



## **Farklı Çiçek Türlerini Derin Öğrenme Yöntemi İle Tanıma** **Recognizing The Different Flower Species By Deep Learning**

**Ulaş Alperen Coşkun<sup>1</sup>, Ayşe Demirhan<sup>1\*</sup>**

<sup>1</sup> Gazi Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Ankara, TÜRKİYE  
Sorumlu Yazar / Corresponding Author \*: [ayseoguz@gazi.edu.tr](mailto:ayseoguz@gazi.edu.tr)

Geliş Tarihi / Received: 04.02.2021

Araştırma Makalesi/Research Article

Kabul Tarihi / Accepted: 01.09.2021

DOI:10.21205/deufmd.2022247007

Atıf şekli/How to cite: COŞKUN, U.A., DEMİRHAN,A.(2022).Farklı Çiçek Türlerini Derin Öğrenme Yöntemi İle Tanıma.DEUFMD, 24(70), 55-64.

### **Öz**

Bu çalışmada derin öğrenme teknikleri kullanılarak çiçek türlerini tanıyabilen bir algoritma geliştirilmiştir. Bitkileri ve çiçekleri ayırt etmek araştırmacılar, ziraat mühendisleri, orman mühendisleri, çiftçiler ve botanikçiler için önem taşımaktadır. Çiçek türlerini ayırt edebilmek için her çiçeğe özgü özellik ve biçimlerin çıkarılması gerekmektedir. Çiçeklerin karmaşık arka planı, farklı çiçek türleri arasındaki benzerlik ve aynı çiçek türleri arasındaki farklılıklar nedeniyle çiçek görüntülerinin sınıflandırılması zorlu bir görevdir. Bu nedenle çiçek görüntülerinin bilgisayar ortamında tanınması ve gruplandırılması çeşitli kolaylıklar sağlayarak başarıyı arttırmaktadır. Bu çalışmada bir çiçeğin görüntüsü sisteme yüklendiğinde çiçeğin türünü tahmin eden bir sistem geliştirilmiştir. Sistemin eğitiminde ve test işlemlerinde Oxford 102 veri seti kullanılmıştır. Bu veri seti 102 farklı çiçek türüne ait 7370 görüntü içermektedir. Çiçek türlerini sınıflandırmak için son yıllarda görüntü işleme konusundaki başarıları nedeniyle ResNet152 derin öğrenme mimarisi kullanılmıştır. Test görüntüleri için %99 sınıflama başarısı gösteren sistemin diğer çiçek sınıflama yöntemlerinden daha başarılı olduğu görülmüştür.

**Anahtar Kelimeler:** Çiçek Sınıflandırma, Derin Öğrenme, ResNet152, Derin Kalıntı Ağlar

### **Abstract**

In this study, an algorithm that can recognize flower species using deep learning techniques has been developed. Differentiating plants and flowers is important for researchers, agricultural engineers, forestry engineers, farmers and botanists. In order to distinguish flower types, features and forms specific to each flower need to be extracted. Classifying flower images is a challenging task because of the complex background of flowers, the similarity between different flower types, and the differences between the same flower types. For this reason, the recognition and grouping of flower images in computer environment increases the performance by providing various facilities. In this study, a system has been developed that predicts the type of flower when the image of a flower is loaded into the system. The Oxford 102 data set was used in the training and testing of the system. This data set contains 7370 images of 102 different flower species. Due to its achievements in image processing in recent years, ResNet152 deep learning architecture is used in this study to classify flower species. The system, which showed 99% classification success for test images, was found to be more successful than other flower classification methods.

**Keywords:** Flower Classification, Deep Learning, ResNet152, Deep Residual Network

## 1. Giriş

Bitkiler ve çiçekler evimizi, bahçemizi ve çevremizi güzelleştiren ve çok farklı türleri bulunan canlılardır. Bu canlıların sağlıklı şekilde geleceğe taşınması, kıymetinin bilinmesi, gelecek nesillere önemini anlatılması ve korunması gereklidir. Özellikle bazı nesli tükenen bitkiler koruma altına alınarak yaşatılmalıdır [1]. Bitkileri ve çiçekleri ayırt etmek araştırmacılar, ziraat mühendisleri, orman mühendisleri, çiftçiler ve botanikçiler için önem taşımaktadır [2]. Bitki ve çiçekleri ayırt etmek için her çiçeğe özgü özellik ve biçimlerin çıkarılması gerekmektedir. Bu özellikler sayesinde çiçek türleri gruplandırılmakta ve çiçekler kendilerine özgü bir grup ve adla temsil edilmektedir.

Çiçek görüntülerinin tanınması ve gruplandırılması vakit alan, zor ve maddi açıdan külfetli bir işlemdir. Bununla birlikte, çiçeklerin karmaşık arka planı, farklı çiçek türleri arasındaki benzerlikler ve aynı çiçek türleri arasındaki farklılıklar nedeniyle, çiçek görüntülerinin tanınması ve çiçek sınıflandırma zorlu bir görevdir [3]. Bu nedenle çiçek görüntülerinin bilgisayar ortamında tanınması ve gruplandırılması çeşitli kolaylıklar sağlayarak başarıyı arttırmaktadır. Derin öğrenme yöntemleri son zamanlarda görüntü işleme ve sınıflandırma konularındaki yüksek başarımları göstermektedir [4]. Bu nedenle farklı çiçek türlerinin tanınması ve gruplandırılması amacıyla derin öğrenme yaklaşımı kullanılmıştır. Fakat literatürde çiçek türlerini otomatik olarak tanımayı yönelik farklı yöntemler kullanan çalışmalar da bulunmaktadır. Jobin vd. fraktal boyuta dayalı olarak bitki sınıflandırması ve tanımlaması için yaprak görüntülerinde üç seviyeli kontur, kontur-sinir ve sinir fraktal boyutlarını hesaplamışlardır. 500 yapraklık bir test seti ile %84 doğruluk oranına ulaşmışlardır [5]. Pauwels vd. ağaç taksonomisi alanında görüntü tabanlı sorgulamalar gerçekleştiren bir çalışma gerçekleştirmiştir. Yaprak görüntüleri incelenerek yaprak arka plandan ayrılmış, yaprak şekli bir dizi sayısal özellik kullanılarak karakterize edilmiş ve sınıflandırma işlemi en yakın komşu yöntemiyle yapılmıştır [6].

Çiçeklerin şekli, rengi ve görüntüsü sınıflandırmada büyük önem taşımaktadır. Das vd. örnek çiçek görüntüsü ve renk adlarını kullanarak çiçek görüntülerini bir veritabanı

içinde sorgulamaya yönelik, şekil ve biçim bozulmasını tolere edebilen bir sistem geliştirmiştir. İki aşamalı olan segmentasyon modelinde ilk aşamada, ön ve arka planın ayrılması işlemi yapılmış, ikinci aşamada ise çiçek taç yapısının çıkarılması gerçekleştirilmiştir [7]. Nilsback ve Zisserman çiçekler arasındaki önemli görsel benzerliğe sahip kategorileri ayırt etmek için "görsel kelime çantası" modelini ve en yakın komşu sınıflandırıcı mimarisini kullanmıştır. Bir çiçeği diğerinden ayıran renk, şekil ve doku gibi çeşitli özellikleri temsil eden görsel bir kelime dağarcığı geliştirilerek, çiçek kategorileri arasında var olan belirsizlikleri gidermeye çalışmışlardır. 17 çiçek türü ve 1360 görüntüden oluşan bir veri kümesinde renk özellikleri ile %73,7, şekil özellikleri ile %71,8 ve renk ve şekli birleştirilerek %81,3 performansa ulaşmışlardır [8].

İçeriğe dayalı görüntü elde etme ve sınıflandırma son yıllarda giderek daha çok ilgi çeken önemli konulardandır. Görüntü sınıflandırmasıyla ilgili araştırmalarda genellikle renk, doku ve şekil gibi düşük seviyeli görüntü özelliklerine odaklanılarak görüntülerdeki nesnelere arasındaki kavramsal ilişkiler gözmezden gelmektedir [9]. Tseng vd. görüntü nesnelere arasındaki ilişkileri dikkate alan hiyerarşik bir sınıflama yöntemini ağaç ve çiçekleri de içeren bir veri tabanı üzerinde denemişlerdir [9]. Cho ve Lim çiçek görüntülerini karakterize ederek bu özelliklere dayalı bir içerik tabanlı görüntü alma sistemi geliştirmişlerdir. Arama doğruluk oranını artırmak için görüntü veri tabanını sınıflandırmada yeni bir virüs enfeksiyon kümeleme yöntemi önermişlerdir. Elde edilen sonuçlar, renk ve şekil özelliklerine göre kümelemenin, yalnızca renk veya yalnızca şekle göre kümelemeden daha iyi erişim sonuçları verdiğini göstermiştir [10]. Özellik kombinasyonlarının benzer sınıflardan oluşan büyük bir veri kümesindeki sınıflandırma performansını ne ölçüde iyileştirebileceğini araştıran bir başka çalışmada 103 sınıflı, her biri 250 ile 40 örnek içeren bir çiçek veri setinde yerel şekil/doku, sınırın şekli, yaprakların genel uzamsal dağılımı ve renk özellikleri SVM sınıflandırıcıda giriş olarak kullanılmış ve en iyi tek özellik için %55,1, tüm özelliklerin kombinasyonu için %72,8 doğruluk elde edilmiştir [11].

Çiçeklerin sınıflandırılması ile ilgili son yıllarda derin öğrenme yöntemleri de kullanılmaya

başlanmıştır. Liu vd. 79 kategoriye sahip bir veri kümesi oluşturmuş ve evrişimli sinir ağına (ESA) dayalı bir sınıflandırma işlemi yaparak %76,54 sınıflandırma doğruluğu elde etmişlerdir. Bu çalışma Oxford 102 Flowers veri kümesinde %84,02 sınıflandırma doğruluğuna ulaşmıştır [12]. Xia vd. çiçeklerin sınıflandırılması için TensorFlow platformunun Inception-v3 modeline dayanan bir transfer öğrenme yöntemi önermişlerdir. Yazarlar Oxford 102 Flowers ve Oxford 17 Flowers veri kümelerini kullanarak sırasıyla %94 ve %95 doğruluk oranı elde etmiştir [13]. Wu vd. evrişimli sinir ağını ve transfer öğrenmeyi kullanarak VGG-16, VGG-19, Inception-v3 ve ResNet50 modelleri ile çiçek sınıflandırma yapmışlardır. Oxford-17 ve Oxford-102 çiçek veri kümeleri için %91 ile %100 arasında değişen başarımları elde etmişlerdir [14]. Başka bir çalışmada ise yazarlar çok farklı çiçek türlerini ayırt edebilmek için iki aşamalı bir derin öğrenme sınıflandırıcısı önermiştir. İlk olarak çiçek bölgesindeki minimum sınırlayıcı kutu ile ayrılmıştır. Daha sonra farklı çiçek türlerini ayırt etmek için bir evrişimli sinir ağı sınıflandırıcısı kullanılmıştır. Sınıflandırma sonuçları Oxford 102 çiçek veri kümesinde %97,1 ve Oxford 17 çiçek veri kümesinde ise %98,5 olmuştur [15].

Derin öğrenme bilişim teknolojisi son yıllarda yaygın olarak kullanılmaya başlamıştır. Çoğalan kullanımlara bağlı olarak veri miktarları da büyük boyutlara ulaşarak çok çeşitli hale gelmiştir. Ses, görüntü, video, yazı vb. veri kümeleri çok büyük boyutlara ulaşmıştır. Bu büyük boyuttaki verileri işleyerek bilgiye çevirmek için geleneksel yöntem ve araçlar yetersiz kalmıştır. Derin öğrenme bir makine öğrenmesidir ve derin öğrenmede özellik çıkarma ve dönüştürme için doğrusal olmayan birim katmanları kullanılır. Katmanlar ardışık olarak, önceki katmandaki çıktıyı girdi olarak alırlar [16]. Algoritmalar desen analizi veya sınıflandırma amacıyla kullanılabilirler. Derin öğrenme yapı temsillerinin öğrenilmesine dayanır ve veriler çok fazla özellik seviyesinden oluşur. En büyük özelliklerinden en küçük özelliklerine doğru sıralanarak bir temsil oluşturulur. Bu temsil, soyutlamanın farklı seviyelerine karşılık gelen birden çok temsil seviyesini göstermektedir [17]. Derin öğrenmede asıl mantık verinin temsilden öğrenmeye dayalıdır. Bir görüntü için temsil; kenar kümeleri, özel şekiller veya piksel başına yoğunluk değerlerinin bir vektörüdür. Bu

özellikler veriyi en iyi şekilde temsil etmektedir. Derin öğrenme yöntemindeki üstünlük elle çıkarılan özellikler yerine veriyi en iyi temsil eden sistematik özelliklerin çıkarımı için en aktif algoritmaları kullanmasıdır [18].

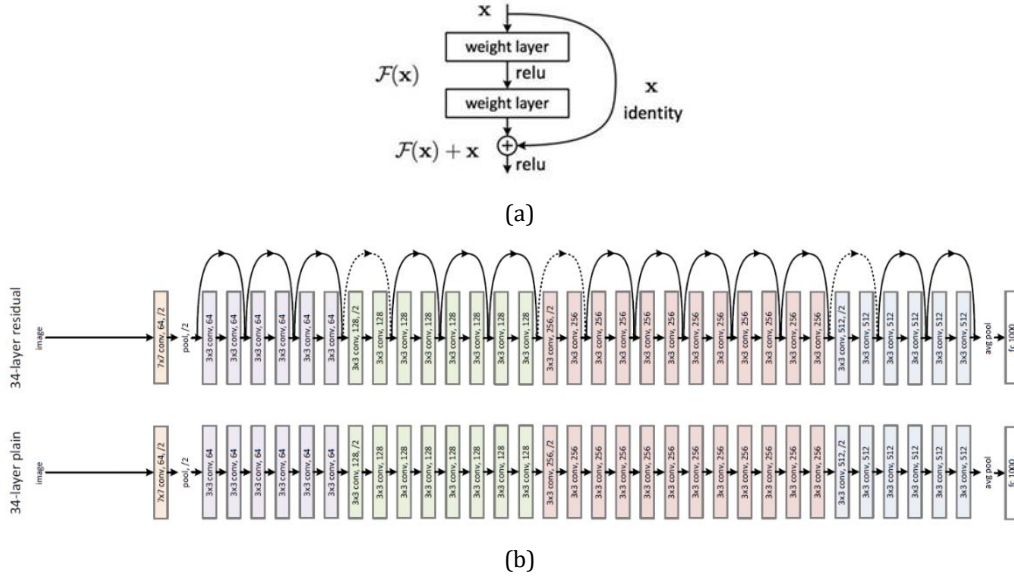
Bu çalışmada çiçek türlerini ayırt edebilmek için transfer öğrenme yöntemlerini temel alan bir derin öğrenme modeli oluşturulmuştur. Geliştirilen model 102 farklı türde çiçeği sınıflandırabilmektedir. Çalışmada kullanılan derin öğrenme metodu ve veri seti ile ilgili bilgiler 2. Bölüm'de yer almaktadır. 3. Bölüm'de deneysel analizlere yer verilmiştir. Tartışma ve sonuç ise 4. Bölümde verilmiştir.

## 2. Materyal ve Metot

### 2.1. ResNet152 Modeli

Derin öğrenme, insan beyninde bulunan nöronların çalışması örnek alınarak ortaya çıkmış bir yapay sinir ağı modelidir. Derin öğrenme yöntemi sınıflandırma, nesne tanıma, görüntü işleme, video işleme, ses tanıma, sinyal tanıma, otomatik araç denetimi, fizyolojik işaretleri izleme, tanımlama, yorumlama ve bunun gibi birçok alanda başarılı sonuçlar elde etmiştir [16]. Derin öğrenme ağının eğitimi sırasında öğretmenli ya da öğretmensiz öğrenme gibi farklı öğrenme yöntemleri kullanılır. Öğretmenli öğrenmede ağ etiketli girdi verileri ile eğitilerek ağırlıkları belirlenmektedir. Ağın ağırlıklar girdi verisinin ağa belirli sayıda tekrarlar uygulanması ile güncellenmektedir [17].

Derin evrişimli sinir ağlarına dayalı geliştirilen modellerin birçok avantajı bulunmaktadır. Bu avantajlardan bazıları geleneksel görüntü tanımlayıcılara göre daha iyi sonuçlar elde etmesi, nesneyi arka plandan ayırma ve bölütleme gibi ön-işlem aşamaları uygulamaya gerek duymadan ileri düzey görevleri gerçekleştirebilmesidir [18]. Derin ağların avantajlarının yanı sıra dezavantajları da vardır. Örneğin eğitim ve test aşamasında güçlü donanımsal kaynaklar gerektirmesi bunlardan biridir. Derin öğrenme çok katmanlı bir yapıya sahiptir. Her katmanda ayrı işlem yapılarak buradan elde edilen çıktılar sonraki katmana iletilir [16-18]. Her katmanın farklı bir işlevi bulunmaktadır. Derin öğrenmede bulunan katmanlar şunlardır: 1) Evrişim katmanı; evrişim katmanında filtre boyutuna göre görüntüler küçültülür. Girdi görüntüleri ve evrişim filtresi bir özellik haritası oluşturmak



Şekil 1. (a) ResNet modülü (b) ResNet mimarisini

için evrişim işlemine tabii tutulur. 2) Havuzlama katmanı; bu katman boyut azaltmak için kullanılır. Havuzlama, belirli bir filtre boyutundaki alanlar üzerinden girdileri alarak tek değere düşüren (alt örnekleme) prosedürdür. Bu işlemden sonra bazı bilgiler eksilmektedir fakat ağın ezberlemesi önlenmektedir. 3) Tam bağlı katman; her giriş kendinden önce gelen katmanın tüm nöronlarına bağlı olduğu bir katmandır ve sınıf skorlarını optimize eden bir matris yapısına sahiptir. 4) ReLu katmanı; bir özellik vektörü oluşturulduktan sonra, özellik vektöründeki her bir değer ReLu gibi doğrusal olmayan bir katmandan geçirilir. Günümüzde en çok kullanılan aktivasyon fonksiyonu ReLu'dur. Bu katmanda her bir giriş ögesi için bir eşikleme işlemi gerçekleştirilmektedir. 5) Dropout katmanı; evrişimli sinir ağlarında ağın veriyi ezberlememesi veya gereğinden fazla öğrenmemesi için kullanılmaktadır. Böylece zayıf ve gereksiz bilginin unutulmasını sağlayarak ağın performansı artırılmaktadır. Bu katmanda belirli bir olasılıkla girdi öğelerinin değeri rastgele sıfır olarak ayarlanır. 6) Normalizasyon katmanı; girdilerin normalleştirildiği bu katman evrişimli sinir ağlarının eğitimini hızlandırmak için kullanılmaktadır. 7) Softmax katmanı; sınıflandırma işleminde derin sinir ağında

kullanılan son katmandır ve sınıflandırıcıdan elde edilen sonuca bir olasılık değeri atar [17].

Microsoft ResNet günümüzde tüm mimarilerden daha derin olarak planlanmış bir derin kalıntı (deep residual) ağı mimarisidir. Değişik katman sayılarından oluşan farklı versiyonları ResNet50, ResNet152, vb. bulunmaktadır [4, 19]. ResNet mimarisini ImageNet'in 2015 yarışmasında birinci olan evrişimli sinir ağı mimarisidir. Bu yarışmada %3,6 gibi bir hata oranı ile oldukça yüksek performans göstermiştir. İnsanlar ortalama %5 ila %10 hata oranı ile görüntüyü sınıflandırırken %3,6'lık bir hata oranı ile ResNet insandan daha iyi bir görsel tanıma yaptığını göstermiştir [20].

Geleneksel derin öğrenme ağları katman sayısı artırılarak daha derin hale getirildiğinde yok olan/patlayan gradyanlar sorunu ortaya çıkmaktadır. Ağın geri yayılımı sırasında, hata fonksiyonunun her eğitim tekrarında mevcut ağırlıklara oranla kısmi türevi (gradyanı) alındığında bu işlem  $n$ -katmanlı bir ağın ilk katmanlarında gradyanları hesaplamak için bu sayıların  $n$  tanesinin çarpılmasını gerektirir [21]. Ağ derin olduğunda ve bu sayılar küçük ise sayıların  $n$  tanesinin çarpım sonucu sıfır olur (yok olma). Ağ derin olduğunda ve bu sayılar büyük ise sayıların  $n$  tanesinin çarpımı çok büyük olur (patlama) [22]. Gradyanların kaybolması ya da patlaması nedeniyle ağın

derinliği arttırıldıkça performans da düşebilmektedir. Gradyanların yok olması/patlama sorununu çözmek için ağa birkaç ağırlık katmanından sonra çıktıya  $x$  girişini ekleyen bir atlama/kısayol bağlantısı eklenir (Şekil 1 (a)) [18, 22]. Burada çıkış eşitlik (1)'deki gibi oldur. Ağırlık katmanları eşitlik (2)'de verilen kalıntı haritalamayı öğrenmek için kullanılmaktadır. Bu nedenle ResNet ağındaki öğrenme kalıntı (residual) öğrenme olarak isimlendirilir. Ağırlık katmanında herhangi bir yok olan gradyan olsa bile daha önceki katmanlara geri aktarmak için  $x$  kimlik değeri kullanılabilir [22, 23].

$$H(x) = F(x) + x \quad (1)$$

$$F(x) = H(x) - x \quad (2)$$

ResNet152 modelinde  $x$  giriş değeri  $F(x)$  fonksiyonuna eklendikten sonra eşitlik (2)'deki

değer ReLu katmanından geçirilir. Dolayısıyla 2. katmanın sonuna giriş eklenerek, geçmiş katmanlardaki değerler ileriki katmanlara daha güçlü bir şekilde iletilir ve bu sayede öğrenme daha hızlı şekilde gerçekleşir (Şekil 1 (b)) [22].

## 2.2. Veri seti

Bu çalışmada Oxford 102 Flowers veri seti kullanılmıştır [11]. Bu veri seti 7370 adet çiçek görüntüsü içermektedir. Veri setinde 102 kategori ve her kategoride 40 ile 258 arası görüntü bulunmaktadır. Görüntülerdeki çiçekler çok farklı poz ve ışıklandırma özelliklerine sahiptir. Çiçek görüntülerinin %90'ı eğitim, %5'i doğrulama ve %5'i test verisi olacak şekilde üçe bölünmüştür. Şekil 2'de veri setinde bulunan görüntülerden örnekler gösterilmiştir.



Şekil 2. Oxford 102 veri setinde bulunan örnek çiçek görüntüleri

## 3. Deneysel Analizler

Bu çalışmada farklı çiçek türlerini tanımak için Python programlama dili içerisinde bulunan PyTorch, NumPy, Matplotlib kütüphaneleri kullanılmıştır. 102 çiçek türüne ait toplam 7370 görüntü 6552 adet eğitim, 409 adet doğrulama ve 409 adet test olmak üzere üçe ayrılmıştır. Eğitim performansını arttırmak için görüntüleri çeşitlendirmek ve girdi görüntü sayısını arttırmak üzere rastgele ölçekleme, kırpma ve çevirme dönüşümleri yapılmıştır. Görüntünün

yüzde 50 olasılıkla yatay ekseninde ve %50 olasılıkla dikey ekseninde döndürülmesi ile  $-180^\circ$  ve  $+180^\circ$  arasında rastgele yönlendirilmiş halleri elde edilmiştir. Görüntülerin en boy oranı da 0,08 ile 1,1 arası bir oranda rastgele değiştirilmiştir. Ağda kullanılmadan önce tüm görüntüler sabit  $224 \times 224$  piksel boyutuna getirilmiştir. Eğitim, doğrulama ve test görüntülerinin tamamı üzerinde rastgele ölçekleme, kırpma ve çevirme dönüşümleri yapılmıştır (Şekil 3)



(a)



(b)



(c)

**Şekil 3.** Rastgele ölçeklenmiş, kırpılmış ve çevrilmiş (a) eğitim, (b) doğrulama ve (c) test görüntüleri

Bu çalışmada ImageNet veri seti üzerinde önceden eğitilmiş bir ağ olan ResNet152 kullanıldığından ağda girdi olarak kullanılacak bütün görüntülerin ImageNet verisetinin özelliklerine göre normalize edilmesi gerekmektedir. Verilerin normalizasyonu torchvision kütüphanesi ile yapılmıştır. R, G ve B kanallarında ortalamalar için sırasıyla [0,485, 0,456, 0,406] ve standart sapmalar için [0,229, 0,224, 0,225] değerleri kullanılmıştır. Normalizasyon işlem sonucunda her renk kanalının ortalaması 0 olmakta ve değerler -1 ile 1 aralığında yer almaktadır.

ResNet152 modeli seçildikten sonra giriş verilerini 102 sınıfa ayırmak için 2048 düğümlü bir giriş katmanı, 1000 düğümlü gizli katman ve

102 nörona sahip bir çıkış katmanı içeren bir ağ oluşturularak eğitime başlanmıştır. Yapay sinir ağı optimizasyonu için AdaGrad yöntemi kullanılmıştır. AdaGrad, gradyan tabanlı bir optimizasyon algoritmasıdır ve genellikle büyük ölçekli sinir ağlarının eğitiminde kullanılır. AdaGrad yönteminde her adım için farklı bir öğrenme katsayısı vardır. Bu çalışmada öğrenme oranı 0,01'de başlatılmış ve eğitim ilerledikçe ağırlıkların ince ayarı için  $10^{-6}$  değerine kadar düşürülmüştür [24, 25]. Tablo 1'de ağın eğitiminde kullanılan parametreler verilmiştir.

Eğitim sonucunda ağın başarımlarını ölçmek için doğruluk kullanılmıştır. Doğruluk, bir sınıflandırma görevinde doğru sonuçların toplam durumlara oranıdır. Doğruluk, incelenen

toplam durumlar içindeki doğru tahminlerin (hem doğru pozitifler (DP) hem de doğru negatifler (DN)) oranıdır (Eşitlik 3).

**Tablo 1.** Ağ parametreleri

Sütun Başlığı	Sütun Başlığı
Girdi Boyutu	224x224x3
Önişlem	Rastgele ölçekleme, kırpma ve çevirme
Katmanlar	2048 düğüm giriş katmanı, 1000 düğüm gizli katman ve 102 nörona sahip 1 çıkış katmanı
Aktivasyon fonksiyonu	ReLU
Normalizasyon	ImageNet
Dropout oranı	0,5
Optimizasyon yöntemi	AdaGrad

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (3)$$

Burada yanlış pozitif (YP) doğru tahmin edilen ancak aslında yanlış olan durumları, yanlış negatif (YN) ise yanlış tahmin edilen ancak aslında doğru olan durumları ifade etmektedir [26].



**Tablo 2.** Üç sınıflı bir karışıklık matrisi

		Tahmin edilen sınıf		
		A	B	C
Gerçek sınıf	A	10	2	1
	B	0	6	1
	C	0	3	8



Karışıklık matrisi, bir sınıflandırıcının test verilerine göre sınıflandırma performansını özetler. Bir karışıklık matrisinin iki boyutu vardır, bir boyut bir nesnenin gerçek sınıfını gösterirken, diğeri sınıflandırıcının tahmin ettiği sınıfı gösterir. Tablo 2, A, B ve C sınıfları ile üç sınıflı bir sınıflandırma görevi için bir karışıklık matrisi örneğini sunmaktadır. Matrisin ilk satırı A sınıfından toplam 13 nesnenin 10 tanesinin doğru sınıflandığını, 2 tanesinin B ve 1 tanesinin ise C şeklinde yanlış sınıflandığını ifade etmektedir [26]. Bu çalışmadaki doğruluk

hesaplaması için 102 sınıflı bir karışıklık matrisi kullanılmıştır.

Ağın eğitim süreci üç aşamada gerçekleştirilmiştir. Evrişim katmanının eğitimi aşamasında parametreler dondurularak ve güncelleme devre dışı bırakılarak ezberleme önlenmiştir. Eğitimin ilk aşamasında öğrenme oranı 0,01'den başlayıp 0,001 azaltılarak devam etmiştir. Bu aşamada ağ 22 tekrar eğitilip %97,56 doğruluğa ulaşılmıştır. Eğitimin ikinci aşamasında öğrenme oranı 0,001 olarak ayarlanmış ve öğrenme doğruluğu %98,78 olmuştur. Son eğitim aşamasında ise öğrenme oranı 0,00001'e düşürülmüş ve %99,02 sınıflama doğruluğuna ulaşılmıştır. Ağın eğitim ve doğrulama doğruluk eğrileri Şekil 4'te, eğitim ve doğrulama kayıp eğrileri ise Şekil 5'tedir




**Şekil 4.** (a) Eğitim (b) doğrulama doğruluk eğrileri



**Şekil 5.** (a) Eğitim (b) doğrulama kayıp eğrileri

Şekil 6'da ise eğitim adımlarındaki değişim ile test görüntülerinden elde edilen doğrulukta ki değişim gösterilmektedir.

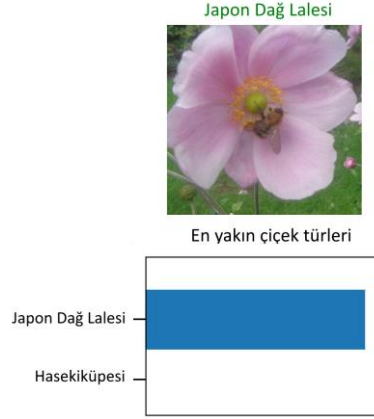


**Şekil 6.** Eğitim adımları ile test kümesindeki doğruluk değişimi

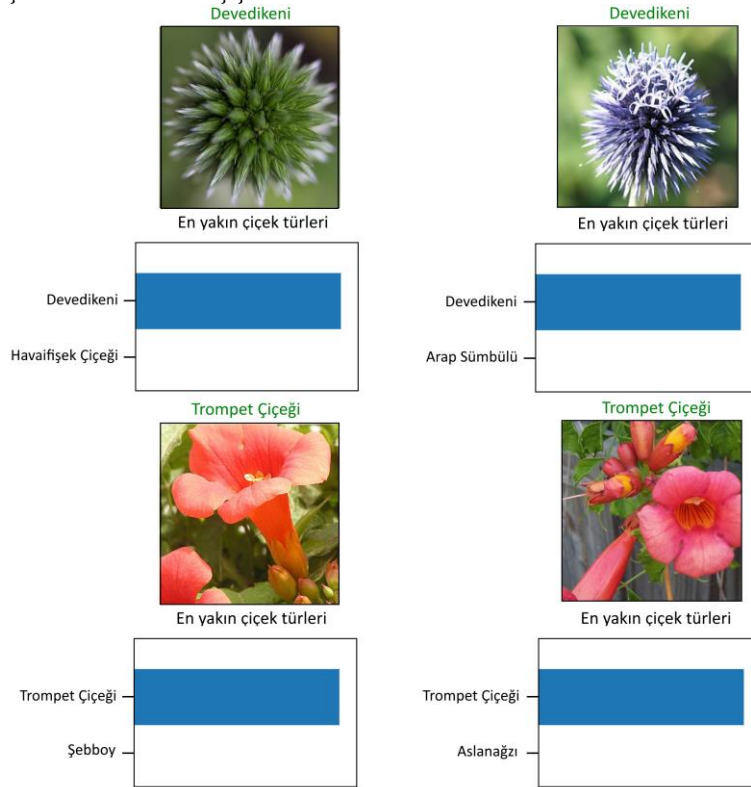
Şekil 7'de test veri setinde bulunan bir çiçek görüntüsü ve ağın tahmin ettiği çiçek türü bilgisi alt alta görülmektedir. Tahmin edilen çiçek türü şeklindeki gibi en olası iki tahmin değerini alt alta gösterecek biçimde verilmiştir.

Şekil 8 test kümesinden rastgele seçilen çeşitli çiçek görüntüleri ve sistem tarafından bu görüntüler için tahmin edilen çiçek türlerini

göstermektedir. Şekil 7 ve Şekil 8'den de görüleceği üzere sistem çiçek türlerini neredeyse hiç yanlış ve karıştırma payı olmadan %99,02 oranında doğru olarak tahmin edebilmektedir.



**Şekil 7.** Seçilen çiçek türü tahmini



**Şekil 8.** Test kümesinden seçilen çeşitli çiçekler için tahmin edilen çiçek türleri



#### 4. Tartışma ve Sonuç

Bu çalışmada farklı çiçek türlerini ResNet152 derin öğrenme yöntemini kullanarak tanıyan bir sistem geliştirilmiştir. Farklı özelliklerdeki karmaşık arka planlar, şekil, doku, renk ve görüntü olarak farklı çiçek türlerinin birbirine benzemesi ve aynı çiçek türlerinin birbirinden farklı görünebilmesi nedeniyle zor bir görev olan çiçek türlerini sınıflandırma işlemi için uçtan uca otomatik öznitelik çıkarma ve sınıflandırma özelliği bulunan derin öğrenme yöntemi tercih edilmiştir. Bu çalışmada tüm mimarilerden daha derin olarak planlanmış bir derin kalıntı ağı olan ve görüntü sınıflandırma görevlerinde başarılı sonuçlar veren ResNet152 derin öğrenme mimarisi ile 102 farklı türdeki çiçek görüntüleri %99 başarı ile birbirinden ayırt edilebilmiştir.

Çalışmadan elde edilen sonuçlar aynı veri setini kullanan diğer derin öğrenme çalışmaları ile Tablo 3'te kıyaslanmıştır. Tablodan da görüldüğü üzere çiçek türlerini sınıflandırma görevinde en yüksek başarı bu çalışmada

kullanılan ResNet152 modeli ile elde edilmiştir. ResNet152 ile diğer derin öğrenme yöntemlerine kıyasla daha yüksek başarı elde edilmesinin nedeni bu ağın diğer ağlara kıyasla daha derin bir evrişimli sinir ağı yapısına sahip olmasıdır. Bu değerler ResNet152 derin öğrenme mimarisinin farklı çiçek türlerini tanımak ve sınıflandırmak için başarıyla kullanılabileceğini göstermiştir.

Gelecek çalışmalarda, bu çalışmadan elde edilen sonuçların araştırmacılar, ziraat mühendisleri, orman mühendisleri, çiftçiler ve botanikçiler ile çiçek türünü tanımaya ihtiyaç duyabilecek diğer kişiler tarafından kolaylıkla kullanılabilmesi için bir mobil uygulama ve arayüz tasarımı yapılması planlanmaktadır. Yapılan çalışma yalnızca çiçek türlerini değil bunun yanında farklı bitki türlerini de tanımak üzere geliştirilebilir. Aynı zamanda ülkemize özgü çiçek ve bitki türlerini tanımaya ve sınıflandırmaya yönelik çalışmalar da potansiyel araştırma konularındadır.

**Tablo 3.** Çalışma sonuçlarının diğer çalışmalarla kıyaslanması

Referans	Model	Veri seti	Sınıflama doğruluğu
[27]	Inception-v3	Oxford 102	%97,68
[27]	Xception	Oxford 102	%96,58
[27]	OverFeat	Oxford 102	%90,58
[28]	Alexnet	Oxford 102	%50,60
[28]	Caffenet	Oxford 102	%54,84
[28]	Googlenet	Oxford 102	%66,60
Bu çalışma	ResNet152	Oxford 102	%99,02

#### Kaynakça

- [1] Dinçer, D., Bekçi, B., & Bekiryazıcı, F. 2016. Türkiye'deki doğal bitki türlerinin üretiminde doku kültürü tekniklerinin kullanımı, Nevşehir Bilim ve Teknoloji Dergisi, Cilt. 5, s. 295-302. DOI: 10.17100/nevbittek.211012
- [2] Desmond, R., & Ellwood, C. 2020. Dictionary of British and Irish botanists and horticulturists: including plant collectors, flower painters and garden designers. CRC Press, London, 900s.
- [3] Wu, Y., Qin, X., Pan, Y., & Yuan, C. 2018. Convolution neural network based transfer learning for classification of flowers. IEEE 3<sup>rd</sup> International Conference on Signal and Image Processing (ICSIP), July 13-15, 562-566.
- [4] Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. 2017. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning, Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI'17), February 4-9, San Francisco, 4278-4284.
- [5] Jobin, A., Nair, M. S., Tatavarti, R. 2012. Plant Identification Based on Fractal Refinement Technique (FRT), Procedia Technology, Cilt. 6, s. 171-179. DOI: 10.1016/j.protcy.2012.10.021
- [6] Pauwels, E. J., Zeeuw, P. M., Rangelova, E. B. 2009. Computer-Assisted Tree Taxonomy By Automated Image Recognition, Engineering Applications of Artificial Intelligence, Cilt. 22, s. 26-31. DOI: 10.1016/j.engappai.2008.04.017

- [7] Das, M., Manmatha, R. and Riseman, E.M. 1999. Indexing Flower Patent Images Using Domain Knowledge, IEEE Intelligent Systems and Their Applications, Cilt. 14, s. 24-33. DOI: 10.1109/5254.796084
- [8] Nilsback, M.A. and Zisserman, A. 2006. A Visual Vocabulary for Flower Classification, IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06), June 17-22, New York, USA, 1447-1454. DOI: 10.1109/CVPR.2006.42
- [9] Tseng, V., Wang, M., Su, J. 2005. A New Method for Image Classification by Using Multilevel Association Rules, 21<sup>st</sup> International Conference on Data Engineering Workshops (ICDEW'05), April 3-4, Tokyo, 1180-1188. DOI: 10.1109/ICDE.2005.164
- [10] Cho, S.-Y. and Lim, P.-H. 2006. A novel Virus Infection Clustering for Flower Images Identification, 18<sup>th</sup> International Conference on Pattern Recognition (ICPR'06), August 20-24, Hong Kong, 1038-1041. DOI: 10.1109/ICPR.2006.144
- [11] Nilsback, M. and Zisserman, A. 2008. Automated Flower Classification over a Large Number of Classes, Sixth Indian Conference on Computer Vision, Graphics & Image Processing, December 16-19, Bhubaneswar, 722-729. DOI: 10.1109/ICVGP.2008.47
- [12] Liu, Y., Tang, F., Zhou, D., Meng Y. and Dong, W. 2016. Flower Classification Via Convolutional Neural Network, IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA), November 7-11, Qingdao, 110-116. DOI: 10.1109/FSPMA.2016.7818296
- [13] Xia, X., Xu, C. and Nan, B. 2017. Inception-v3 for Flower Classification, 2<sup>nd</sup> International Conference on Image, Vision and Computing (ICIVC), June 2-4, Chengdu, 783-787. DOI: 10.1109/ICIVC.2017.7984661
- [14] Wu, Y., Qin, X., Pan, Y. and Yuan, C. 2018. Convolution Neural Network Based Transfer Learning for Classification of Flowers, IEEE 3<sup>rd</sup> International Conference on Signal and Image Processing (ICSIP), July 13-15, Shenzhen, 562-566. DOI: 10.1109/SIPROCESS.2018.8600536
- [15] Hiary, H., Saadeh, H., Saadeh, M., & Yaqub, M. 2018. Flower Classification Using Deep Convolutional Neural Networks. IET Computer Vision, 12(6), 855-862. DOI: 10.1049/iet-cvi.2017.0155
- [16] Deng, L. and Yu, D. 2013. Deep Learning: Methods and Applications, Foundations and Trends in Signal Processing, Cilt. 7, s. 197-387. DOI: 10.1561/20000000039
- [17] Bengio, Y. 2009. Learning Deep Architectures for AI, Foundations and Trends in Machine Learning, Cilt. 2, p. 1-127. DOI: 10.1561/22000000006
- [18] Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. 2020. A survey of the recent architectures of deep convolutional neural networks. Artificial Intelligence Review, Cilt. 53, s. 5455-5516. DOI: 10.1007/s10462-020-09825-6
- [19] ResNet – Azure Machine Learning | Microsoft Docs. 2020. <https://docs.microsoft.com/tr-tr/azure/machine-learning/algorithm-module-reference/resnet> (Erişim Tarihi: 02.02.2021).
- [20] Amidi, A., Amidi, S. 2021. The Evaluation of Image Classification Explained 2021. <https://stanford.edu/~shervine/blog/evolution-image-classification-explained> (Erişim Tarihi: 02.02.2021).
- [21] Song H.A., Lee SY. 2013. Hierarchical Representation Using NMF. ss 466-473. Lee, M., Hirose, A., Hou, Z.G., Kil, R.M., ed. 2013. Neural Information Processing. ICONIP 2013. Lecture Notes in Computer Science, vol 8226, Springer, Berlin, Heidelberg, 638s. DOI: 10.1007/978-3-642-42054-2\_58
- [22] Tsang, S.-H., 2018. Review: ResNet — Winner of ILSVRC 2015 (Image Classification, Localization, Detection). <https://towardsdatascience.com/review-resnet-winner-of-ilsvrc-2015-image-classification-localization-detection-e39402bfa5d8> (Erişim Tarihi: 02.02.2021).
- [23] Danişman, T. 2020. Segmentation of Portrait Images Using a Deep Residual Network Architecture, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, Cilt. 22, s. 569-580. DOI: 10.21205/deufmd.2020226523
- [24] Çarkacı , N. 2018. Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler. <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> (Erişim Tarihi: 02.02.2021).
- [25] Neto, S. 2019. Build An Image Classifier to Recognize 102 Different Species of Flowers. Towards Data Science. <https://towardsdatascience.com/flower-species-classifier-c8893030cd90> (Erişim Tarihi: 02.02.2021).
- [26] Ting, K.M. Confusion Matrix. ss 209. Sammut, C., & Webb, G.I., ed. 2011. Encyclopedia of machine learning, Springer Science & Business Media, New York, 1031s.
- [27] Gogul, I., Kumar, V.S., 2017. Flower Species Recognition System Using Convolution Neural Networks and Transfer Learning, Fourth International Conference on Signal Processing, Communication and Networking (ICSCN), March 16-18, Chennai, 1-6. DOI: 10.1109/ICSCN.2017.8085675
- [28] Nguyen, T.T.N., Van Tuan Le, T.L.L., Vu, H., Pantuwong, N., Yagi, Y., 2016. Flower Species Identification Using Deep Convolutional Neural Networks, AUN/SEED-Net Regional Conference for Computer and Information Engineering, September 6-7, Kuala Lumpur, 1-6.