğin ResNet-18 için hata matrisini yorumlandığında; matriste papatya sınıfına baktığımızda %91.9 oranında papatyaları doğru sınıfta tahmin edildiğini görüyoruz. Model test veri setinde bulunan papatya görüntülerinden 91 tanesini doğru olarak papatya sınıfında bulunmuşken, 4 tanesini karahindiba, 1 tanesini gül, 2 tanesini ayçiçeği ve 1 tanesini de lale olarak yanlış tahmin etmiştir. Aynı şekilde karahindiba sınıfına baktığımızda test veri setindeki 86 adet karahindiba görüntüsünü doğru sınıfta bulurken 3 tanesini papatya, 2 tanesini gül ve 2 tanesini ayçiçeği sınıfında olarak yanlış tahmin etmiştir. Diğer modellerinde hata matrislerinde hangi sınıfın yüzde kaç doğrulukla tahminde bulunduğu şekilde görülmektedir. Modelin performans ölçütleri hata matrisindeki doğru ve yanlış sınıfta bulma değerlerine göre hesaplanır. ESA modellerinin performans ölçütleri değerlendirildiğinde en yüksek doğruluk oranına sahip model %97.26 ile GoogLeNet iken, daha sonra %97.23 ile ShuffleNet, %92.84 SqueezeNet, %91.42 ile ResNet18 ve %89.05 ile AlexNet olmuştur. Ayrıca performans ölçütlerinin hassasiyet değerleri değerlendirildiğinde en yüksek hassasiyet oranı 0.974 ile GoogLeNet iken en düşük orana sahip model 0.891 ile AlexNet'tir. Duyarlılık değerlerinde de başarı sıralaması AlexNet, GoogLeNet, ShuffleNet, SqueezeNet ve ResNet-18 için sırasıyla 0.891, 0.974, 0.972, 0.926 ve 0.914 olarak hesaplanmıştır. Yine aynı modellere ait F-skorlarında da duyarlılık değerlerine yakın değerler elde edilmiştir.

#### 4. Tartışma

Çalışmada ön eğitilmiş ESA modellerinden AlexNet, GoogLeNet, SqueezeNet, ShuffleNet ve ResNet-18 modelleri kullanılmıştır. Aynı veri setini kullanarak farklı yöntemler ile sınıflandırma çalışması yapılan çalışmaların karşılaştırması Tablo 4'de özetlenmiştir.

Tablo 4. Çalışmanın diğer çalışmalarla karşılaştırılması  
(Table 4. Comparison of the study with other studies).

Kaynak	Yöntem	Başarı (%)
(Toğaçar et al.)	ESA ve özellik seçimini kullanmıştır	91,10
(Guo, Hu, Wu, Peng, & Wu)	ESA ve genetik algoritma kullanmıştır.	74,34
(Luus, Khan, & Akhalwaya)	ESA, boyut azaltma yöntemleri ve yarı denetimli öğrenme yöntemlerini kullanmıştır.	79,33
(Bingol, 2022)	ESA, Komşuluk Bileşen Analizi	93,49
<b>Çalışmada kullanılan yöntem</b>	<b>ESA ve boyut azaltma yöntemi kullanılmıştır.</b>	<b>97,26</b>

Çalışmanın başarı oranının diğer yapılan çalışmalardan daha iyi olduğu görülmüştür. Baosu Guo ve arkadaşları, genetik algoritma yöntemini kullanarak sınıflandırma yapmış ve başarı oranını %74,34 olarak elde etmiştir. Francois Luus ve arkadaşları görüntü boyutunu yarı denetimli öğrenme ile düşürerek sınıflandırma çalışması yapmış ve başarı oranını e-ISSN: 2148-2683

%79,33 olarak elde etmişlerdir. M. Toğaçar ve arkadaşları ESA ve özellik seçimi yöntemlerini birlikte kullanarak çiçek sınıflandırması yapmış ve başarı oranı %91.10 olarak elde etmişlerdir. Bu çalışmada elde edilen başarı oranı literatürdeki diğer yöntemlerden daha yüksek olduğu görülmektedir.

#### 5. Sonuçlar

Bu çalışmada 3670 adet çiçek görüntüsü bulunan veri setinin sınıflandırılması için AlexNet, GoogLeNet, ShuffleNet, SqueezeNet ve Resnet-18 ön eğitilmiş ESA modelleri kullanılmıştır. Modellerin tahmin performans sonuçları karşılaştırmalı olarak irdelenmiştir ve modellerin analiz süreleri de incelenmiştir. En kısa süren model AlexNet modeli olurken en uzun süren analiz ResNet-18 modelinde gerçekleşmiştir. Modellerin performans değerleri karşılaştırıldığında en iyi performans gösteren model GoogLeNet iken daha sonra ShuffleNet, SqueezeNet ve ResNet18 modeli olmuştur. İlerleyen çalışmalarda ESA eğitim sürecini azaltmak için algoritma geliştirilmesi amaçlanmaktadır. Ayrıca bu tür algoritmaların kullanıldığı uygulamaların kullanılan akıllı telefon, tablet gibi cihazlar için uygulama geliştirilmesi amaçlanmaktadır.

#### Kaynakça

- Acikgoz, H. (2022). A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting. *Applied Energy*, (305). doi:https://doi.org/10.1016/j.apenergy.2021.117912.
- Atik, I. (n.d.). COVID-19 Case Forecast with Deep Learning BiLSTM Approach: The Turkey Case. *International Journal of Mechanical Engineering*, 7(1), 6307–6314.
- Aydın, C. (2018). Makine öğrenmesi algoritmaları kullanarak itfaiye istasyonu ihtiyacının sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (14), 169–175.
- Bingol, H. (2022). Derin Öğrenme Modellerinde Komşuluk Bileşen Analizi Yöntemi Kullanarak Çiçek Görüntülerinin Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 439–447. doi:10.35234/fumbd.1053501
- Cho, S.-Y., & Lim, P.-T. (2006). A novel Virus Infection Clustering for Flower Images Identification. In *18th International Conference on Pattern Recognition (ICPR '06)* (Vol. 2, pp. 1038–1041). doi:10.1109/ICPR.2006.144
- Coşkun, U. A., & Demirhan, A. (2022). Farklı Çiçek Türlerini Derin Öğrenme Yöntemi İle Tanıma. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 24(70), 55–64. doi:10.21205/deufmd.2022247007
- Das, M., Manmatha, R., & Riseman, E. M. (1999). Indexing flower patent images using domain knowledge. *IEEE Intelligent Systems and Their Applications*, 14(5), 24–33. doi:10.1109/5254.796084
- Demir, F., Abdullah, D. A., & Sengur, A. (2020). A New Deep CNN Model for Environmental Sound Classification. *IEEE Access*, (8), 66529–66537.
- Guo, B., Hu, J., Wu, W., Peng, Q., & Wu, F. (2019). The Tabu\_Genetic Algorithm: A Novel Method for Hyper-Parameter Optimization of Learning Algorithms. *Electronics*, 8(5). doi:10.3390/electronics8050579
- Guru, D., Kumar, Y. H., & Shantharamu, M. (2010). Texture Features and KNN in Classification of Flower Images. *International Journal of Computer Applications, Special Issue on RTIPPR*, 1, 21–29.

- Hiary, H., Saadeh, H., Saadeh, M. K., & Yaqub, M. (2018). Flower classification using deep convolutional neural networks. *IET Comput. Vis.*, *12*, 855–862.
- Kaggle. (2021, December 6). Kaggle. *Kaggle data set*. dataset. Retrieved from <https://www.kaggle.com/datasets>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, *25*, 1097–1105.
- Liu, Y., Tang, F., Zhou, D., Meng, Y., & Dong, W. (2016). Flower classification via convolutional neural network. In *2016 IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA)* (pp. 110–116). doi:10.1109/FSPMA.2016.7818296
- Lius, F. P. S., Khan, N., & Akhalwaya, I. (2019). Active Learning with TensorBoard Projector. *CoRR*, *abs/1901.00675*. Retrieved from <http://arxiv.org/abs/1901.00675>
- Narayanan, B. N., Ali, R., & Hardie, R. C. (2019). Performance analysis of machine learning and deep learning architectures for malaria detection on cell images (Vol. 11139, p. 111390W). Presented at the Applications of Machine Learning, International Society for Optics and Photonics.
- Nilsback, M.-E., & Zisserman, A. (2006). A Visual Vocabulary for Flower Classification. In *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)* (Vol. 2, pp. 1447–1454). doi:10.1109/CVPR.2006.42
- Nilsback, M.-E., & Zisserman, A. (2008). Automated Flower Classification over a Large Number of Classes. In *2008 Sixth Indian Conference on Computer Vision, Graphics Image Processing* (pp. 722–729). doi:10.1109/ICVGIP.2008.47
- Nilsback, M.-E., & Zisserman, A. (2010). Delving Deeper into the Whorl of Flower Segmentation. *Image Vision Comput.*, *28*(6), 1049–1062. doi:10.1016/j.imavis.2009.10.001
- Potur, E. A., & Erginel, N. (2021). Kalp Yetmezliği Hastalarının Sağ Kalımlarının Sınıflandırma Algoritmaları ile Tahmin Edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, *(24)*, 112–118.
- Sağlam, A., Melike, T., & BAYKAN, N. (2020). Geri Dönüştürülebilir Atıkların Materyallerine Göre Sınıflandırılması için Raspberry Pi Tabanlı Donanım Geliştirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 30–38.
- Sargül, M., Ozyildirim, B. M., & Avcı, M. (2019). Differential convolutional neural network. *Neural Networks*, *116*, 279–287. doi:<https://doi.org/10.1016/j.neunet.2019.04.025>
- Shailendrakumar, M. M., Sachin, R. G., & Dattatraya, S. B. (2011). On Scale Invariance Texture Image Retrieval using Fuzzy Logic and Wavelet Co-occurrence based Features. *International Journal of Computer Applications*, *18*, 10–17.
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, *31*(1). Retrieved from <https://ojs.aaai.org/index.php/AAAI/article/view/11231>
- Toğaçar, M., Ergen, B., & Cömert, Z. (2019). A Deep Feature Learning Model for Pneumonia Detection Applying a Combination of mRMR Feature Selection and Machine Learning Models. *IRBM*. doi:10.1016/j.irbm.2019.10.006
- Tseng, V. S., Wang, M.-H., & Su, J.-H. (2005). A New Method for Image Classification by Using Multilevel Association Rules. In *21st International Conference on Data Engineering Workshops (ICDEW'05)* (pp. 1180–1180). doi:10.1109/ICDE.2005.164
- Wu, Y., Qin, X., Pan, Y., & Yuan, C. (2018). Convolution Neural Network based Transfer Learning for Classification of Flowers. *2018 IEEE 3rd International Conference on Signal and Image Processing (ICSIP)*, 562–566.
- Xia, X., Xu, C., & Nan, B. (2017). *Inception-v3 for flower classification*.
- Zhang, X., Zhou, X., Lin, M., & Sun, J. (2017). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices.