



Identifying species of trees through bark images by convolutional neural networks with transfer learning method

Bahadır Elmas*^{ORCID}

Mimar Sinan Fine Arts University, Faculty of Arts and Sciences, Department of Statistics, 34380, Sisli Istanbul, Turkey

Highlights:

- A dataset of barks images has been gathered
- Species of trees have been identified from the images of barks
- It is demonstrated that for Convolutional Neural Networks, by Transfer Learning method is efficient in finding fast and accurate solutions to the problems.

Keywords:

- Identifying Species of Trees
- Bark Images
- Pre-Trained Networks
- Transfer Learning

Article Info:

Research Article
Received: 13.02.2020
Accepted: 10.01.2021

DOI:

10.17341/gazimmfd.689038

Correspondence:

Author: Bahadır Elmas
e-mail:
bahadir.elmas@msgsu.edu.tr
phone: +90 212 246 0011 /
5502

Graphical/Tabular Abstract

Identifying trees by images of barks via Deep Learning method has a potentially useful contribution to many areas, such as revision of forests, preparation of sustainable management plans for forest resources, operations and processing of trees for paper and furniture industries, preservation of trees having vital importance to environments, definition of species and sub-species of fruits for orcharding, for amateur purposes, and entirely for handling tree sources efficiently. Even though the current progress in Deep Learning has proven to be impressive, the lack or insufficiency of datasets has limited the use of Deep Learning on identification of tree species from barks images. In order make contribution to the researches on this field, and to prove that tree identification via images of barks with high accuracy is possible, 24.686 bark images of 59 tree species from different parts of Turkey has been collected within a span of a year, and the data set is used for this work.




Figure A. Design of fully connected layers to the problem

Purpose: The aim of this paper is to demonstrate that it is possible to identify tree species from images of barks by using transfer learning method with convolutional neural networks, and additionally to illustrate transfer learning method provides fast and accurate solutions to similar problems. Furthermore, the data set gathered for this research make contribution to the literature, by providing a new dataset, considering the insufficiency of bark images datasets.

Theory and Methods:

In convolutional neural networks, input and hidden layers usually learn high-level features from edges, shapes or part of shapes, while the last layers learn more specific features of the dataset. The input and hidden layers of the pre-trained convolutional neural network models employed in this research are preserved by using transfer learning, although the last layers are designed in accordance with the problem. Afterwards, the built networks are trained with the data set gathered for this research and a fast and accurate solution to problem is obtained.

Results:

The paper demonstrates that identification of tree species by images of barks is possible through transfer learning method with the use of seven pre-trained convolutional neural networks, AlexNet, DenseNet201, ResNet18, ResNet50, ResNet101, VGG16, and VGG19. It has been demonstrated that identification of tree species by images of barks is possible through transfer learning method. Additionally, it has been inferred that transfer learning method provides fast and accurate solutions to classification problems. Furthermore, the impact of the depth, layer, number of parameters and batch size of the networks has been analyzed. While the average accuracy of all the networks, regarding the ratio of number of images and training data, is between 93.21% and 95.89%, the average of accuracy of the two most successful networks is 99.46%.

Conclusion:

This work demonstrates that it is possible to identify tree species from bark images by using transfer learning with convolutional neural networks, and additionally transfer learning provides fast and accurate solutions to classification problems. Furthermore, the paper emphasizes that the depth, layer, number of parameters, and batch size of the networks have effect on the solution of the problem.



Evrişimli sinir ağları ile ağaç kabuğu görüntülerinden ağaç türlerinin transfer öğrenme yöntemiyle tanımlanması

Bahadır Elmas*^{ID}

Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü, 34380, Şişli İstanbul, Türkiye

Ö N E Ç İ K A N L A R

- Ağaç kabuğu görüntü veri seti oluşturulmuştur
- Ağaç kabuğu görüntülerinden ağaç türlerinin tanımlanması yapılmıştır
- Evrişimli Sinir Ağlarında, Transfer Öğrenme yönteminin problemlere hızlı ve başarılı çözümler getireceği gösterilmiştir

Makale Bilgileri

Araştırma Makalesi

Geliş: 13.02.2020

Kabul: 10.01.2021

DOI:

10.17341/gazimmfd.689038

Anahtar Kelimeler:

Ağaç türü tanımlama,
ağaç kabuğu görüntüleri,
önceden eğitilmiş ağlar,
transfer öğrenme

ÖZ

Derin Öğrenme yöntemiyle ağaç kabuğu görüntülerinden ağaçların tanımlanması, ağaçların geleceğe taşınmasında, yaşamsal açıdan önemli ağaçların koruma altına alınmasında, orman kaynaklarının sürdürülebilir yönetim planlarının yapılmasında, botanik konusunda deneyimi olmayan kişilerin doğayı araştırmasında, meyvecilik sektöründe farklı ya da aynı sınıfın alt türlerinin belirlenmesinde, kereste/mobilya/kâğıt vb. sektörlerdeki ağaç kesim operasyonları ile ağaçların işleme süreçlerinde, ağaçların doğru ve verimli kullanılmasında yararlı olabilecek bir problem çözümdür. Fakat Derin Öğrenmedeki son gelişmeler etkileyici sonuçlar ortaya koymasına rağmen, veri kümesi eksikliği veya yetersizliği ağaç kabuğu türlerinin tanımlanmasında derin öğrenme kullanımını kısıtlamıştır. Bu alandaki çalışmalara katkı sağlamak ve ağaç kabuğu görüntülerinden ağaçların tanımlanmasının mümkün olduğunu göstermek amacıyla 59 ağaç türünün 24686 ağaç kabuğu görüntüsü Türkiye'deki çeşitli bölgelerden bir yıllık süreçte toplanarak bir veri seti oluşturulmuştur. Bu veri setiyle yedi adet önceden eğitilmiş evrişimli sinir ağı, AlexNet, DenseNet201, ResNet18, ResNet50, ResNet101, VGG16, VGG19'da transfer öğrenme yöntemi kullanılarak ağaç kabuğu görüntülerinden ağaç türü tanımlanmasının mümkün olduğu gösterilmiştir. Bunu yanı sıra transfer öğrenme yönteminin bu tür problemlere hızlı ve başarılı çözümler getireceği gösterilmiş ve ağların derinlik, katman, parametre sayısının ve parti büyüklüğünün (Batch Size) çözüme etkisi incelenmiştir. Çalışmada kullanılan tüm ağların, görüntü sayısı ve eğitim verisi oranına bağlı olarak başarı ortalamaları %93,21 ile %95,89 arasındayken, en başarılı iki ağı başarı ortalaması ise %99,46'dır.

Identifying species of trees through bark images by convolutional neural networks with transfer learning method

H I G H L I G H T S

- A dataset of barks images has been gathered
- Species of trees have been identified from the images of barks.
- It is demonstrated that for Convolutional Neural Networks, by Transfer Learning method is efficient in finding fast and accurate solutions to the problems

Article Info

Research Article

Received: 13.02.2020

Accepted: 10.01.2021

DOI:

10.17341/gazimmfd.689038

Keywords:

Identifying species of trees,
bark images,
pre-trained networks,
transfer learning

ABSTRACT

Identifying trees by images of barks via Deep Learning method has a potentially useful contribution to many areas, such as revision of forests, preparation of sustainable management plans for forest resources, operations and processing of trees for paper and furniture industries, preservation of trees having vital importance to environments, definition of species and sub-species of fruits for orcharding, for amateur purposes, and entirely for handling tree sources efficiently. Even though the current progress in Deep Learning has proven to be impressive, the lack or insufficiency of datasets has limited the use of Deep Learning on identification of tree species from barks images. In order make contribution to the researches on this field, and to prove that tree identification via images of barks with high accuracy is possible, 24686 bark images of 59 tree species from different parts of Turkey has been collected within a span of a year, and the data set is used for this work. With the use of seven pre-trained convolutional neural networks, AlexNet, DenseNet201, ResNet18, ResNet50, ResNet101, VGG16, VGG19. It has been demonstrated that identification of tree species by images of barks is possible through transfer learning method. Additionally, it has been inferred that transfer learning method provides fast and accurate solutions to classification problems. Furthermore, the impact of the depth, layer, number of parameters and batch size of the networks has been analyzed. While the average accuracy of all the networks, regarding the ratio of number of images and training data, is between 93.21% and 95.89%, the average of accuracy of the two most successful networks is 99.46%.

1. GİRİŞ (INTRODUCTION)

Ağaç türlerini kabuk görüntülerinden tanımlama yeteneği önemli bir sorun olmasına rağmen sınırlı ilgi görmüştür. Bunun nedeni bu alandaki veri azlığı veya yetersizliğidir. Ağaç türlerinin kabuk görüntüsünden tanımlamak, yapraklarının, çiçeklerin veya meyvelerinin görünümü gibi özelliklerle karşılaştırıldığında birçok avantaja sahiptir. Her şeyden önce, mevsimsel değişikliklere rağmen ağaç kabukları her mevsim görünümünü korumaktadırlar. Ayrıca, ağaçlar ömrünü tamamlayıp kurusalar, devrilseler veya kesilip depolansalar dahi uzun süre ağaç kabuğu kütüklerin üzerinde bozulmadan durumu korur. Dolayısıyla ağaç kabuğundan ağaç türü belirlemek her zaman, her şartta mümkündür. Ağaç türlerinin tanımlanması, bazı ağaç türlerin kabuk desenlerinde çok ince farklar bulunması ve doğada çok sayıda ağaç türü olması nedeniyle bu konuda eğitilmiş ve tecrübeli insanların dahi zorlandığı bir iştir. Bu alanda uzmanlar ile yapılan çalışmalarda başarı oranı %55 ile %80 arasında kalmıştır [1]. Bu nedenle ağaç türlerinin tanımlanmasında görme problemleri üzerinde etkileyici sonuçlar veren ve her geçen gün hızlı ilerleme kaydedilen Derin Öğrenme yöntemlerinden evrişimli sinir ağlarını kullanmak birçok alanda yararlı olabilecek bir problem çözümüdür. Ormanlık uygulamaları açısından, bu görsel tür tanımlaması orman kaynaklarının sürdürülebilir yönetim planlarının ve envanterinin yapılması ile doğa araştırmacıları ve botanik konusunda deneyimi olmayan kişilerin çevresindeki doğayı tanıması ve araştırmasında uzmanlığa ihtiyaç duymadan karşılaştıkları ağaçların türlerinin belirlenmesinde kullanılabilir. Bunun yanı sıra kereste sektörü; ağaç kesim operasyonlarında, ağaç kesim personeli veya nakliye firmalarının ağaçları türlerine göre sınıflandırmasında bu görsel tanımlama yararlı olacaktır [2]. Ayrıca bu sektördeki kereste fabrikası işlemleri, işlenen kütüğün tür bilgisine dayalı olarak optimize edilebilir. Tarım sektöründe meyvecilik yapan çiftçiler ve çiftçilerle birlikte çalışan meyve ve meyve yan ürünlerinde hizmet veren işletmelerin aynı meyvenin farklı türlerinin belirlenmesinde bu yöntemden yararlanabilir. Mobilya sektöründe ise bu yöntem kullanılarak otomatik ve güvenilir bir şekilde işlenecek ağaçlarda tanımlama yapılarak bahçe, ev, tekne v.b. mobilya uygulamalarında hangi tür ağaçların kullanılacağı belirlenebilir.

Derin öğrenmedeki son gelişmeler sinir ağlarının birçok görsel tanıma görevinde insan performansını geçebildiğini göstermiştir [3]. Derin öğrenme yaklaşımlarının önemli dezavantajı, tatmin edici sonuçlar elde etmek için genellikle çok büyük veri setlerine ihtiyaç duymalarıdır. Örneğin, ImageNet veritabanı, 15 milyon'dan fazla resim olan 22000 kategoriye ayrılmış bir veri setidir. Dünyada 3 Trilyon ağaç olup 60065 ağaç türü olmasına rağmen literatürde ağaç kabuğunun tanımlanabilmesi için boyut veya çeşitlilik bakımından eşdeğer bir veri tabanı yoktur [4]. Bu alandaki, en büyük görsel veri seti BarkNet 1.0 ve AFF veri setleridir [1, 5]. BarkNet 1.0 veri setinde 23 ağaç türü olup toplam görüntü sayısı 23000'dir. AFF veri setinde ise 11 türü

kapsayan yaklaşık 1200 görüntü vardır. Bu veri eksikliği ağaç tanımlamasında neden ağaç kabuğu kullanımının yaygın olmadığına göstergesidir. Bu çalışmayla söz konusu bu sorunun çözümüne katkıda bulunmak ve evrişimli sinir ağlarını eğitmek için yeni bir ağaç kabuğu veri seti oluşturulmuştur. Bu amaçla 59 farklı ağaç türünden ve 1189 adet ağaçtan 24686 adet ağaç kabuğu görüntüsü Kayseri-Abdullah Gül Üniversitesi Kampüsü, İstanbul-Aydos Ormanı, Bursa-İznik / Yenişehir ilçeleri, Ankara, Malatya, Yalova illerinde bir yıllık kapsayan bir süreçte toplanmıştır. Bu çalışma bir başlangıç çalışması olup, ilk aşamada oluşturulan ağaç kabuğu veri seti ile önceden eğitilmiş ağları transfer öğrenme yöntemleriyle eğiterek ağaç türlerinin tanımlanmasının mümkün olduğunu göstermektedir. Bu çalışma sonucunda kazanılacak bilgi ve tecrübeler doğrultusunda çalışmanın devamında planlanan proje ile veri setini Türkiye sınırlarını kapsayacak şekilde mümkün olduğunca büyütme ve ağaç kabuğu görüntülerinden ağaç tanımlaması yapabilecek yüksek çözünürlükte veri girişi olan, söz konusu göreve özgün bir ağ tasarlamaktır. Yine proje kapsamında meyve ağaçlarının alt türlerinin tanımlanmasını yapabilecek ikinci özgün bir ağ tasarımı yapılacaktır. Her iki ağ tasarımı herkesin ulaşabileceği uygulamalar haline getirilerek oluşturulan veri setiyle birlikte kamuya açılacaktır.

2013'den itibaren, Image-CLEF Challenge'de bitkilerin tanımlanması için yapılan çalışmalarda yaprak verilerinin yanı sıra bitkinin diğer kısımlarında kullanılmaya başlanmıştır. Ekipler, bitkilerin farklı kısımlarının görüntüsüyle bitki türlerini tanımlamak için algoritmalar ve programlar geliştirmişlerdir [6, 7]. 2014 yılına kadar algoritmaların çoğu Scale-Invariant Feature Transform veya Speeded-Up Robust Features gibi noktaların tespit edilmesi ve karakterizasyonuna, Fourier veya LBP (Local Binary Pattern) dönüşümlerinden elde edilen renk bilgilerine ve bag-of-words yaklaşımlarına dayanmaktaydı [8-10]. ImageCLEF 2015'den itibaren ise bitkilerin tanımlanması veya özelliklerin çıkarılmasında derin öğrenme yaklaşımları kullanılmaya başlanmıştır [11].

M. Sulc vd. LifeCLEF 2014'de bitki türlerinin fotoğraflardan tanımlanmasına yönelik önceden eğitilmiş ResNet 152'yi kullanmışlar ve %50 ile %60 arasında başarı elde etmişlerdir [12]. N. Sunderhauf vd. LifeCLEF 2015'de Fransa'dan 500 farklı ot, ağaç ve eğreltiotu türünden alınan 47000'den fazla kök, yaprak, meyve, çiçek ve dal deseni görüntülerini kullanarak evrişimli sinir ağları ile sınıflandırma yapmışlar ve ortalama %25 başarı elde etmişlerdir. Söz konusu çalışmada yaprak için başarı oranı %8, yaprak taramaları için başarı oranı %53 civarında iken dal deseni görüntüleri için ise başarı oranı %5'in altındadır [13]. J. Champ vd. LifeCLEF 2015'de Batı Avrupa'da yaşayan ağaç, ot ve eğreltiotu türüne ait 1000 adet türün çok sayıda çiçek, yaprak, meyve, kök ve dal görüntülerini toplamışlardır. Çalışmalarında evrişimli sinir ağlarını kullanarak sınıflandırma yapmışlar ve %58 başarı oranı elde etmişlerdir [14]. H. Goeau vd. LifeCLEF 2017'de yaptıkları

çalışmada AlexNet, GoogLeNet, ResNet, VGGNet gibi birçok mimari kullanarak çiçek, çiçek-meyve-yaprak, çiçek-yaprak, çiçek-yaprak-dal deseni, tüm bitki görüntüsü, dal deseni, meyve, meyve-yaprak, yaprak, yaprak-dal deseni görüntüleri üzerine yaptıkları çalışmada %48 ile %95 arasında değişen başarı oranları elde etmişlerdir. Çalışmalarındaki dal deseni görüntülerdeki başarı oranı %90'dır [15]. LifeCLEF'de yaprak, meyve, kök veya dal deseni gibi farklı parçaların görüntülerini kullanarak bitkilerin tanımlanmasının yapıldığı çalışmalarda derin öğrenme yaklaşımları kullanılmıştır. Söz konusu çalışmalarda ağaç kabuk görüntüleri sayısı çok az olup daha çok yaprak, çiçek, meyve gibi görüntüler üzerine odaklanan çalışmalardır.

Z.K. Huang vd. Gabor dalgacık temelli doku özelliklerini çıkarmışlar ve sınıflandırıcı olarak radyal tabanlı olasılık ağı kullanmışlardır. Söz konusu yöntemle, yaklaşık 300 ağaç kabuğu görüntüsü içeren bir veri seti kullanılarak %80'e yakın başarı elde etmişlerdir [16]. S. Fiel ve R. Sablatnig yaptığı tez çalışmasında ağaç türlerinin ağaç kabuğu görüntülerinden otomatik olarak belirlenmesi için bir yöntem sunmuşlardır. Önerilen yöntem AFF veri seti üzerinde test etmişler ve %69,7 başarı oranı elde etmişlerdir [17]. M. Sulc ve J. Matas LBP birleştirilmiş histogramları ile oluşturulan özellik eşlemeli çok ölçekli tanımlayıcıların SVM sınıflandırmasıyla ağaç kabuğu tanımlaması için AFF veri seti kullanılarak bir yöntem önermişlerdir. Önerilen yöntemde %82,5 tanıma oranına ulaşmıştır [18]. S. Boudra vd. yaptığı çalışmada; Multi-Resolution LBP, Multi-Block LBP, LBP-Filtering, Multi-Scale LBP ve Pyramid LBP gibi farklı Multi-Scale LBP tanımlayıcılarının verimliliğini AFF ve Trunk12 veri setinde incelemişler ve sonuç olarak Multi-Scale LBP tanımlayıcılarının temel LBP'den daha iyi performans gösterdiğini gözlemlenmiştir. Çalışmalarındaki başarı oranı LBP tanımlayıcısına bağlı olarak %80 ile %90 arasında değişiklik göstermiştir [19]. A. Bressane vd. ağaç gövdesi görüntülerinin doku sınıflandırması için istatistiksel parametrelerin uygulanması üzerine bir çalışma yapmışlardır. Brezilya'daki beş yerli yaprak döken türünden 540 görüntü örneği alınarak, dokulardan entropi, homojenlik, pürüzsüzlük, asimetri, ortalama ve standart sapma ölçüleri alınmıştır. Çalışmalarında Karar Ağacı kullanılarak, bir biyometrik tür tanıma sistemi inşa edilmiş ve türlerin sınıflandırılması için %83 başarı oranı elde etmişlerdir [20]. A. Othmani vd. karasal lazer tarama sistemlerinin üç boyutlu ağaç kabuğu analizine dayalı bir bilgisayar destekli ağaç türü tanımlama yöntemi sunmuşlardır. Yöntemin performansını incelemek için Avrupa ormanlarında en baskın türler arasında yer alan 6 ağaç türünden alınan 969 görselden oluşan bir veri setinde

%99 başarı oranı elde etmişlerdir [21]. T. Mizoguchi vd. evrişimli sinir ağı kullanılarak Lidara dayalı ağaç türleri sınıflandırması için yeni bir yöntem önermişlerdir. Sınıflandırma kriterleri için ağaç kabuk dokusunu ve ağaç türü olarak da Japon Sedir ve Selvi'ye odaklanmışlardır. Lidar ile ağaç arasındaki mesafe bağlı olarak ortalama %89,8 başarı elde etmişlerdir [22]. M. Carpentier vd. 23 farklı ağaç türünden 23000'den fazla ağaç kabuğu görüntüsü toplayarak bir veri seti oluşturmuşlar ve derin öğrenmeyi kullanarak ağaç türlerini tanımlamışlardır. Çalışmalarında elde ettikleri başarı oranı %93,88 ile %97,81 arasındadır [23].

2. DENEYSEL METOT (EXPERIMENTAL METHOD)

Makine öğrenmesi, bir sistemin belirli bir problem üzerinde karar vermesini sağlayan yöntemlerin geliştirildiği bilgisayar bilim alanıdır [24]. Derin öğrenme ise, çok büyük verilerde özelliklerin çıkarılması için kullanılan, yapay sinir ağlarından türetilmiş, çoklu katmanlı, makine öğrenmesi sistemlerinin alt gruplarında incelenen ve de çoğu durumda klasik makine öğrenme yöntemlerinin aksine veri ön işleme gerektirmeyen bir makine öğrenme metodudur [25, 26]. Fakat makine öğrenimine göre yetenekleri farklılaşmıştır. İnsan düzeyine yakın görüntü sınıflandırması, konuşma tanıma, metin okuma ve seslendirme gibi konuları kapsamaktadır [27]. Derin öğrenme algoritmaları içerisinde birçok sınıflandırma modeli kullanılmaktadır. Bunların arasında en sık kullanılan ve popüler olan evrişimli sinir ağlarıdır [25]. Evrişimli sinir ağları nesnelerin sınıflandırılması ve tespiti ile ilgili yapılan yarışmalarda normal makine öğrenmesi yöntemlerinden çok daha iyi dereceler alarak alanının en iyisi olduğunu kanıtlamıştır [28]. Bunun yanı sıra sinyal işleme, sözlük, ilaç, tıp, finans sektörü ve savunma sanayinde kullanılmaktadır. Evrişimli sinir ağları çoğunlukla Şekil 1'deki gibi Convolution (Evrişimli Katmanlar) [29, 30], Rectified Linear Unit (ReLU), Pooling (Havuzlama) ve Fully Connected Layers (Tam Bağlantılı Katmanlar) katmanlarından oluşur [26, 31].

Yeni bir evrişimli sinir ağı yaratmanın ve eğitmenin ilk adımı ağ mimarisini tanımlamaktır. Ağ mimarisi, dâhil edilen katmanların türlerine ve sayılarına bağlı olarak değişebilir. Dâhil edilen katmanların türleri ve sayısı, uygulamaya veya verilere bağlıdır. Örneğin, kategorik yanıtlar varsa, bir softmax ve bir sınıflandırma katmanına sahip olunmalıdır. Yanıt sürekli ise, ağıın sonunda bir regresyon katmanının olması gerekir. Yalnızca bir veya iki evrişimli katmana sahip küçük bir ağ, az sayıda gri tonlamalı görüntü verisini öğrenmek için yeterli olabilir. Diğer taraftan, milyonlarca renkli görüntü içeren karmaşık veriler için daha karmaşık ağlara ihtiyaç vardır [30]. Evrişimli sinir ağlarında Şekil



Şekil 1. Evrişimli Sinir Ağ Katmanları (Convolutional Neural Networks Layers)

2'deki gösterildiği gibi ilk katmanlarda verilen girdi üzerinde, filtreler yoluyla özellik çıkarımı gerçekleştirilir [30]. Aynı zamanda bir yandan hesaplama maliyetini düşürmek diğer yandan ise girdiden öğrenilen özelliklerin özet bilgisini diğer katmanlara aktarmak amacıyla boyut düşürme fonksiyonları kullanılır. Daha sonra girdiden elde edilen bu özellikler tek boyutlu bir vektör haline getirilir ve tam bağlantılı katman veya katmanlara girdi olarak verilip, sınıflandırma işlemi gerçekleştirilir. Ağın filtreler ve ağırlıklar altındaki performansı, bir kayıp fonksiyonu ile hesaplanır ve öğrenilebilir parametreler yani filtreler ve ağırlıklar geri yayılım yoluyla kayıp değerine göre güncellenir.

Derin Öğrenme yapısı 2006 yılında tanıtılmış olsa da daha çok ImageNet yarışması ile popüler hale gelmiştir. ImageNet tarafından yapılan yarışmada görüntü tanıma için algoritmalar ortaya konmuş, bu algoritmalarından Derin Öğrenme mimarileri oldukça başarılı sonuçlarla ön plana çıkmıştır. Derin Öğrenme yöntemlerinin her biri farklı mimari kullanarak eğitim işlemi gerçekleştirilmektedir. Bu çalışmada kullanılan Derin Öğrenme ağları AlexNet [32, 33], DenseNet201 [34], ResNet18 [35], ResNet50 [35], ResNet101 [35], VGG16 [36, 37], VGG19 [37] ağlarıdır. Tablo 1'de söz konusu ağların katman, derinlik, parametre sayısı, görüntü giriş boyutları, Tablo 4'de ise ağ mimarileri verilmiştir.


Tablo 1. Çalışmada kullanılan Derin Öğrenme ağları (Deep Learning networks used in the study)

Ağlar	Katman	Derinlik	Parametre Sayısı (Milyon)	Görüntü Giriş Boyutu
AlexNet	25	8	61	227 x 227
DenseNet201	709	201	20	224 x 224
ResNet18	72	18	11,7	224 x 224
ResNet50	177	50	25,6	224 x 224
ResNet101	347	101	44,6	224 x 224
VGG16	41	16	138	224 x 224
VGG19	47	19	144	224 x 224

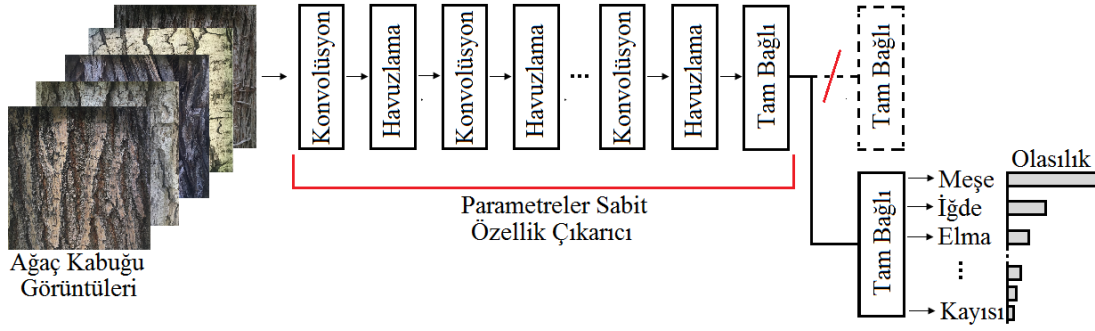
Bazı evrişimli sinir ağlarının eğitilmesi, ağın karmaşıklığı ya da veri setinin büyüklüğü nedeniyle standart bilgisayar işlemcilerinde gerçekleştirmek oldukça zordur. Bu nedenle grafik işleme birimlerine ihtiyaç duyulur. Uzun süren eğitimler sonucunda eğitilmiş birçok modelden problem için uygun bir model seçilerek problemin çözümünde kullanılabilir. Eğitilmiş bir ağın, ilgili ikinci bir görevde

yeniden tasarlandığı, hızlı ilerleme ve gelişmiş performans sağlayan bu makine öğrenmesi tekniğine Transfer Öğrenme denir. Transfer Öğrenmesi, ağır eğitilmesi için, yeterli zaman yok ve donanım yetersizse, ne kadar veri olduğuna dair endişelenmeden, bir Derin Öğrenme modeli oluşturmanın en hızlı ve en kolay yoludur. Geleneksel makine öğrenme teknikleri, her görevi sıfırdan öğrenmeye çalışırken, transfer öğrenme teknikleri, önceki görevlerden elde ettiği bilgileri yeni bir görevi öğrenme hedefine aktarır [38]. Araştırmalar, ImageNet gibi çok büyük görüntü verilerinden öğrenilen özelliklerin, çeşitli görüntü tanıma görevlerine yüksek oranda aktarılabilir olduğunu göstermiştir.


Transfer öğrenme sürecinin başlangıç aşamasında neyin, ne zaman ve nasıl aktarılacağı sorularına cevap aranır. Neyin aktarılacağı; kaynak veriden hangi bilgi aktarılınca hedef görevin başarısının artacağına cevap aranan bölümdür. Ne zaman aktarılacağı; verinin hangi durumlarda aktarılacağı ya da aktarılmaması gerektiği durumlar belirlenir. Nasıl aktarılacağı; transfer öğrenme için hangi yöntemlerin kullanılacağına karar verilir [38]. Evrişimli ağlar giriş ve ara katmanlar genellikle kenar, doku, desen, gibi üst seviye özellikleri öğrenirken son katmanlar veri kümesinin daha spesifik özelliklerini öğrenir. Bu yüzden giriş ve ara katmanlar korunurken son katman probleme uygun şekilde tasarlanıp daha sonra mevcut veri setiyle eğiterek hızlı bir şekilde yeni bir model elde edilir [39]. Veri ve hedef görev, orijinal modelin üzerinde çalıştığı veri ve hedef görevle benzerlik gösteriyorsa, bu yaklaşım en iyi sonucu verir. Bununla birlikte, bir modeli sıfırdan eğitmek için yeterli veri varsa ve görevler o kadar yakın olmasa da, önceden eğitilmiş bir model kullanarak parametreleri başlatmak, rasgele başlatmadan daha iyi sonuçlar verebilir. Ayrıca sahip olunan veri problemleri ve miktarı yetersiz ise; bu veri için tasarlanmış özel model, önce genel bir görev için hazırlanmış büyük bir veri kümesi kullanılarak eğitilip daha sonra mevcut veri ile eğitilebilir. Bu yöntemde aktarılan şey temel olarak parametrelerin başlangıç değerleridir. Ağırlıkları rastgele başlatmak yerine önceden eğitilmiş bir ağı kullanarak başlatmak; ağın öğrenmede iyi bir başlangıç yapmasını, öğrenme gelişiminde daha dik eğimi ve daha yüksek performans elde etmesini sağlayarak yakınsamayı hızlandırır. Yeterli veri olmadığı durumlarda, bu tür transfer öğrenimi, bir ağı aşırı öğrenmeden koruyarak eğitmek için iyi bir seçenektir. Transfer öğrenmede eğitimi ön eğitimden korumak için, öğrenme oranını uygun büyük bir değerden başlayarak kademeli olarak düşürmek yaygın bir uygulamadır. Şekil 3'deki gibi Tam Bağlı katman dışındaki




Şekil 2. Evrişimli Sinir Ağ Çalışma Akışı (Convolutional Neural Networks Workflow)



Şekil 3. Tam Bağlı katmanların probleme göre tasarımı. (Design of fully connected layers to the problem)



Şekil 4. Evrişimli Ağlarda ilk katmanların transferi (Transfer of first layers in Convolutional Neural Networks)




Şekil 5. Evrişimli Ağlarda son katmanların transferi (Transfer of last layers in Convolutional Neural Networks)

tüm katmanları aktarmak en yaygın transfer öğrenme türüdür. Bu çalışmada da bu yöntemin kullanılması tercih edilmiştir. Ayrıca Şekil 4'deki önceden eğitilmiş bir ağın ilk n katmanını bir hedef ağa aktarıp geri kalan katmanları rastgele başlatmak ta mümkündür.

Aktarılan kısmın, ilk katmanlar olması gerekmez. Şekil 5'deki gibi görevler aynıysa ancak girdi verilerinin türü biraz farklıysa, son katmanları da aktarmak mümkündür.

Transfer öğrenme pek çok görev için kullanılabilir. Ancak bir model başka bir modele aktarmak her zaman mümkün değildir. Veri türünün ve görevin oldukça farklı olduğu durumlar bu kapsama girer. Transfer öğreniminin uygulanamayabileceği bir başka durum, özellikleri aktarılan model ile aktarılan modelin mimarisinin uyumsuzluk durumudur. Farklı mimariye sahip modeller arasında bilgi aktarımını sağlayan teknik model ise Şekil 6'da verilen Damıtmadır. Önceden eğitilmiş bir modelin damıtılması; yeni modeli, doğrudan veriler üzerinde eğitmek yerine önceden eğitilmiş modelin çıktılarını taklit edecek şekilde eğitilmesidir. Bu yaklaşım özellikle kaynak modelden daha küçük bir modelin eğitilmesinde oldukça verimlidir. Ağaç kabuğu görüntülerinden ağaçların sınıflandırmasında Derin Öğrenme yöntemlerinden evrişimli sinir ağlarının kullanımındaki en önemli engel, eğitim amaçlı mevcut veri setlerinin yetersiz olmasıdır. Tablo 2, şu ana kadar çeşitli çalışmalar için oluşturulmuş mevcut veri setlerini göstermektedir.



Şekil 6. Eğitilmiş bir modelin damıtılması (Distillation of a trained model)

Tablo 2. Mevcut ağaç kabuğu resim verileri (Available bark image data)

Referans	Tür Sayısı	Görüntü Sayısı
Z. Chi vd. [40]	8	200
Z.K. Huang vd. [16]	17	300
Trunk 12 [19]	12	393
A. Bressane vd. [20]	5	540
L. J. Blanco vd. [41]	23	920
AFF [1]	11	1183
BarkNet 1.0 [5]	23	23000

Söz konusu veri setleri sınırlı sayıda tür ve bu türlere ait sınırlı sayıda görüntü içermektedir. Bu çalışma ve sonrasında planlanan çalışmalarla yetersiz olan veri setlerine katkı yapma amaçlanmaktadır. Bu amaçla, 59 farklı ağaç türün



Şekil 7 Gövde kalınlığının desen üzerinde etkisi (Effect of trunk thickness on the pattern)

24686 ağaç kabuğu görüntüsü bir yıllık bir süreçte toplanmıştır. Ayrıca ağaç türü sayısını artırmak amacıyla 23 ağaç türünden oluşan BarkNet 1.0 veri setinden bu çalışmada kullanılan veri setinde bulunmayan 18 adet ağaç türünden rastgele 400'er resim alınarak veri setine eklenmiştir. Böylece toplamda 77 ağaç türüne ve 31886 görüntü sayısına ulaşılmıştır. Bu işlemin yapılmasındaki amaç veri setini dahada büyüterek çalışmanın amaçlarından biri olan ağaç kabuğu görüntülerinden ağaç türlerinin tanımlanabileceğini başka verilerle test etmektir. Doğa gözlemleri sonucunda ağaç kabuğu görüntüleri toplanırken aşağıdaki hususlara dikkat edilmiştir:

Ağaç yaşının gövde kalınlığı üzerinde doğrudan etkisi vardır. Ağaç gövdesinin kalınlığının artması desen boyutu ve desenler arasındaki yarıkların boyutunu etkilemektedir. Bu durum dikkate alınarak farklı yaşlarda ve gövde kalınlığındaki ağaçlar üzerinde çekim yapılarak mümkün olduğu kadar genç-yaşlı ağaç oranı dengede tutulmaya çalışılmıştır. Şekil 7'de gövde kalınlığının ağaç gövde deseni üzerindeki etkisi verilmiştir. Şekil 8'de gösterildiği gibi coğrafi yön nedeniyle yosunlaşmadan kaynaklanan ağaç kabuğu deseninde renk değişiminin olması, yosun örtüsünün Şekil 9'daki gibi kabuk desenin üzerini kaplaması veya Şekil 10'da verildiği gibi güneşte kavrulma nedeniyle bir miktar renk değişimi meydana gelmesi ya da ağaç kabuğunun ufalanarak dökülmesi göz önünde tutularak ara yönler dâhil tüm coğrafi yönlerden eşit sayıda görüntü alınmaya çalışılmıştır.



Şekil 8. Yosunlaşma nedeniyle renk değişimi
(Color change due to moss)



Şekil 9. Yosunlaşma nedeniyle ağaç kabuğu deseninin örtülmesi
(Covering tree bark pattern due to moss)



Şekil 10. Güneş ışığı nedeniyle renk değişimi ve ağaç kabuğu dökülmesi
(Color change and bark loss due to sunlight)

Ağaç yumruları ağaç gövde formlarını bozarak kabuk deseninin bozulmasına veya kabuğun dökülmesine neden olur. Ayrıca ağaçlardaki ballanma, reçine, zamk gibi akıntılar ağaç kabuğu deseninde renk değişimi veya desenlerin üzerinin örtülmesi nedeniyle desen kaybına yol açmaktadır. Bu durumlar göz önünde tutularak Şekil 11 ve Şekil 12'deki gibi görüntüler de veri setine dahil edilmiştir.



Şekil 11. Ballanma ve reçine nedeniyle renk değişimi ve desen kaybı
(Color change and pattern loss due to balling and resin)

Işık değişkenliğini eğitime dâhil etmek için güneşli havalardan, kapalı havaya dört mevsim fotoğraf çekimi yapılmıştır. Bunun yanı sıra ağaç gövdesinin gölgede kalması ya da çevresindeki ağaçların dal ve yaprakların arasından gelen ışığın gövde üzerinde aydınlık ve gölgeli bölgeler oluşturması nedeniyle ağaç renginin ve deseninin fotoğraflara düzgün yansımaması, ayrıca çevredeki bitki örtüsü renginin fotoğraf çekimlerinde etkili olması nedeniyle tüm durumları yansıtacak Şekil 13 ve Şekil 14'deki gibi fotoğraf çekimleri gerçekleştirilmiştir.

Toprak seviyesinden yukarıya doğru çıktıkça kabuk desenlerinin boyutları ve desenler arasındaki yarıkların genişliğindeki değişimleri dikkate almak için Şekil 15'deki gibi toprak seviyesinden ulaşılabilen en yüksek noktaya kadar fotoğraf çekimleri yapılmıştır.

Veri seti tamamlandıktan sonra her fotoğraf sadece ağaç kabuğun görülebildiği yerleri koruyacak şekilde tüm



Şekil 12. Ağaç yumruları nedeniyle ağaç kabuğu dökülmesi ve desen kaybı (Bark and pattern loss due to tree tubers)



Şekil 13. Işık-Gölge'nin desen üzerindeki etkisi (Effect of Light-Shadow on the pattern).



Şekil 14. Çevre bitki örtüsü nedeniyle fotoğraflarda yeşil rengin baskın olması (Green color predominates in photographs due to environmental vegetation)

fotoğraflar Şekil 16'daki gibi kırılmıştır. Fotoğraflar ağ girişinin 227x227 veya 224x224 olması ve fotoğrafların kare formatta ağ girişine verilmesinin ağ performansını arttıracığı düşüncesiyle Şekil 16'da gösterildiği gibi kare şeklinde olacak şekilde birkez daha kırılma işlemi gerçekleştirilmiştir. Ağ girişine verilen görüntülerin kare veya dikdörtgen şeklinde olması durumunun ağ performansına etkisi bu çalışmada ayrıca incelenmiştir.



Şekil 15. Toprak seviyesi ve yukarısının desen üzerinde etkisi (Effect of soil level and above on the pattern).

Tablo 3'de çalışmada kullanılan tüm veri seti verilmiştir. Veri setinde toplam 77 tür ağaç olup bunların ilk 59'u bu çalışma için toplanmış verilerdir. 60 ile 77 arasındaki ağaçlar

ise BarkNet1.0 veri setinden alınmış ağaç türleridir. Şekil 17'de veri setlerinde kullanılan ağaç türlerinin kabuk desenleri verilmiştir.



Şekil 16. Fotoğraf kırılma aşamaları (Photo cropping steps)

Tablo 4'de AlexNet, DenseNet201, ResNet18, ResNet50, ResNet101, VGG16 ve VGG19 ağlarının mimari yapıları verilmiştir [32-37]. Ağaç kabuğu görüntülerinden ağaçların sınıflandırılması ImageNet'ten farklı bir problem olduğu için ImageNet ile eğitilen söz konusu önceden eğitilmiş ağlara

Tablo 3. Veri Seti (Data Set)

No	Bilimsel Adı	Türkçe Adı	Ağ.Gör. Sy Sy.	No	Bilimsel Adı	Türkçe Adı	Ağ.Gör. Sy Sy.
01	Fraxinus	Dişbudak	22 428	40	Prunus Armeniaca	Kayısı	25 573
02	Picea Abies	Avrupa Ladini	21 400	41	Cydonia Oblonga	Ayva	16 405
03	Aesculus	At Kestanesi	18 400	42	Pyrus Communis	Avrupa Armudu	19 400
04	Crataegus	Alıç	21 415	43	Prunus Cerasus	Vişne	20 400
05	Ailanthus Altissima	Kokar Ağaç	23 400	44	Quercus Robur	Saplı Meşe	23 433
06	Robinia Pseudoacacia	Yalancı Akasya	18 400	45	Pinus Pinea	Fıstık Çamı	22 400
07	Pterocarya Fraxinifolia	Kanatlı Ceviz	17 400	46	Prunus Persica	Şeftali	21 400
08	Salix Babylonica	Salkım Söğüt	20 467	47	Acer Platanoides	Çınar Yapraklı Akçaağaç	29 400
09	Salix alba	Ak Söğüt	15 400	48	Prunus Domestica	Avrupa Eriği	16 400
10	Prunus Triflora	Japon Eriği	16 400	49	Prunus Domestica	Erik	23 400
11	Acer Plat. Royal Red	Kır.Kral Akça.	28 400	50	Pinus Pinaster	Sahil Çamı	25 400
12	Cedrus Libani	Lübnan Sediri	16 400	51	Cupressus Sempervirens	Akdeniz Servisi	26 476
13	Platanus Occidentalis	Batı Çınarı	23 512	52	Prunus Mahaleb	Mahlep	14 400
14	Cedrus Deodara	Himalaya Sediri	19 400	53	Cedrus Atlantica	Atlas Sediri	25 400
15	Olea Europaea	Zeytin	32 400	54	Chamaecyparis Nootkatensis	Nutka Servisi	20 442
16	Ficus Carica	İncir	18 400	55	Ginkgo Biloba	Mabet Ağacı	21 400
17	Pinus Nigra	Karaçam	22 498	56	Quercus Gambelii	Gambel Meşe	18 421
18	Acer Negundo	Dişbudak Yapraklı Akçaağaç	15 400	57	Tilia platyphyllos	Büyük Yapraklı İhlamur	21 400
19	Blue Spruce	Mavi Ladin	24 435	58	Prunus Avium	Kiraz	14 400
20	Quercus Infectoria	Mazı Meşesi	21 400	59	Taxus Baccata	Porsuk Ağacı	- 400
21	Juglans	Ceviz	17 400	60	Betula Alleghaniensis	Sarı Huş	- 400
22	Malus Pumila	Elma	23 420	61	Betula Papyrifera	Kâğıt Huşu	- 400
23	Gladiçya	Yalancı Keçiboynuzu	19 400	62	Quercus Rubra	Kırmızı Amerikan Meşesi	- 400
24	Populus Canescens	Boz Kavak	22 454	63	Picea Glauca	Ak Ladin	- 400
25	Populus Alba	Ak Kavak	20 400	64	Picea Mariana	Kara Ladin	- 400
26	Catalpa Speciosa	Kuzey Katalpa	16 400	65	Picea Rubens	Kırmızı Ladin	- 400
27	Populus Nigra	Kara Kavak	21 437	66	Acer Rubrum	Kırmızı Akçaağaç	- 400
28	Norway Spruce	Norveç Ladini	17 400	67	Acer Saccharum	Şeker Akçaağacı	- 400
29	Picea Orientalis	Doğu Ladini	18 400	68	Fraxinus Americana	Amerika Dişbudağı	- 400
30	Cupressus Arizonica	Arizona Servisi	16 400	69	Fagus Grandifolia	Amerikan Kayın	- 400
31	Betula Pendula	Adi Huş	26 414	70	Larix Laricina	Amerika Melezi	- 400
32	Thuja Occidentalis	Batı Mazısı	25 520	71	Ulmus Americana	Amerika Karaağacı	- 400
33	Morus alba	Beyaz Dut	22 456	72	Ostrya Virginiana	Amerika Kayacığı	- 400
34	Morus Nigra	Kara Dut	18 480	73	Populus Tremuloides	Amerika Titrek Kavağı	- 400
35	Elaeagnus Pungens	İğde	22 400	74	Pinus Strobus	Veymut Çamı	- 400
36	Pinus Sylvestris	Sarıçam	21 400	75	Pinus Resinosa	Amerikan Kızılcamı	- 400
37	Platanus Orientalis	Doğu Çınarı	23 400	76	Tsuga Canadensis	Kanada Sugası	- 400
38	Juniperus Oxycedrus	Katran Ardıcı	19 400	77	Abies Balsamea	Balsam Göknarı	- 400
39	Malus Sylvestris	Orman Elması	17 400				

çalışma için oluşturulmuş veri seti, giriş katmanından ağa verilmiştir. Ağların birinci katmanından sınıflandırma katmanına kadar olan ara katmanlar Şekil 3'deki gibi korunmuştur. Çalışmada kullanılan ağlar 1000 sınıflandırma yaparken bu çalışma 59 veya 77 sınıflandırma yapmaktadır. Bu nedenle ağların sınıflandırma katmanları Şekil 3'deki gibi 59 veya 77 sınıflandırma yapacak şekilde tasarlanmıştır. Ağlardan AlexNet, VGG16 ve VGG19'da havuzlama katmanında maksimum havuzlama yöntemi kullanılırken, DenseNet-201, ResNet-18, ResNet-50 ve ResNet-101 ağlarında ise maksimum ve ortalama havuzlama yöntemi kullanılmıştır.

Çalışmada kullanılan ağlar oluşturulan veri setiyle MATLAB R2019a ortamında eğitilmiştir. Eğitimde kullanılan bilgisayarın işletim sistemi 64 bit, işlemcisi Intel(R) Core(TM) i7-7820HQ CPU @ 2.90 GHz, RAM'i 16 GB olup ekran kartı Radeon Pro 560'dır.

3. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Verilerin toplanması aşamasında az sayıda ağaçtan ağaç kabuklarının özgün desen ve renk görüntülerinin toplanması yerine Şekil 7 ile Şekil 15 arasında verilen etkenlerin ağaç kabuğu deseni üzerindeki olumsuz etkilerini içeren fotoğrafların veri setine eklemenin ağın güvenilirlik ve performansı üzerinde etkili olacağı sonucuna varılmıştır. Bu amaçla aynı ağaçtan çok fazla görüntü toplamak yerine çok sayıda ağaçtan özgün desen ve renk görüntüleriyle birlikte ağaç kabuğu desenini olumsuz etkileyen sorunları yansıtacak görüntüler de veri setine eklenmiştir. Yeni tanımlayıcı sistemler geliştirirken ortaya çıkan yaygın sorulardan biri; veri setinin boyutunun ve eğitim verisi oranının ne olacağıdır. Diğer sorular ise; ağların derinlik, katman, parametre sayısının, parti büyüklüğünün ve görüntülerin kare veya dikdörtgen olmasının çözüme etkisinin ne olacağıdır. Bu



Şekil 17. Veri setindeki ağaç kabuğu görüntü örnekleri (Examples of tree bark images in the data set)

Tablo 4. Ağ Mimarileri (Network Architectures)

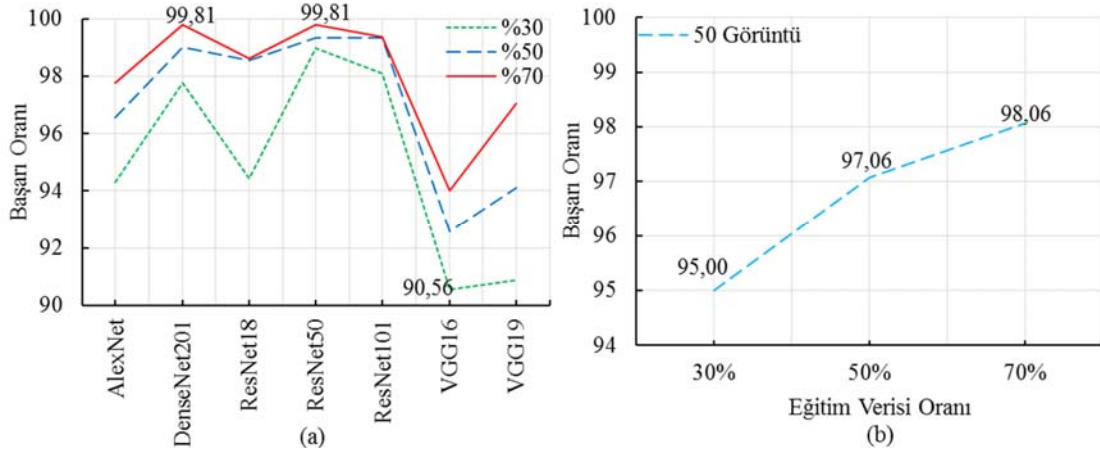
AlexNet	DenseNet201	ResNet-18	ResNet-50	ResNet-101	VGG16	VGG19
11x11con,96	7x7,con	7x7,con,64	7x7,con,64	7x7,con,64	[3x3con,64]x2	[3x3con,64]x2
max-pool	max-pool	max-pool	max-pool	max-pool	max-pool	max-pool
5x5con,256	1x1,con	3x3con,64	1x1con,64	1x1con,64	[3x3con,128]x2	[3x3con,128]x2
max-pool	3x3,con	3x3con,64	3x3con,64	3x3x3con,64	max-pool	max-pool
3x3con,384	1x1,con	3x3con,128	1x1con,256	1x1con,256	[3x3con,256]x3	[3x3con,256]x4
3x3con,384	aver-pool	3x3con,128	1x1con,128	1x1con,128	max-pool	max-pool
3x3con,256	1x1,con	3x3con,256	3x3con,128	x43x3con,128	x4 [3x3con,512]x3	[3x3con,512]x4
max-pool	3x3,con	3x3con,256	1x1con,512	1x1con,512	max-pool	max-pool
fc4096	1x1,con	3x3con,512	1x1con,256	1x1con,256	[3x3con,512]x3	[3x3con,512]x4
fc4096	aver-pool	3x3con,512	3x3con,256	x63x3con,256	x23 max-pool	max-pool
fc1000	1x1con	aver-pool	1x1con,1024	1x1con,1024	fc4096	fc4096
softmax	3x3,con	fc1000	1x1con,512	1x1con,512	fc4096	fc4096
	1x1,con	softmax	3x3con,512	x33x3con,512	fc1000	fc1000
	aver-pool		1x1con,2048	1x1con,2048	softmax	softmax
	1x1,con		aver-pool	aver-pool		
	3x3,con		fc1000	fc1000		
	aver-pool		softmax	softmax		
	fc1000,softmax					

soruları yanıtlamak ve yukarıda ayrıntılı olarak belirtilen ağaç sayısı ve görüntü çeşitliliğinin tanımlama doğruluğu üzerinde etkisini deneysel olarak görmek amacıyla 4 adet veri seti oluşturulmuştur.

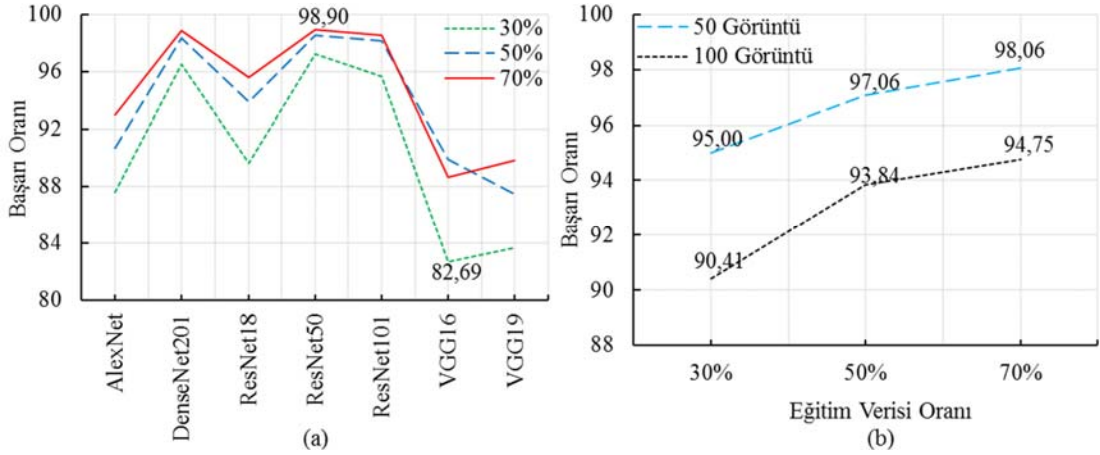
Birinci veri setinde her ağaç türünden ortalama 3'er ağaç olmak üzere her ağaçtan en az 15'er adet fotoğraf çekimi yapılmış ve her ağaç türünden en az 50'şer adet görüntü toplanmıştır. Birinci veri setindeki ağaç sayısının az olmasının yanısıra doğa olaylarına maruz kalmayan, ağacın özgün renk ve desenini yansıtan görüntülerden oluşmaktadır. Şekil 18a ve Tablo 5'de birinci veri seti sütunundan görüleceği gibi ağların performansları eğitim verisi oranına bağlı olarak %90,56 - %99,81 arasında değişmektedir. En 1262

düşük başarı oranı eğitim verisi oranı %30 iken VGG16 ağında %90.56 ile gerçekleşmiştir. En yüksek başarı oranı ise eğitim verisi oranı %70 iken DenseNet201 ve ResNet50 ağlarında %99.81 ile gerçekleşmiştir. Eğitim verisi oranına göre tüm ağların ortalama başarı oranı ise Şekil 18b ve Tablo 5'de görüleceği gibi %95 ile %98,06 arasında değişmektedir.

İkinci veri seti oluşturulurken birinci veri setindeki görüntülere, özellikle doğa koşullarına maruz kalan ağaç ve ağaç bölgelerinden çekilen görüntüler dâhil edilmiştir. Bu işlem sonucunda ağaç sayısı ve görüntü sayısı iki katına çıkmıştır. Ağaç ve görüntü sayısı artmasına rağmen eğitim sonucunda tüm ağların başarı oranında belirgin bir düşüş gözlenmiştir. Bunun nedeni doğa koşullarına maruz kalan



Şekil 18. Birinci veri seti grafikleri (First dataset charts)



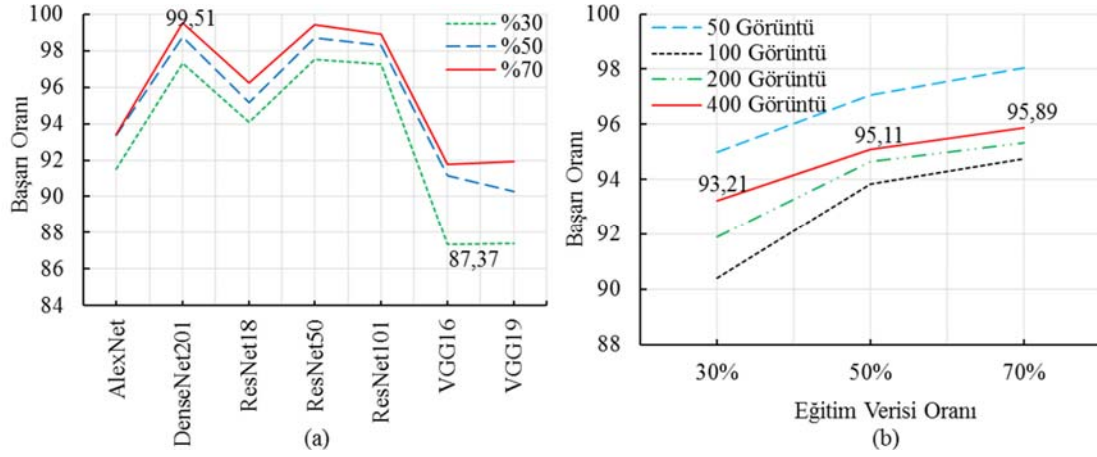
Şekil 19. İkinci veri seti grafikleri (Second dataset charts)

ağaç kabuğu görüntüleridir. Şekil 19a ve Tablo 5'deki ikinci veri seti sütunundan da görülebileceği gibi eğitim verisi oranına bağlı olarak ağların başarı oranı %82,69 ile %98,90 arasındadır. En düşük başarı oranı eğitim verisi oranı %30 iken VGG16 ağında %82,69 ile gerçekleşmiştir. En yüksek başarı oranı ise eğitim verisi oranı %70 iken ResNet50 ağında %98,90 ile gerçekleşmiştir. Eğitim verisi oranına göre tüm ağların ortalama başarı oranı ise Şekil 19b ve Tablo 5'deki ilgili sütunundan da görüleceği gibi %90,41 ile %94,75 arasında değişmektedir. Tüm ağların eğitim verisi oranına göre ortalama başarı oranı ortalama 3,7 puan düşüş göstermiştir.

Üçüncü veri setindeki veriler ise doğa koşullarına maruz kalınan ve kalınmayan ağaçlardan toplanmış karma görüntülerin ikinci veri setindeki görüntülere eklenmesiye oluşturulmuş olup ikinci veri setindeki toplam ağaç ve görüntü sayısının yaklaşık iki katına eşittir. Bu klasörün oluşturulmasıyla ortalama ağaç sayısı 12'ye, ağaç türü başına görüntü sayısı en az 200'e çıkmıştır. Görüntü sayısının özellikle de ağaç sayısının artmasıyla tüm ağların performansında artış gözlenmiştir. Ağaç sayısındaki artış ve görüntü çeşitliliğinin ağın performansı ve güvenilirliğini artırdığının gözlenmesi üzerine aynı yöntemle ağaç sayısı ve

görüntü sayısı birkez daha iki katına çıkaracak olan dördüncü veri seti oluşturulmuştur. Böylece her ağaçtan en az 400 görüntüye ve tür başına ortalama 20 ağaç ulaşılmıştır. Söz konusu veri setiyle eğitilen ağların başarıları, Şekil 20a'da gösterildiği gibi eğitim verisi oranı %30, %50 ve %70'iken %87,37 ile %99,51 arasında değişmektedir. En düşük başarı oranı, eğitim verisi oranı %30 iken VGG16 ağında %87,37 ile gerçekleşmiştir. En yüksek başarı oranı ise eğitim verisi oranı %70 iken DenseNet201 ağında %99,51 ile gerçekleşmiştir. Ayrıca eğitim verisi oranına göre tüm ağların ortalama başarı oranı ise Şekil 20b ve Tablo 5'deki ilgili sütunundan da görüleceği gibi %93,21 ile %95,89 arasında değişmektedir.

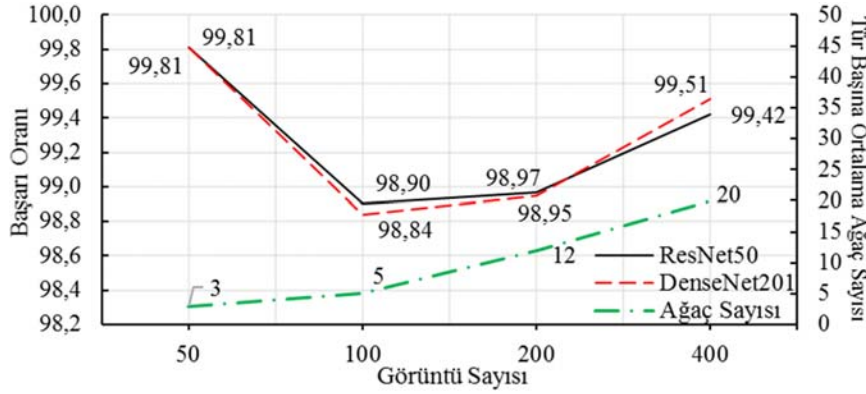
Tablo 5 ve Şekil 20'den de görülebileceği gibi genel eğilim; veri seti büyüdükçe ve eğitimde kullanılan yüzdelik dilim arttıkça ağların daha iyi sonuçlar verdiği yöndedir. Şekil 20a eğitim verisi oranı arttıkça tüm ağların başarı oranının arttığını göstermektedir. Şekil 20b'de ise görüntü sayısı ve eğitim verisi oranı arttıkça tüm ağların ortalama başarı oranının arttığı görülebilir. Tablo 5'deki en büyük başarı oranı birinci veri setinde DenseNet201 ve ResNet50 ağında %99,81 ile gerçekleşmiştir. Çünkü bu veri seti ağacın özgün renk ve desenini yansıtan ağaç bölgelerinden çekilen



Şekil 20. Dördüncü veri seti grafikleri (Fourth dataset charts)

Tablo 5. Ağların 59 tür ağacı tanımlama başarı oranları (Networks' success rate of identifying 59 species trees)

Ağ Modelleri	Birinci Veri Seti			İkinci Veri Seti			Üçüncü Veri Seti			Dördüncü Veri Seti		
	Ort. Ağaç Sayısı: 3			Ort. Ağaç Sayısı: 5			Ort. Ağaç Sayısı: 12			Ort. Ağaç Sayısı: 20		
	Min. Gör. Say.: 50			Min. Gör. Say.: 100			Min. Gör. Say.: 200			Min. Gör. Say.: 400		
Eğitim Yüzde Değeri												
	30%	50%	70%	30%	50%	70%	30%	50%	70%	30%	50%	70%
AlexNet	94,29	96,56	97,78	87,56	90,69	92,94	88,73	92,45	93,00	91,53	93,35	93,40
DenseNet201	97,78	99,00	99,81	96,48	98,33	98,84	96,60	98,67	98,95	97,32	98,78	99,51
ResNet18	94,44	98,56	98,63	89,63	93,89	95,60	90,87	94,89	95,97	94,07	95,16	96,25
ResNet50	98,97	99,33	99,81	97,22	98,55	98,90	97,42	98,62	98,97	97,54	98,70	99,42
ResNet101	98,10	99,33	99,36	95,63	98,13	98,50	97,04	98,27	98,70	97,25	98,30	98,92
VGG16	90,56	92,56	94,00	82,69	89,87	88,66	86,93	90,12	90,82	87,37	91,17	91,79
VGG19	90,87	94,11	97,04	83,63	87,43	89,81	85,57	89,50	90,87	87,42	90,28	91,93
Ortalama	95,00	97,06	98,06	90,41	93,84	94,75	91,88	94,65	95,33	93,21	95,11	95,89



Şekil 21. Tür başına ağaç sayısı-Ağ Başarısı (Trees per species-Network Accuracy)

görüntülerden oluşmaktadır. Dolayısıyla elde edilen başarı oranı oldukça yüksektir. Sadece ağacın özgün renk ve desenini temsil eden görüntüler değil, doğa koşullarına maruz kalan ağaçlardan çekilen görüntülerin veri setine eklenmesiyle belirgin bir düşüş gösteren ağ başarıları, ağaç sayısı arttıkça ve doğa koşullarına maruz kalan ağaçlardan çekilen görüntüler veri setine eklendikçe ağların başarı oranı artış göstermiştir. Bu koşulları sağlayan dördüncü veri seti birinci veri setinin başarı oranına oldukça yaklaşmıştır. Şekil 21'de tüm veri setlerinde en yüksek başarı oranı elde edilen


DenseNet201 ve ResNet50'nin tür başına ağaç sayısı artışına paralel olarak ağ başarı oranlarının da arttığı görülebilir.

Tablo 6'da ResNet50 ve DenseNet201'in tür başına 400 görüntü, eğitim verisi oranı %30 olduğu durum için 59 tür ağaçtan oluşan veri setindeki her ağaç türü için ayrı ayrı başarı oranları verilmiştir. Tablo 6'da görüleceği gibi söz konusu durum için ResNet50'nin ortalama başarı oranı %97,54, DenseNet201 için ise %97,32'dir. Her iki ağ için eğitim oranı %70'e çıkarıldığında ağların başarı oranı

Tablo 6. ResNet50(Ağ1) ve DenseNet201(Ağ2) ağlarının 59 tür ağacı tanımlama başarı oranları
(59 species tree identification success rates of ResNet50 (Net1) and DenseNet201 (Net2) networks)

No Ağaç Adı	Ağ1 Ağ2	No Ağaç Adı	Ağ1 Ağ2	No Ağaç Adı	Ağ1 Ağ2
01 Dişbudak	99,2 99,2	21 Ceviz	96,6 99,2	41 Ayva	97,5 96,3
02 Avrupa Ladini	95,0 98,3	22 Elma	98,3 99,3	42 Avrupa Armudu	97,0 96,4
03 At Kestanesi	95,8 95,0	23 Yalancı Keçib,	100 98,0	43 Vişne	100 98,5
04 Alıç	95,8 96,6	24 Boz Kavak	100 98,8	44 Saplı Meşe	98,3 96,6
05 Kokar Ağaç	99,7 99,5	25 Ak Kavak	100 96,6	45 Fıstık Çamı	99,2 99,0
06 Yalancı Akasya	98,0 98,1	26 Kuzey Katalpa	93,3 98,3	46 Şeftali	98,6 97,5
07 Kanatlı Ceviz	100 100	27 Kara Kavak	99,2 99,2	47 Çınar Yapraklı Akçaağaç	100 99,1
08 Salkım Söğüt	95,8 98,3	28 Norveç Ladini	98,3 88,2	48 Avrupa Eriği	97,0 97,0
09 Ak Söğüt	97,5 99,2	29 Doğu Ladini	99,1 98,6	49 Erik	95,0 94,3
10 Japon Eriği	98,3 98,3	30 Arizona Servisi	100 98,0	50 Sahil Çamı	100 100
11 Kır Kral Akçaağacı	99,5 99,0	31 Adi Huş	100 98,4	51 Akdeniz Servisi	98,8 97,5
12 Lübnan Sediri	97,0 97,2	32 Batı Mazısı	99,2 98,0	52 Mahlep	98,0 97,0
13 Batı Çınarı	99,2 98,7	33 Beyaz Dut	98,3 98,9	53 Atlas Sediri	98,6 97,8
14 Himalaya Sediri	100 99,2	34 Kara Dut	100 99,1	54 Nutka Servisi	97,2 96,8
15 Zeytin	95,7 95,0	35 İğde	94,1 95,0	55 Mabet Ağacı	97,0 95,0
16 İncir	97,0 97,4	36 Sarıçam	99,1 98,7	56 Gambel Meşe	95,0 95,7
17 Karaçam	89,1 88,2	37 Doğu Çınarı	99,2 99,2	57 Büy, Yap, Ihlamur	98,7 97,7
18 Dişb, Yap, Akç,	96,2 96,4	38 Katran Ardıcı	99,2 99,2	58 Kiraz	96,0 95,2
19 Mavi Ladin	93,3 97,5	39 Orman Elması	98,3 95,8	59 Porsuk Ağacı	99,3 99,1
20 Mazı Meşesi	95,0 92,3	40 Kayısı	84,9 96,0	Ortalama:	97,54 97,32

ResNet50 için %99,42 ve DenseNet201 için ise %99,51 olmaktadır. Eğitim verisi oranı %30'dan %70'e çıkarıldığında ağların başarıları ortalama iki puan artış göstermiştir. Veri setini genişletmek ve ağın performansını test amacıyla BarkNet1.0 veri setinde olup bu çalışma için oluşturulan veri setinde bulunmayan 18 farklı tür ağacın kabuk görüntülerinden rastgele 400'er adet görüntü alınıp çalışmanın veri setine dâhil edilerek ağaç türü sayısı 77'ye yükseltilmiştir. Fakat BarkNet1.0 veri setindeki görüntüler Şekil 22'de görüldüğü gibi dikdörtgen şeklindeyken bu çalışma için toplanan görüntüler kare şeklindedir. Bu iki veri setindeki farklılığı ortadan kaldırmak amacıyla BarkNet1.0 veri setinden alınan 18 tür ağaca ait 7200 görüntü Şekil 22'de gösterildiği gibi kırpılarak kare şekline dönüştürülmüştür.

**Şekil 22.** BarkNet 1.0 veri setinin düzenlenmesi
(Editing BarkNet 1.0 dataset)

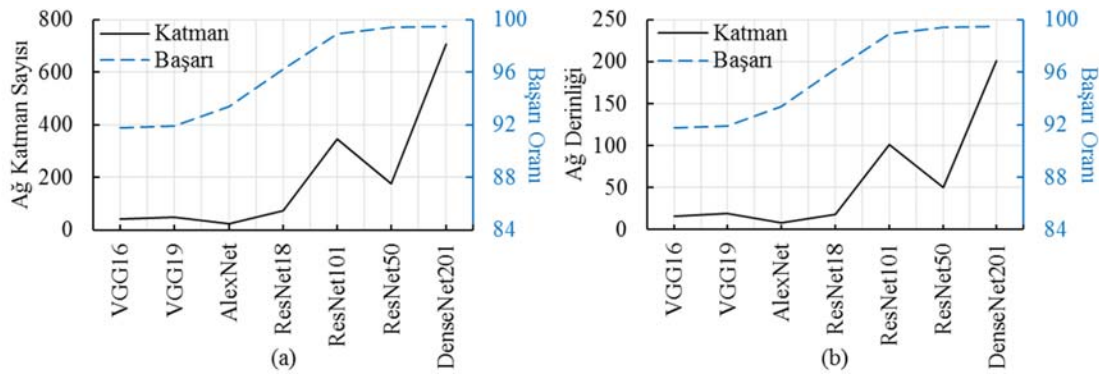
Kırpma işlemi gerçekleştirildikten sonra 77 tür ağaç ve toplam 31.886 görüntüden oluşan veri setiyle ağlar eğitilmiştir. Bu eğitimde kullanılan ResNet50 ve DenseNet201'e ait her ağaç türünün başarı oranları Tablo 7'de verilmiştir. Ağların

başarı oranları ResNet50 için %97,2 DenseNet201 için ise %97,8'dir. Bu eğitimde ağaç türü başına en az 400 görüntü, eğitim verisi oranı %30 alınmıştır. Eğitim verisi oranı %30'dan %70'e çıkarıldığında ise ağların başarı oranları ResNet50 için %98,05'e, DenseNet201 için %98,4'e çıkmıştır. Deneylerde, ağların katman sayısının ve ağ derinliğinin sınıflandırma hassasiyeti üzerindeki etkisinde incelenmiş, katman sayısının ve derinliğinin ağ doğruluk değeri ile doğru orantılı olduğu gözlenmiştir. Eğitimlerde elde edilen diğer bir sonuç; parametre sayısı az olan ağların bu çalışmadaki gibi özel problemlere uygulandığında ağ performanslarının parametre sayısı fazla olan ağlara göre daha iyi olduğudur. Söz konusu bu durumu yansıtan eğitim sonuçları Şekil 24'deki grafikte görülebilir. Düzenleştirme etkisini değerlendirmek amacıyla Tablo 5'deki en başarılı ve başarısız ikişer ağ alınarak parti büyüklükleri 8, 16, 32 ve 64 olacak şekilde ağlar test edilmiştir. Eğitimler ağaç türü başına en az 400 görüntü, eğitim verisi oranı %30 alınarak yapılmış ve eğitim sonuçları Tablo 9'da verilmiştir.

Tablo 8'deki verilerle çizilen Şekil 23a ve Şekil 23b'de Katman Sayısı ve Derinliği fazla olan ağlar soldan sağa doğru sıralanırken ağ başarısı da aynı şekilde soldan sağa doğru artış göstermektedir. Sonuçlar parti büyüklüğünün (Batch Size) 8 olması durumunda ağ performanslarının daha iyi olacağı yönündedir. Tablo 5'deki sonuçlar parti büyüklüğünün 32 alınarak elde edilmiş sonuçlardır. Parti büyüklüğünün 8 olması durumunda Tablo 5'deki dördüncü veri seti sütununda eğitim verisi oranı %30 iken en başarılı iki ağdan ResNet50'nin başarı oranı %97,54'den %97,72'ye, DenseNet201'in başarı oranı %97,32'den %97,53'e çıkmıştır. Söz konusu durumu yansıtan grafikler Şekil 25'de verilmiştir. BarkNet1.0 veri setinden elde edilen 18 tür ağacın 7200 görüntüsünün dikdörtgen ve kare formatlı iki

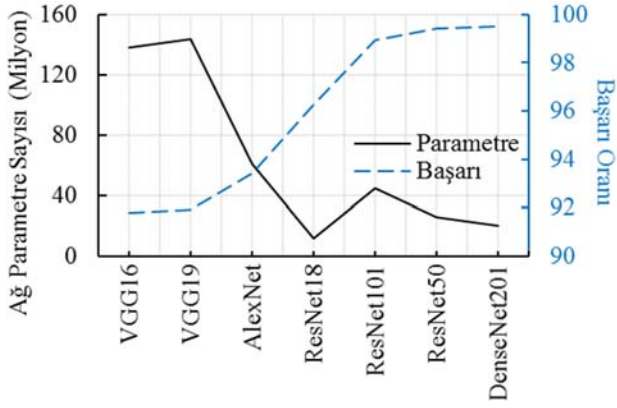
Tablo 7. ResNet50(Ağ1) ve DenseNet201(Ağ2) ağlarının 77 tür ağacı tanımlama başarı oranları
(77 species tree identification success rates of ResNet50 (Net1) and DenseNet201 (Net2) networks)

No	Ağaç Adı	Ağ1	Ağ2	No	Ağaç Adı	Ağ1	Ağ2	No	Ağaç Adı	Ağ1	Ağ2
01	Dişbudak	98,3	99,0	27	Kara Kavak	87,4	100	53	Atlas Sediri	98,9	98,6
02	Avrupa Ladini	84,0	94,9	28	Norveç Ladini	100	97,0	54	Nutka Servisi	96,0	96,0
03	At Kestanesi	96,6	97,0	29	Doğu Ladini	97,5	100	55	Mabet Ağacı	97,0	97,0
04	Alıç	91,6	94,9	30	Arizona Servisi	100	100	56	Gambel Meşe	95,0	95,0
05	Kokar Ağaç	99,2	100	31	Adi Huş	100	100	57	Büy. Yap. İhlamur	100	100
06	Yalancı Akasya	98,4	98,1	32	Batı Mazısı	98,3	99,0	58	Kiraz	99,3	99,5
07	Kanatlı Ceviz	99,5	100	33	Beyaz Dut	100	100	59	Porsuk Ağacı	100	100
08	Salkım Söğüt	100	97,0	34	Kara Dut	98,3	97,0	60	Sarı Huş	99,7	98,0
09	Ak Söğüt	96,6	100	35	İğde	95,0	96,0	61	Kâğıt Huşu	91,6	89,9
10	Japon Eriği	96,6	99,0	36	Sarıçam	98,5	98,4	62	Kır. Ame. Meşesi	100	100
11	Kır. Kral. Akç.	100	100	37	Doğu Çınarı	99,1	99,4	63	Ak Ladin	93,3	98,0
12	Lübnan Sediri	97,0	97,0	38	Katran Ardıcı	99,5	99,1	64	Kara Ladin	97,5	100
13	Batı Çınarı	100	100	39	Orman Elması	96,6	99,0	65	Kırmızı Ladin	100	92,9
14	Himalaya Sediri	97,5	97,0	40	Kayısı	84,9	89,9	66	Kırmızı Akçaağaç	92,4	92,9
15	Zeytin	95,4	95,7	41	Ayva	98,2	97,8	67	Şeker Akçaağacı	100	100
16	İncir	98,0	98,0	42	Avr. Armudu	94,0	94,1	68	Ame. Dişbudağı	100	100
17	Karaçam	97,5	94,9	43	Vişne	100	100	69	Ame. Kayın	100	99,0
18	Diş. Yap. Akç.	97,0	97,0	44	Saplı Meşe	98,6	93,0	70	Ame. Melezi	90,8	95,0
19	Mavi Ladin	96,6	99,0	45	Fıstık Çamı	98,0	98,9	71	Ame. Karaağacı	93,3	96,0
20	Mazı Meşesi	95,0	95,0	46	Şeftali	98,2	98,4	72	Ame. Kayacığı	99,2	98,0
21	Ceviz	100	99,0	47	Çınar Yap.Akç.	100	100	73	Ame. Titrek Kav.	99,2	100,0
22	Elma	100	100	48	Avrupa Eriği	97,3	96,9	74	Veymut Çamı	92,4	99,0
23	Yalancı Keçiboy.	100	100	49	Erik	94,0	94,0	75	Ame. Kızılcıamı	100	98,0
24	Boz Kavak	100	100	50	Sahil Çamı	100	100	76	Kanada Sugası	94,2	90,9
25	Ak Kavak	95,8	100	51	Akd, Servisi	97,5	98,0	77	Balsam Gökarnı	99,2	100
26	Kuzey Katalpa	95,8	100	52	Mahlep	98,0	98,2		Ortalama:	97,2	97,8

**Şekil 23.** Katman Sayısı-Ağ Doğruluk, Derinlik-Ağ Doğruluk grafikler
(Layer Number-Network Accuracy, Depth-Network Accuracy graphics)

veri seti kullanılarak AlexNet, ResNet50, DenseNet201 ve VGG19 ağları aynı parametrelerle eğitilmiş, eğitim sonucunda ağ başarısının Tablo 10'da görüleceği gibi birbirine oldukça yakın değerler elde edilmiştir. Bu sonuç

giriş verisinin geometrik şeklinin ağ başarısı için önemli olmadığını göstermektedir. Fakat bu durum bir sonraki çalışmada özgün ağ tasarımında giriş çözünürlüğünün yüksek olması durumunda tekrar ele alınacaktır.



Şekil 24. Ağ Parametre Sayısı-Ağ Başarı Oranı grafiği
(Network Parameter Number-Network Accuracy graphics)

Tablo 10. Diktörge, Kare veri setleri ağ başarı tablosu
(Rectangular, Square datasets network success table)

Veri Tipi	AlexNet	ResNet50	DenseNet201	VGG19
Dikdörtgen	91,63	98,47	98,34	86,75
Kare	91,22	98,67	98,26	86,82

4. SONUÇLAR (CONCLUSIONS)

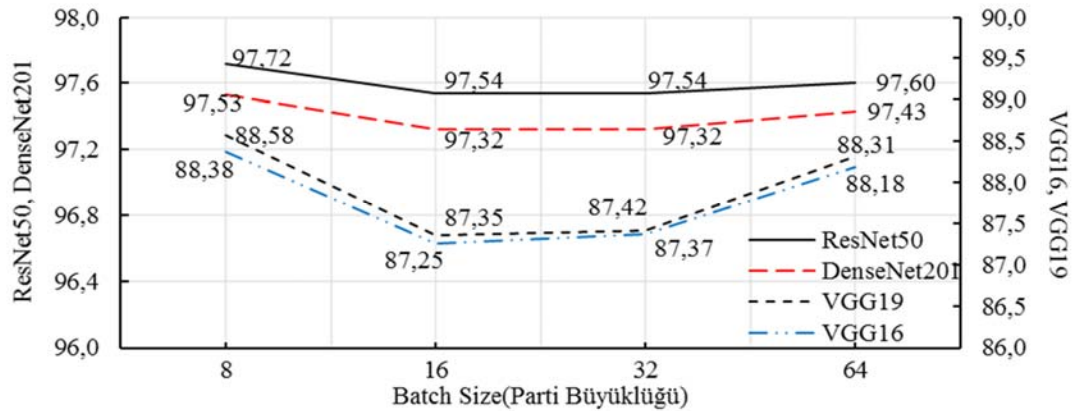
Bu çalışma ile önceden eğitilmiş ağlarda transfer öğrenmeyi kullanarak ağ başarı oranı ile yapılabileceği gösterilmiştir. Bu sonuç probleme, veriye ve ağa uygun transfer öğrenmesi yöntemi seçildiğinde önceden eğitilmiş ağların bu ve benzeri problemlerin çözümlerine katacakları yararları göstermesi açısından

Tablo 8. Görüntü sayısı 400, eğitim verisi oranı %70'iken, Katman-Derinlik-Başarı tablosu
(Number of images 400, training data ratio 70%, layer-depth-accuracy table)

Ağlar	Katman	Derinlik	Parametre Sayısı (Milyon)	Başarı
AlexNet	25	8	61	93,40
DenseNet201	709	201	20	99,51
ResNet18	72	18	11,7	96,25
ResNet50	177	50	25,6	99,42
ResNet101	347	101	44,6	98,92
VGG16	41	16	138	91,79
VGG19	47	19	144	91,93

Tablo 9. Parti Büyüklüğü-Ağ başarı tablosu (Batch Size- Network Accuracy table)

Parti Büyüklüğü-Ağ Başarı Tablosu					
Ağ Modeli	Batch Size (Parti Büyüklüğü)	59 Ağaçlık Veri Seti	Ağ Modeli	Batch Size (Parti Büyüklüğü)	59 Ağaçlık Veri Seti
ResNet50	8	97,72	VGG19	8	88,58
	16	97,54		16	87,35
	32	97,54		32	87,42
	64	97,60		64	88,31
DenseNet201	8	97,53	VGG16	8	88,38
	16	97,32		16	87,25
	32	97,32		32	87,37
	64	97,43		64	88,18



Şekil 25. Parti Büyüklüğü-Ağ Başarı grafiği (Batch Size-Network Accuracy graphics)

önemlidir. Gerek toplanan veriler gerekse başka veri setlerinden alınan verilerden oldukça yüksek başarı gösteren ve ileriye dönük iyi bir çözüm olduğunu ispatlayan bu görsel tür tanımlaması; ağaçların tanımlanmasında, ağaçların geleceğe taşınmasında, yaşamsal açıdan önemli ağaçların koruma altına alınmasında, orman kaynaklarının sürdürülebilir yönetim planlarının yapılmasında, botanik konusunda deneyimi olmayan kişilerin doğayı araştırmasında, meyvecilik sektöründe farklı ya da aynı sınıfın alt türlerinin belirlenmesinde, kereste/mobilya/kâğıt vb. sektörlerdeki ağaç kesim operasyonları ile ağaçların işleme süreçlerinde, ağaçların doğru ve verimli kullanılmasında yararlı olabilecek bir problem çözümüdür.

Çalışmanın ana amaçlarından biri olan ağaç kabuğu görüntülerinden ağaç türlerinin tanımlanmasında karşılaşılan veri kümesi eksikliği veya yetersizliğine oluşturulan veri setiyle katkıda bulunulmuştur. Fakat yeryüzünde ağaç sayısı ve buldukları ortam çeşitliliği düşünüldüğünde veri setini dahada büyütmek tek kişilik bir çalışmadan çok uzak olup bir ekip işi ve uzun yıllar sürecek çalışmalar ile olabilir. Bu amaçla Türkiye'yi kapsayan bir projeye ağaç tanımlanmasına katkıda bulunan bu çalışmanın geliştirilmesi ve veri tabanının büyütülerek kamuya açılması planlanmaktadır. Verilerin toplanması ve eğitim süreçlerinde ağın, görüntü sayısından çok veri setindeki görüntülerin toplandığı ağaç sayısına karşı çok daha duyarlı olduğu gözlenmiştir. Ağaç başına çok sayıda resim çekmek yerine, çok sayıda ağaçtan veri toplamanın ağ performansı açısından çok daha önemli olduğunu sonucuna varılmıştır. Ağaç sayısı ve ağaçların maruz kaldığı doğa şartlarını dikkate alarak görüntü sayısını çeşitlendirerek artırmak tanımlamanın güvenilirliğini daha da artıracak bir durumdur.

Önceden eğitilmiş ağlarda, ağaç türü sayısı arttıkça ve aynı sınıfa ait ağaçların desen benzerliğinden dolayı başarı oranının düşeceği öngörülmektedir. Ağ mimarisini ağaç kabuğu görüntülerinden ağaçların tanımlanması görevine, özellikle ağ girişini yüksek çözünürlükte görüntü alabilecek şekilde tasarlamak iyi bir yaklaşım olacağı sonucuna varılmıştır. Çalışmada kullanılan ağların katman sayısı ve derinliği arttıkça ağ başarı oranı artmıştır. Ağ parametre sayısı arttıkça ise başarı oranının düştüğü gözlenmiştir. Veri boyutunun ağ parametre sayısına göre çok küçük kalması bu sonucu doğurmuştur. Ayrıca parti büyüklüğünün ağ başarı oranını az da olsa etkilediği, ağaç kabuğu görüntüsünün geometrik şeklinin üzerinde çalışılan ağlarda sonucu çok etkilemediği gözlenmiştir. Bu sonuçlar transfer öğrenme yönteminin kullanıldığı problem çözümlerinde ağ seçiminde dikkat edilecek önemli hususlardır. Çalışmada kullanılan ağlar arasında tüm deneylerde yüksek performans gösteren ağlar ve çalışma esnasında kazanılan tecrübeler planlanan proje kapsamındaki yeni ağ tasarımında kullanılacaktır.

KAYNAKLAR (REFERENCES)

1. Fiel S. ve Sablatnig R., Automated identification of tree species from Images of the bark, leaves and needles, in

- Proceedings of 16th Computer Vision Winter Workshop, Mitterberg, Austria, 1-6, 2-4 Şubat, 2011.
2. Hellstrom T., Larkeryd P., Nordfjell T., Ringdahl O., Autonomous forest vehicles: Historic, envisioned, and state-of-the-art, *International Journal of Forest Engineering*, 20 (1), 31-38, 2009.
 3. He K., Zhang X., Ren S., Sun J., Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification, in *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 1026-1034, 2016.
 4. Beech E., Rivers M., Oldfield S., Smith P. P., GlobalTreeSearch: The first complete global database of tree species and country distributions, *Journal of Sustainable Forestry*, 36 (5), 454-489, 2017.
 5. Carpentier M., Giguère P., Gaudreault J., Tree species identification from bark images using convolutional neural networks, 2018 *IEEE/RISJ International Conference on Intelligent Robots and Systems (IROS)*, 1075-1081, 2018.
 6. Goëau H., Bonnet P., Joly A., Bakic V., Barthélémy D., Boujemaa N., Molino J.F., The imageCLEF 2013 plant identification task. *CLEF 2013 Working Notes*, Valencia-Spain, hal-00960929, 2013.
 7. Goëau H., Joly A., Bonnet P., Selmi S., Molino J.F., Barthélémy D., Boujemaa N., LifeCLEF plant identification task 2014. In *CLEF2014 Working Notes*, Sheffield-UK, 598-615, September 15-18, 2014.
 8. Lowe D. G., Object recognition from local scale-invariant features, *Proceedings of the seventh IEEE international conference on computer vision*, 1150-1157, 1999.
 9. Bay H., Tuytelaars T., Van Gool L., Surf: Speeded up robust features, In *Computer vision-ECCV 2006*, 404-417, Springer, 2006.
 10. Ojala T., Pietikainen M., Harwood D., A comparative study of texture measures with classification based on featured distributions, *Pattern Recognition*, 29 (1), 51-59, 1996.
 11. Goëau H., Bonnet P., Joly A., LifeCLEF plant identification task 2015, In *CLEF2015 Working Notes*, Toulouse-France, 2015.
 12. Šulc M., Mishkin D., Matas J., Very deep residual networks with maxout for plant identification in the wild, In *CLEF2016 Working Notes*, Portugal, 2016.
 13. Sunderhauf N., McCool C., Upcroft B., Tristan P., Fine-grained plant classification using convolutional neural networks for feature extraction, In *CLEF2014 Working Notes*, 756-762, 2014.
 14. Champ J., Lorieul T., Servajean M., Joly A., A comparative study of fine-grained classification methods in the context of the LifeCLEF plant identification challenge 2015, In *CLEF2015 Working Notes*, Toulouse-France, 2015.
 15. Goëau H., Bonnet P., Joly A., Plant identification based on noisy web data: the amazing performance of deep learning, In *CLEF2015 Working Notes*, Dublin-Ireland, 2017.

16. Huang Z.K., Quan Z.H., Du J.X., Bark classification based on contourlet filter features using RBPNN, In *Intelligent Computing*, 1121–1126, 2006.
17. Fiel S. ve Sablatnig R., Automated identification of tree species from images of the bark, leaves and needles, 16th Computer Vision Winter Workshop, Mitterberg-Austria, 67–74, 2011.
18. Sulc M. ve Matas J., Kernel-mapped histograms of multi-scale LBPs for tree bark recognition, 28th International Conference of Image and Vision Computing New Zealand (IVCNZ), Wellington-New Zealand, 82–87, 2013.
19. Boudra S., Yahiaoui I., Behloul A., A comparison of multi-scale local binary pattern variants for bark image retrieval, 16th International Conference on Advanced Concepts for Intelligent Vision Systems (ACIVS), Catania-Italy, 764–775, 2015.
20. Bressane A., Roveda J. A. F., Martins A. C. G., Statistical analysis of texture in trunk images for biometric identification of tree species, *Environmental Monitoring and Assessment*, 187 (212), 2015.
21. Othmani A. A., Jiang C., Lomenie N., Favreau J. M., Piboule A., Voon L. F. C. L. Y., A novel computer-aided tree species identification method based on burst wind segmentation of 3D bark textures, *Machine Vision and Applications*, 27 (5), 751–766, 2016.
22. Mizoguchi T., Ishii A., Nakamura H., Inoue T., Takamatsu H., Lidar-based individual tree species classification using convolutional neural network, *SPIE Optocal Metrology 2017 Videometrics Range Imaging and Applications*, 10332, 2017.
23. Carpentier M., Giguère P., Gaudreault J., Tree species identification from bark images using convolutional neural networks, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2018.
24. Arı A., Hanbay D., Tumor detection in MR images of regional convolutional neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3), 1395-1408, 2019.
25. Dandil E., Polattimur R., Dog Behavior Recognition and Tracking based on Faster R-CNN, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (2), 819-834, 2020.
26. Yıldız O., Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 2241-2260, 2019.
27. Bingöl K., Akan A. E., Örmecioğlu H. T., Er A., Artificial intelligence applications in earthquake resistant architectural design: Determination of irregular structural systems with deep learning and ImageAI method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (4), 2197-2209, 2020.
28. Aktaş A., Doğan B., Demir Ö., Tactile paving surface detection with deep learning methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (3), 1685-1700, 2020.
29. Lawrence S., Giles C. L., Tsoi A. C., Back A. D., Face recognition: A convolutional neural-network approach, *IEEE Transactions on Neural Networks*, 8 (1), 98-113, 1997.
30. <https://www.mathworks.com/help/deeplearning/ug/introduction-to-convolutional-neural-networks.html>, Yayın tarihi, 2019. Erişim tarihi Kasım 26, 2019.
31. Baykal E., Dogan H., Ercin M. E., Ersoz S. , Ekinci M., Transfer learning with pre-trained deep convolutional neural networks for serous cell classification, *Multimedia Tools and Applications*, 1-19, 2019.
32. Zhou Y., Nejati H., Do T. T., Cheung N. M., Cheah L., Image-based vehicle analysis using deep neural network: A systematic study, *IEEE international conference on digital signal processing*, 276-280, 2016.
33. Krizhevsky A., Sutskever I., Hinton G. E., ImageNet classification with deep convolutional neural networks, *NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems*, Nevada, 1097–1105, 2012.
34. Huang G., Liu Z., Maaten L. V. D., Weinberger K. Q., Densely connected convolutional networks, *IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 4700-4708, 2018.
35. He K., Zhang X., Ren S., Sun J., Deep Residual Learning for Image Recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 770-778, 2016.
36. Theckedath D., Sedamkar R. R., Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks, *Springer Nature Computer Science*, 79, 1-7, 2020.
37. Ye H., Han H., Zhu L., Duan Q., Vegetable pest image recognition method based on improved VGG convolution neural network, *Journal of Physics: Conference Series*, 1237 (3), 2019.
38. Pan S. J., Yang Q., A survey on transfer learning, *IEEE Transactions on Knowledge and Data Engineering*, 22 (10), 1345-1359, 2010.
39. <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>, Erişim tarihi Ekim 12, 2019
40. Chi Z., Houqiang L., Chao W., Plant species recognition based on bark patterns using novel Gabor filter banks, *International Conference on Neural Networks and Signal Processing*, Nanjing, 1035–1038, 2003.
41. Blanco L. J., Travieso C. M., Quinteiro J. M., Hernandez P. V., Dutta M. K., Singh A., A bark recognition algorithm for plant classification using a least square support vector machine, in *2016 Ninth International Conference on Contemporary Computing (IC3)*, Noida, 1–5, 2016.

