

## Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması

Ferdi DOĞAN; fdogan@adiyaman.edu.tr, Adıyaman Üniversitesi, Kâhta Meslek Yüksek Okulu, Adıyaman/Türkiye  
İbrahim TÜRKOĞLU; iturkoglu@firat.edu.tr, Fırat Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, Elazığ/Türkiye

Received 28 February 2018; Accepted 20 March 2018; Published online 2 April 2018

### Özet

*Bu makalede, bitki yapraklarının sınıflandırılması için kullanılan pek çok yönteme karşı derin öğrenme yoluyla sınıflandırılması yapılarak derin öğrenme algoritmalarının başarımları ortaya konulmuştur. Görüntü işleme yöntemleri ile yapılan sınıflandırma işlemlerinde ön işlem, özellik çıkarımı ve sınıflandırma yöntemi aracılığı ile sonuç alınmaktadır. Derin öğrenme yöntemlerinde yapılan işlemlerde bu gibi işlemlere ihtiyaç duyulmamaktadır. Derin öğrenme yöntemlerinde, ön işlem ve özellik çıkarım gibi aşamalar Konvolüsyonel Sinir Ağları aracılığı ile gerçekleştirilmektedir.*

*Bu çalışmada, yaprak örüntüsü olarak kullanılan veri tabanında, görüntü örnekleri 32 sınıftan oluşan yaklaşık 1900 görüntü vardır. Her bir görüntü sınıfı için ortalama 60 adet görüntü yer almaktadır. Burada yer alan görüntüler yansıma ve tersleme işlemleriyle 4 katına çıkarılmış yaklaşık olarak 7600 görüntü ile işlemler yapılmıştır.*

*Derin öğrenme yöntemlerinden ise AlexNet, Vgg16, Vgg19, ResNet50, GoogleNet gibi derin öğrenme algoritmaları kullanılmış her bir algoritma için yaprak sınıflandırma uygulaması yapılarak, başarımları değerlendirilmiştir.*

**Anahtar Kelimeler:** Derin Öğrenme, Evrimsel Sinir Ağları, Yaprak Sınıflandırma, Derin Öğrenme Algoritmaları.

## The Comparison Of Leaf Classification Performance Of Deep Learning Algorithms

### Abstract

*In this article, the achievements of deep learning algorithms have been put forward by classifying plant leaves through deep learning although there are many methods used for the classification of plant leaves. Results are obtained through pre-treatment, feature extraction and classification method in classification processes made with image processing methods. There is no need for such operations in deep learning methods. In deep learning methods, the steps such as pre-processing and feature extraction are performed through Convolution Neural Networks.*

*In this study, there are about 1900 images of 32 samples in the database used as leaf pattern. There is an average of 60 images for each image class. The images here have been increased 4 times by reflection and reversing operations and processes have been made with approximately 7600 images.*

*Deep learning algorithms such as AlexNet, Vgg16, Vgg19, ResNet50 and GoogleNet have been used for leaf classification applications for each algorithm and their performance has been evaluated.*

**Keywords:** Deep Learning, Convolutional Neural Networks, Leaf Classification, Deep Learning Algorithms.

### 1. Giriş

Bitkiler yaşadığımız dünya içerisinde yaşamın en önemli kaynaklarından. Bu kaynakların sağlıklı şekilde geleceğe taşınması yaşamsal faaliyetlerin önemi açısından elzem bir konudur. Özellikle bazı bitkilerin koruma altına alınarak yaşam döngüsü içerisinde yer alması gerekmektedir. Bu yaprakların tanınması insanoğlunun geleceği açısından önemlidir. Bitki yapraklarının sınıflandırılması bu noktada

önem arz etmektedir. (Kulkarni ve ark. 2013) Bitki yapraklarının şekil, kıvrım, boyut gibi pek çok özelliklerine bakılarak hangi sınıfa ait olduğu ortaya çıkar. Bu süreçte yaprağın biyolojik, fizyolojik yapılarının incelenmesi ve kimyasal bazı işlemlere tabi tutularak tanınması gerekebilir (Lee ve ark.2013). Bitkiyi tanımlayacak olan özellik ve şekillerin çıkarılması ve bitkiyi tanımlayıcı etkenlerin belirlenmesi gerekmektedir. Her bir sınıf için özellikler ayrıca belirlenmeli o sınıfı temsil edecek en öncelikli seçimler yapılmalıdır (Hu ve ark. 2012).

Bitki yapraklarının teşhisi işlemi her yaprağın ayrıca incelenmesi sonucunda ortaya çıkacaktır. Pek çok sınıfa ait bitki yapraklarının tek tek incelenerek sınıflandırılması zaman ve maliyet açısından uygun olmayan bir durumdur. Bunun için yaprak görüntülerinin alınarak bilgisayar ortamında otomatik olarak teşhis edilmesi ve sınıflandırılmanın yapılması zaman ve maliyet açısından oldukça kolaylık sağlayacaktır.

Bilgisayarlı görü işlemi sınıflandırma ve tanımlama işlemlerinde oldukça iyi sonuçlar vermektedir (Szegegy ve ark. 2017). Analiz ve teşhis işlemlerinin zaman ve maliyetinin yüksek olduğu ortamlarda sonuca daha hızlı ve kolay ulaşmayı sağlamaktadır. Bununla beraber doğruluk oranının yüksek olması bilgisayarlı görü sistemini güvenilir kılmaktadır. Yaprak sınıflandırma işlemi içinde bilgisayarlı görü sistemi kullanılmış ve oldukça iyi sonuçlar vermiştir (Szegegy ve ark. 2016). Bu sonuçlar sınıflandırmaya doğru bir yönelim sağlamıştır. Yaprak sınıflandırma ile ilgili yapılan pek çok çalışma yer almaktadır. Bu çalışmalarda çoğunlukla ön işlem, özellik çıkarımı ve sınıflandırma işlemi yapılmıştır. Farklı yaklaşımlarla yapılan özellik çıkarımlarında birbirine yakın sonuçlar elde edilmektedir. Bilhassa özellik çıkarım süreci ciddi bir iş olup zaman alan bir süreç olup sonraki aşamada yapay sinir ağları kullanarak yapraklar sınıflandırma işlemine tabi tutulmuş ve sonuçlar elde edilmiştir (Arribas ve ark. 2011; Belhumeur ve ark. 2008; Bama ve ark. 2011; Gu ve ark. 2005; Kumar ve ark. 2012; Wu ve ark. 2007; Lee ve ark 2006; Tzionas ve ark. 2005)

Yapılan bazı çalışmalarda; Genel amaçlı bir otomatik yaprak tanıma için görüntü ve veri işleme teknikleri ile olasılıksal sinir ağları (Probabilistic Neural Network-PNN) kullanılmıştır. 12 tip yaprak özelliklerini ortaya koyan özellik çıkarımı ve PNN giriş vektör grafiklerden 5 diklik değişkeni belirlenmiştir. 32 tür bitki sınıflandırmak için 1800 yaprak kullanılarak eğitilmiş ve 90 %'dan büyük bir doğruluk oranı elde edilmiştir (Wu ve ark. 2007). Bir başka çalışmada, Zernike momenti ile birleştirilen şekil, damar, renk, doku özelliklerini kullanarak bitkileri sınıflandırma-tanımlamak için bir çerçeve kullanılmıştır. Sınıflandırıcı olarak radyal temelli olasılıksal sinir ağı (Radial Basis Probabilistic Neural Network-RBPNN) kullanılmıştır. Radyal tabanlı sinir ağını eğitmek için sınıflandırıcı performansını artıran bir çift aşamalı eğitim algoritması kullanılmıştır. Flavia yaprak veri kümesindeki sınıflandırma işlemi sonucunda önerilen yöntemin %93,82'lik bir doğruluk oranı elde edilmiştir (Kulkarni ve ark. 2013). Yaprak tanımlama için bir mobil uygulama gerçekleştirilmiştir. Bu uygulamada görüntü yaprakları kamera aracılığı ile tek yaprak şekilde alınıp sonrasında 3 aşamada gerçekleştirilmektedir. Görüntü bölütleme, özellik çıkarımı ve tür tanıma olarak yapılmıştır (Zhao ve ark. 2015). Diğer bir çalışmada bitkilerin sınıflandırılması için yaprakların damarları ve şekilleri baz alınarak bir yöntem önerilmiştir. Bu yaklaşımda yaprak görüntüsünün kontur ve ağırlık mesafesi arasındaki mesafeyle Fast Fourier Dönüşümü (Fast Fourier Transform-FFT) kullanılarak ana damar ve frekans verileri yer almaktadır. 4 temel geometrik özellik ve 5 damar şekil özelliği kullanılarak morfolojik işlem yapılmıştır. 32 sınıfa ait 1907 adet yaprak görüntüsü kullanılarak %97,19 doğruluk oranı elde edilmiştir (Lee ve ark. 2013). Aimen Aakif ve arkadaşlarının yaptığı çalışmada meyve yaprakları 3 aşamada tanımlanıyor. Ön işlem, özellik çıkarımı ve sınıflandırma. Burada morfolojik işlemler uygulanarak özellik çıkarımı için fourier tanımlayıcılarından faydalanılmıştır. Daha sonra yapay sinir ağları kullanarak sınıflandırma işlemi yapılmıştır. 817 görüntü ile 14 sınıfa ait meyve yaprağı sınıflandırılmış ve %96 başarımla elde edilmiştir. Farklı yaprak veritabanları kullanılarak aynı başarımla elde edilmiştir (Aakif ve Khan 2015). Yaprak sınıflandırma için pek çok farklı yaklaşımlar mevcuttur. Her sınıflandırmada farklı özellik çıkarımları ve yöntemler kullanılmıştır. Geliştirilen yöntemlerle sınıflandırma başarımları artırılmaya çalışılmış ve sonuçların doğruluk oranları arttırılmaya çalışılmıştır (Wu ve ark. 2015; Kumar ve ark. 2016; Wang ve ark. 2016; Chaki ve ark. 2015). Ancak derin öğrenme ile yapılmış bir yaprak sınıflandırmaya rastlanmamıştır.

Derin öğrenme yapay sinir ağlarının ileri düzeyli bir yaklaşımıdır. Tek katmanlı yapay sinir ağlarından çok katmanlı yapay sinir ağlarına ve sonrasında derin öğrenme algoritmalarının oluşumuna doğru ilerlemiştir. Yapay sinir ağlarının temelini oluşturan insan beyin hücreleri matematiksel modeli; bilgisayarı görü, sinyal işleme, ses işleme, sınıflandırma, tanı, teşhis vb. gibi pek çok alanda kullanılmasına ön ayak olmuştur. Günümüz bilgi teknolojisinin ağır bastığı bir süreçte her türlü işlemlerin bilgisayar ortamında yapılması; zaman, maliyet ve iş gücü açısından önem taşımaktadır. Bu sürecin her aşamasında yapay sinir ağları kullanılır hale gelerek doğru sonuçlar vermiş ve kabul görmüştür. Pek çok büyük bilgi teknolojisi şirketleri yapay sinir ağları ile uğraşmakta ve geliştirdikleri yapay sinir ağı yapılarıyla entegre ürünler kullanmaktadır (Krizhevsky ve ark. 2012; LeCun ve ark. 2015; Goodfellow ve ark 2016).

Derin öğrenme algoritmaları Geoffrey Hinton ve Ruslan Salakhutdinov'un yayınladıkları makale ile ortaya atılmış (Hinton ve ark 2016) ve sonraki yıllarda pek çok derin öğrenme algoritmaları ortaya çıkmıştır (Goodfellow ve ark 2016). Derin öğrenme algoritmalarında oluşturulan çok katmanlı bir yapay sinir ağı yapısına mevcuttur. Bu çok katmanlı yapıda görüntüye ait özellik çıkarımları sinir ağı katmanları içerisinde oluşturulmaktadır. Katmanlı yapı öznelikleri gizli katmanda çıkararak ağırlık değerliklerini eğitim sürecinde ortaya çıkarmaktadır. Konvolüsyon işlemi ile görüntüye ait kenar ve özellikler belirlenmekte ağıdaki diğer katmanlar bu özellikleri alarak bir alt katmana iletmektedir. İlk katman girdi katmanı son katman ise sınıflandırma katmanı olarak bilinmektedir. Bu iki katman arasında yer alan ara katmandaki işlemlerde ise konvolüsyon, maxpooling, dropout, normalizasyon, Relu, Softmaxlayer, Fullconnectedlayer katmanları mevcuttur (Schmidhuber ve ark. 2015; Guo ve ark 2016).

Katmanlar içerisinde meydana gelen matematiksel yapılarda oldukça fazla veri işlenmektedir. Böyle yoğun bir işlem sürecinin olduğu derin öğrenme yapısında performansı yüksek bilgisayarlar kullanılmalıdır. Bir görüntü içerisinde yer alan RGB 3 kanallı matriste yer alan veriler her katmanda işlenmekte ve ağırlıklar tespit edilmektedir. Derin öğrenme algoritmaları içerisinde başarı oranının artırılması örnek sayısının çok olması ile ilişkilidir. Örnek sayısı arttıkça sonuçlarda daha iyi olduğu görülmektedir. Örnek sayısı arttıkça da veri seti de büyümektedir. Bu sebeple derin öğrenme içerisinde yapılan işlemler yüksek başarıma sahip bilgisayarlarda yapılmaktadır. Yüksek miktarda veri olması sebebiyle ağır eğitim süreci oldukça zaman almaktadır. Sadece işlemci destekli bir bilgisayarda bir ağın eğitim süreci günler hatta haftalar almaktadır. Ancak GPU (Graphics Processing Unit) kullanılması derin öğrenme ağının eğitim sürecini ciddi oranda kısaltmaktadır. Grafik işlemci bu işlemi çok daha hızlı yapmaktadır. Bu makalede, yaprak sınıflandırması için Alexnet, Vgg16, Vgg19, ResNet50, GoogleNet derin öğrenme algoritmaları kullanılarak yaprakların sınıflandırmada başarımları üzerinden karşılaştırılması yapılmıştır.

## 2. Derin Öğrenme Algoritmaları

Günümüz derin öğrenme algoritmalarının temeli insan beynindeki bir nöronun bilgisayar benzetmesi yapılmaya çalışılmasıyla ortaya çıkmış bir süreçtir. Donald Hebb'in sinir hücresinin sinir ağlarının yapısının incelenmesi ile başlamıştır. Daha sonra bilgisayar ortamında matematiksel olarak modelinin oluşturulması yapay sinir ağlarının çıkış noktası olarak bilinmektedir (Hebb ve ark 2005). Yapay sinir ağlarının ortaya çıkışı ve ilerleyiş süreci içerisinde yıllar geçmiş ve son yıllarda derin öğrenme terimi ortaya atılarak çalışmalar bu konu üzerinde yoğunlaşmıştır.


Derin öğrenme özellikle sınıflandırma, tanıma ve tespit için kullanılmaktadır (Deng ve Yu 2014). Yapılan çalışmalar bu yönde ağırlık kazanmıştır. Son zamanlarda derin öğrenme algoritmaları pek çok alanda kullanılmakta ve günlük yaşamımızda pek çok teknolojik yapı içerisinde kullanılmaktadır. Yüksek başarımların elde edilmesi bu konuya eğilimi artırmıştır. Yapılan pek çok sınıflandırma, tanıma çalışmaları mevcuttur.

Derin öğrenme mimarilerinde ağın eğitimi esnasında birkaç farklı öğrenme stratejisi bulunmaktadır. Bunlar öğretmenli öğrenme, öğretmensiz öğrenme ve takviyeli öğrenmedir. Öğretmenli öğrenmede ağın girişinde bulunan girdi verisinin çıkışta ne olduğu bilgisi verilir. Ağın ağırlıklar aynı verinin

tekrar tekrar ağı giriş verisi olarak sokularak ağın ağırlıklarının buna göre düzeltilmesi sağlanır. Böylelikle ağı eğitilerek ağırlıklar belirlenir (Makantasis ve ark. 2015). Öğretmensiz öğrenmede ise giriş verisinin çıkışta ne olduğu bilgisi verilmez. Ağı giren her veri çıkışta yakın bir kümeye ait bir değer alır. Böylelikle her veri çıkışta bir kümenin üyesi olur (Radford ve ark. 2015; Higgins ve ark. 2016). Takviyeli öğrenmede ise ağıda girdi verisinin çıkışta ne olduğu bilgisi verilmez. Çıkış sonucunda doğru ya da yanlış olduğu bilgisi verilir. Doğru ise 1 yanlış ise 0 değeri atanır. Buna göre ağı eğitimi gerçekleştirilir (Papernot ve ark. 2016).


Derin öğrenme yapısı konvolüsyonel sinir ağına ileri düzeyli bir yapısını temsil etmektedir. Konvolüsyon işlemi ile girdi verisine ait öznitelikler otomatik olarak çıkarılır ve sonraki katmanlara bu özniteliklerle gönderilir. Konvolüsyon işlemi bir görüntüde yer alan belirgin özellikleri çıkarır. Kenarlar kıvrımlar baskın noktalar ortaya çıkar. Çok katmanlı bir yapıya sahip olan derin öğrenme konvolüsyonel sinir ağında her katmanda ayrı bir işlem yürütülerek bir sonraki katmana veriler bırakılır. Her katman kendi işlevini yerine getirir. Derin öğrenme mimarilerinde yer alan katmanlar ve bu katmanların yapmış olduğu işlemler şunlardır.

**Konvolüsyon katmanı:** Konvolüsyon işlemi görüntü matrisi üzerinde 3x3, 5x5, 7x7, 9x9, 11x11 boyutundaki bir matrisin gezdirilmesi ile oluşur. Belirtilen küçük boyutlu matrisler tüm görüntü matrisi üzerinde dolaşarak görüntüdeki öznitelikleri belirginleştirir. Ve görüntü boyutunda yeni bir görüntü matrisi elde edilir (Liu ve ark. 2015). Buna örnek olarak Şekil 1’de bir örnek verilmiştir.




Şekil 1 Konvolüsyon işlemi. a) Görüntü Matrisi b) Filtre c) Filtre sonucunda oluşan yeni görüntü matrisi

**Havuzlama (Maxpool) Katmanı:** Havuzlama katmanı olarak bilinen bu katmanda genellikle konvolüsyon işlemi sonrasında olan bir katmandır (Castelluccio ve ark. 2015). Bu katmanda görüntüde tercihe göre NxN boyutundaki aralıkta bir matris tercih edilir. Bu boş matris görüntü matrisi içerisinde kaydırılarak matris içerisinde yer alan en büyük değeri alır ve yeni bir görüntü matrisin bir değerini oluşturur. 2x2 şeklindeki bir matris düşünülecek olursa şekil 2’de yer alan örnek değeri oluşturur. Yeni oluşan görüntü matrisi boyutu küçültülerek yeni görüntü matrisi oluşturulur. Böylelikle ağıdaki işlenen veri miktarı da düşürülmüş olur.




Şekil 2 Havuzlama işleminin gerçekleştirimi

**Tam Bağlı (Full-Connected) Katmanı:** Kendinden önce gelen katmandaki verileri bu katmanda tek boyutlu bir matris şeklinde yer alır. Nöronlar bu katmanda tam bağlı olarak yer alır. Her nöron kendinden sonra gelen nöronla bağlanır. Bu sebeple tam bağlı katman olarak bilinir (Adler ve ark. 2016). Bu katmandaki nöronların bağlantıları şekil 3’te görüntülenmektedir.




Şekil 3 Tam bağı katman

**Relu (Rectified Linear Unit) Katmanı:** Aktivasyon fonksiyonunun gerçekleştiği katman olarak yer alır. Bu katmanda elde edilen veriler aktivasyon fonksiyonuna tabi tutularak bir değer elde edilir. Bu katmanda kullanılacak olan pek çok aktivasyon fonksiyonu vardır. Bunlardan bazıları hiperbolik tanjant, sinüs, step, eşik değer fonksiyonları kullanılmaktadır. Derin öğrenme ağlarında kullanılan aktivasyon fonksiyonu genellikle  $f(x) = \max(0, x)$ 'dir (Yang ve ark. 2015). Şekil 4.



Şekil 4 Relu aktivasyon fonksiyonu

**Dropout Katmanı:** Derin öğrenme katmanlarında öğrenimi gerçekleştirilmiş bir ağda aşırı öğrenmeyi yani ezberlemeyi ortadan kaldırmak için kullanılan bir katmandır. Sinir ağı içerisinde aşırı öğrenmeyi oluşturan bazı bağlantıları ortadan kaldırma işlemi yapar. Böylelikle ağın ezber yapması engellenir. Ağın performansını artırır (Hinton ve ark. 2012; Xiao ve ark. 2016). Şekil 5'da normal bir yapay sinir ağı bağlantıları ve dropout uygulanmış ağ yapısı görülmektedir.




Şekil 5 Standart sinir ağı görünümü ve Dropout kullanılan sinir ağı görünümü

**Normalizasyon (Ölçeklendirme) Katmanı:** Derin Yapay sinir ağında ağın normalize edilmesi ağın performansını etkilemektedir. Katmanlardan elde edilen verileri düzenli hale getirmektedir. Katmana girdi olan veriler çok büyük ya da çok küçük değerler olabilir. Bu değerlerin normalize edilerek belirli bir aralıkta temsil edilmesi daha sağlıklı olacaktır. Böylelikle hem ağın performansı hem de girdi verilerin ölçeklenerek belirli bir aralıkta temsil edilmesi sağlanır (Ioffe ve Szegedy 2015).

**Entropi (Softmax) Katmanı:** Önceki katmandan gelen değerleri alarak sınıflandırma işlemi içerisinde olasılıksal değer üretimi gerçekleştirir. Sınıflandırma yaparken hangi sınıfa daha yakın olduğuna dair değer üretir. Derin öğrenme ağı içerisinde katmanda üretilen olasılıksal değeri probalistik hesaplama gerçekleştirerek her bir sınıf için olasılık değeri ortaya koyar (Tang 2013). Bu hesaplama yapılırken cross entropy kullanır.


Derin konvolüsyon katmanları arasındaki bağlantılar ve sınıflandırma için yapılacak olan mimari genel olarak Şekil 6'da yer almaktadır.



Şekil 6 Derin Konvolüsyon sinir ağı mimarisi

## 2.1 AlexNet

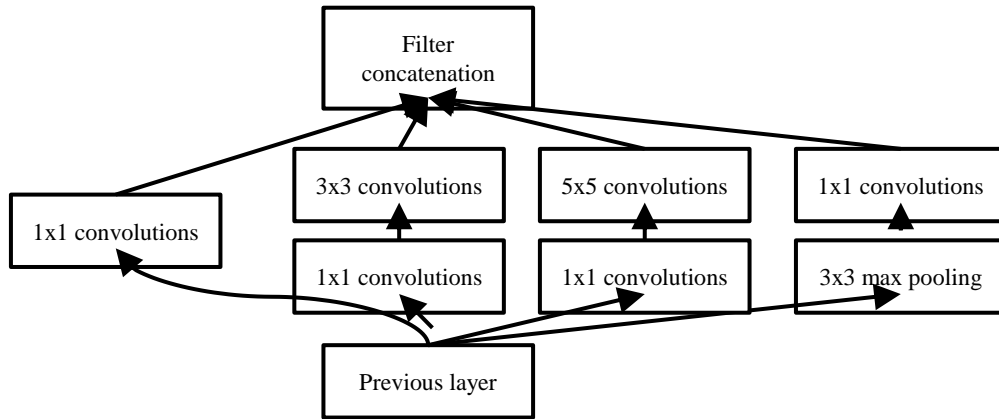
Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından ortaya atılan bir derin öğrenme algoritmasıdır (Krizhevsky ve ark. 2012). 25 katmandan oluşan bu derin konvolüsyonel sinir ağında 5 adet konvolüsyon katmanı, 3 adet maxpool katmanı, 2 adet dropout katmanı, 3 adet tam bağlı katman, 7 adet relu katmanı, 2 adet normalizasyon katmanı, softmax katmanı, giriş ve sınıflandırma(çıkış) katmanında oluşmaktadır. Giriş katmanında yer alacak olan görüntü  $227 \times 227 \times 3$  boyutlarındadır. Son katmanda ise sınıflandırma yapılarak giriş görüntüsündeki sınıflandırma sayısı değeri verilir. Şekil 7'de AlexNet'e ait katmanlar gösterilmektedir. ImageNet veritabanında doğruluk oranı %80 olarak yakalamış bir derin öğrenme algoritmasıdır.



Şekil 8 AlexNet derin öğrenme algoritması


## 2.2 GoogleNet

ImageNet veritabanında %93 doğruluk oranında yüksek bir başarımla elde edilmiş derin öğrenme algoritmasıdır. Vgg derin öğrenme algoritmasından daha hızlı olduğu görülmektedir. Alexnet'ten 12 kat daha fazla parametre içermektedir. Havuzlama katmanları da dahil 27 katman derinliğe sahiptir. Mimari yapısı içerisinde yaklaşık 100 katmandan oluşmaktadır. GoogleNet algoritmasında konvolüsyon, maxpooling, softmaxlayer, fullconnected layer, relulayer, giriş katmanı ve çıkış katmanı gibi 144 katman bulunmaktadır. Girdi katmanında yer alacak görüntü  $224 \times 224 \times 3$  boyutundadır. Konvolüsyon katmanında  $1 \times 1$ ,  $3 \times 3$  ve  $5 \times 5$  boyutunda filtreler kullanılmaktadır.  $3 \times 3$  boyutunda havuzlama kullanılmaktadır. Aktivasyon için doğrusal aktivasyon kullanılmaktadır (Szegedy ve ark. 2015). Kullanılan filtre yapıları şekil 9'da görülmektedir.



Şekil 9 GoogleNet'te kullanılan filtre ve boyut küçültme yapıları

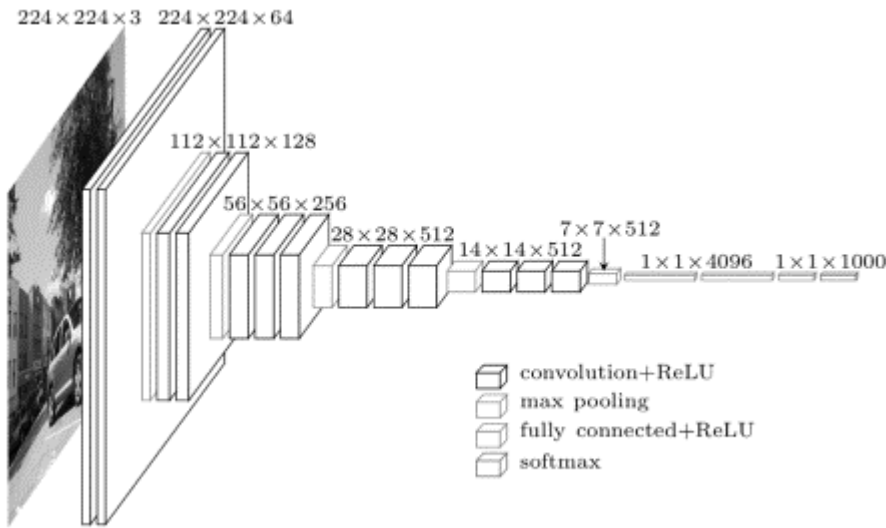
GoogleNet'e ait katmansal yapı Şekil 10'da görülmektedir.



Şekil 10 GoogleNet derin öğrenme algoritması

### 2.3 Vgg16

Vgg16 derin öğrenme algoritması Oxford üniversitesi Görsel Geometri Grubu tarafından ILSVRC-2014 yarışmasında daha iyi sonuçlar elde etmek için kullanılan 13 konvolüsyon 3 tam bağlı katmanından oluşan bir ağıdır. Maxpool, Fullconnectedlayer, Relulayer, Dropoutlayer ve Softmaxlayer katmanlarıyla birlikte toplamda 41 katman yer almaktadır. Girdi katmanında yer alacak görüntü  $224 \times 224 \times 3$  boyutundadır. Son katman ise sınıflandırma katmanıdır. ImageNet veritabanında %89 doğruluk yakalamış bir derin öğrenme algoritmasıdır (Chen ve ark. 2016; Simonyan ve Zisserman 2014). Şekil 11'de VGG derin öğrenme algoritması örneği yer almaktadır.



Şekil 11 Vgg16 ve Vgg19 derin öğrenme mimarisi görünümü


### 2.4 Vgg19

Vgg19 derin öğrenme algoritması Oxford üniversitesi Görsel Geometri Grubu tarafından Vgg16 algoritmasının akabinde oluşturulan 16 konvolüsyon 3 tam bağlı katmanlı bir ağıdır. Maxpool, Fullconnectedlayer, Relulayer, Dropoutlayer ve Softmaxlayer katmanlarıyla birlikte toplamda 47 katman yer almaktadır. Vgg16'da olduğu gibi giriş katmanı  $224 \times 224 \times 3$  boyutundadır. Son katman ise sınıflandırma katmanıdır. ImageNet veritabanında %88 doğruluk yakalamış bir derin öğrenme algoritmasıdır (Simonyan ve Zisserman 2014; He ve ark. 2014). Şekil 11'de VGG derin öğrenme algoritması örneği yer almaktadır.

### 2.5 ResNet50

VggNet, AlexNet gibi geleneksel ardışık ağ mimarisinden farklı bir yapıya sahiptir. Resnet mikro mimari modülü yapısı ile diğer mimarilerden ayrışır. Bazı katmanlar arasındaki değişim gözardı edilerek alt katmana geçiş işlemi yapılması tercih edilebilir. Resnet mimarisinde bu duruma izin

verilerek başarımları daha üst seviyelere çıkarılmıştır. Resnet50 mimarisinde 177 katmandan oluşan bir ağ yer almaktadır. Bu katmansal yapıya ek olarak katmanlar arası bağlantıların nasıl olacağı hakkında bilgi mevcuttur (He ve ark. 2016). Giriş katmanı  $224 \times 224 \times 3$  boyutundadır. Şekil 12’de Resnet mimarisinde kullanılan bağlantı örneği görülmektedir.




Şekil 12 ResNet bağlantı örneği.

### 3. Yaprak Görüntülerinin Sınıflandırılması

Bitki yaprakları sınıflandırılması için UCI-Machine Learning Repository veritabanı kullanılmıştır (Silva ve ark. 2013). Bu veritabanında 32 sınıftan oluşan ve her sınıfta yaklaşık olarak 60 adet yaprak görüntüsü bulunmaktadır. Derin öğrenme algoritmalarında örnek sayısının çok olması başarımları etkilediğinden her sınıftaki yaprak görüntüleri tersleme ve yansıma yapılarak 4 katna çıkarılmıştır. Her sınıfta ortalama 240 adet görüntü olacak şekilde çoğaltılmıştır. Toplamda 7628 yaprak görüntüsü kullanılmıştır. Yaprak görüntüleri  $1600 \times 1200$  olmasına karşın derin öğrenme algoritmalarında kullanılmak için  $224 \times 224$  ve  $227 \times 227$  boyutlarına indirgenmiştir. Kullanılan bilgisayar sisteminde; i7 2.8ghz işlemci, Gtx 960m 6GB GPU kartı ve 24GB RAM özelliklerine sahip donanım bulunmaktadır. Bu görüntülerin %80 eğitim için %20 ise test için kullanılmıştır. Eğitim ve test görüntüleri rasgele olarak seçilmiştir. 6101 adet eğitim için 1527 adet test için kullanılmıştır. Uygulama için Matlab derin öğrenme algoritmalarından faydalanılmıştır. Sınıflandırma için öğretmenli öğrenme yapısı kullanılmıştır. Yaprak sınıflandırma için kullanılan sınıflar ve bunlara ait örnek görüntüler Şekil 13’de görülmektedir.








Şekil 13. Sınıflandırma yapılan UCI veri seti görüntüleri

Bitki yapraklarının sınıflandırılması için AlexNet, GoogleNet, Vgg16, Vgg19 ve ResNet50 derin öğrenme algoritmaları kullanılmıştır. Gerçekleşen konvolüsyon sonucunda yaprak sınıflarının oluşan filtreli görüntüleri şekil 14’te görülmektedir.



Şekil 14 Oluşan filtre ve görüntü örnekleri

Yukarıda yer alan filtre sonucu oluşan görüntü örneği AlexNet derin konvolüsyon ağına aittir. Her derin öğrenme mimarisine ait filtre yapısı birbirinden farklı görüntüler vermektedir. Derin öğrenme algoritmalarında kullanılan iterasyon sayısı düşük tutulmuştur. İterasyon sayısı arttıkça eğitim süreci uzamakta ve çok daha zaman almaktadır. GPU destekli her eğitim süreci 1-3 arası saat sürerken CPU kullanılarak yapılan eğitim süreci 24 saatten fazla olduğu görülmüştür.

#### 4. Sonuçlar

5 farklı derin öğrenme ile gerçekleştirilen yaprak sınıflandırma çalışmasında yüksek doğruluk oranları elde edilmiştir. Genel olarak her derin öğrenme algoritması başarılı bir görüntü çizmiştir. 32 sınıftan oluşan UCI yaprak veritabanı kullanılarak derin öğrenme algoritmaları ile aşağıdaki tabloda yer alan doğruluk oranları elde edilmiştir. İterasyon sayısının artması ile birlikte bu doğruluk oranlarında kısmi değişiklikler olduğu görülmüştür. Derin öğrenme algoritmaları ve başarımları tablo 1’de yer almaktadır.

Tablo 1 Derin öğrenme algoritmaları ile bitki yapraklarının sınıflandırılması başarımları.

Kullanılan Algoritma	Katman Sayısı	Eğitim Görüntü Sayısı	Test Görüntü Sayısı	Toplam Görüntü Sayısı	Doğruluk Oranı
AlexNet	25	6101	1527	7628	%99,72
GoogleNet	144	6101	1527	7628	%97,77

Vgg16	41	6101	1527	7628	%99,12
Vgg19	47	6101	1527	7628	%98,36
ResNet50	177	6101	1527	7628	%99,15

Bitki yapraklarının sınıflandırması işlemlerinde farklı yöntemler kullanılarak sınıflandırma başarımının artırılması üzerine ciddi çalışmalar yapılmıştır. Her çalışmada farklı bir yaklaşım öne sürülmüş başarımlar artırılmıştır. Bu çalışmaların hemen hepsinde ön işlem, özellik çıkarımı için farklı yöntemler ve metotlar, daha sonrasında ise yapay sinir ağları kullanılmıştır. Bu süreçlerin her biri hem zaman açısından hem de iş yükü açısından oldukça zordur. Bununla birlikte elde edilen %90 üzeri başarımlar literature kazandırılmış çok önemli çalışmalar olarak görülmektedir. Yapılan pek çok çalışma bu oranın %88-%97 arasında olduğunu göstermektedir. Derin öğrenme algoritmaları ile yapılan sınıflandırma işlemleri pek çok yöntemden daha iyi sonuçlar ortaya koymuştur. Tablo'2 de verilen başarımlar oranlarına bakılacak olursa %97,77-%99,72 aralığında yüksek başarımlar elde ettiği görülecektir. Yaptığımız çalışmada konvolüsyonel derin öğrenme ağında yer alan iterasyon sayısının düşük tutulması sebebiyle bu oranlar elde edilmiştir. Iterasyon sayısı makul düzeyde artırılarak bu oranların %100'e daha da yaklaşacağı tahmin edilmektedir.

Derin öğrenme ağlarında ön işlem ve özellik çıkarımı için farklı yöntemler yer almadığından sınıflandırma işleminde bu safhalar kullanılmamıştır. Bu da zaman ve iş yükü açısından derin öğrenme algoritmalarını daha üstün kılmaktadır. Hem başarımlar oranlarının yüksek olması hemde kullanılan algoritmik yapısı itibarıyla diğer yaklaşımlardan çok daha iyi sonuçlar vermektedir. Sınıflandırma işlemlerinde derin öğrenme algoritmalarının kullanılması doğru bir seçim olacaktır.

## References

- Aakif, A., & Khan, M. F. (2015). Automatic classification of plants based on their leaves. *Biosystems Engineering*, 139, 66-75.
- Adler, A., Elad, M., & Zibulevsky, M. (2016). Compressed Learning: A Deep Neural Network Approach. *arXiv preprint arXiv:1610.09615*.
- Arribas, J. I., Sánchez-Ferrero, G. V., Ruiz-Ruiz, G., & Gómez-Gil, J. (2011). Leaf classification in sunflower crops by computer vision and neural networks. *Computers and Electronics in Agriculture*, 78(1), 9-18.
- Bama, B. S., Valli, S. M., Raju, S., & Kumar, V. A. (2011). Content based leaf image retrieval (CBLIR) using shape, color and texture features. *Indian Journal of Computer Science and Engineering*, 2(2), 202-211.
- Belhumeur, P. N., Chen, D., Feiner, S., Jacobs, D. W., Kress, W. J., Ling, H., ... & Zhang, L. (2008, October). Searching the world's herbaria: A system for visual identification of plant species. In *European Conference on Computer Vision* (pp. 116-129). Springer, Berlin, Heidelberg.
- Castelluccio, M., Poggi, G., Sansone, C., & Verdoliva, L. (2015). Land use classification in remote sensing images by convolutional neural networks. *arXiv preprint arXiv:1508.00092*.
- Chaki, J., Parekh, R., & Bhattacharya, S. (2015). Plant leaf recognition using texture and shape features with neural classifiers. *Pattern Recognition Letters*, 58, 61-68.
- Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2016). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *arXiv preprint arXiv:1606.00915*.
- Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and Trends® in Signal Processing*, 7(3-4), 197-387.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1). Cambridge: MIT press.

- Gu, X., Du, J. X., & Wang, X. F. (2005, August). Leaf recognition based on the combination of wavelet transform and gaussian interpolation. In *International Conference on Intelligent Computing* (pp. 253-262). Springer, Berlin, Heidelberg.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27-48.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision* (pp. 1026-1034).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Hebb, D. O. (2005). *The organization of behavior: A neuropsychological theory*. Psychology Press.
- Higgins, I., Matthey, L., Glorot, X., Pal, A., Uria, B., Blundell, C., ... & Lerchner, A. (2016). Early visual concept learning with unsupervised deep learning. *arXiv preprint arXiv:1606.05579*.
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.
- Hu, R., Jia, W., Ling, H., & Huang, D. (2012). Multiscale distance matrix for fast plant leaf recognition. *IEEE Transactions on Image Processing*, 21(11), 4667-4672.
- Ioffe, S., & Szegedy, C. (2015, June). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning* (pp. 448-456).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- Kulkarni, A. H., Rai, H. M., Jahagirdar, K. A., & Upparamani, P. S. (2013). A leaf recognition technique for plant classification using RBPNN and Zernike moments. *International Journal of Advanced Research in Computer and Communication Engineering*, 2(1), 984-988.
- Kulkarni, A. H., Rai, H. M., Jahagirdar, K. A., & Upparamani, P. S. (2013). A leaf recognition technique for plant classification using RBPNN and Zernike moments. *International Journal of Advanced Research in Computer and Communication Engineering*, 2(1), 984-988.
- Kumar, N., Belhumeur, P. N., Biswas, A., Jacobs, D. W., Kress, W. J., Lopez, I. C., & Soares, J. V. (2012). Leafsnap: A computer vision system for automatic plant species identification. In *Computer vision—ECCV 2012* (pp. 502-516). Springer, Berlin, Heidelberg.
- Kumar, P. S., Rao, K. N. V., Raju, A. S. N., & Kumar, D. N. (2016, December). Leaf classification based on Shape and Edge feature with k-NN Classifier. In *Contemporary Computing and Informatics (IC3I), 2016 2nd International Conference on* (pp. 548-552). IEEE.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436.
- Lee, C. L., & Chen, S. Y. (2006). Classification of leaf images. *International Journal of Imaging Systems and Technology*, 16(1), 15-23.
- Lee, K. B., & Hong, K. S. (2013). An implementation of leaf recognition system using leaf vein and shape. *International Journal of Bio-Science and Bio-Technology*, 5(2), 57-66.
- Liu, L., Shen, C., & van den Hengel, A. (2015). The treasure beneath convolutional layers: Cross-convolutional-layer pooling for image classification. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4749-4757).

- Makantasis, K., Karantzalos, K., Doulamis, A., & Doulamis, N. (2015, July). Deep supervised learning for hyperspectral data classification through convolutional neural networks. In *Geoscience and Remote Sensing Symposium (IGARSS), 2015 IEEE International* (pp. 4959-4962). IEEE.
- Papernot, N., Abadi, M., Erlingsson, U., Goodfellow, I., & Talwar, K. (2016). Semi-supervised knowledge transfer for deep learning from private training data. *arXiv preprint arXiv:1610.05755*.
- Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Silva, P. F., Marcal, A. R., & da Silva, R. M. A. (2013, June). Evaluation of features for leaf discrimination. In *International Conference Image Analysis and Recognition* (pp. 197-204). Springer, Berlin, Heidelberg.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. (2017, February). Inception-v4, inception-resnet and the impact of residual connections on learning. In *AAAI* (Vol. 4, p. 12).
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015, June). Going deeper with convolutions. *Cvpr*.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2818-2826).
- Tang, Y. (2013). Deep learning using linear support vector machines. *arXiv preprint arXiv:1306.0239*.
- Tzionas, P., Papadakis, S. E., & Manolakis, D. (2005, October). Plant leaves classification based on morphological features and a fuzzy surface selection technique. In *Fifth International Conference on Technology and Automation, Thessaloniki, Greece* (pp. 365-370).
- Wang, Z., Sun, X., Zhang, Y., Ying, Z., & Ma, Y. (2016). Leaf recognition based on PCNN. *Neural Computing and Applications*, 27(4), 899-908.
- Wu, S. G., Bao, F. S., Xu, E. Y., Wang, Y. X., Chang, Y. F., & Xiang, Q. L. (2007, December). A leaf recognition algorithm for plant classification using probabilistic neural network. In *Signal Processing and Information Technology, 2007 IEEE International Symposium on* (pp. 11-16). IEEE.
- Wu, Y. J., Tsai, C. M., & Shih, F. (2016). Improving Leaf Classification Rate via Background Removal and ROI Extraction. *Journal of Image and Graphics*, 4(2).
- Xiao, T., Li, H., Ouyang, W., & Wang, X. (2016, June). Learning deep feature representations with domain guided dropout for person re-identification. In *Computer Vision and Pattern Recognition (CVPR), 2016 IEEE Conference on* (pp. 1249-1258). IEEE.
- Yang, J., Nguyen, M. N., San, P. P., Li, X., & Krishnaswamy, S. (2015, July). Deep Convolutional Neural Networks on Multichannel Time Series for Human Activity Recognition. In *IJCAI* (pp. 3995-4001).
- Zhao, Z. Q., Ma, L. H., Cheung, Y. M., Wu, X., Tang, Y., & Chen, C. L. P. (2015). ApLeaf: An efficient android-based plant leaf identification system. *Neurocomputing*, 151, 1112-1119.