



**İSKENDERUN TEKNİK**

ÜNİVERSİTESİ

MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK  
LİSANS  
TEZİ**

**EVRIŞİMLİ SINIR AĞI  
KULLANILARAK YAPRAK  
RESİMLERİNİN  
SINIFLANDIRILMASI**

**Yunus CAMGÖZLÜ**

BİLGİSAYAR MÜHENDİSLİĞİ  
ANABİLİM DALI

ŞUBAT 2021



**EVRIŞİMLİ SİNİR AĞI KULLANILARAK YAPRAK RESİMLERİNİN  
SINIFLANDIRILMASI**

**Yunus CAMGÖZLÜ**

**YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ  
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

**Şubat 2021**

Yunus CAMGÖZLÜ tarafından hazırlanan “EVRIŞİMLİ SİNİR AĞI KULLANILARAK YAPRAK RESİMLERİNİN SINIFLANDIRILMASI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

**Danışman:** Doç. Dr. Yakup Kutlu

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.

.....  
.....

**Başkan:** Prof. Dr. Serdar Yıldırım

Bilgisayar Mühendisliği Anabilim Dalı, Alparslan Türkeş Bilim ve Teknoloji Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.

.....  
.....

**Üye:** Doç. Dr. Yakup Kutlu

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.

.....  
.....

**Üye:** Doç. Dr. Sertan Alkan

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.

.....  
.....

Tez Savunma Tarihi: 22 / 01 / 2021

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ersin BAHÇECİ

Mühendislik ve Fen Bilimleri Enstitüsü Müdürü

## ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülediğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
  - Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
  - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
  - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
  - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
  - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Yunus CAMGÖZLÜ

22 / 01 / 2021

EVRIŞİMLİ SINIR AĞI KULLANILARAK YAPRAK RESİMLERİNİN  
SINIFLANDIRILMASI  
(Yüksek Lisans Tezi)

Yunus CAMGÖZLÜ

İSKENDERUN TEKNİK ÜNİVERSİTESİ  
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Şubat 2021

ÖZET

Çevremizde bulunan birçok bitki hakkında bilgi sahibi değiliz, yararları ve zararları konusunda halk arasındaki bilgilerle hareket etmekteyiz. Bu gibi durumlarda zehirli olmasına rağmen şifalı olarak bilinen bitkilerin yanlış kullanılması ölüme kadar gidebilecek pek çok soruna yol açmaktadır. Bu gibi durumlarda bitkilerin tanınması uzmanlık gerektirmektedir. Bu sorun gelişen teknoloji ile uzmanlık gerektirmeden giderilebilecek bir eksikliklerdir. Bu sebeple yaprak resimleri üzerinde yapay zeka teknikleri kullanılarak hazır bir sistem oluşturulması amaçlanmıştır. Yapay zeka teknolojilerinin ön planda olduğu bugünlerde, bu alanda pek çok yöntem kullanılmaktadır. Bu yöntemlerden biri derin öğrenmedir. Çoğu alanda derin öğrenme yöntemlerinin uygulandığını söyleyebiliriz. Yüz tanıma, ses tanıma, otonom araçlar, siber tehdit analizleri, sağlık sektörü gibi alanlardır. Bu yöntem kullanılırken tanımlama, sınıflandırma, tahmin etme gibi pek çok amaca hizmet eder. Derin öğrenme algoritmalarından biri olan evrişimsel sinir ağı girdi olarak aldığı verilerle özellikleri öğrenerek, bu özellikler yardımıyla istenilen sonucu elde eder. Literatürde farklı öznelik çıkarım yöntemleri kullanılarak elde edilen verilerin farklı sınıflandırma yöntemleri ile kullanıldığı görülmektedir. Oluşturulan evrişimli sinir ağı modellerinden veya önceden eğitilmiş modellerden çıkarılan özneliklerin farklı sınıflandırma yöntemleri ile kullanılması gibi yaklaşımlar bulunmaktadır. Bu tez çalışmasında, farklı sayıda yaprak görüntülerinden oluşan veri setleri kullanılmıştır. Tüm resimleri içeren 270 farklı türden oluşan tek bir büyük veri seti oluşturulmuş ve bu veri setine özel yeni bir evrişimli sinir ağı modeli eğitilerek sonuçları incelenmiştir. Renkli veya gri resim farkı, arka plan renginin etkisi, farklı görüntü boyutu ve filtre boyutu gibi değişikliklerin başarıma etkisi incelenerek iyileştirme çalışmaları yapılmıştır. Bu çalışmalar sonucu elde edilen verilerle oluşturulan modelin yapısı ve bu modelin eğitiminde kullanılacak verilerin durumu belirlenmiştir. Oluşturulan evrişimli sinir ağı modeli kullanılarak yaprak sınıflandırılması yapılmıştır, ayrıca bu model kullanılarak öznelik öğrenimi yaklaşımı ile öznelik dönüşümü gerçekleştirilmiş ve farklı sınıflandırma yöntemleri ile başarımları incelenmiştir. Veri setinin büyüklüğü sonucu eğitim için gerekli güçlü donanım ihtiyacı sebebiyle eğitim ihtiyacı olmayan önceden eğitilmiş modellerin kullanılması ve sonuçların karşılaştırılması sağlanmıştır. Bu amaçla belirlenen 4 farklı önceden eğitilmiş modelden öznelikler çıkarılarak aynı sınıflandırma yöntemleri ile sınıflandırılmıştır. Yapılan sınıflandırma işlemleri sonucu elde edilen veriler değerlendirilerek düşük işlem gücüne sahip donanımlarda en iyi sonucun elde edilebileceği bir yaklaşımın belirlendiği ve 270 türe sahip veri seti için %89 eğitim, %86 oranında test başarımları sağlanmıştır.

Anahtar Kelimeler : Bölütleme, Derin Öğrenme, Derin ConvNets, Yapay Görme

Sayfa Adedi : 70

Danışman : Doç. Dr. Yakup KUTLU

CLASSIFICATION OF LEAF IMAGES USING CONVOLUTIONAL NEURAL NETWORK  
(M. Sc. Thesis)

Yunus CAMGÖZLÜ

ISKENDERUN TECHNICAL UNIVERSITY  
ENGINEERING AND SCIENCE INSTITUTE

February 2021

ABSTRACT

We do not have information about many plants around us, we act with the information among the people about their benefits and harms. In such cases, the wrong use of herbs known as medicinal, although toxic, causes many problems that can lead to death. In such cases, expertise is required to identify plants. This problem is a deficiency that can be eliminated with developing technology without requiring expertise. For this reason, it is aimed to create a ready system using artificial intelligence techniques on leaf images. Nowadays, where artificial intelligence technologies are at the forefront, many methods are used in this field. One of these methods is deep learning. We can say that deep learning methods are used in most areas. Areas such as face recognition, voice recognition, autonomous vehicles, cyber threat analysis, healthcare. While using this method, it serves many purposes such as definition, classification, and prediction. Convolutional neural network, one of the deep learning algorithms, learns the features with the data it receives as input and obtains the desired result with the help of these features. It is seen in the literature that the data obtained by using different feature extraction methods are used with different classification methods. There are approaches such as using the features extracted from the created convolutional neural network models or pre-trained models with different classification methods. In this thesis, data sets consisting of different numbers of leaf images were used. A single large data set consisting of 270 different species including all images was created and a new convolutional neural network model specific to this data set was trained and the results were examined. Improvement studies have been carried out by examining the effect of changes such as color or gray image difference, effect of background color, different image size and filter size. The structure of the model created with the data obtained as a result of these studies and the status of the data to be used in the training of this model were determined. Leaf classification has been made using the convolutional neural network model. Also, using this model, feature transformation has been performed with the approach of feature learning and its performance has been investigated with different classification methods. As a result of the size of the data set, it was ensured that pre-trained models that do not need training due to the need for powerful equipment for using and the results were compared. For this purpose, features were extracted from 4 different pre-trained models and classified with the same classification methods. By evaluating the data obtained as a result of the classification process, an approach to achieve the best result in hardware with low processing power was determined and 89% training, 86% test performance were achieved for the data set with 270 species.

KeyWords : Segmentation, Deep Learning, Deep ConvNets, Artificial Vision  
PageNumber : 70  
Supervisor : Doç. Dr. Yakup KUTLU

## TEŐEKKÜR

Yıllardır danışmanlığımı, akıl hocalığımyı yapan ve her zaman daha fazlasını kovalamamı sađlayan Doç. Dr. Yakup Kutlu hocama, yıllarca çeřitli sebeplerle bilgi ve deneyimlerine ihtiyaç duyduğum Bilgisayar Mühendisliđi bölüm hocalarıma, her zaman yanımda olan aileme bana verdikleri desteklerinden dolayı teşekkür ederim.



## İÇİNDEKİLER

	<b>Sayfa</b>
ÖZET .....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER .....	vii
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ.....	ix
RESİMLERİN LİSTESİ .....	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR İNCELEMESİ .....	4
2.1. Klasik Örüntü Tanıma Yaklaşımları .....	4
2.2. Derin Öğrenme Temelli Yaklaşımlar.....	6
2.3. Evrişimli Sinir Ağı ve Özellik Çıkarımı .....	7
3. MATERYAL VE METODLAR .....	9
3.1. Veri Setleri.....	9
3.1.1. Leafsnap Veri Seti .....	9
3.1.2. Flavia Veri Seti .....	11
3.1.3. Mendeley Veri Seti.....	11
3.1.4. Swedish Leaf Veri Seti.....	12
3.1.5. UCL Veri Seti .....	13
3.2. Veri Seti Birleştirilmesi.....	14
3.3. Görüntü İşleme Teknikleri .....	15
3.4. Evrişimli Sinir Ağı .....	18



3.4.1. Konvolüsyon Katmanı .....	19
3.4.2. Havuzlama Katmanı .....	20
3.4.3. Düzleme Katmanı .....	21
3.4.4. Sınıflandırma Katmanı .....	22
3.5. Öğrenme Aktarımı ve Öznitelik Çıkartma .....	23
3.5.1. MobileNet Modeli .....	24
3.5.2. DenseNet121 Modeli .....	25
3.5.3. InceptionV3 Modeli .....	26
3.5.4. VGG16 Modeli .....	27
3.6. Sınıflandırma ve Performans Değerlendirmesi .....	28
3.6.1. En Yakın Komşu Algoritması .....	28
3.6.2. Aşırı Öğrenme Makinesi .....	29
3.6.3. Destek Vektör Makinesi .....	30
3.6.4. Çapraz Doğrulama .....	31
4. ARAŞTIRMA BULGULARI .....	33
4.1. Ön İşlemler .....	34
4.2. Sınıflandırma .....	35
4.2.1. Uygun Model Belirlenmesi .....	35
4.2.2. Oluşturulan Modelin Kullanımı .....	42
4.2.3. Önceden Eğitilmiş Hazır Modellerin Kullanımı .....	44
5. SONUÇ VE ÖNERİLER .....	45
5.1. Sonuçlar .....	45
5.2. Karşılaştırma .....	54
5.3. Öneriler .....	58

KAYNAKLAR.....	59
EKLER.....	64
ÖZGEÇMİŞ.....	70



## ÇİZELGELERİN LİSTESİ

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 3.1. Veri setlerinin detaylı gösterimi .....	15
Çizelge 3.2. Veri setlerindeki ortak türler ve bu türlerin görüntü sayıları .....	15
Çizelge 3.3. Hata Matrisi .....	27
Çizelge 4.1. Veri çoğaltma sonrası veri setlerinin toplam görüntü sayısının detaylı gösterimi.....	34
Çizelge 4.2. Evrişimli sinir ağı ile yaprak sınıflandırmada tür, görüntü sayısı ve iterasyon sayısı .....	42
Çizelge 4.3. Oluşturulan model ile önceden eğitilmiş modellerin görüntü boyutu, düzleme katman boyutu gibi parametrelerin karşılaştırılması .....	44
Çizelge 5.1. Evrişimli sinir ağı ile yaprak sınıflandırmada tür, görüntü sayısı, eğitim ve test başarı oranı .....	51
Çizelge 5.2. Özellik çıkarımı sonrası EYKA ile yapılan sınıflandırma sonuçları .....	51
Çizelge 5.3. Özellik çıkarımı sonrası DVM ile yapılan sınıflandırma sonuçları.....	52
Çizelge 5.4. Tüm veri setlerinin AÖM ile yapılan sınıflandırma başarımlarının detaylı gösterimi.....	52
Çizelge 5.5. Mendeley veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi.....	53
Çizelge 5.6. Swedish Leaf veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi.....	53
Çizelge 5.7. Flavia veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi.....	53
Çizelge 5.8. UCL veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi.....	53
Çizelge 5.9. Leafsnap veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi.....	53
Çizelge 5.10. Tüm veri seti birleşiminin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi.....	54
Çizelge 5.11. Mendeley veri setinin farklı sınıflandırma yöntemleri ile sınıflandırma başarımlarının kıyaslanması .....	54

Çizelge 5.12. UCL veri setinin literatürdeki farklı sınıflandırma yöntemlerinin başarımları ile bu çalışmada ki sınıflandırma başarımlarının kıyaslanması.....	55
Çizelge 5.13. Leafsnap veri setinin literatürdeki farklı sınıflandırma yöntemlerinin başarımları ile bu çalışmada ki sınıflandırma başarımlarının kıyaslanması.....	55
Çizelge 5.14. Swedish Leaf veri setinin literatürdeki farklı sınıflandırma yöntemlerinin başarımları ile bu çalışmada ki sınıflandırma başarımlarının kıyaslanması.....	56
Çizelge 5.15. Flavia veri setinin literatürdeki farklı sınıflandırma yöntemlerinin başarımları ile bu çalışmada ki sınıflandırma başarımlarının kıyaslanması.....	57
Çizelge 5.16. Birleşmiş veri setinin farklı sınıflandırma yöntemleri ile sınıflandırma başarımlarının detaylı gösterimi .....	58

## ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Konvolüsyon katmanında renkli resimlere uygulanan işlemlerin detaylı gösterimi.....	19
Şekil 3.2. Maksimum, ortalama ve minimum havuzlama katmanının örnek gösterimi .....	20
Şekil 3.3. Evrişimli sinir ağı maksimum havuzlama katmanı detaylı gösterimi .....	21
Şekil 3.4. Evrişimli sinir ağı düzleme katmanı detaylı gösterimi .....	22
Şekil 3.5. Sinir ağı yapısının temsili gösterimi .....	22
Şekil 3.6. TB katmanı detaylı gösterimi .....	23
Şekil 3.7. MobileNet önceden eğitilmiş modelin, 128 x 128'lik renkli giriş görüntülerine göre gösterimi.....	25
Şekil 3.8. DenseNet121 önceden eğitilmiş modelin, 128 x 128'lik renkli giriş görüntülerine göre gösterimi.....	26
Şekil 3.9. InceptionV3 önceden eğitilmiş modelin, 128 x 128'lik renkli giriş görüntülerine göre gösterimi.....	27
Şekil 3.10. VGG16 önceden eğitilmiş modelin, 128 x 128'lik renkli giriş görüntülerine göre gösterimi.....	29
Şekil 3.11. Doğrusal ve doğrusal olmayan hiper uzayların sınıflandırılmasının gösterimi .....	31
Şekil 3.12. Doğruluk Matrisi .....	32
Şekil 4.1. Yapılan çalışmanın şematik gösterimi.....	33
Şekil 4.2. Evrişimli sinir ağı ile yaprak sınıflandırmada havuzlama etkisi .....	36
Şekil 4.3. Modelde yapılan farklı filtre boyutu denemelerinin gösterimi.....	36
Şekil 4.4. Mendeley veri setindeki 66 x 50 – 90 x 75 – 132 x 100 boyutlu resimlerin filtre boyutu değişimi ile elde edilen sonuçların ortalaması .....	37
Şekil 4.5. 132 x 100 boyutlu görüntüler için 9 x 9 ve 3 x 3 filtre boyutlu modellerin 100 iterasyonda elde edilen başarımların kıyaslaması.....	38
Şekil 4.6. Mendeley veri setinde kullanılarak 66 x 50 – 90 x 75 – 132 x 100 boyutlu resimlerin farklı filtre boyutlarındaki işlem süresinin dakika olarak süre kıyaslaması .....	38

Şekil 4.7. Farklı arka plan rengine sahip yaprak görüntüleri için 3 farklı boyutla yapılan eğitimlerin dakika olarak işlem süresi kıyaslaması .....	40
Şekil 4.8. Renkli arka planlı yaprak görüntülerinin 3 farklı görüntü boyutu için ortalama başarımların kıyaslaması .....	40
Şekil 4.9. Beyaz arka planlı yaprak görüntülerinin 3 farklı görüntü boyutu için ortalama başarımların kıyaslaması .....	41
Şekil 4.10. Evrişimli sinir ağı ile sınıflandırma yapılan model detaylı gösterimi .....	41
Şekil 4.11. Evrişimli sinir ağı ile sınıflandırma yapılan modelin 90 x 75 boyutlu görüntü kullanımının detaylı gösterimi .....	43
Şekil 5.1. Evrişimli sinir ağı ile yaprak sınıflandırmada İterasyon sayısı, tür sayısı ve görüntü sayısı arasındaki ilişki .....	46
Şekil 5.2. Evrişimli sinir ağı ile yaprak sınıflandırmada iterasyon sayısı, tür sayısı ve ortalama görüntü sayısı arasındaki ilişki .....	47
Şekil 5.3. Leafsnap veri setinin her tür için görüntü sayısı dağılımı .....	47
Şekil 5.4. Flavia veri setinin her tür için görüntü sayısı dağılımı .....	48
Şekil 5.5. Mendeley veri setinin her tür için görüntü sayısı dağılımı .....	48
Şekil 5.6. Swedish Leaf veri setinin her tür için görüntü sayısı dağılımı .....	49
Şekil 5.7. UCL veri setinin her tür için görüntü sayısı dağılımı .....	49
Şekil 5.8. Birleşmiş veri setinin her tür için görüntü sayısı dağılımı .....	50

## RESİMLERİN LİSTESİ

<b>Resim</b>	<b>Sayfa</b>
Resim 3.1. Leafsnap veri setinden örnek bir görsel.....	9
Resim 3.2. Leafsnap veri setinin farklı türlerinden örnek resimler.....	10
Resim 3.3. Flavia veri setinin farklı türlerinden örnek resimler .....	11
Resim 3.4. Mendeley veri setinin farklı türlerinden örnek resimler .....	12
Resim 3.5. Swedish Leaf veri setinin farklı türlerinden örnek resimler .....	13
Resim 3.6. UCL veri setinin farklı türlerinden örnek resimler .....	14
Resim 3.7. Döndürme işleminde farklı açılı örnek resimler .....	17
Resim 3.8. Evrişimli sinir ağı detaylı gösterimi .....	18

## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

<b>Kısaltmalar</b>	<b>Açıklamalar</b>
<b>AÖM</b>	Aşırı Öğrenme Makinesi
<b>AÜ AÖM</b>	Alt - Üst Üçgenleme AÖM
<b>ÇKA</b>	Çok Katmanlı Algılayıcı
<b>DAA</b>	Doğrusal Ayrımcı Analizi
<b>DDB</b>	Doğrultulmuş Doğrusal Birim
<b>DVM</b>	Destek Vektör Makinesi
<b>EİKPSO</b>	En İyi İkili Kılavuz Sürüsü Optimizasyonu
<b>ESA</b>	Evrışimli Sinir Ağı
<b>EYKA</b>	En Yakın Komşu Algoritması
<b>GDEOM</b>	Gri Düzey Eş Oluşum Matrisi
<b>Hess AÖM</b>	Hessenberg Ayrıştırma Tabanlı AÖM
<b>HG</b>	Hiperspektral Görüntüler
<b>KBA</b>	Komşu Bileşenleri Analizi
<b>KKNSA</b>	Kendi kendini Normalleştirme Sinir Ağı
<b>LR</b>	Lojistik Regresyon
<b>MFCC</b>	Mel - Frekans Cepstrum
<b>NB</b>	Naive Bayes
<b>OPD</b>	Ortalama Projeksiyon Dönüşümü
<b>OSA</b>	Olasılıksal Sinir Ağı
<b>ÖDUD</b>	Ölçek Değişmez Unsurlar Dönüşümü
<b>ÖGEH</b>	Ölçeğe Göre Eğrilik Histogramları
<b>RTOSA</b>	Radyal Temel Olasılıklı Sinir Ağı
<b>SAR</b>	Sentetik Açıklıklı Radar
<b>ŞB</b>	Şekil Bağlamı
<b>TB</b>	Tam Bağlı
<b>TBA</b>	Temel Bileşenler Analizi
<b>ÜDB</b>	Üstel Doğrusal Birim
<b>YGH</b>	Yönlendirilmiş Gradyanların Histogramı



**YGPH**  
**YİD**

Yönlendirilmiş Gradyanların Piramit Histogramı  
Yerel İkili Desenler



## 1. GİRİŞ

Teknoloji insan hayatına giderek daha fazla katkıda bulunurken, insanların günlük yaşamlarında kullandığı araba, buzdolabı hatta evler gibi bir çok şey giderek akıllanmaya, diğer bir deyişle yapay zeka ile daha içli dışlı olmaya başlamıştır. Yapay zekanın bu denli yaygınlaşması ile birlikte makine öğrenmesi veya derin öğrenme gibi yöntemlerle geliştirilmesi, farklı alanlara göre uygulanabilmesi için bir çok çalışma yapılmıştır. Bu çalışmalar geçmişte makine öğrenmesi ile başlarken günümüzde ise derin öğrenme ile devam etmektedir. “Makine öğrenimi, verileri veya geçmiş deneyimleri kullanarak bir performans ölçütünü optimize etmek için bilgisayarları programlamaktır” (Alpaydın, 2004: 3). Makine öğrenmesi sınıflandırılmış ya da etiketlenmiş verilere ihtiyaç duyarken derin öğrenme aldığı verileri çok katmanlı yapısını kullanarak bu verilerin özelliklerini katmanlar aracılığıyla belirler. Derin yapay sinir ağları olarak da geçen derin öğrenmenin alt dallarından biri olan evrişimli sinir ağıdır. Bu yapılarda büyük miktarda bir veya birden çok türde veriyi alır, bunları oluşturulan model ya da hazır modellerle kullanır ve sınıflandırma için ayırt edici özellikleri kendisi öğrenir. Bu özelliklere göre de sınıflandırma yapar. Evrişimli sinir ağı, katmanlı yapısıyla girdi olarak gelen verinin özelliklerini belirleyerek sınıflandırmaya uygun hale getirir, bu elde edilen özelliklerin azaltılarak en uygun özelliklerin bulunması gibi çeşitli işlemlerden geçirir ve sinir ağı ile sınıflandırma yapar. Genel anlamda görüntü işleme teknikleri ile öznetelik çıkartılması sağlanmaktadır. Ön işlem görevi gören birçok işlemden sonra yapılan farklı sınıflandırma metodlarıyla yüksek başarımlar elde edilmektedir. Bu yapılan işlemler için çok fazla zaman harcamak, lisanslı yazılıma ihtiyaç duyulabilmesi ya da duruma özel küçük programlar oluşturularak, mevcut veriye uygulanacak sınıflandırma yöntemine hazırlanmaya çalışılır. Bu gibi zaman, maddi ya da emek harcamasının azaltılması ya da ortadan kaldırılması için evrişimli sinir ağı gibi kendi kendine özellikleri öğrenip, bu özelliklere göre sınıflandırma yapabilen bir yöntem kullanılması daha uygun olabilir.

Bilim dünyasında, iş dünyasında hatta teknoloji dünyasında bir şeyleri sınıflandırmak devam eden sistematik bir çalışma alanıdır. Bu çalışma alanının bir dalı olan doğadaki nesnelere üzerinde çalışma yapan birçok bilim insanı, hayvanlardan başlayarak ağaçlar, meyveler, yapraklar gibi birçok varlığı sınıflandırma ve tanımlama yapmışlardır.

Bazen bu ayrımları yapmak ciddi uzmanlık gerektirmektedir. Özellikle sađlık sektörünün yapı taşlarından olan bitkilerin alternatif tıp olarak halk arasında kullanılmaktadır. Buna ek olarak Difenbahya, Baldıran otu ve Zakkum gibi bazı insanların şifalı olduğuna inandığı zehirli bitkiler çevremizde sıkça görölmektedir. Zehirli türlerin kişiler tarafından bilinmesini beklemek veya hangi türün zehirli olduğunun tanınması uzmanlık gerektirmektedir. Bu sebeplerden dolayı bitkileri hızlı ve doğru bir şekilde sınıflandıran, uzmanlık gerektirmeyen yapay zeka destekli sistemlere ihtiyaç vardır. Bu çalışmada yaprak sınıflandırmak için bir akıllı sistem geliştirilecektir. Bu sistemde yüksek yaprak sayısına sahip bir veri seti oluşturulacaktır ve derin öğrenme teknikleri ile yüksek başarılı bir sınıflandırma sistemi oluşturulacaktır.

Bu sınıflandırma işlemlerinde nesne ne kadar küçölürse başarımın o kadar artacağı düşünölebilir ancak yapraklar gibi kısmen küçük yapılarda bile damarlı yapılar, girintili kenarları olan birçok yaprak türü bulunmaktadır ve bu gibi yaprak özellikleri görüntüdeki nesnenin tanımlanması ve sınıflandırılmasını zorlaştırabilir. En yakın komşu, destek vektör makinesi, karar ağaç yapısı gibi yöntemler yaprağın geometrik özellikleri vb. gibi bu yöntemler için çıkarılmış öznitelikler kullanılarak sınıflandırmadaki zorlukların aşılması sağlanır. Bu yöntemlere ek olarak öznitelik çıkarmayı kendi kendine yapabilen evrişimli sinir ağı da eklenmektedir. Evrişimli sinir ağının yapısı gereği kullanılan görüntülerin büyüklüğü, kalitesi, siyah beyaz görüntü, gri görüntü ya da renkli görüntü olması, kullanılacak modeldeki katman ve fonksiyon sayısını ve nasıl kullanılacağını belirler. Bununla birlikte bu özellikler ve sınıflandırılacak tür sayısı, işlemin ne kadar süreceğini belirler. İhtiyaca göre VGG, GoogleNet gibi çok katmanlı hazır modeller kullanılarak eğitilmiş modellerden sonuç elde edilir. Büyük miktarda yaprak görüntülerini kullanarak, derin öğrenme algoritması olan evrişimli sinir ağı ile bu resimlerdeki benzerlikler ve farklılıkları ayırt ederek sınıflandırma yapılır. Yapılan çalışmalara baktığımızda oluşturulan veri setleri ayrı ayrı eğitilmiş ya da eğitilmiş verilerin farklı sınıflandırma yöntemleri ile kullanılarak daha yüksek başarımlar elde edilmeye çalışılmıştır.

Bu çalışmada yapılan geniş tarama ile belirlenen veri setleri ve bu veri setleri birleştirilerek oluşturulan birleştirilmiş yeni veri seti, boyutlandırma, uygunluk kontrolü, arka plan temizleme, gri resme çevirme, veri çoğaltma gibi ön işlemler uygulanarak evrişimli sinir ağı ile yaprak sınıflandırma için hazırlanmıştır.

Bu ön işlemlerin amacı başarıyı arttırmak, diğer taraftan oluşacak veri büyüklüğünü azaltmak ve buna bağlı olarak gerekli işlem gücü ile işlem zamanı olabildiğince minimize edilmiştir. Düşük işlem gücünün olduğu sistemlerde yapılacak çalışmalarda başarı ve gerekli işlem gücü ile bu işlem için gereken zamanının azaltılması için evrişimli sinir ağının optimize edilmesi gerekmektedir.

Evrişimli sinir ağı ile yaprak sınıflandırılırken belirlenen modeldeki konvolüsyon katmanlarının filtre boyutları ve sırası, farklı resim boyutu modelin oluşturulması sırasında incelenmiştir. Evrişimli sinir ağında kullanılan modeller de başarıya etki eden çok fazla parametre bulunmaktadır. Bu parametrelerden biri de havuzlama katman sayısı ve havuzlama katmanı türüdür. Bu çalışmada kullanılacak modelin belirlenmesinde rol oynayan havuzlama katman sayısı ve havuzlama katman türü analizi yapılmıştır. Son olarak belirlenen modelin eğitiminde kullanılacak olan verilerin, farklı görüntü boyutlarında renkli veya gri resim olması ve bu görüntülerin arka planlarının renkli ya da beyaz renk olması gibi durumlara göre elde edilen sonuçlar değerlendirilerek kullanılacak yapı belirlenmiştir.

Tüm veri setlerinin birleştirilmesi ile oluşan veri setinde, tüm görüntülerin belirli bir standardı yakalaması için arka plan rengi beyaz olmayan veri setlerine arka plan çıkarma işlemi uygulanmıştır.

Düşük işlem gücün ön planda tutularak iterasyon sayısının azaltıldığı, veri setlerindeki görüntü boyutlarının ve görüntü sayısının buna göre belirlendiği bu çalışmada evrişimli sinir ağı ile sınıflandırılmıştır. Sonuçları görmek ve karşılaştırmak için kullanılan model ile öznetelik çıkarılarak en yakın komşu algoritması, destek vektör makinesi ve aşırı öğrenme makinesi sınıflandırma yöntemleri ile sınıflandırılmıştır. Ayrıca yapılan literatür taraması sonucu belirlenen 4 farklı önceden eğitilmiş modelden çıkarılan veriler yine aynı yöntemler kullanılarak sınıflandırılmıştır. Bu sınıflandırma işlemleri sonucu elde edilen sonuçlara ve bu sonuçların karşılaştırılmasına göre düşük işlem gücüne sahip sistemlerde yüksek başarı elde etmek için nasıl bir yaklaşım kullanılabileceğinin belirlenmesi amaçlanmıştır.

## 2. LİTERATÜR İNCELENMESİ

Literatürde yaprak sınıflandırma ve tanıma yönelik yapılan çalışmalara bakıldığında 2 farklı yaklaşımdan bahsedilebilir. Bunlardan ilki klasik örüntü tanıma yaklaşımıdır. Görüntü işleme teknikleri kullanılarak yaprak resimlerinden anlamlı öznitelik çıkarılması ve bu özniteliklerin sınıflandırma yöntemleriyle performansları değerlendirilmektedir. Diğer yaklaşım ise derin öğrenme modelleri kullanılmasıdır. Bu yaklaşım öznitelik öğrenme olarak tanımlanmaktadır. Burada görüntü iyileştirme amaçlı bazı görüntü işleme yöntemleri kullanılırken öznitelik çıkartma gibi bir işlem yapılmamaktadır. ESA modelleri ile gerçekleşen bir yaklaşımda resimler giriş verisi olarak kullanılırken çıkış resim türlerini kapsamaktadır.

### 2.1. Klasik Örüntü Tanıma Yaklaşımları

Yaprak görüntüleri üzerinden sınıflandırma yapılırken pek çok yöntem sınıflandırma için gerekli özelliklerin oluşturulmasına ihtiyaç duyar, bu öznitelikleri çıkarmak içinde görüntülere birçok ön işlem uygulanır. Bu gibi uygulamalara örnek vermek gerekirse, Bilgili ve Uçan (2011) yaptıkları çalışmada, yaprak dış kenarları ve alanı bulunduktan sonra bu verilerden öznitelik çıkarımı yapılarak geriye yayılma algoritması ile sınıflandırılmıştır. Kır, Öz, Gülbağ (2012) tarafından yapılan çalışmada, en-boy oranı, yaprak sapı ve ucunun incelenmesi ile elde edilen verilerle en yakın komşu algoritması ile sınıflandırma yapılmıştır. Kadir, Edi, Susanto, Santosa (2011) yaptıkları çalışmada, yaprak şekli, rengi ve yapısı gibi özniteliklerin çıkarılması sonrası olasılıksal sinir ağı ile sınıflandırılmıştır. Bashish, Braik, Bani-Ahmad (2011) yaptıkları çalışmada, ön işlem uygulanması, K-means kümeleme, renk uzayı değiştirme gibi işlemlerle elde edilen özniteliklerden çıkarılan verilerle yapay sinir ağına dayalı bir sınıflandırma yapılmıştır. Kumar ve diğerleri (2012) tarafından yapılan çalışmada, yaprak görüntüsündeki şeklin eğriliği, görüntüdeki piksel değerleri, yaprağın görüntüdeki kapladığı alan gibi önceki çalışmalardan farklı özelliklerle de yapılan çalışmalar mevcuttur. Renk odaklı segmentasyondan sonra şekilde eğriliğe dayalı öznitelikler ve en yakın komşu algoritması ile türlerin tanımlanması yapılmıştır. Wang, Lu, Chi, Feng (2011) yaptıkları çalışmada, şekil bağlamı ve ölçek değişmez unsur dönüşümünün tanımlayıcı öznitelikleri ile en yakın komşu algoritmasına dayalı bir sınıflandırma yapılmıştır.

Bazı çalışmalarda birden çok sınıflandırma yönteminin kullanıldığı da görülmektedir. Lavania ve Matey (2014) yaptıkları çalışmada, görüntünün minimum ve maksimum piksel değerleri çıkarılıp bu değerler ölçek değişmez unsur dönüşümü algoritmasında işlenerek elde edilen noktalar veri tabanındaki noktalarla karşılaştırılarak sınıflandırılır, ortalama projeksiyon dönüşümü ile bulunan kenar noktalar çeşitli işlemlerden sonra şeklin hatlarını ortaya çıkarır ve bu sayede şekil hatlarına dayalı sınıflandırma yapılır. Hossain ve Amin (2010) yaptıkları çalışmada, yaprak resminin siyah beyaz resme çevrilmesinden sonra dış merkezlik, yaprağın eni ve boyu, yaprağın resimde kapladığı alan, dış bükey alan gibi birkaç özelliğin daha bulunduğu bu özellik grubu öznitelik kullanılarak sınıflandırılmıştır. Cerutti, Tougne, Coquin, Vacavant, (2014) tarafından yapılan çalışmada, yaprak resimleri ve çokgen bir model, yaprağın ana simetri eksenini ve yaprağın kenarlarındaki noktalar kullanılarak elde edilen öznitelikler çeşitli işlemlerden geçirilerek boyut, kavis ve dikey pozisyonların dizilerine dayalı bir sınıflandırma yapılır. Chaisuk, Phromsuthirak, Areekul (2017) yaptıkları çalışmada, yaprak resimleri segmentasyon işleminden geçtikten sonra şeklin kenarları ve merkez noktaları belirlenir. İkinci dereceden eğri tahmini, orta yaprak eksenini normalizasyonu, yaprak şeklinin kenarlarına dayalı öznitelik çıkarımı, bölümlenme morfolojik özellik ekstraksiyonu, farklılık ölçümüyle desen eşleştirme gibi yöntemler kullanılarak sınıflandırma yapılmıştır. Tsolakidis, Kosmopoulos, Papadourakis (2014) tarafından yapılan çalışmada, yaprak görüntülerine, resmin önce gri sonra siyah beyaz hale getirilmesi gibi ön işlemler yapıldıktan sonra Zernike anları, yönlendirilmiş gradyanların histogramı gibi öznitelik çıkarımı işlemleri uygulanır ve son olarak doğrusal DVM ile sınıflandırma yapılır. Hewitt ve Mahmoud (2018) yaptıkları çalışmada, özellik kümesi, temel şekil özelliklerini ve eğrilik haritalarına benzer şekilde, yerel ölçekte integral değişmezlerden (LAI) çıkarılan sinyal özniteliklerini içerir. Sınıflandırma için DVM kullanılmıştır. Vo, Dand, Nguyen, Pham (2019) tarafından yapılan çalışmada, VGG16 modeli kullanılarak derin konvolüsyon öznitelikleri çıkarılmıştır ve bu özniteliklerle DVM, en yakın komşu gibi 7 farklı sınıflandırma yöntemi uygulanmıştır. Wu ve diğerleri (2007) yaptıkları çalışmada, yaprak görüntüleri ön işlemlerden geçirildikten sonra basit geometrik özellikler ve dijital morfolojik özellikler çıkarılır. Temel bileşenler analizi kullanılarak sinir ağının girdi miktarı azaltılmıştır, daha sonra olasılıksal sinir ağları ile sınıflandırma yapılmıştır. Sujith ve Neethe (2020) tarafından yapılan çalışmada, yaprak görüntülerine uygulanan ön işlemler sonrası gri düzey eş oluşum matrisi, yerel ikili desenler, yönlendirilmiş gradyanların piramit histogramı ile özellik çıkarımı yapıldıktan sonra çıkarılan özellikler birleştirilir.

Bu özelliklerden komşu bileşenleri analizi kullanılarak tekrar özellik çıkarılır. Azaltılan özellik vektörleri ile bitki tür tahmini yapılmaktadır. Zhang, Cui, Wang, Kang, Min (2020) yaptıkları çalışmada, ön işlemler sonrası doku ve şekil özellikleri çıkarılmıştır. Bu özellikler azaltma ve normalizasyon işlemi uygulanarak DVM ile sınıflandırma için kullanılır. Keivani, Mazloum, Sedaghatfar, Tavakoli (2020) tarafından yapılan çalışmada, görüntülere uygulanangri resme çevirme ve segmentasyon işlemleri sonrası belirlenen 4 farklı özellik sınıflandırma öncesi normalizasyonla birlikte en iyi ikili kılavuz sürüsü optimizasyonu ile seçilir ve DVM ile sınıflandırılır. Tomar ve Agarwal (2016) yaptıkları çalışma da, yapılan ön işlemler sonrası özellik çıkarımı yapılır ve özellik veri tabanı oluşturulur. Bu veri tabanından seçilen özellikler DVM ile sınıflandırma için kullanılır. Kumar, Gupta, Gao, Singh (2019) tarafından yapılan çalışmada, uygulanan ön işlemler sonrası morfolojik özellikler çıkarılır. Çok katmanlı algılayıcı sonrası Ada-Boosting uygulanarak özellik sınıflandırma modeli ile sınıflandırılır. Kulkarni, Rai, Upparamani (2013) yaptıkları çalışma da, yaprak resimlerine uygulanan ön işlemler sonrası 5 farklı özellik çıkarılır ve bu özellikler radyal temel olasılıklı sinir ağı ile sınıflandırılır. Padoo ve Maravillas (2015) tarafından yapılan çalışmada, yaprağın şekil ve doku özelliklerini kullanarak Naive Bayesian ile sınıflandırma yapılmıştır. Mostafa, El-Latif, Reda (2020) yaptıkları çalışma da, yaprağın morfolojik özellikleri kullanılarak otomatik yaprak tanıma sistemi oluşturulmuştur. Wang ve ark. (2014) tarafından yapılan çalışmada, yaprak görüntülerinden elde edilen doku ve morfolojik özellikler kullanılarak DVM ile sınıflandırma yapılmıştır. Wang, Du, Guo ve Hu (2020) yaptıkları çalışmada, çeşitli ön işlemler ve öznitelik çıkartma işlemlerinden sonra DVM ile sınıflandırılmıştır.

## **2.2. Derin Öğrenme Temelli Yaklaşımlar**

Evrişimli sinir ağı, oluşturulan modeller ile eğitilmiş modellerin kullanılması ve farklı modellerin birleştirilmesi gibi çeşitli çalışmalar literatürde mevcuttur. Barre, Stöver, Müller, Steinhage (2017) tarafından yapılan çalışmada, 11 konvolüsyon, 6 maksimum havuzlama içeren model ile sınıflandırma yapılmıştır. Krause, Baek, Lim, Sugita (2018) yaptıkları çalışmada, yaprak ile çiçek görüntülerine ayrı ayrı işlemler uygulanır. Evrişimli sinir ağı ile sınıflandırma sonuçlarına dayalı bir bitki tahmin etme analizi yapılmıştır. Al-Qurran, Al-Ayyoub, Shatnawi (2019) tarafından yapılan çalışmada, oluşturulan evrişimli sinir ağı modeli yüksek başarımla sınıflandırma yapılması için transfer öğrenimi ve veri artırımı gibi teknikler kullanılmıştır.

Shah, Singha, Awate, (2017) yaptıkları çalışmada yaprak görüntülerine ve yaprağın bir bölümünün bulunduğu doku yamaları olarak geçen 2 farklı girdi 2 farklı evrişimli sinir ağı modeli ile eğitildikten sonra birleştirilerek sınıflandırma yapılır. Evrişimli sinir ağı modelinde evrişimli sinir ağının doğrusal olmama fonksiyonu olan doğrultulmuş doğrusal birim yerine üstel doğrusal birim kullanılarak sınıflandırma yapılmıştır (Atabay, 2016).

### 2.3. Evrişimli Sinir Ağı ve Özellik Çıkarımı

Evrişimli sinir ağı ile eğitilen verilerin özellikleri sınıflandırma katmanından önce çıkarılarak farklı sınıflandırıcılar ya da hazır modeller aracılığıyla sınıflandırıldığı literatür de görülmektedir. Alaslani ve Elrefaei (2018) tarafından yapılan çalışmada, önceden eğitilmiş Alex-Net modelinden çıkarılan öznitelikler ile çok sınıflı DVM yöntemi kullanılarak sınıflandırma yapılmıştır. Zhu, Isaacs, Fu, Ferrari (2017) tarafından yapılan çalışma da, Alex-Net gibi önceden eğitilmiş bir modelle eğitim yaptıktan sonra çıkarılan öznitelikler DVM ile sınıflandırıcı eğitimi yapılır. Son olarak DVM ile sınıflandırıcı seçimleri oluşturulur. Pearline, Raj, Vajravelu (2019a) tarafından yapılan çalışmada, veri setlerine 2 farklı önceden eğitilmiş modeli ayrı ayrı uygulayıp çıkan öznitelik vektörlerini kullanarak 8 farklı sınıflandırma metoduyla sınıflandırma yapılmıştır. Pearline, Kumar, Harini (2019b) yaptıkları çalışmada, yaprak veri setleri 2 farklı yol izlenerek, biri önceden eğitilmiş derin öğrenme modelleri ve diğeri ise öznitelikler çıkarma yöntemleri kullanılmıştır, çıkan sonuçlar ise doğrusal ayrımcı analizi (DAA), lojistik regresyon, Naive Bayes gibi 7 farklı sınıflandırma metoduyla test edilmiştir. Zhu, Liu, Qi, (2018) yaptıkları çalışmada, 16 konvolüsyonlu evrişimli sinir ağı yapısındaki tam bağlı katmanın özellik haritası birinci özellik olarak seçilmiştir. Softmax katmanın özellik haritası ise ikinci özellik olarak belirlenmiş ve bu özellik haritalarına göre DVM uygulanmıştır. Lee, Chan, Mayo, Remagnino, (2017) yaptıkları çalışmada, evrişimli sinir ağı ile eğitildikten sonra, eğitilen öznitelikler dekonvolüsyon ile çıkarılır, farklı katmanlardan çıkarılan bu özelliklere dayalı DVM gibi sınıflandırma yöntemleri ile sınıflandırma yapılmıştır. Beikmohammadi ve Faez (2018) tarafından yapılan çalışmada, önceden eğitilmiş modelden özellik çıkarımı yapılmıştır ve lojistik regresyon ile sınıflandırılmıştır. Wang ve ark. (2017) yaptıkları çalışmada, Yapılan ön işlemler sonrası ESA ile yapılan eğitimden öznitelik çıkarımı yapılarak DVM ile sınıflandırılmıştır.



Öznelik aktarımı yaklaşımı farklı alanlarda derin öğrenme uygulamaları olarak kullanılmıştır. Literatürde yapılan çalışmaların bir kısmına bakmak gerekirse, Lee, Chan, Mayo, Remagnino (2017) tarafından yapılan çalışmada, sentetik açıklıklı radar resimlerinin evrişimli sinir ağı ile eğitilmesi sonrası çıkarılan öznelikler AÖM ile sınıflandırılmıştır. Chen, Jiang, Li, Jia ve Ghamisi (2016) yaptıkları çalışmada, HG'lerin sınıflandırılmasında önerilen 3 boyutlu evrişimli sinir ağının özellikleri çıkarılarak DVM ve EYKA gibi sınıflandırıcılarla sınıflandırılmıştır. Hu ve diğerleri (2018) yaptıkları çalışmada, su altı akustik sinyallerinin evrişimli sinir ağı eğitimi sonrası AÖM ile sınıflandırılması ve bu sınıflandırma sırasında literatürde bulunan 2 farklı özellik türü ile evrişimli sinir ağı özellikleri kıyaslanmıştır. Izadpanahkakhk, Razavi, Taghipur - Gorjikotaie, Zahiri ve Uncini (2018) tarafından yapılan çalışma da, avuç izi görsellerini çeşitli ön işlemlerden geçirdikten sonra evrişimli sinir ağının önceden eğitilmiş modeller kullanarak çıkarılan özellikleri DVM ve EYKA gibi sınıflandırıcılar ile sınıflandırılmıştır. Srinivas, Roy, Mohan (2016) yaptıkları çalışma da, vücudun farklı bölgelerinin X-ray görüntülerinin evrişimli sinir ağı ile eğitimi sonrası çıkarılan özellikleri farklı sınıflandırma yöntemlerinde kullanılan özelliklerle kıyaslanmıştır. Varshni, Thakral, Agarwal, Nijhawan ve Mittal (2019) yaptıkları çalışma da, göğüs X-ray görüntüleri DenseNet-169 hazır modeli kullanılarak özellik çıkarımı yapılmıştır ve DVM ile sınıflandırılmıştır.

### 3. MATERYAL VE METODLAR

#### 3.1. Veri Setleri

Bu çalışmada tek arka plana sahip, farklı ölçekte, büyüklükte ve tek bir yaprağın olduğu yaprak görüntülerinden oluşan veri setleri kullanılmıştır. Bu veri setleri yapılan detaylı bir taramadan ve elde edilen veri setlerinin sınıflandırma için uygunluğu test edildikten sonra Leafsnap, Flavia, Mendeley, Swedish Leaf ve UCL veri setlerinin kullanılmasına karar verilmiştir. Ayrıca bu 5 veri setinin birleşiminden oluşan genel bir veri seti haline getirilerek sınıflandırma sistemi için kullanılmıştır.

##### 3.1.1. Leafsnap Veri Seti

Kumar ve diğerleri, (2012) tarafından oluşturulan Leafsnap veri seti, lab ve field olarak 2 farklı kategoriye ayrılmış şekildedir. Bu çalışmada lab bölümüne odaklanılmıştır. Bu bölümdeki resimlerin kenar bölgelerinde, Resim 3.1'de gösterilen sınıflandırmayı zorlaştıracak renk paletleri ve cetvel bulunmaktadır.



Resim 3.1. Leafsnap veri setinden örnek bir görsel

Görüntüler kırılarak sınıflandırma için uygun hale getirilmiştir. Sabit arka plan görüntülerinden oluşan bu veri setinde her bir yaprağın gri arka planlı 2 fotoğrafı mevcutken, 2 adette beyaz arka planlı fotoğrafı bulunmaktadır. 184 tür barından bu veri setindeki 11 234 adet yaprak fotoğrafları farklı ölçeklerde fotoğraflama yapılmıştır. Çok fazla türün olduğu bu veri setinde tekil çok küçük yapraklardan, çok yapraklı farklı yapılar mevcuttur. Leafsnap otomatik bitki türü tanımak için oluşturulan bilgisayarlı görme sisteminde kullanılmıştır. Evrişimli sinir ağı, EYKA gibi farklı sınıflandırma yöntemi ve çeşitli öznetelik çıkarma yöntemleri ile kullanılmış çalışmalar literatürde bulunmaktadır. Bu veri setinde ki resimler Resim 3.2’de gösterildiği gibi farklı ölçeklerde ve büyüklükler bulunmaktadır.



Resim 3.2. Leafsnap veri setinin farklı türlerinden örnek resimler

### 3.1.2. Flavia Veri Seti

Beyaz arka plana sahip bu veri seti 32 tür ve toplam 1907 görüntüden oluşmaktadır. Wu ve diğerleri (2007) tarafından oluşturulan Flavia veri seti, farklı özellikler çıkarılarak OSA ile eğitilmek için oluşturulmuştur. Bunun yanı sıra literatürde evrişimli sinir ağı veya farklı sinir ağları ile kullanılmıştır. Resim 3.3'deki fotoğrafa göre veri setinde ki görüntüler farklı açılarda ve boyutta olduğu görülmektedir.



Resim 3.3. Flavia veri setinin farklı türlerinden örnek fotoğraflar

### 3.1.3. Mendeley Veri Seti

Chouhan Singh, Kaul, Jain, (2019) tarafından oluşturulan Mendeley veri seti hastalıklı ve sağlıklı yapraklar toplanarak araştırmacılar ve akademisyenlerin kullanımına sunulmuştur. 12 tür ve 4404 fotoğraftan oluşan bu veri seti bazı türlerde farklı arka planlı görüntüler de mevcuttur. Mendeley veri setinde bulunan hastalıklı yaprak fotoğraflarından şekli bozuk olan ya da yaprağın büyük bir kısmının rengi hastalık yüzünden değişmiş veya yaprağın şeklinin bozulmasına sebep olan bu görüntüler veri setinden çıkarılmıştır.

Resim 3.4'deki örnek veri seti fotoğraflarına bakıldığında yakın renkte arka plana sahip bu yaprak görüntülerinde ki yaprakların açılı bir şekilde çekildiği görülmektedir.



Resim 3.4 Mendeley veri setinin farklı türlerinden örnek resimler

### 3.1.4. Swedish Leaf Veri Seti

Söderkvist (2001) tarafından oluşturulan Swedish Leaf veri seti, 15 tür ve 1125 görüntü bulunan bu veri setindeki yaprak görüntüleri dikey olarak çekilmiş ve beyaz arka planın fazlalıkları kırılmıştır. Bu veri setini şekil, doku ve geometrik özellikleri elde eden ve bu özelliklerle sınıflandırma yapan çalışmalar mevcuttur. Ayrıca çok ölçekli uzaklık matrisi, üçgen uzaklık matrisi, DVM ve EYKA gibi farklı yaklaşımlar literatürde bulunmaktadır.

Resim 3.5'deki yaprak görüntülerine göre yaprak resimlerinin dikey boyutunun yüksek olduğu ve genel olarak benzer ölçüğe sahip olduğu görülmektedir.



Resim 3.5. Swedish Leaf veri setinin farklı türlerinden örnek resimler

### 3.1.5. UCL Veri Seti

Silva, Marcal, Silva, (2013) tarafından oluşturulan UCL veri seti, 40 tür ve 443 görüntüden oluşmaktadır. Bu veri setinde ki yaprak görüntüleri dikey olarak çekilmiş ve koyu arka planın fazlalıkları kırılmıştır. Tablet kamerası ile yapılan çekimler yüksek kalitede olmamakla birlikte yapraklarla arka plan rengi yakın olması resimlerle çalışılmasını zorlaştırabilir. Temel bileşenler analizi ve hiyerarşik kümeleme gibi yöntemler kullanılarak çalışmalar yapılmıştır.

Resim 3.6'ya göre veri setindeki yaprak fotoğraflarının kısmen farklı arka plana sahip olduğu ve yukardan dik bir şekilde fotoğrafların çekildiği görülmektedir.



Resim 3.6. UCL veri setinin farklı türlerinden örnek resimler

### 3.2. Veri Seti Birleştirilmesi

Değişik boyut ve arka plana sahip olan bu veri setleri incelenerek, tüm veri setlerinin bulunduğu yeni birleştirilmiş veri seti oluştururken birçok ön işlem yapılması gerektiği görülmüştür. Tüm veri setleri titizlikle kontrol edilmiş ve ortak türlerin olduğu görülmüştür. Oluşturulan yeni birleştirilmiş veri setinde bu durum dikkate alınarak ortak türler birleştirilmiştir. (Bkz. Çizelge 3.1) Tabloya bakıldığında her bir veri setindeki tür sayılarının toplamı 283 tür olarak görülürken ortak türlerin birleştirilmesi sonucunda tür sayısı 270'e düşmüş, ortak türlerin görüntüleri kendi aralarında birleştirilmiştir.

Çizelge 3.1. Veri setlerinin detaylı gösterimi

Veri Seti Adı	Tür Sayısı	Toplam Görüntü Sayısı
Mendeley	12	4 149
Swedish Leaf	15	1 125
Flavia	32	1 907
UCL	40	443
Leafsnap	184	11 234
<b>Toplam</b>	<b>283</b>	<b>18 858</b>

Çizelge 3.2'deki (Bkz. Türlerin dağılım ve sayıları EKLER bölümünde detaylı olarak verilmiştir.) verilere göre veri setlerindeki, veri çoğaltma işlemi sonrası tüm veri setlerinin birleşik halinin görüntü sayısı ve veri çoğaltma işlemi yapılmış ortak türlerin görüntü sayıları gösterilmektedir. Bu çizelgelere bakıldığında 11 ortak tür ve bu türlerin 2 ya da 3 farklı veri setin de bulunması sonucu, ortak türler birleştirilerek toplam tür sayısı 13 azalarak 270'e düşürülmüştür.

Çizelge 3.2. Veri setlerindeki ortak türler ve bu türlerin görüntü sayıları

Tür Adı	Leafsnap	Flavia	UCL	Swedish Leaf	Mendeley
Acer Palmatum	X (60)	X (56)	X (16)		
Acer Negundo	X (80)		X (10)		
Cedrus Deodora	X (40)	X (77)			
Ginkgo Biloba	X (60)	X (62)			
Magnolia Grandiflora	X (60)	X (57)	X (11)		
Nerium Oleander		X (66)	X (11)		
Prunus Serrulata	X (60)	X (55)			
Quercus Robur	X (58)		X (12)		
Tilia Tomentosa	X (60)		X (13)		
Ulmus Glabra	X (52)			X (75)	
Betula Pubescens			X (14)	X (75)	

Ortak türler tablosuna bakıldığında, farklı veri setlerinde bulunan ortak türler için veri çoğaltma işlemi yapılmadan önceki görüntü sayıları görülmektedir. Tür sayısı arttıkça ortak tür sayısında artmıştır.

### 3.3. Görüntü İşleme Teknikleri

Dijitalleşmenin altın çağında nerdeyse her yerde olan kameralar ile elde edilen fotoğraf ve videoların profesyonel alanlarda ve akademik alanlarda yapılan çalışmalarda sıklıkla kullanıldığı görülmektedir.



Bu durum yapılan çalışmalarda elde edilen verinin uygunluğunun kontrol edilmiştir. Uygun değilse, uygun hale getirilmesi gibi pek çok sorunu gün yüzüne çıkarmaktadır. Görüntü işleme teknikleri kullanımına örnek vermek gerekirse görüntünün ters çevrilmesi, siyah beyaza dönüştürülmesi veya histogram eşitleme gibi basitten karmaşığa kadar birçok farklı uygulama ile yapılan çalışmalara yarar sağlamaktadır.

Bu çalışmada kullanılan görüntü işleme tekniklerine baktığımızda, birçok farklı boyutta görüntü ile uğraşmak ve bunları aynı yapıya hazırlamak için görüntü boyutları belirlenen görüntü boyutuna göre her veri seti için yeniden boyutlandırılmıştır. Leafsnap veri setinde bulunan görüntülerin kenar bölgelerin de cetvel ve renk paletleri bulunması nedeniyle görüntülerin sadece yaprak ve arka plana sahip olacak şekilde düzenlenmesi gerekmiştir.


Veri setlerinin farklı sayıda görüntü ve tür içermesi verilerin çoğaltılmasının nedenlerinden biridir. Ayrıca kullanılan veri setlerinde tür ve görüntü sayısı dağılımındaki dengesizlikler, birçok veri setinin birleştirileceği bir yapı oluşturulacağı ve bu yüksek tür sayısına sahip veri seti ile eğitilecek olan modelin daha iyi bir sınıflandırma işlemi yapabilmesi için veri çoğaltma yapılmıştır.

(Bkz. Çizelge 3.1) Leafsnap veri setinde 184 tür ve 11234 görüntü içerirken UCL veri setinde 40 tür ve 443 görüntü bulunur ayrıca Mendeley veri setinde 12 tür olmasına rağmen 4149 görüntü vardır. Bahsedilen veri setlerinde tür sayısı ile görüntü sayısı arasında doğrusal bir artış olmaması, tüm veri setlerinin birleştirildiğinde yapılacak olan sınıflandırmanın başarı oranını düşürebileceği ve aşırı öğrenme söz konusudur. Ayrıca resimlerin farklı rotasyonlarda olması sebebiyle eğitim öncesi bu sorunlara çözüm olarak farklı rotasyonlarda verilere dönüştürülerek veri çoğaltma yapılmıştır. Buna bağlı olarak yapılan veri çoğaltma işlemi veri setlerindeki görüntüler Leafsnap ve tüm veri setlerinin birleştirilerek oluşturulan veri seti hariç diğer 4 veri seti 11 farklı açıda döndürülerek orijinal resim de dahil olmak üzere bir resmin 12 farklı hali elde edilmiştir (Bkz. Resim 3.7). UCL veri setinde bulunan görüntü sayısının az, tür sayısının fazla olması sebebiyle yapılan döndürme işlemi öncesi yansıtma işlemi uygulanmıştır. Birleştirilmiş veri seti oluşturulurken UCL veri seti haricindeki diğer veri setlerinde bulunan orijinal resimlere ek olarak bu veri setlerindeki görüntü sayılarının her bir türdeki görüntü sayısına göre 10 parçaya bölünmüştür. Daha sonra bu bölümlerin her biri 30, 60, 90, 120, 150, 180, 210, 240, 270 ve 300 derece döndürme işlemleri ve yansıtma işlemine tabi tutulmuştur.

Veri setlerinin birleştirilmiş hali için, Mendeley ve UCL veri setlerine arka plan çıkarma işlemi uygulanmıştır. Mendeley veri setinde az tür ve çok fazla görüntü bulunması nedeniyle bu veri setinin görüntü sayısı birleştirilmiş veri setine eklenirken azaltılmıştır.

Leafsnap veri setinde bulunan orijinal görüntülere ek olarak 90, 180 ve 270 derece döndürme işlemi uygulanmış görüntüler eklenmiştir. Birleştirilmiş veri seti ve Leafsnap veri setlerinin farklı işlemlere tabi tutulmasının nedeni 12 farklı açıda elde edilecek görüntü sayısının yüksek işlem gücü ve fazla zaman gerektireceği gibi sınıflandırma işlemleri yapılan sistemin işlem gücü kapasitesi içerisinde kalmasına özen gösterilmiştir. Birleştirilmiş veri setinde kullanılan veri setlerinden arka planı beyaz olmayan veri setlerine arka plan çıkarma işlemi uygulanarak tüm veri setlerinin belirli bir standartta olması sağlanmıştır.

Resim 3.7’de bu 11 farklı açı görülmektedir. Bu açılar ise, 30, 60, 90, 120, 150, 180, 210, 240, 270, 300, 330’ dur. 30 derecelik açı artış değerini daha da düşürerek daha çok veri elde edilebilir ancak daha fazla işlem gücü gerekeceği için 11 farklı açı değeri uygun görülmüştür. Resmin döndürülmesi ile oluşan kaymalar ise resmin boyutu yükseltilecek ortadan kaldırılmıştır.




Resim 3.7. Döndürme işleminde farklı açılı örnek fotoğraflar

Yapılan tüm ön işlemlerden sonra yapılacak olan ESA eğitiminde kullanılan görüntülerin piksel değerleri 255'e bölünerek normalizasyon işlemi uygulanmıştır. Yapılan bu işlem ile başarıyı arttırmak ve gereken işlem gücünün azaltılması amaçlanmıştır.

### 3.4. Evrişimli Sinir Ağı

Evrişimli sinir ağı, girdi olarak gelen veriyi katmanlarda bulunan filtrelerle alınan verideki farklılıkları elde ettiği ağırlık değerlerine göre sinir ağı aracılığıyla sınıflandırır. Evrişimli sinir ağı katmanları konvolüsyon, kümeleme ve tam bağlı katman ya da diğer bir deyişle sınıflandırma katmanından oluşur, bu katmanların her birinden kaç adet ve kullanılan katmanların filtre yapılarının nasıl olacağı ise kullanılan veriye, oluşacak işlem gücü gibi pek çok etmene bağlıdır.

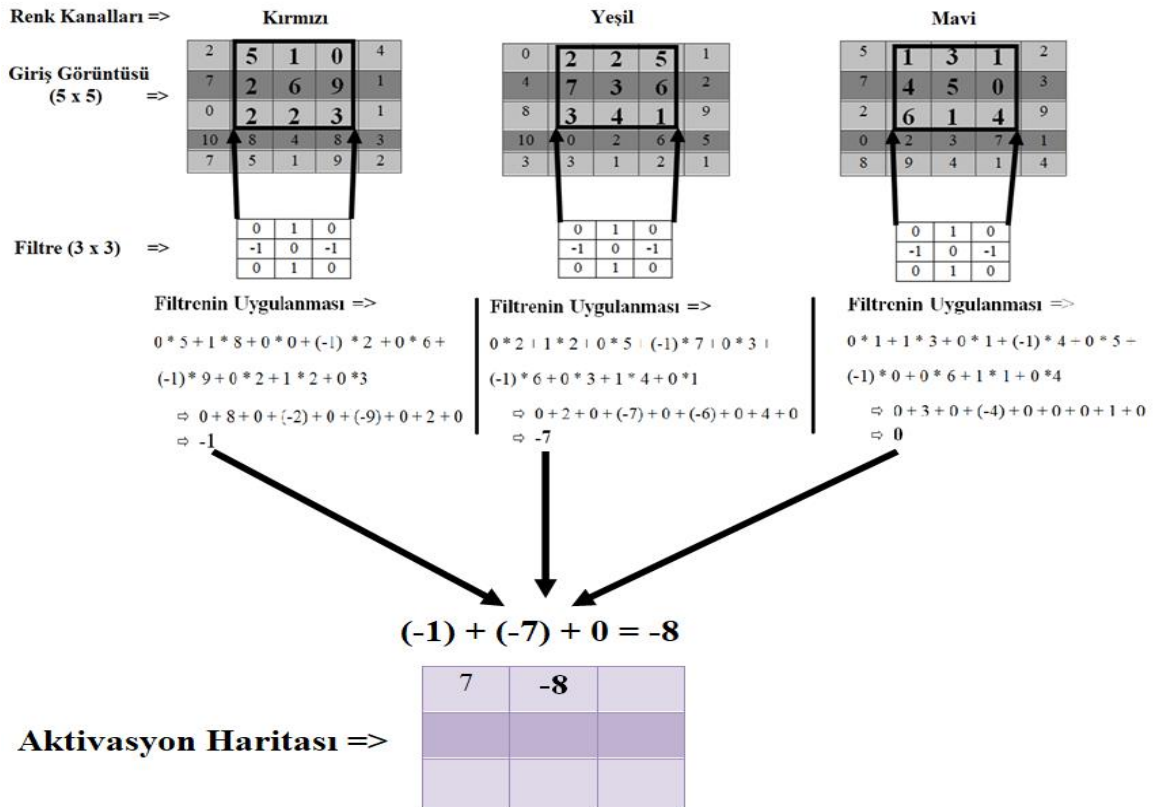
Resim 3.8'de evrişimli sinir ağının katmanları detaylı gösterilmiştir. 2 bölüm olarak gözükürken bu görsel de konvolüsyon ve havuzlama katmanlarından oluşan ilk bölüm özellik öğrenme, ikinci bölüm ise bu öğrenilen özelliklere göre sınıflandırma yapan sınıflandırma katmanıdır.



Resim 3.8. Evrişimli sinir ağı detaylı gösterimi

### 3.4.1. Konvolüsyon Katmanı

Konvolüsyon katmanı evrişimli sinir ağının en önemli katmanıdır, bu katmanda girdi olarak alınan verilere çok boyutlu filtreler uygulanarak özellik haritaları çıkarılır. Genellikle birden çok konvolüsyon katmanının olduğu modeller farklı özelliklerin ortaya çıkmasını sağlarken aynı zamanda da alınan veriyi filtre boyutuna bağlı olarak küçültür. Bu katmanda bulunan filtreler ile öznelik öğrenimi yapılmaktadır. Kullanılan filtrelerin sayısı, boyutu ve türü gibi farklı parametreler yapılan sınıflandırma da elde edilecek başarıya etki etmektedir. Bu parametrelerden biri olan filtre boyutu parametresi Camgözlü ve Kutlu (2020) yaptıkları çalışma da analiz edilmiş ve elde edilen sonuçlar dikkate alınmıştır. Resim 3.1’de gösterilen resme göre, giriş verisine uygulanan filtrenin veri üzerinde dolaşarak görüntüde ki istenilen özneliklerin farklı katmanlarda nasıl sağlandığı temsili olarak gösterilmiştir.



Şekil 3.1. Konvolüsyon katmanında renkli resimlere uygulanan işlemlerin detaylı gösterimi


Bu katmanda filtreler uygulanırken verinin çok fazla küçülmesi istenmez, bunun nedeni ise daha sonraki konvolüsyon katmanlarının da aynı işlem sonucu veri küçültülecek olması ve çıkarılabilecek özelliklerin başlangıçta olabildiğince çok olması istenir.

Kademeli olarak azalmayı sağlamak için verinin kenarlarına 0 değerleri eklenir. Konvolüsyonla birlikte doğrultulmuş doğrusal birim fonksiyonunda kullanılarak gelen verileri kontrol eder, bu veriler pozitifse işlem yapılmadan aktarılır, negatifse 0 olarak değiştirilip gönderilir. Bu işlem ağıın daha iyi ve daha hızlı bir şekilde çalışmasına olanak sağlar.

### 3.4.2. Havuzlama Katmanı

Genellikle bir veya birden çok konvolüsyon katmanı arasında bulunan bu katmanda konvolüsyon katmanı gibi uyguladığı filtre uygular. Üç türü vardır, bunlar maksimum, ortalama ve minimum havuzlamadır. Bu katmanın kullanılan modeldeki sayısı, havuzlama katman türü gibi parametreler değiştirilerek yapılan sınıflandırma için en iyi model oluşturulur. Havuzlama katmanı türü ve kullanılan havuzlama katmanı sayısı gibi parametrelerin incelendiği Camgözlü ve Kutlu (2019) tarafından yapılan çalışma sonucu elde edilen sonuçlara göre model oluşturulmuştur.

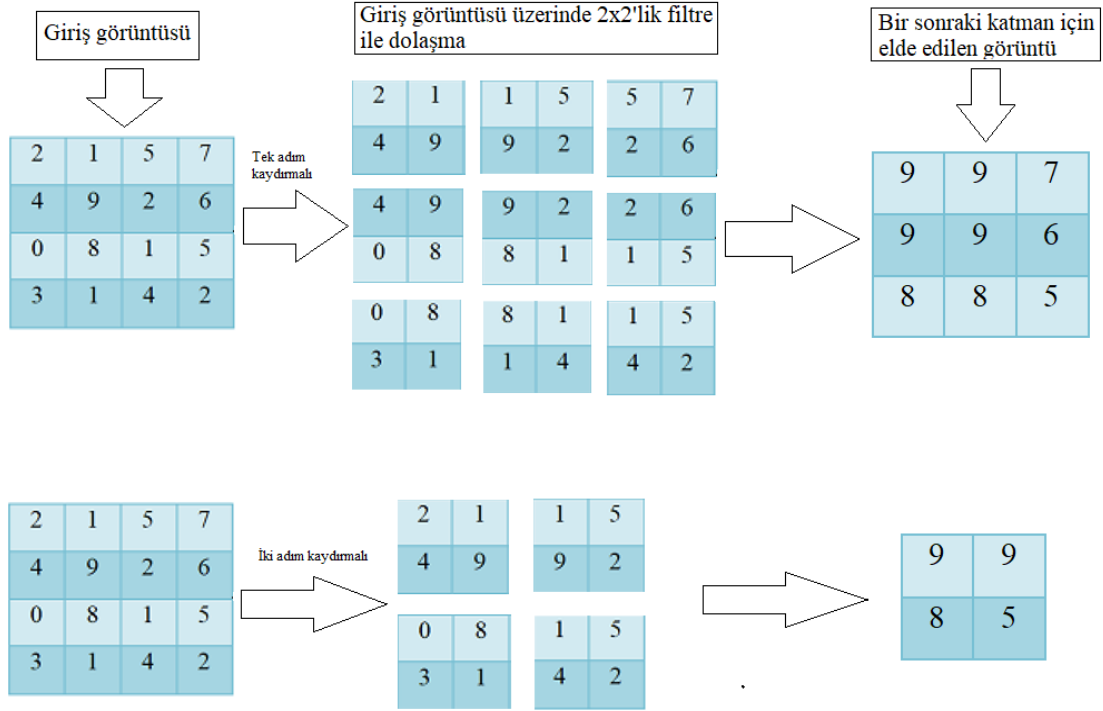
Örnek bir giriş görüntüsü üzerinden yapılan Şekil 3.2'deki gösterimle anlatılmak istenen, bu üç türün adında anlaşılacağı gibi birisi veri üzerinde filtreyi dolaştırarak maksimum ya da minimum değeri alır, son olarak ortalama havuzlama ise filtrenin geçerli olduğu alandaki değerlerin ortalamasını alır. Konvolüsyon katmanı gibi havuzlama katmanı da oluşturulan modellerde birden çok kez kullanılabilir.



Şekil 3.2. Maksimum, ortalama ve minimum havuzlama katmanının örnek gösterimi

(Bkz. Şekil 3.3) Giriş görüntüsü üzerinden teklive ikili kaydırma yapılarak 2x2 boyutlu filtrelerle havuzlama katmanının çalışma prensibi görülmektedir.


Bu çalışmada maksimum ve minimum havuzlama katmanlarıyla birlikte havuzlama katman sayısının etkisi oluşturulacak olan modelin belirlenmesi için incelenmiştir. Daha az işlem süresi gerektiren ve daha iyi başarımlar sağlayan ortalama havuzlama kullanılmıştır.



Şekil 3.3. Evrişimli sinir ağı maksimum havuzlama katmanını detaylı gösterimi

### 3.4.3. Düzleme Katmanı


Bu katmanın görevi gelen veriyi düzenleyip iletmektir. Detaylı bir şekilde bahsetmek gerekirse birçok konvolüsyon ve havuzlama katmanından oluşan bir yapıyı sınıflandırma katmanına bağlar, bu sırada gelen çok boyutlu matrisi tek boyutlu bir matrise çevirir, çevrilen bu matris ağı sınıf sayısına uygundur. (Bkz. Şekil 3.4) Gösterilen yapıya bakarsak düzleme katmanına gelen temsili veriyi sınıflandırma katmanlarına vektör olarak düzenleyip göndermektedir.



Şekil 3.4 Evrişimli sinir ağı düzleme katmanı detaylı gösterimi


### 3.4.4. Sınıflandırma Katmanı

Bu katmanda TB, düzleme katmanından gelen özellik vektörünü sinir ağı kullanarak eğitir ve sınıflandırma veya başka bir ağda kullanmak için kullanıma hazır hale getirir. Bu katmana girdi olarak gelen vektörde her bir değer bir etiketle eşlenmiştir. TB’de bulunan nöronlar bu değerleri diğer bir deyişle ağırlıkları her bir etikete göre değerlendirir ve yüksek bir doğruluğu olan etiketler seçilir. Bu katmanda oluşturulan modellerde, diğer katmanlar gibi birden çok kez kullanılabilir. Şekil 3.5’de gösterilen sinir ağı yapısının kısmi gösterimidir. Bu katman evrişimli ağının sınıflandırma katmanı olarak çalışır Bu katmanda kullanılan ağırlıklar ile önceki katmanlarda elde edilen özellikler arasında ki ilişkiye bakarak tahminler yapmaktadır.



Şekil 3.5. Sinir ağı yapısının temsili gösterimi

(Bkz. Şekil 3.6) Gösterilen denklem ve şekli açıklamak gerekirse, denklemde önceki katmanlardan elde edilen özelliklerin ağırlık ve diğer parametreler kullanılarak her bir katmanda ki düğümlere göre hesaplamalar yapılır.



Şekil 3.6. TB katmanı detaylı gösterimi

### 3.5. Öğrenme Aktarımı ve Öznitelik Çıkartma

Öznitelik çıkartma elde edilen veya oluşturulan verilerin temel bileşenler analizi, doğrusal ayırmacı analizi gibi yöntemleri kullanılarak oluşturulan verilerin analiz, sınıflandırma veya başka bir işlemin giriş verisi olarak kullanılmasıyla devam eden bir süreçtir. ESA'da ise öznitelik öğrenimi yapılmaktadır. Evrişimli sinir ağı ile yapılan eğitimde girdi olarak gelen verilerden elde ettiği öznitelik verileri diğer bir deyişle öznitelik haritaları sınıflandırma katmanından önce bulunan düzleme katmanından alınır. Bunun yanı sıra eğitilmiş hazır modellerin kendi ağırlıklarına göre ya da ImageNet gibi çeşitli hazır veri setlerinin ağırlıkları kullanılarak elde edilen verilerden vektör elde edilir. Daha sonra bu vektörler kullanılarak farklı sınıflandırma yöntemleri ile sınıflandırma yapılır. Bu modellerin eğitimi için yüksek miktarda veri setine ihtiyaç duyulmaktadır. Fakat büyük miktarda veri toplamak zordur veya maliyet gerektirmektedir. Bu sebeple öğrenme aktarımı veya parametre aktarımı yöntemi olarak bilinen yöntem geliştirilmiştir




“Transfer öğrenimi, bir ağı küçük bir veri kümesinde eğitmek için yaygın ve etkili bir stratejidir; burada ağ, 1000 sınıfla 1,4 milyon görüntü içeren ImageNet gibi son derece büyük bir veri kümesinde önceden eğitilir, daha sonra yeniden kullanılır ve verilen göreve uygulanır” (Yamashita, Nishio, Do, Togashi, 2018). Bu şekilde literatürde düzenlenmiş modeller mevcuttur. Eğitilmiş veri setleri veya VGG, AlexNet gibi özelleştirilmiş modellerde bulunan binlerce farklı nesnelere tanıma yeteneği sayesinde daha kısa sürede daha iyi sonuç elde edilmesi de sağlanabilir.

Literatürde yapılan incelemeler sonucu farklı işlemler için yaygın şekilde kullanılan 2 farklı düzleme katman boyutuna göre seçilen önceden eğitilmiş modeller farklı görüntü boyutlarına göre işlem yapabilmektedir. Bu çalışmada kullanılan önceden eğitilmiş modeller Simonyan ve Zisserman (2015) tarafından oluşturulan VGG16, Szegedy, Vanhocke, Ioffe, Shlens (2015) tarafından oluşturulan InceptionV3, Howard, Zhu, Chen, Kalenichenko (2017) tarafından oluşturulan MobileNet ve son olarak Huang, Liu, Maaten (2018) tarafından oluşturulan DenseNet121 belirlenmiştir. Kullanılacak farklı görüntü boyutları arasından ortak olan en düşük görüntü boyutu olan 128x128 tercih edilmiştir.

### **3.5.1. MobileNet Modeli**


(Bkz. Şekil 3.7) Detaylı olarak gösterimi yapılan MobileNet önceden eğitilmiş hazır modeli ImageNet kullanılarak eğitilmiştir. “MobileNet'ler, hafif, derin sinir ağları oluşturmak için derinlemesine ayrılabilir kıvrımlar kullanan modern bir mimariye dayanmaktadır.” Howard ve diğerleri (2017).



Şekil 3.7. MobileNet önceden eğitilmiş hazır modelin, 128 x 128 lik renkli giriş görüntüleri kullanılarak detaylı gösterimi

### 3.5.2. DenseNet121 Modeli

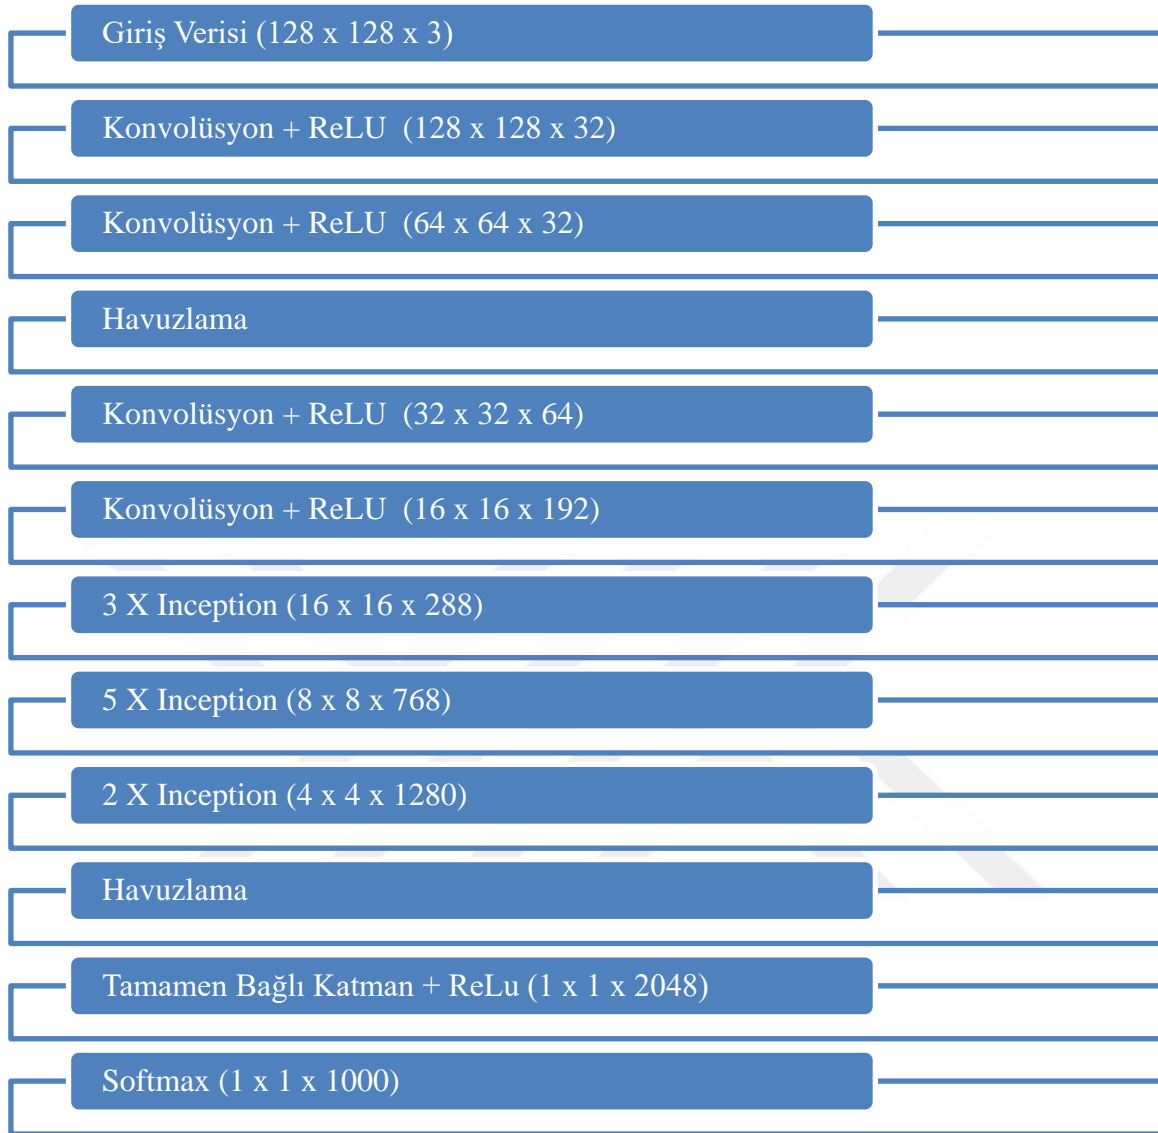
(Bkz. Şekil 3.8) Densenet121 hazır modelin detaylı gösterimi bulunmaktadır. DenseNet121 önceden eğitilmiş modelinde her katman ileri beslemeli bir şekilde diğer katmanlarla bağlanmıştır. Büyük ölçekli görsel tanıma yarışması ILSVRC2012’de belirlenen veri seti kullanılarak eğitilmiştir.



Şekil 3.8. DenseNet121 önceden eğitilmiş hazır modelin, 128 x 128'lik renkli giriş görüntüleri kullanılarak detaylı gösterimi

### 3.5.3. InceptionV3 Modeli


(Bkz. Şekil 3.9) Bu çalışmadaki kullanılan halinin detaylı gösterimi bulunan InceptionV3 önceden eğitilmiş hazır modeli, büyük ölçekli görsel tanıma yarışması ILSVRC2012'de belirlenen veri seti kullanılarak eğitilmiştir.



Şekil 3.9. InceptionV3 önceden eğitilmiş hazır modelin, 128 x 128'lik renkli giriş görüntüleri kullanılarak detaylı gösterimi

### 3.5.4. VGG16 Modeli

(Bkz. Şekil 4.12) VGG16 önceden eğitilmiş hazır modeli, ImageNet'in 1000 sınıflık ve her sınıf için 1000 görüntünün olduğu bir alt küme ile eğitilmiştir. Bu küme 1,2 milyon eğitim verisi, 50 000 doğrulama verisi ve 150 000 test verisi içermektedir. Kullanılan bu yüksek çözünürlüklü görüntüler 256 x 256'lık görüntü boyutuna indirgenmiştir. Bu çözünürlüğün yanı sıra farklı 128 x 128 gibi farklı görüntü boyutlarında da kullanılmaktadır.



Şekil 3.10. VGG16 önceden eğitilmiş hazır modelin, 128 x 128'lik renkli giriş görüntüleri kullanılarak detaylı gösterimi

### 3.6. Sınıflandırma ve Performans Değerlendirmesi

#### 3.6.1. En Yakın Komşu Algoritması

EYKA, bilinmeyen bir belgeyi de sınıflandırmak için KNN sınıflandırıcı, belgenin komşularını eğitim belgeleri arasında sıralar ve girdi belgesinin sınıfını tahmin etmek için en benzer komşusunun sınıf etiketlerini kullanır (Tan, 2006).

En yakın komşu algoritması k değeri yani yakın komşu sayısının uzaklık hesabıyla belirlenerek en yakın komşu grubuna eklenerek çalışmaktadır. En yakın komşuya olan uzaklığın hesaplanması için farklı formüller mevcuttur. Bunlar öklid, minkowski ve manhattan olmak üzere 3 adet uzaklık hesaplama fonksiyon bulunmaktadır. Bu çalışmada da kullanılan öklid uzaklık hesaplama formülü aşağıda gösterilmektedir.

$$d(p,q) = ((q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2)^{1/2} \quad (3.1)$$

EYKA ile üretilmiş bir modelin başarı oranını elde etmek için birçok farklı yol vardır. Bunlardan birkaçına örnek vermek gerekirse Jaccard index, F1- score ve LogLoss. EYKA için uzaklık hesaplama fonksiyonu olarak öklid tercih edilmiştir.

### 3.6.2. Aşırı Öğrenme Makinesi

Geri yayılma tabanlı sinir ağları veya destek vektör makinesi gibi diğer geleneksel öğrenme algoritmalarından farklı olarak, AÖM'nin gizli katmanlarının parametreleri rastgele oluşturulur ve ayarlanmaları gerekmez, bu nedenle eğitim örnekleri alınmadan önce gizli düğümler kurulabilir (Tang ve Deng, 2016). Aşırı öğrenme makinesi Huang tarafından önerilmiştir. Girdi olarak aldığı verileri birden çok gizli katmanlar ve bu katmanlarda bulunan gizli düğümleri ileri doğru bağlayarak rastgele atar.

$$f(x) = \sum_{k=1}^L B_k g(w_k * x_k + b_k), k = 1, \dots, N \quad (3.2)$$

Yukarıda ki denkleme baktığımızda L gizli katman sayısını, N eğitim örnek sayısını, w giriş ve gizli katman arasında ki ağırlık vektörü, g aktivasyon fonksiyonu, x giriş vektörü ve b yol vektörü ve son olarak B gizli katman ile çıkış katmanı arasındaki ağırlık vektörüdür. B matrisi ters matris olarak kullanılmaktadır.

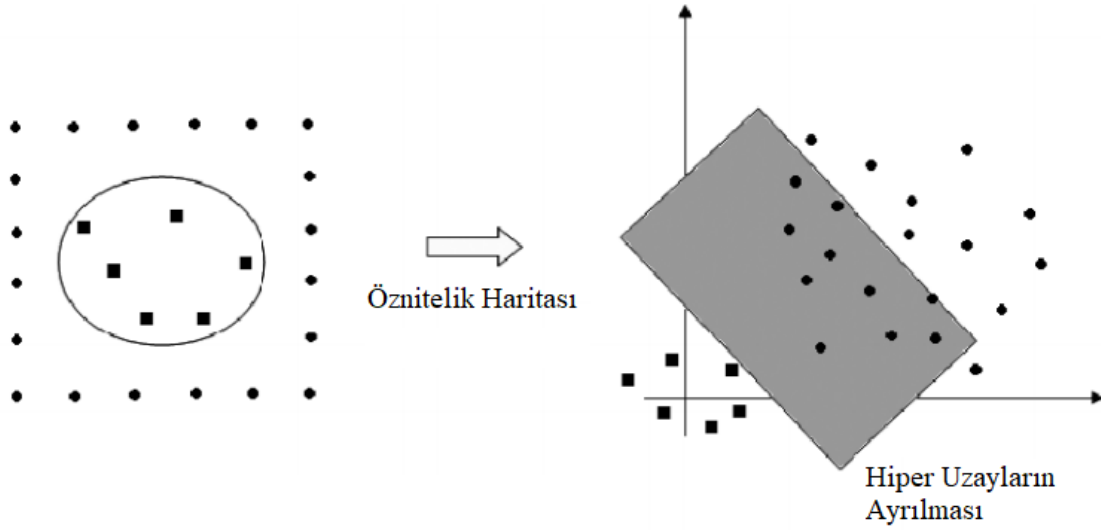
$$T = HB \quad (3.3)$$

$$\begin{aligned}
 \mathbf{H} &= \begin{bmatrix} g(w_1 * x_1 + b_1) & \dots & g(w_L * x_1 + b_L) \\ \vdots & \dots & \vdots \\ g(w_1 * x_N + b_1) & \dots & g(w_L * x_N + b_L) \end{bmatrix}_{N \times L} \\
 \mathbf{B} &= \begin{bmatrix} b_1^T \\ \vdots \\ b_L^T \end{bmatrix}_{L \times m} \quad \mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}
 \end{aligned} \tag{3.4}$$

Giren çıkış verileri  $m$ ,  $H$  gizli katmanın çıkış matrisi ve  $T$  ise hedeflenen eğitim matrisidir. Geleneksel öğrenme algoritmalarının aksine AÖM, girdi ağırlıklarını ve gizli nöron önyargılarını rastgele seçer ve Moore Pensore genelleştirilmiş ters koşullara göre çıktı ağırlıklarını belirler (Kutlu ve diğerleri. 2015). Farklı sözde ters alma algoritmaları kullanılarak AÖM algoritmaları geliştirilmiştir. Gram-Schmidt Metod, Household Reflection, Hessenberg AÖM (HessAÖM) ve alt – üst üçgenleştirme (AÜELM) modeli bunlara örnektir (Altan ve diğerleri. 2018; Kutlu ve diğerleri. 2015; Kutlu ve diğerleri. 2019). Bu çalışmada kullanılan AÖM'deki nöron sayısı 300, 500, 700, 900, 1200, 1500, 3000 ve 5000 olarak belirlenmiştir.

### 3.6.3. Destek Vektör Makinesi

Destek vektör makinesi, en yakın eğitim örneği ile hiper düzlem arasındaki ayrımı maksimuma çıkararak en uygun hiper düzlem ayrımını bulmaya çalışır (Demir ve Ertürk, 2010). Literatürde de sıkça kullanılan bu sınıflandırma yöntemi regresyon olarakda işlem yapmaktadır. Kullanılan çekirdek fonksiyonun büyük bir öneme sahip olduğu bu yaklaşımda daha çok liner verileri sınıflandırmada kullanılır.



Düşük Boyutlu Doğrusal Olmayan Sınıflandırıcı

Yüksek Boyutlu Doğrusal Sınıflandırıcı

Şekil 3.11 Doğrusal ve doğrusal olmayan hiper uzayların sınıflandırılmasının gösterimi (Ukil, 2007)


Kullanılan veriye göre doğrusal ve doğrusal olmayan verilerin DVM ile sınıflandırılmasının gösterimi Şekil 3.7’de gösterilmiştir. DVM, çekirdek olarak adlandırılan matematiksel fonksiyonları kullanarak girdi olarak gelen veriyi istenilen şekile dönüştürür. Polinom, Gauss, Gauss radyal temel, Laplace radyal temel, hiperbolik tanjant, sigmoid ve tek boyutlu doğrusal spline fonksiyonlar kullanılmaktadır.

### 3.6.4. Çapraz Doğrulama

Mevcut örnek sayısının az olması nedeniyle genellikle bir sınıflandırma modelinin doğrulanması için çapraz doğrulama kullanılır. Eğitim, doğrulama ve test setine ayrılma çoğu zaman mümkün olmadığından, çapraz doğrulama verilerin daha iyi kullanılmasını sağlar (Westerhuis ve diğerleri 2008). Bu çalışmada yapılan çapraz doğrulama işlemi kullanılan veri setinde ki dağılımın düzgün olmasa da kullandığı her verinin düzgün olarak dağılması için istenilen sayıda alt parçaya böler. Veri setini k parçaya böler ve k-1 adet test bölümü ayırır daha sonra bu eğitim ve test bölümleri değiştirerek daha doğru bir dağılımla sınıflandırma yapılması sağlanmış olur.



Şekil 3.11'deki tabloda yer alan değerlere göre yapılan işlem gerçek pozitif ve gerçek negatif tahminlerin tüm tahminlere oranının belirlenmesidir. “Örnek pozitifse ve pozitif olarak sınıflandırılmışsa, gerçek pozitif (GN) olarak atanır; negatif olarak sınıflandırılırsa, yanlış negatif (HN) olarak atanır. Örnek negatifse ve negatif olarak sınıflandırılmışsa, gerçek negatif (GN) olarak atanır; pozitif olarak sınıflandırılırsa, yanlış pozitif (HP) olarak atanır” (Kutlu, 2010).



Şekil 3.12 Doğruluk Matrisi

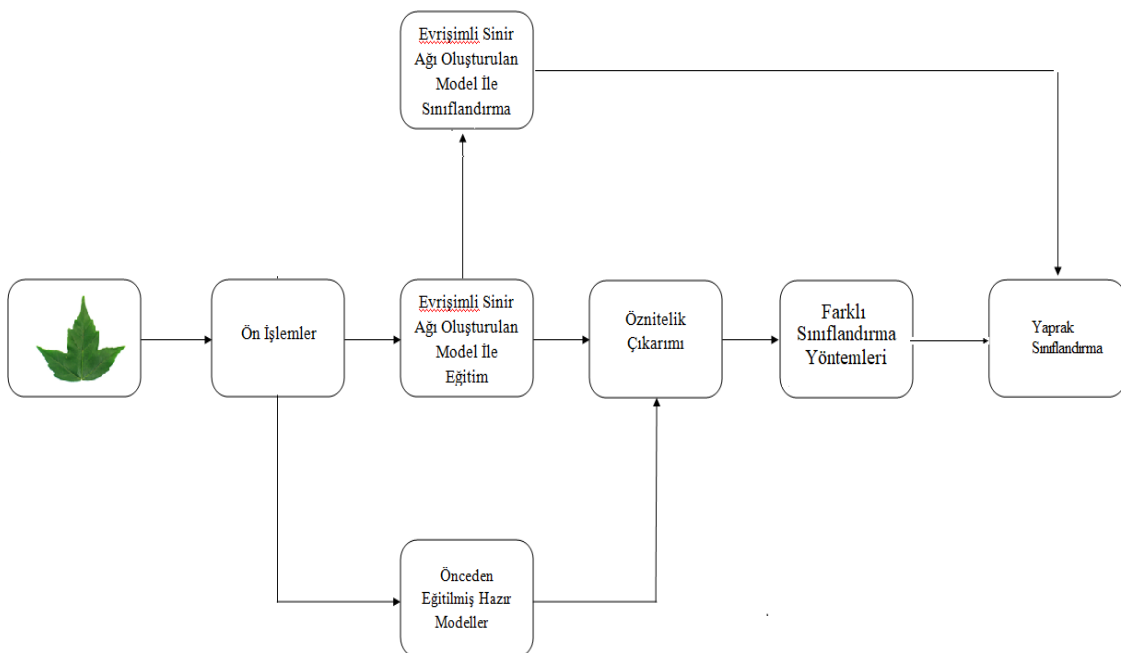
Bu çalışmada kullanılan başarımlı hesaplama formülü aşağıda gösterilmektedir.

$$Başarımlı = \frac{Gerçek\ Pozitif}{Gerçek\ Pozitif + Gerçek\ Negatif + Hatalı\ Pozitif + Hatalı\ Negatif} \times 100 \quad (3.5)$$

#### 4. ARAŞTIRMA BULGULARI

Bu bölümde farklı veri setlerinin ve bu veri setlerinin birleştirilmiş halinin sınıflandırma öncesi yapılan ön işlemleri, evrişimli sinir ağı modelini, evrişimli sinir ağı ile yapılan yaprak sınıflandırmadan bahsedilecektir. Yapılan ESA eğitiminde açık kaynak kodlu, python, C++, Java gibi farklı programlama dillerini destekleyen tensorflow kütüphanesi kullanılmıştır. Python ile yazılan kodlar, AMD Ryzen 5 3600x işlemci, Nvidia GTX 1080 ekran kartı ve 32 gigabayt sistem belleğine sahip bir bilgisayarda çalıştırılmıştır.

Bu çalışmada 2 farklı yaklaşım uygulanmıştır. Birinci yaklaşımda yeni bir ESA modelinin oluşturulması, eğitilmesi ve test sonuçlarının alınmasıdır. Diğer yaklaşımda ise oluşturulan ESA modeli ve önceden eğitilmiş ESA modelleri kullanılarak öznelik öğrenimi yaklaşımıyla öznelik transferi yapılmakta ve elde edilen öznelik vektörleri farklı sınıflandırıcılarla (EYKA, DVM, AÖM) sınıflandırma performansları incelenmiştir. 5 farklı veri seti için ayrı ayrı değerlendirilerek sonuçlar alınmıştır. Veri setleri birleştirilerek ortak bir birleşik veri setine dönüştürülmüş ve bu birleşik veri seti için aynı işlemler yapılarak sonuçlar alınmıştır. Farklı sınıflandırma yöntemleri ile elde edilen sonuçlar literatürdeki çalışmalarla karşılaştırılmıştır. Yapılan çalışmanın şematik gösterimi Şekil 4.1'de gösterilmektedir.



Şekil 4.1. Yapılan çalışmanın şematik gösterimi

#### 4.1. Ön İşlemler

Yapılan çalışmada veri setlerinin belirlenmesi için literatür taraması yapılmış ve kullanılan veri setleri, farklı yaklaşımlar, kullanılan yöntemle yapılan çalışmalar ve veri setlerinin birleştirilerek ortak tek bir veri setinin nasıl sonuçlar vereceği incelenmiştir. Bu araştırmanın ışığında kullanılabilir veri setleri seçilmiştir. Tüm veri setleri birleştirilerek elde edilen veri seti oluşturulurken diğer veri setlerinin evrişimli sinir ağı ile eğitimi için gerekli ön işlemler yapılmıştır. Daha sonra bu veri setlerindeki 283 tür tekrardan gözden geçirilip veri setlerindeki ortak türlerin birleşimi ile oluşturulan veri setinin son hali ortaya çıkarılmıştır. Ayrıca birleştirilmiş veri setinde tüm görüntülerin arka plan renginin aynı olması için arka plan rengi beyaz olmayan görüntüler içeren veri setlerine arka plan çıkartılması işlemleri uygulanmıştır. Yapılan birçok çalışmada kullanılan veri setlerinin eğitimin daha iyi yapılması için veri çoğaltma, görüntü boyutunun belirlenmesi, uygun olmayan verileri çıkarma gibi pek çok işlem yapılmıştır. Ayrıca kullanılan verilerin farklı arka plan, farklı boyut ve çekilen fotoğrafların farklı ölçekte olması bu işlemlerin yapılmasını zorunluluk haline getirmiştir. Sonuç olarak yapılan ön işlemler sonrası veri çoğaltma işlemi ile birlikte elde edilen görüntü sayısı Çizelge 4.1’ de gösterilmiştir. Veri setleri sınıflandırmaya hazırlanmadan önce her veri setindeki görüntülerin aynı boyutta olması gerekir. Ayrıca görüntü boyutu büyüklüğünün etkisini incelemek anlamında 3 farklı görüntü boyutu için analizler yapılmıştır.

Çizelge 4.2. Veri çoğaltma sonrası veri setlerinin toplam görüntü sayısının detaylı gösterimi

Veri Seti	Tür Sayısı	Görüntü Sayısı	Veri Çoğaltma Sonrası Görüntü Sayısı
Mendeley	12	4 149	52 624
Swedish Leaf	15	1 125	13 500
Flavia	32	1 907	22 877
UCL	40	443	10 632
Leafsnap	184	11 234	57 966
<b>Birleşmiş Veri Seti</b>	<b>270</b>	<b>18 858</b>	<b>62 424</b>

## 4.2. Sınıflandırma


Bu çalışmada belirlenen veri setlerinin düzenlenmesi, bu veri setlerinin çeşitli ön işlemlerden geçirilmesi ve kullanılan verinin çoğaltılması gibi aşamalardan sonra kullanılacak modelin tüm veri setlerinin birlikte sınıflandırılması da düşünülerek ve yapılan çalışmalardan elde edilen geri dönüşler sonucunda evrişimli sinir ağı ile yaprak sınıflandırması yapılmıştır.

### 4.2.1. Uygun Model Belirlenmesi

Bu çalışmada kullanılan model, “Analiz için, evrişimli sinir ağı ile yaprak sınıflandırmasında havuzlama etkisini göstermek için farklı sayıda havuzlama kullanılmıştır. Ayrıca, bu çalışmada maksimum havuzlama ve ortalama havuzlama olmak üzere iki havuzlama yöntemi kullanılmıştır” (Camgözlü ve Kutlu, 2019).

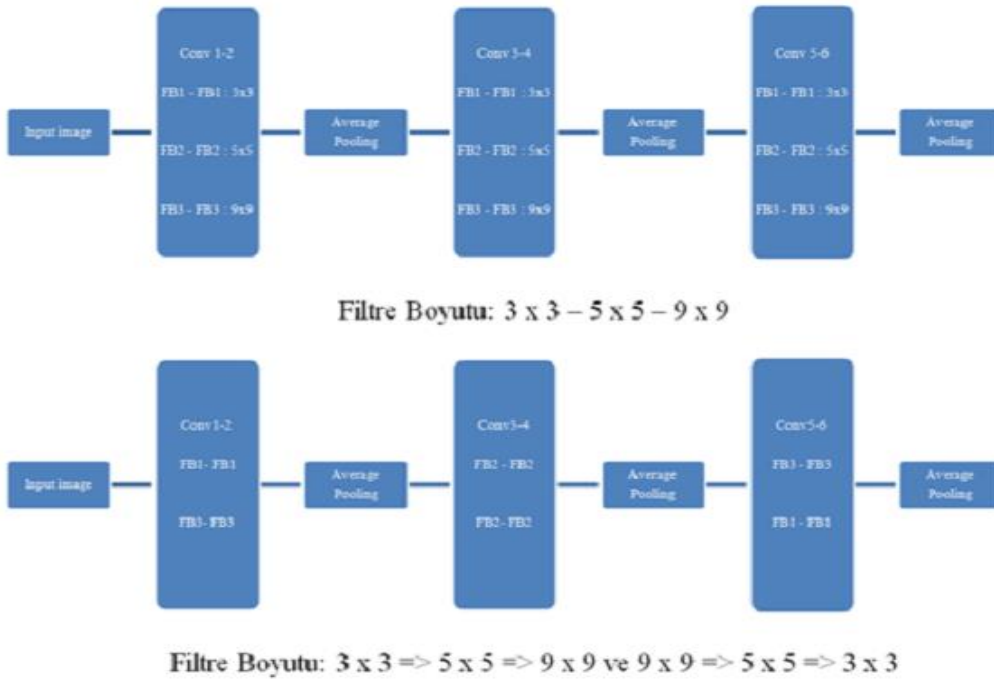
Leafsnap veri setinin field adlı bölümünden seçilen görüntülerden belirli sayıda türün kullanıldığı bu çalışma sonucu elde edilen verilere göre belirlenmiştir. Başarıma bağlı sonuçlara bakarsak havuzlama sayısını 3 alırken konvolüsyon katmanı sayısı ise 6 olarak belirlenmiştir.

Evrişimli sinir ağı ile yaprak sınıflandırma da havuzlama etkisinin sonuçları Şekil 4.2’de gösterilmiştir. Bu sonuçlara göre kullanılan model oluşturulmuştur. 6 konvolüsyon katmanı ve 3 ortalama havuzlama katmanı olan bir model belirlenmiştir (Camgözlü ve Kutlu, 2019). Ortalama havuzlama, maksimum havuzlamaya göre daha iyi sonuç verdiği için seçilmiştir, daha başarılı olan 2 havuzlama katmanlı model yerine 3 havuzlama katmanlı modelin kullanılmasının nedeni daha çok tür ve daha çok verinin bulunmasıdır. Bunun yanı sıra kullanılan filtrelerin boyutları da aynı şekilde belirlenmiştir. Havuzlama yöntemi olarak da yine başarı oranına bakılarak ortalama havuzlama seçilmiştir. Son olarak sınıflandırma fonksiyonu olarak softmax kullanılmıştır.



Şekil 4.2. Evrişimli sinir ağı ile yaprak sınıflandırmada havuzlama etkisi

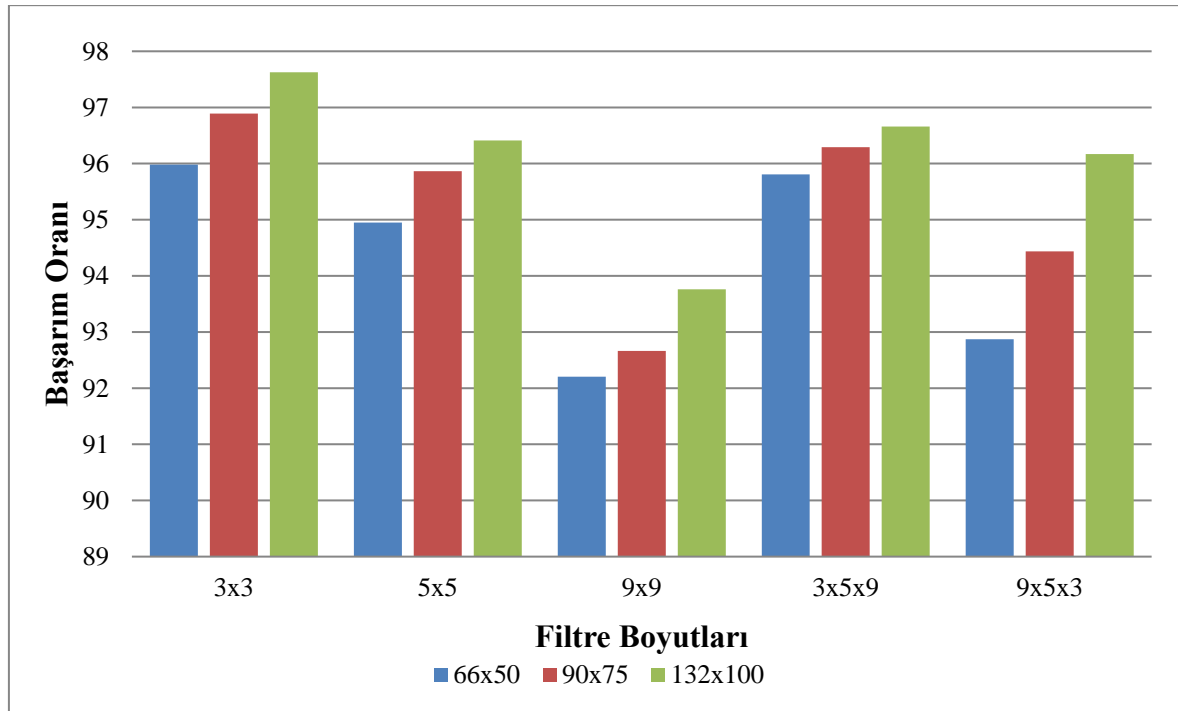
Konvolüsyon filtre boyutu analizi için kullanılan model ve bu modelin filtre boyutlarının detaylı gösterimi Şekil 4.3’de gösterilmiştir. Literatürde kullanılan pek çok veri setinin incelenmesi ve çeşitli denemeler yapılması sonrası 6 farklı veri setinden elde edilen sonuçlara göre ölçekleme bağımsız sadece döndürme işlemi uygulanmış görüntülerde farklı filtre boyutlarının denenmesi sırasında 3x3 boyutlu filtre için sonuçlar uygundur.



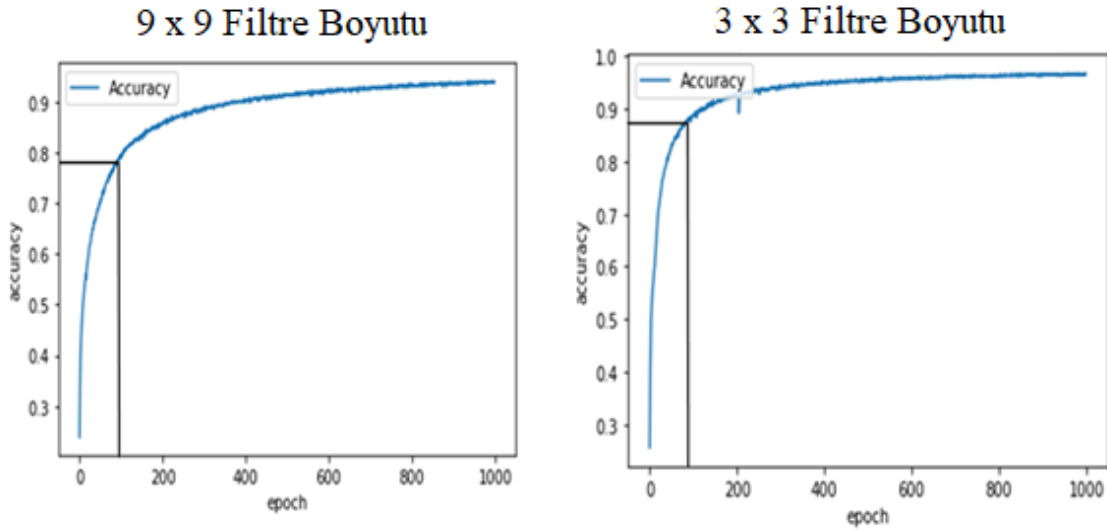
Şekil 4.3. Modelde yapılan farklı filtre boyutu denemelerinin gösterimi

Konvolüsyon filtre boyutu incelemesinde 12 yaprak türü ve 4404 adet sabit arka plan üzerinde yaprak görüntüsünden oluşan Mendeley veri setinin kullanılarak modeldeki konvolüsyon katmanlarının filtre boyutları 3 farklı değer ve 3 farklı şekilde düzenlenmiştir. Yapılan değişiklikler Şekil 4.3’de gösterilmektedir. 6 adet konvolüsyon katmanının her biri 3, 5 ve 9 filtre boyutlu olarak kullanılmıştır. Filtre boyutu farklılıklarının oluşturduğu etkiyi belirlemek için belirlenen 3 farklı filtre boyutu her konvolüsyonda ayrı modeller oluşturularak kullanılmıştır. Ayrıca filtre boyutundaki artış ve azalışın olduğu durumlarda ise her 2 konvolüsyon katmanından sonra filtre boyutları artırılmış ya da azaltılmıştır. Farklı havuzlama sayısı, farklı havuzlama türü ve farklı konvolüsyon filtre boyutu gibi parametreler üzerinden oluşturulmuştur (Camgözlü ve Kutlu, 2020a). Farklı veri setleri ve bu veri setlerinin birlikte kullanıldığı için yapılan çalışmaların bu modelin oluşturulmasında büyük yararı olmuştur.

Şekil 4.4’deki sonuçlara göre 3 farklı görüntü boyutunda, filtre boyutundaki artışın başarımı olumsuz etkilediği görülmektedir. Ayrıca aynı modelde farklı konvolüsyon katmanlarındaki filtre boyutlarının artışının (3 - 5 - 9) başarımı çok az azalttığı görülürken bu filtre boyutlarının azalışının (9 - 5 - 3) başarımı daha fazla düşürdüğü görülmektedir.

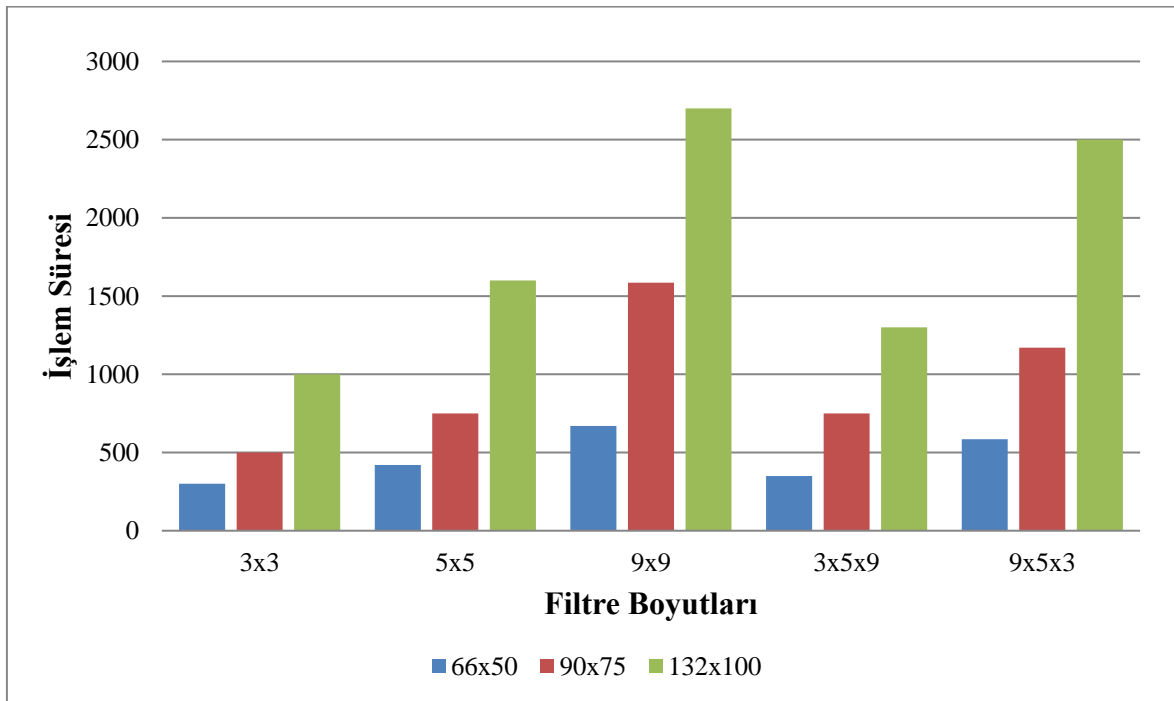


Şekil 4.4. Mendeley veri setinde ki 66 x 50 – 90 x 75 – 132 x 100 boyutlu görüntülerin filtre boyutu değişimine göre elde edilen sonuçların ortalaması



Şekil 4.5. 132 x 100 boyutlu görüntüler için 9 x 9 ve 3 x 3 filtre boyutlu modellerin 100 iterasyonda elde edilen başarımlarını karşılaştıran grafik

2 farklı görüntü boyutunda filtre boyutunun 100 iterasyona ulaşma hızının değişimini gösterilmiştir. (Bkz. Şekil 4.4) Şekil 4.5'e göre düşük filtre boyutunun daha yüksek başarımlara ulaştığı görülmektedir. İterasyon sayısını belirlerken (Bkz. Şekil 4.5) başarımlar devamlı artmaktadır. Bu sebeple ESA eğitiminde (Bkz. Çizelge 4.2) iterasyon sayıları belirlenmiştir.

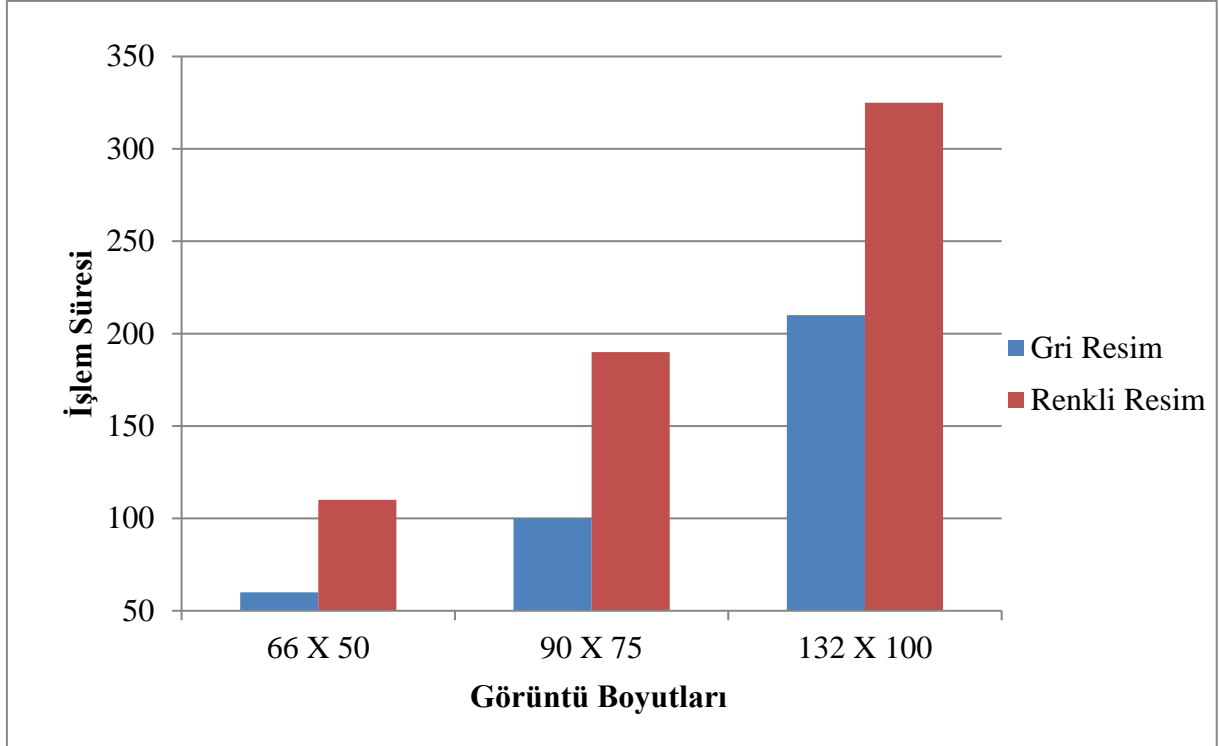


Şekil 4.6. Mendeley veri seti kullanılarak 66 x 50 – 90 x 75 – 132 x 100 boyutlu resimlerin farklı filtre boyutlarında ki işlem süresinin dakika olarak süre karşılaştırması

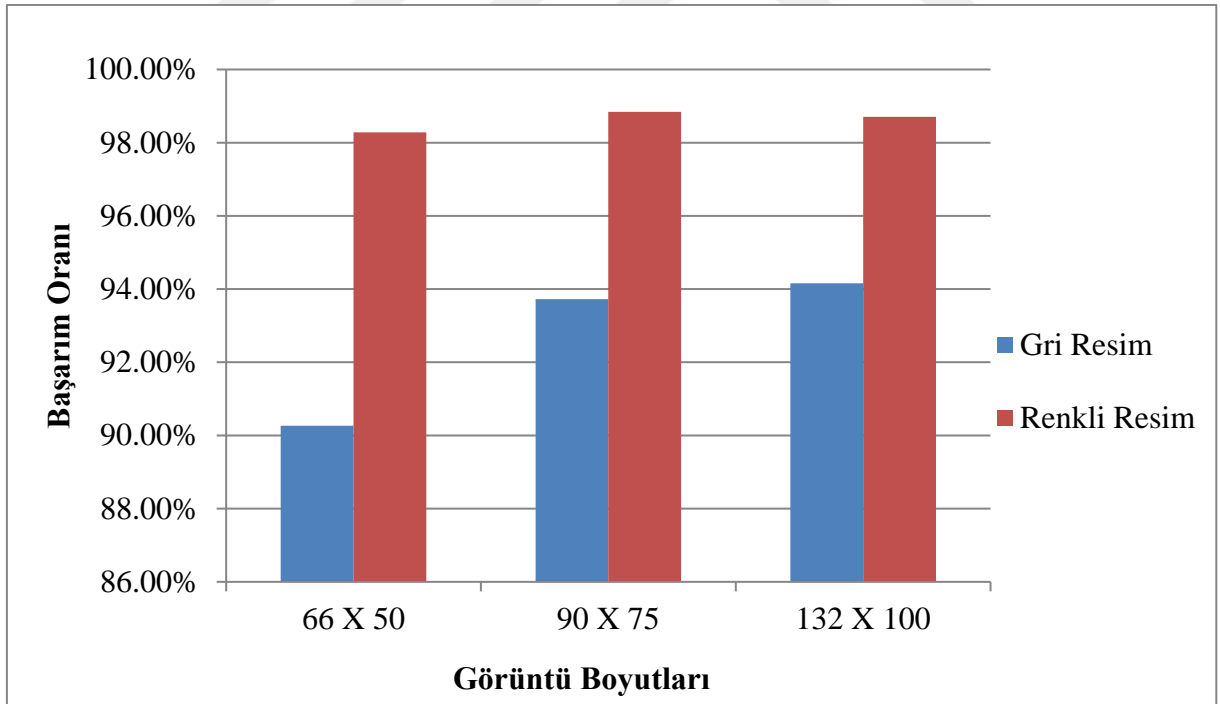
(Bkz. Şekil 4.6) Grafik doğrultusunda, görüntü boyutunda ki artış ile işlem sürelerinin artışının bağlantılı olması beklenen bir sonuç iken elde edilen başarımların gösterildiği grafiğe bakıldığında düşük filtre boyutu için daha yüksek başarıma sahip olduğu görülmektedir. Ek olarak filtre boyutundaki değişimlerin işlem süresine olan etkisi düşük filtre boyutunun kullanılmasında önemli bir etken olmuştur. Yapılan çalışma sonucu elde edilen sonuçlara göre filtre boyutunun azaltılması hem başarımın artmasına, başarıma ulaşma süresinin kısalmasına ve düşük filtre boyutunun bir sonucu olarak yapılan işlemin daha kısa sürmesini sağlamaktadır. Görüntü boyutu arttıkça başarımın artacağı beklenirken, elde edilen işlem süreleri bu başarım değerlerini değerlendirmede büyük öneme sahiptir. Özellikle düşük donanımla yapılan veya çok fazla tekrar gerektiren durumlarda işlem süresinin kritik olduğu su götürmez bir gerçektir.

Renkli, gri resim farkı ve beyaz arka plan ile renkli arka plan farkının 3 farklı görüntü boyutu için elde edilen sonuç grafiklerine baktığımızda (Bkz. Şekil 4.7, Şekil 4.8) Şekil 4.9'da görüntü boyutu artışı ile işlem süresi artışının gri resimlere oranla renkli resimlerde daha fazla olduğu görülmektedir. Gri ve renkli resimler kullanılarak elde edilen başarımlara göre hem beyaz hem de renkli arka planlı görüntülerde renkli resimlerde bulunan fazla sayıdaki veri nedeniyle görüntü boyutu değişimi sonucu elde edilen başarım farkı çok az olmuştur. Beyaz ve renkli arka planlı görüntülerle elde edilen sonuçlara göre, kullanılan Mendeley veri setindeki görüntülerin arka plan renginin çok sayıdaki ışık kaynağı nedeniyle değişiklik göstermiştir. Bu sebeple renkli resim sonuçlarında daha bariz bir şekilde ortaya çıkan yaprak dışındaki farklı resim bölgeleri de tanınarak başarım oranı artmıştır.






Şekil 4.7. Farklı arka plan rengine sahip yaprak görüntüleri için 3 farklı boyutta yapılan eğitimlerin dakika olarak işlem süresi kıyaslaması

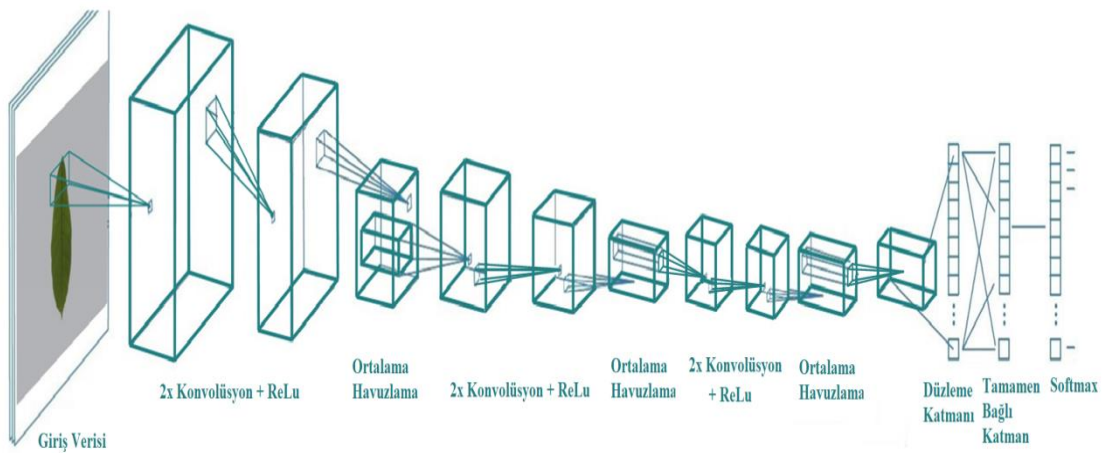


Şekil 4.8. Renkli arka planlı yaprak görüntülerinin 3 farklı görüntü boyutu ve renkli görüntüler için ortalama başarımların kıyaslaması



Şekil 4.9. Beyaz arka planlı yaprak görüntülerinin 3 farklı görüntü boyutu için ortalama başarımların karşılaştırılması

Şekil 4.10'da bu çalışmada kullanılan veri setlerinin evrişimli sinir ağı ile sınıflandırmada kullanılan modelin detaylı gösterimi bulunmaktadır. Oluşturulan modele baktığımızda 6 konvolüsyon katmanı ve 3 ortalama havuzlama katmanından oluşmaktadır.



Şekil 4.10. Evrişimli sinir ağı ile sınıflandırma yapılan model detaylı gösterimi

Yapılan çalışmalar sonucu elde edilen veriler ışığında konvolüsyon filtre boyutu 3 olarak belirlenmiş olup 90x75 görüntü boyutu ve gri renkli resimler ile eğitim yapılmıştır. Sınıflandırma işleminde tür, görüntü sayısı ve iterasyon ilişkisi Çizelge 4.3'de özetlenmiştir. Yapılan denemeler sonucunda elde edilen iterasyon sayısı değerlerine ve başarımlarına bakıldığında daha yüksek başarımlar elde etmek için gereken iterasyon sayısı, belirlenenden çok daha fazla olduğu evrişimli sinir ağı ile sınıflandırma sırasında yapılan gözlemler ve başarımlarına dayanarak öngörülmüştür. Buna bağlı olarak da minimum iterasyon, maksimum başarımlar için optimum iterasyon değerleri seçilmiştir.

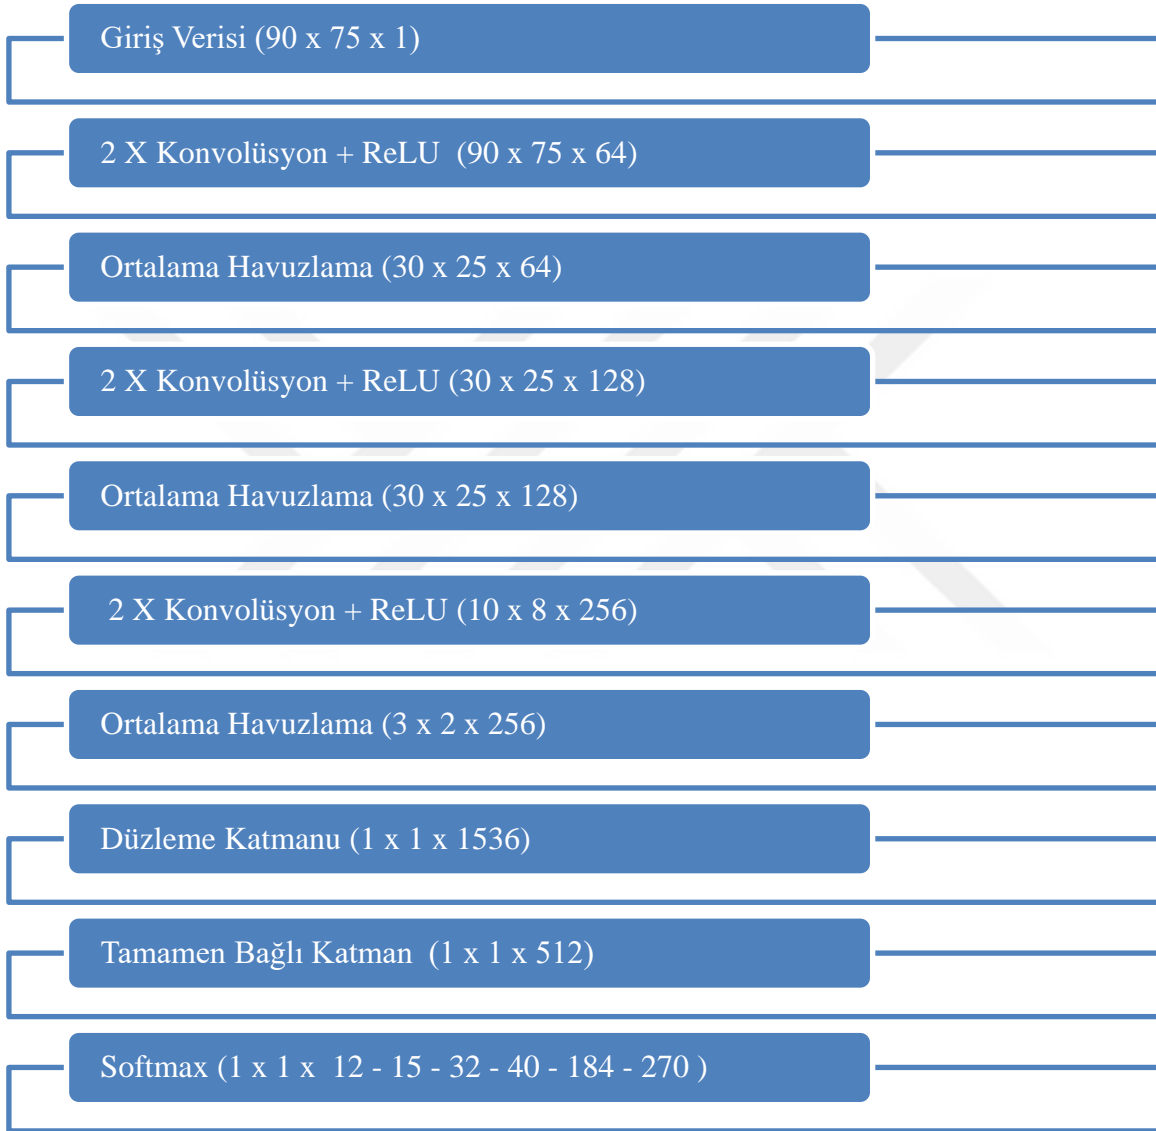
Çizelge 4.3. Evrişimli sinir ağı ile yaprak sınıflandırma da tür, görüntü sayısı ve iterasyon sayısı

Veri Seti	Tür Sayısı	Görüntü Sayısı	İterasyon Sayısı	Filtre Boyutu	Görüntü Boyutu
Mendeley	12	52 624	2 000	3 x 3	90 x 75
Swedish Leaf	15	13 500	10 000	3 x 3	90 x 75
Flavia	32	22 877	5 000	3 x 3	90 x 75
UCL	40	10 632	20 000	3 x 3	90 x 75
Leafsnap	184	57 966	10 000	3 x 3	90 x 75
<b>Birleşmiş Veri Seti</b>	<b>270</b>	<b>62424</b>	<b>5 000</b>	<b>3 x 3</b>	<b>90 x 75</b>

#### 4.3.1. Oluşturulan Modelin Kullanımı

Bu çalışma sırasında oluşturulacak modelin farklı parametreleri değiştirilerek en ideal modelin elde edilmesi için birçok deneme yapılmıştır. Sonuç olarak elde edilen model kullanılarak 5 farklı veri seti ve bu veri setlerinin birleştirilmiş hali için az miktarda iterasyon ile yüksek başarımlar elde edilmesi amaçlanmıştır.

Şekil 4.11’de detaylı olarak gösterilen modele baktığımızda renkli olmayan 90x75 boyutlu görüntülerin kullanıldığı ve kademeli olarak küçültülen ve bu işlem sırasında elde edilen özellikleri sonra ki katmanlara aktaran bu yapı da son katman sınıflandırılacak tür sayısına göre değişiklik göstermektedir.



Şekil 4.11. Evrişimli sinir ağı ile sınıflandırma yapılan modelin 90x75 boyutlu görüntü kullanımının detaylı gösterimi

### 4.3.2. Önceden Eğitilmiş Hazır Modellerin Kullanımı

Kullanılan önceden eğitilmiş modellerin görüntü boyutları ve renkli resim olarak işlem görmelerinin nedeni, bu modellerin ImageNet (Deng ve diğerleri, 2009) ile eğitilmiş olmasıdır.

Belirlenen önceden eğitilmiş hazır modeller ve bu çalışmada evrişimli sinir ağı ile sınıflandırma yapmak için oluşturulan model karşılaştırılması Çizelge 4.4’de gösterilmektedir. Düzleme katman boyutu farkının çok fazla olduğu görülmektedir. Bunun sebeplerinden biri kullanılan görüntü boyutunun fazla olması ve renkli resimler ile işlem yapılmasıdır. Ayrıca önceden eğitilmiş modellerin çok fazla katmana sahip olması da bu farkın ortaya çıkmasında etkili olmuştur. Düzleme katmanı öncesi görüntünün küçülerek geldiği son boyut ve son konvolüsyon katmanındaki farklılıklarda kullanılan hazır modeller ve oluşturulan modelin düzleme katmanındaki farkı açıkça ortaya koymaktadır.

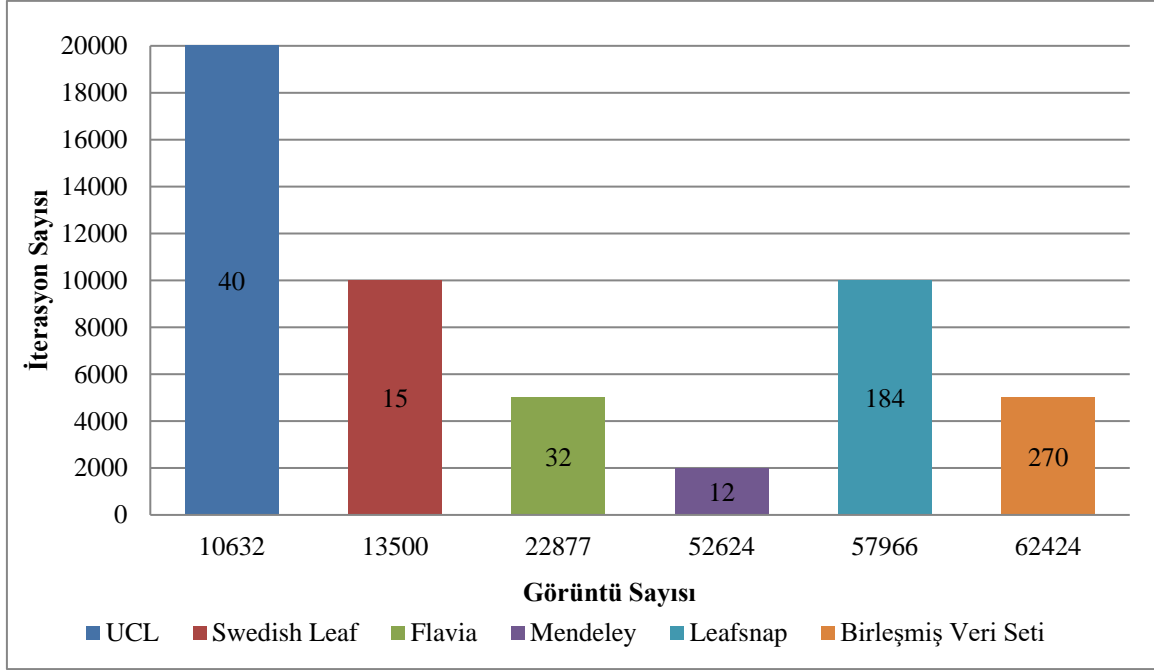
Çizelge 4.4. Oluşturulan model ile önceden eğitilmiş hazır modellerin görüntü boyutu, düzleme katman boyutu gibi parametrelerin karşılaştırılması

Model Adı	Düzleme		Düzleme Katmanı Öncesi
	Katman Boyutu	Görüntü Boyutu	
VGG16	8 192	128 x 128 x 3	4 x 4 x 512
InceptionV3	8 192	128 x 128 x 3	2 x 2 x 2048
MobileNet	16 384	128 x 128 x 3	4 x 4 x 1024
DenseNet121	16 384	128 x 128 x 3	4 x 4 x 1024
<b>Oluşturulan Model</b>	<b>1 536</b>	<b>90 x 75 x 1</b>	<b>3 x 2 x 256</b>

## 5. SONUÇ VE ÖNERİLER


Bu çalışmada, yaprak görüntülerinden oluşan veri setlerinin evrişimli sinir ağı ile sınıflandırılması gerçekleştirilmiştir. 5 veri seti ve bu veri setlerinin birleştirilerek elde edilen veri setlerinin tür sayısı, veri setinde bulunan görüntü sayısı ve yapılan denemeler ile elde edilen sonuçlar değerlendirilerek iterasyon sayısı belirlenmiş ve sınıflandırma yapılmıştır. Evrişimli sinir ağı ile yapılan bu sınıflandırma işleminin literatürdeki diğer yöntemler ve evrişimli sinir ağı kullanan yaprak sınıflandırma çalışmalarının kıyaslaması yapılmıştır. Ayrıca evrişimli sinir ağı eğitimi sonrası öznitelik dönüşümü yaklaşımı ile elde edilen verilerin EYKA, DVM ve AÖM ile sınıflandırılması sonucu elde edilen veriler değerlendirilmiştir. Son olarak 4 farklı önceden eğitilmiş hazır modellerin ImageNet ağırlıkları kullanılarak elde edilen özelliklerinin EYKA, DVM ve AÖM ile sınıflandırılmış, elde edilen sonuçlar diğer sınıflandırma başarımlarıyla ve literatürdeki çalışmalarla kıyaslanmıştır.

Yapılan sınıflandırma işleminde tür, görüntü sayısı ve iterasyon sayısı (Bkz. Çizelge 4.3) verilmiştir. Bu veriler arasındaki ilişki ise (Bkz. Şekil 5.1) gösterilmiştir. Bu verilere göre görüntü sayısı arttıkça iterasyon sayısının genel olarak azaldığı görülmüştür. Tür sayısının çok az, görüntü sayısının ise çok fazla olmasından dolayı daha az iterasyonla daha yüksek başarımlar elde edilen istisnai durum Mendeley veri setine özgüdür. Leafsnap ve tüm veri setlerinin birleşiminin tür sayısı fazla olmasına rağmen iterasyon sayısı azdır. Bunun sebebi yüksek işlem gücü ve buna bağlı olarak mevcut kullanılan sistem ile yapılacak yüksek iterasyon sayılı eğitimin çok uzun süreceği öngörülerek makul bir iterasyon sayısı kararlaştırılmıştır.




Şekil 5.1. Evrişimli sinir ağı ile yaprak sınıflandırma da iterasyon sayısı, görüntü sayısı ve tür sayısı arasındaki ilişki

Ortalama görüntü sayısı ile bu veriler arasındaki ilişki (Bkz. Şekil 5.2) gösterilmiştir. Tür başına düşen ortalama görüntü sayısı Leafsnap, UCL ve birleşmiş veri setinin sınıflandırılmasında daha çok iterasyona ihtiyaç olduğunu göstermektedir. Detaylandırmak gerekirse, 40 tür ile 266 ortalama görüntü sayısına sahip UCL veri seti ve 32 tür başına ortalama 715 görüntü sayısının bulunduğu Flavia veri setini baktığımızda görüntü sayısı dağılımının çok daha iyi olması 4 kat daha az iterasyonla benzer başarımlar sağlanmasına yol açmıştır. Mendeley veri seti içinse durum tam tersidir. Leafsnap ve birleşmiş veri seti gibi yüksek tür sayısına, düşük ortalama görüntü sayısına sahip veri setlerinin yüksek iterasyon ile işlem görmemesinin nedeni veri çoğaltma ile her tür için görüntü sayısını artırılarak daha iyi bir eğitim yapılmasıdır. Buna ek olarak kullanılan modelin, filtre boyutu, havuzlama katman sayısı gibi parametrelerinin optimize edilmesi ve veri setlerindeki görüntülere uygulanan ön işlemlerdir. Bu işlemler sonucunda çalışmanın amaçlarından biri olan az iterasyonla yüksek başarımların sağlanması ve yapılan eğitim sonucu farklı sınıflandırma yöntemlerinde yüksek başarımların sağlanmasıdır. Flavia ve Swedish Leaf gibi ortalama görüntü sayısı kısmen yüksek olup tür sayısının az olması bu veri setlerinin düşük iterasyonda yüksek başarımlara ulaşmasını sağlamıştır.



Şekil 5.2. Evrişimli sinir ağı ile yaprak sınıflandırmada iterasyon sayısı, ortalama görüntü sayısı ve tür sayısı arasındaki ilişki

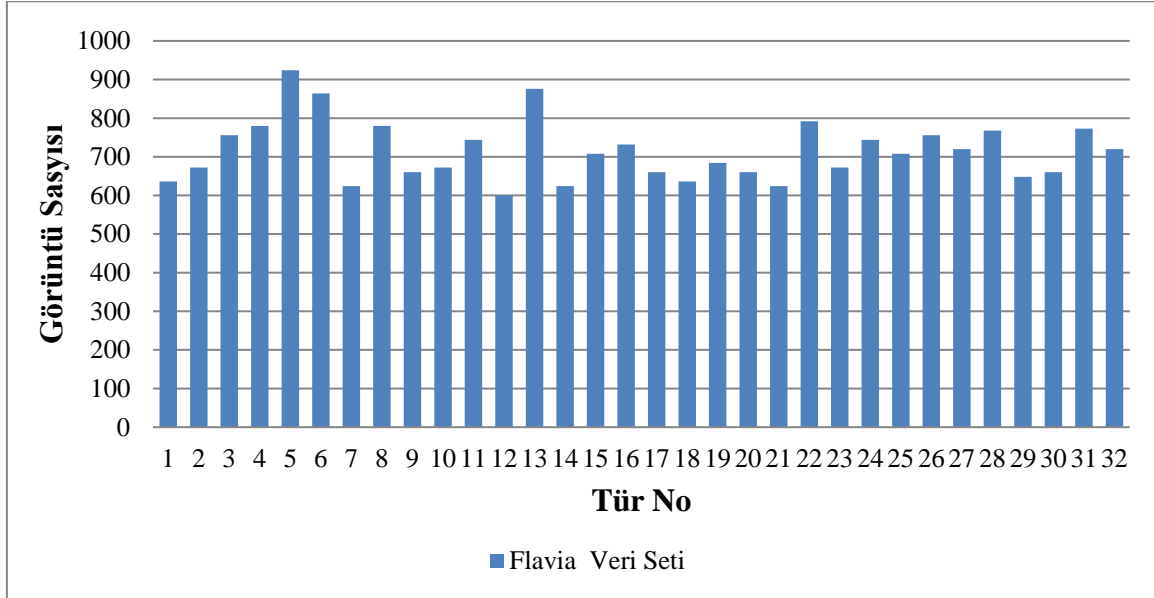
Şekil 5.3'deki dağılım genel olarak düzgün olsa da tür sayısının fazlalığı ve Flavia, Mendeley ya da Swedish Leaf veri setlerine oranla ortalama görüntü sayısının daha az olması istenilen başarımın elde edilebilmesi için daha fazla iterasyon gerekmesine neden olmuştur. Ayrıca veri setinde bulunan düşük görüntü sayısına sahip türlerin olması da düşük iterasyonda yüksek başarım elde edilmesini zorlaştırmaktadır.



Şekil 5.3. Leafsnap veri setinin her tür için görüntü sayısı dağılımı

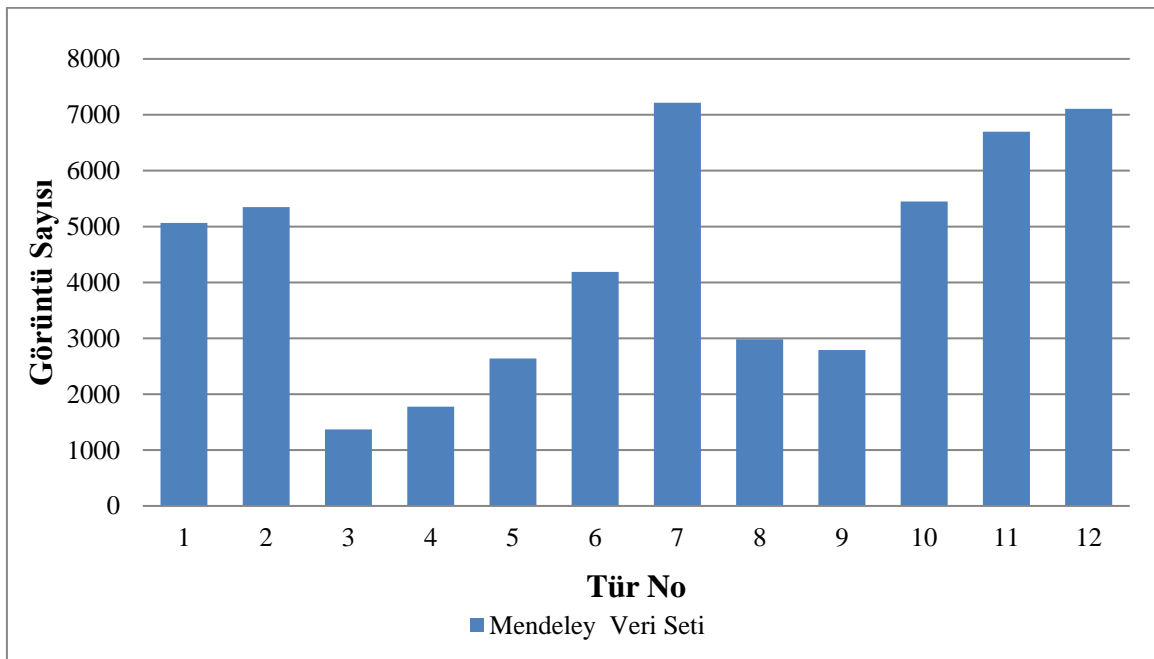


Şekil 5.4'deki verilere göre dağılımın kısmen düzgün olması ve ortalama görüntü sayısının Swedish Leaf veri setine yakın olması daha fazla türü olmasına rağmen Flavia veri setinin daha az iterasyonla iyi bir başarıyı yakalamasını sağlamıştır.




Şekil 5.4. Flavia veri setinin her tür için görüntü sayısı dağılımı

Mendeley veri setinde ki türlerin görüntü dağılımı Şekil 5.5'de gösterilmiştir. Görüntü sayısının fazla, tür sayısının az olması bu dağılım düzgün olmasa da iterasyon sayısının azaltılmasını sağlamıştır.



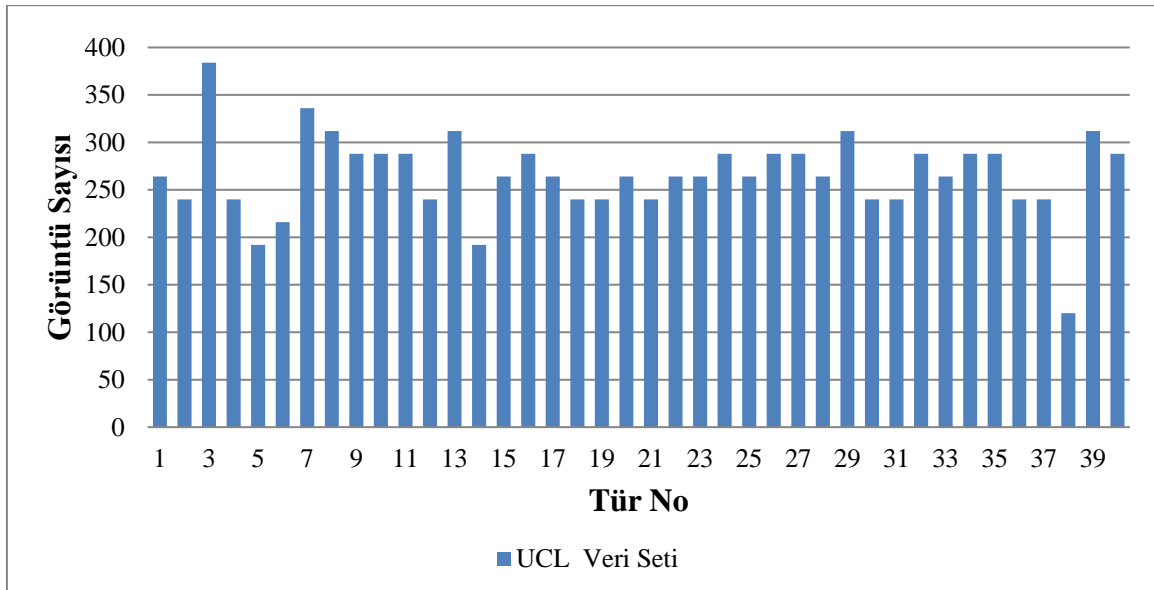
Şekil 5.5. Mendeley veri setinin her tür için görüntü sayısı dağılımı

Şekil 5.6’da Swedish Leaf veri setinin türlere göre görüntü sayısı dağılımı verilmiştir. Bu verilere baktığımızda dağılımın düzgün olduğu görülürken, görüntü sayısı Mendeley veri setine oranla az olmasından dolayı iterasyon sayısı daha fazla olmuştur.




Şekil 5.6. Swedish Leaf veri setinin her tür için görüntü sayısı dağılımı

Şekil 5.7’ye bakıldığında dağılımın bazı türler haricinde yakın olmasına karşın görüntü sayısı ve ortalama görüntü sayısının düşük olması yüksek iterasyon sayısı ile yüksek bir başarı elde edilmesini sağlamıştır.



Şekil 5.7. UCL veri setinin her tür için görüntü sayısı dağılımı

Şekil 5.8'deki tüm veri setlerinin görüntü sayısı dağılımının kısmen dengeli olmaması ve ortalama görüntü ayısının az olması düşük iterasyon da iyi bir başarımlı sağlanmasının nedenidir. Farklı veri setlerinde aynı türün bulunması toplanması bu türlerdeki görüntü sayısının diğer türlere göre daha fazla olmasına sebep olmuştur.



Şekil 5.8. Birleşmiş veri setinin halinin her tür için görüntü sayısı dağılımı

Yapılan sınıflandırma sonucu elde edilen başarımlı oranları Çizelge 5.1'de gösterilmiştir. Bu veriler ve iterasyon sayısı verileri göz önüne alındığında tür sayısının az, görüntü sayısının fazlalığı iterasyon sayısını ve buna bağlı olarak gerekli zamanı ciddi miktarda düşürmektedir. Mendeley, Swedish leaf, Flavia ve UCL veri setlerinin sonuçları bu durumu gözler önüne sermektedir. Birleşmiş veri setinin istatistiklerine bakıldığında seçilen veri setlerinin başarımlı oranlarının yüksekliği, türe oranla görüntü sayısının dağılımı ve sınıflandırmaya uygunluğu düşük iterasyonda yüksek başarımlı sağlamıştır.

Çizelge 5.1. Evrişimli sinir ağı ile yaprak sınıflandırma da tür, görüntü sayısı ve eğitim başarımları

Veri Seti	Tür Sayısı	Görüntü Sayısı	İterasyon Sayısı	Eğitim Başarımları Oranı	Test Başarımları Oranı
Mendeley	12	52 624	2 000	97,35	92,08
Swedish Leaf	15	13 500	10 000	98,94	90,87
Flavia	32	22 877	5 000	97,60	91,89
UCL	40	10 632	20 000	98,58	88,00
Leafsnap	184	57 966	10 000	95,50	86,78
<b>Birleşmiş Veri Seti</b>	<b>270</b>	<b>62 424</b>	<b>5 000</b>	<b>89,25</b>	<b>73,00</b>

ESA ile yapılan yaprak sınıflandırmasında öznitelik aktarma anlayışıyla çıkarılan öznitelik verileri kullanılarak EYKA ile yapılan sınıflandırma sonuçları Çizelge 5.2’de gösterilmiştir. Bu sonuçlara bakıldığında, EYKA sınıflandırma yöntemi için Mendeley veri setinin sınıflandırılmasında oluşturulan modelin, önceden eğitilmiş modellere göre daha başarılı olduğu görülmektedir. Bu veri setinin sağlıklı, hastalıklı yapraklardan oluşuyor olması ve bu veri setinde bulunan yüksek sayıdaki görüntüler kullanılarak modelin yüksek başarımla eğitilmesi diğer modellere göre daha iyi bir başarımları elde etmesini sağlamıştır. Görüntü ve tür sayısı arttıkça başarımları azalmaktadır, ayrıca Swedish Leaf ve Flavia gibi ortalama görüntü sayısı yüksek ve tür sayısı görece az olan veri setlerinin EYKA ile sınıflandırılmasında hazır modellerin daha iyi başarımları sağladığı görülmektedir (Bkz. Çizelge 4.3).

Çizelge 5.2. Öznitelik çıkarımı sonrası EYKA ile yapılan sınıflandırma sonuçları

Metot	Swedish					Tüm Veri Seti
	Mendeley	Leaf	Flavia	UCL	Leafsnap	
ESA + EYKA	<b>95,65</b>	97,32	97,21	89,48	<b>87,46</b>	<b>81,18</b>
InceptionV3 + EYKA	82,19	92,47	93,15	90,17	54,33	68,57
MobileNet + EYKA	89,09	<b>98,67</b>	<b>98,87</b>	<b>95,81</b>	62,53	75,31
VGG16 + EYKA	86,91	97,56	96,98	93,52	56,18	70,45
DenseNet121 +EYKA	89,00	97,15	96,77	95,80	61,22	75,55

Bu çalışma için oluşturulan modelin farklı veri setleri ile eğitimi sırasında modelden çıkarılan öznitelik vektörleri kullanılarak DVM ile sınıflandırma yapılmıştır. Elde edilen sonuçlar Çizelge 5.3’de görülmektedir. Bu sonuçlara baktığımızda literatürde de sıkça kullanılan MobileNet önceden eğitilmiş hazır modelin düşük tür sayısına sahip türler için en iyi başarımları yakaladığı görülmektedir. Tür sayısı arttıkça yapılan eğitimin başarımları olan etkisi göze çarpmaktadır.

Çizelge 5.3. Öznitelik çıkarımı sonrası DVM ile yapılan sınıflandırma sonuçları

Metot	Swedish				Leafsna p	Birleşmiş Seti
	Mendeley	Leaf	Flavia	UCL		
ESA + DVM	97,27	98,47	97,47	94,35	<b>91,71</b>	<b>86,00</b>
InceptionV3 + DVM	91,17	97,22	96,26	94,59	68,33	72,77
MobileNet + DVM	<b>97,74</b>	<b>99,82</b>	<b>99,56</b>	<b>98,78</b>	80,51	84,36
VGG16 + DVM	96,52	99,45	98,63	98,25	78,21	82,79
DenseNet121 + DVM	96,57	99,29	98,53	97,89	80,39	83,56

Bir diğer çalışmada kullanılan veri setlerinin farklı AÖM ile sınıflandırılması sonucu elde edilen sonuçları Çizelge 5.4’de görülmektedir. Bu çalışmada kullanılan tüm veri setleri için elde edilen sonuçların düşük tür sayısına sahip veri setleri için iyi olduğu görülmektedir. ESA eğitiminin ve önceden eğitilmiş modellerin kullanılan veri setleri için yaprak sınıflandırmada yüksek başarımlar sağlamıştır. Leafsnap ve birleştirilmiş veri seti için elde edilen başarımlara baktığımızda tür sayısının çok fazla olması başarımın kullanılan yöntemle göre değişiklik göstermesinde önemli bir rol oynamıştır. Mendeley veri setinin sonuçlarına baktığımızda ise başarımdaki ufak değişimlerin veri setinde bulunan hastalıklı yaprak görüntüleri etkili olmuştur.

Çizelge 5.4. Tüm veri setlerinin AÖM ile yapılan sınıflandırma başarımlarının detaylı gösterimi

Metot	Mendeley	Swedish			Leafsnap	Birleşmiş Veri Seti
		Leaf	Flavia	UCL		
ESA + AÖM	<b>95,33</b>	97,66	96,72	86,73	<b>84,51</b>	<b>78,05</b>
VGG16 + AÖM	87,75	97,62	94,95	92,46	57,70	67,24
InceptionV3 + AÖM	84,31	94,81	94,03	90,55	58,39	65,70
MobileNet + AÖM	93,53	<b>98,90</b>	<b>98,99</b>	<b>96,93</b>	69,64	77,05
DenseNet121 + AÖM	91,46	98,77	97,35	96,67	68,57	76,67

(Bkz Çizelge 5.5, Çizelge 5.6, Çizelge 5.7, Çizelge 5.8, Çizelge 5.9 ve Çizelge 5.10) Sonuçlara baktığımızda nöron sayısının artışı başarımı arttırırken hazır modellerin düzleme katman boyutunun başarımına etki ettiği görülmektedir. Ayrıca ESA ile yapılan eğitimde kullanılan modelden çıkarılan öznitelik verilerinin kullanılması da bazı istisnalar dışında iyi bir başarımlar sağlamıştır.

Çizelge 5.5. Mendeley veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi

Metot	300	500	700	900	1200	1500	3000	5000
ESA + AÖM	70,94	76,36	79,15	81,27	83,09	84,26	86,73	85,19
VGG16 + AÖM	61,07	68,25	71,83	74,77	77,57	79,43	84,52	87,35
InceptionV3 + AÖM	66,77	71,48	74,01	75,94	77,82	79,14	82,52	84,31
MobileNet + AÖM	74,68	80,71	83,71	85,46	87,53	89,05	91,97	<b>93,53</b>
DenseNet121 + AÖM	72,32	78,03	80,69	82,86	84,90	86,07	89,75	91,46

Çizelge 5.6. Swedish Leaf veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi

Metot	300	500	700	900	1200	1500	3000	5000
ESA + AÖM	92,09	94,38	95,24	96,10	96,61	96,97	97,66	97,41
VGG16 + AÖM	81,41	88,01	91,30	92,84	94,16	95,21	97,20	97,62
InceptionV3 + AÖM	84,84	88,20	90,15	91,55	92,46	93,62	95,06	94,81
MobileNet + AÖM	91,43	94,89	96,41	96,93	97,50	98,08	98,97	<b>98,90</b>
DenseNet121 + AÖM	90,96	93,91	95,72	96,19	97,00	97,59	98,70	98,77

Çizelge 5.7. Flavia veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi

Metot	300	500	700	900	1200	1500	3000	5000
ESA + AÖM	85,29	89,37	90,93	92,17	93,25	94,27	95,76	96,72
VGG16 + AÖM	70,65	79,78	84,12	87,15	89,94	91,18	94,62	95,94
InceptionV3 + AÖM	79,37	84,06	86,63	87,87	89,78	90,63	93,08	94,36
MobileNet + AÖM	88,16	92,92	94,93	96,12	96,98	97,47	98,46	<b>98,99</b>
DenseNet121 + AÖM	84,42	89,24	91,18	92,75	94,06	94,78	96,57	97,35

Çizelge 5.8. UCL veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi

Metot	300	500	700	900	1200	1500	3000	5000
ESA + AÖM	70,94	76,36	79,15	81,27	83,09	84,26	86,73	85,19
VGG16 + AÖM	67,30	77,10	81,66	84,72	87,00	88,60	92,01	92,46
InceptionV3 + AÖM	76,05	81,50	84,25	85,60	87,48	88,75	90,55	89,55
MobileNet + AÖM	83,01	88,47	91,72	92,42	93,74	94,31	96,75	<b>96,94</b>
DenseNet121 + AÖM	83,55	88,59	91,01	92,09	93,59	94,51	96,49	96,67

Çizelge 5.9. Leafsnap veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi

Metot	300	500	700	900	1200	1500	3000	5000
ESA + AÖM	51,40	58,02	61,86	64,25	67,09	69,10	74,63	78,05
VGG16 + AÖM	26,95	35,18	39,96	43,82	47,02	51,23	58,40	62,29
InceptionV3 + AÖM	40,25	45,89	49,18	52,04	55,01	56,97	62,21	65,30
MobileNet + AÖM	46,76	54,92	59,28	62,26	65,51	67,55	73,37	76,63
DenseNet121 + AÖM	48,16	54,98	59,41	62,59	66,61	68,65	74,39	<b>78,64</b>

Çizelge 5.10. Birleşmiş veri setinin AÖM ile yapılan sınıflandırma başarımlarının farklı nöron sayıları için detaylı gösterimi

Metot	300	500	700	900	1200	1500	3000	5000
ESA + AÖM	51,40	58,02	61,86	64,25	67,09	69,10	74,63	<b>78,05</b>
VGG16 + AÖM	38,23	44,79	48,22	51,68	54,42	56,67	61,97	65,70
InceptionV3 + AÖM	34,15	42,89	48,21	52,19	56,08	59,13	66,41	70,54
MobileNet + AÖM	47,03	54,61	59,30	62,20	65,18	67,59	73,60	77,05
DenseNet121 + AÖM	45,78	54,06	58,20	61,43	64,39	67,00	73,01	76,67

ESA ile yaprak sınıflandırması için kullanılan veri setlerinden biri olan Mendeley veri seti hastalıklı yapraklardan oluşması nedeniyle literatürde sınıflandırma için kullanılmamaktadır. Bu nedenle yapılan çalışmada kullanılan farklı sınıflandırma yöntemlerinin kıyaslanması Çizelge 5.11’de gösterilmektedir. Bu sonuçlara baktığımızda, farklı sınıflandırma yöntemlerinde elde edilen en yüksek başarımlar MobileNet önceden eğitilmiş modeli ile sağlanmıştır.

Çizelge 5.11. Mendeley veri setinin farklı sınıflandırma yöntemleri ile sınıflandırma başarımlarının kıyaslanması

Çalışmayı Yapan	Metot	Tür Sayısı	Görüntü Sayısı	Başarım Oranı
Bu çalışma da	ESA	12	52 624	92,08
	DenseNet121 + AÖM	12	52 624	95,33
	ESA + EYKA	12	52 624	95,65
	MobileNet + DVM	12	52 624	97,74

Çizelge 5.12’de UCL veri setinin literatürdeki sınıflandırma yöntemleri ile bu çalışmada kullanılan yöntemleri karşılaştırılmıştır. Veri setindeki görüntü sayısının az olması ve tür sayısının görece fazla olması bu veri setinin daha az kullanılmasını ve yapılan çalışmalar da başarımlarının artmasını zorlaştırmıştır. Bu çalışmada yapılan veri çoğaltma işlemleri ve literatürde sıkça kullanılan önceden eğitilmiş hazır modelin destek vektör makinesi ile sınıflandırma işlemi yüksek başarımlar elde etmiştir. Elde edilen başarımlarda 3 faktör etkili olmuştur, yapılan veri çoğaltma işlemi, kullanılan hazır modelin yüksek görüntü boyutuna ve yüksek öznelik vektör boyutuna sahip olmasıdır.

Çizelge 5.12. UCL veri setinin literatürdeki farklı sınıflandırma yöntemlerinin başarımları ile bu çalışmadaki sınıflandırma başarımlarının kıyaslanması

Çalışmayı Yapan	Metot	Tür Sayısı	Görüntü Sayısı	Başarım Oranı
Padao, 2015	Naive Bayesian	30	340	74,10
Tomar, 2016	DVM	40	443	84,70
Silva, 2013	DAA	15	171	87,00
<b>Bu çalışma da</b>	<b>MobileNet + DVM</b>	<b>40</b>	<b>10 632</b>	<b>98,78</b>

Leafsnap veri setinin literatürdeki farklı çalışmalar ile bu çalışmadaki sonuçların karşılaştırması Çizelge 5.13’de özetlenmiştir. Farklı sayıda tür ve görüntü sayısı ile yapılan çalışmalara bakıldığında, aynı sayıda türün kullanıldığı çalışmalar arasında en iyi ikinci başarımlar sağlanmıştır. Bu veri setindeki görüntü sayısı dağılımı, tür sayısının fazla olması ve yapılan eğitimdeki iterasyon sayısının kısıtlı olması başarımın artmasını engellemiştir.

Çizelge 5.13. Leafsnap veri setinin literatürdeki farklı sınıflandırma yöntemlerinin başarımları ile bu çalışmadaki sınıflandırma başarımlarının kıyaslanması

Çalışmayı Yapan	Metot	Tür Sayısı	Görüntü Sayısı	Başarım Oranı
Shah, 2017	DVM	150	7 710	85,37
Barre, 2017	ESA	184	272 300	86,30
Beikmohammadi, 2018	MobileNet + LR	184	29 107	90,54
Hewit, 2018	DVM	183	7 440	92,40
Shah, 2017	ESA	150	7 710	95,61
Kumar, 2012	EYKA	184	29 107	96,80
<b>Bu çalışma da</b>	<b>ESA + DVM</b>	<b>184</b>	<b>57 966</b>	<b>91,71</b>

Her türün sabit sayıda görüntüye sahip olduğu Swedish Leaf veri setinin literatürde yapılan çalışmalarda, öznetelik çıkarma sonrası farklı sınıflandırma yöntemleri ile kullanılması, ESA, DVM ve önceden eğitilmiş hazır modellerin kullanılarak öznetelik çıkarımı sonucu farklı sınıflandırma yöntemlerinin kullanılması gibi farklı yöntemler ile bu çalışmada elde edilen sonuçların karşılaştırılması Çizelge 5.14’de görülmektedir. Literatürde sıkça kullanılan MobileNet hazır modelinin Swedish Leaf veri setinin sınıflandırılmasında en iyi başarımları sağladığı görülmektedir. Yapılan veri çoğaltma işlemi ve veri setindeki görüntü dağılımının düzgün olması ile görüntü sayısının yeterli seviyede olması yüksek başarımla sınıflandırma yapılmasını sağlamıştır.



Çizelge 5.14. Swedish Leaf veri setinin literatürdeki farklı sınıflandırma yöntemlerinin başarımları ile bu çalışmadaki sınıflandırma başarımlarının kıyaslanması

<b>Çalışmayı Yapan</b>	<b>Metot</b>	<b>Tür Sayısı</b>	<b>Görüntü Sayısı</b>	<b>Başarım Oranı</b>
Wang, 2017	ESA + DVM	15	1 125	97,63
Hewitt, 2018	DVM	15	1 125	97,80
Zhang, 2020	DVM	15	1 125	97,93
Tsolakidis, 2014	Doğrusal DVM	15	750	98,13
Sujith, 2020	PHOG + GCLM + LBP	15	1 125	98,23
Wang, 2020	DVM	15	1 125	98,40
Pearline, 2019a	DenseNet + LR	15	1 125	98,93
Atabay, 2016	ESA	15	2 250	99,11
Pearline, 2019a	DDLA + LR	15	1 125	99,41
Pearline, 2019a	MobileNet + LR	15	1 125	99,41
<b>Bu çalışma da</b>	<b>MobileNet + DVM</b>	<b>15</b>	<b>13 500</b>	<b>99,82</b>

Literatürde sıkça kullanılan Flavia veri setinin farklı sınıflandırma yöntemleri ile yapılan çalışmalar ve bu çalışmada elde edilen sonucun karşılaştırılması Çizelge 5.15’de gösterilmektedir. Literatürdeki en iyi başarımları sağlayan çalışmalara bakıldığında, bu çalışmada da kullanılan ESA ve hazır modellerden öznelik çıkarımı sonrası farklı sınıflandırma yöntemleri ile sınıflandırılması gibi metotların olduğu görülmektedir.

Çizelge 5.15. Flavia veri setinin literatürdeki farklı sınıflandırma yöntemlerinin başarımları ile bu çalışmadaki sınıflandırma başarımlarının kıyaslanması

Çalışmayı Yapan	Metot	Tür Sayısı	Görüntü Sayısı	Başarım Oranı
Lavana, 2014	EYKA	33	1 907	87,50
Wu, 2007	OSA	32	1 800	90,00
Shah, 2017	DVM	32	1 907	93,22
Kadir, 2011	OSA	32	1 600	93,75
Kulkarni, 2013	RTOSA	32	1 600	93,82
Kumar, 2019	ÇKA - AdaBoost	32	1 907	95,42
Pearline, 2019b	ESA	32	1 907	96,25
Hewit, 2018	DVM	32	1 907	96,66
Pearline, 2019a	MobileNet + LR	32	1 600	96,67
Tsolakidis, 2014	Doğrusal DVM	32	1 600	97,18
Atabay, 2016	ESA	32	3 814	97,24
Wang, 2014	DVM	32	1 907	97,82
Wang, 2020	DVM	32	1 907	97,83
Barre, 2017	ESA	32	44 623	97,90
Pearline, 2019a	DenseNet + LR	32	1 600	97,92
Sujith, 2020	PHOG + GCLM + LBP	32	1 907	98,23
Zhang, 2020	DVM	32	1 907	98,53
Wang, 2017	ESA + DVM	32	1 907	98,53
Keivani, 2020	Karar Ağacı	32	1 600	98,58
Pearline, 2019a	DDLA + LR	32	1 600	98,71
Mostafa, 2020		32	1 980	99,00
Shah, 2017	ESA	32	1 907	99,28
Lee, 2017	ESA + DVM	32	2 603	99,30
Beikmohammadi, 2018	MobileNet + LR	32	1 907	99,60
<b>Bu çalışmada</b>	<b>MobileNet + AÖM</b>	<b>32</b>	<b>22 877</b>	<b>99,56</b>

Literatüre bakıldığında, kullanılan yaprak veri setlerinin birleştirilerek çok sayıda türe sahip bir şekilde sınıflandırılması görülmemektedir. Bu sebeple yapılan çalışmadaki farklı sınıflandırma yöntemleri kıyaslanmıştır. ESA ile yapılan eğitim başarımının yüksek olması öznelik çıkarımı sonrası DVM ile yapılan sınıflandırma işlemlerinin önceden eğitilmiş hazır modellere oranla daha iyi bir başarımlar göstermesini sağlamıştır.

Çizelge 5.16. Birleşmiş veri setinin farklı sınıflandırma yöntemleri ile sınıflandırma başarımlarının kıyaslanması

Çalışmayı Yapan	Metot	Tür Sayısı	Görüntü Sayısı	Başarım Oranı
Bu çalışma da	ESA	270	62 424	73,00
	ESA + AÖM	270	62 424	78,05
	DenseNet121 + EYKA	270	62 424	81,18
	ESA + DVM	270	62 424	86,00

Farklı sınıflandırma yöntemlerinin kullanıldığı bu çalışmada elde edilen sonuçlar ve literatürdeki çalışmaların incelenmesi sonucu düşük işlem gücüne sahip donanımlarda nasıl bir yöntem kullanılacağı belirlenmiştir. Yaprak sınıflandırma için belirlenen bu yöntemde, önceden eğitilmiş hazır modellerden çıkarılan öznitelik vektörlerinin ESA ile yapılan eğitim sonucu çıkarılan verilerle yakın hatta daha iyi sonuçlar verdiği görülmektedir. Buna göre işlem yapılan sistemin kapasitesine göre farklı öznitelik vektör boyutlarına sahip hazır modellerden çıkarılan özniteliklerin farklı sınıflandırma yöntemleri ile sınıflandırılması hem daha az zaman hem de daha az işlem gücü gerektirdiği belirlenmiştir. Buna göre hazır modeller ile eğitilmiş sonucu elde edilen başarım farkının çok fazla olmaması göz önüne alınarak önceden eğitilmiş modellerin kullanılabilmesi dikkate alınmalıdır. Ancak bu fark yaprak sınıflandırma gibi durumlarda çok önemli değilken insan sağlığı gibi hassasiyet ve yüksek başarımın önemli olduğu konularda ciddi bir önem arz etmektedir.

### 5.1. Öneriler

Yapılan çalışmanın farklı alanlarda kullanımının incelenmesi gerekmektedir. Ayrıca farklı önceden eğitilmiş modellerin, bu çalışma da kullanılan sınıflandırma yöntemleriyle ya da farklı yöntemlerle detaylı bir şekilde incelenmesi gelecek çalışmalara ışık tutması açısından önemlidir. Bu çalışma da yapılan hazır model ve oluşturulan modelin görüntü boyutu, renkli, gri veya siyah beyaz resim gibi farklı parametreler değiştirilerek incelenmelidir.

## KAYNAKLAR

- Alaslani, M., Elrefaei, L. (2018). Convolutional Neural Network Based Feature Extraction for Iris Recognition. *International Journal of Computer Science and Information Technology* Vol. 10, No. 2, Corpus ID: 51772790.
- Alpaydın, E. (2004). *Introduction to Machine Learning (Dördüncü Baskı)*, ss. 3.
- Al-Qurran, R., Al-Ayyoub, M., Shatnawi, A. (2019). Plant Classification in the Wild: A Transfer Learning Approach. *2018 International Arab Conference on Information Technology*.
- Altan, G, Kutlu, Y. (2018). Hessenberg Elm Autoencoder Kernel For Deep Learning. *Programlanması (Beşinci Baskı)*. Türkiye: ASİL Yayınevi, 38-39.
- Atabay, H. (2016). A Convolutional Neural Network with A New Architecture on Leaf Classification. *IIOAB*, Vol. 7, Suppl 5, 326-331.
- Barre, P., Stöver, B., Müller, K., Steinhage, V. (2017). LeafNet: A Computer Vision System for Automatic Plant Species Identification. *Ecological Informatics* 40 (2017) 50-56
- Bashish, D., Braik, M., Bani-Ahmad, S. (2011). Detection and Classification of Leaf Diseases using K-means-based Segmentation and Neural-networks-based Information Technology Journal, 10(2): 267-275.
- Beikmohammadi, A., Faez, K. (2018). Leaf Classification for Plant Recognition with Deep Transfer Learning. *2018 4th Iranian Conference on Signal Processing and Systems*.
- Bilgili, E., Uçan, O. (2011). Geriye Yayılma Algoritması Kullanılarak Yaprak Desenlerinin Sınıflandırılması. *Doğuş Üniversitesi Dergisi*, 2 (2), ss. 1-14.
- Camgözlü, Y., Kutlu, Y. (2019). Analysis of Pooling Effect on CNN using Leaf Database *Natural and Engineering Sciences*, 4(3), SUPPLEMENT I of SYMPOSIUM ARTICLES, 118 – 123.
- Camgözlü, Y., Kutlu, Y. (2020a). Analysis of Filter Size Effect in Deep Learning. *Journal of Artificial Intelligence with Applications*, 1(1), 20-29.
- Camgözlü, Y., Kutlu, Y. (2020b). Derin Öğrenme ile Yaprak Sınıflandırma da Görüntü Boyutu Arka Plan Rengi ve Gri Resim ile Renkli Resim Arasındaki Farkın İncelenmesi. *Akıllı Sistemler ve Uygulamaları Dergisi*, Dergisi, Cilt 3 Sayı 2 Sayfa 130- 133.
- Cerutti, G., Tougne, L., Coquin, D., Vacavant, A. (2014). Leaf Margins as Sequences: A Structural Approach to Leaf Identification. *Pattern Recognition Letters* Volume 49, 77-184.
- Chaisuk, P., Phromsuthirak, K., Areekul, V. (2017). Leaf Classification Based on a Quadratic Curved Axis. *2017 IEEE International Conference on Image Processing (ICIP)*.

- Chen, Y., Jiang, H., Li, C., Jia, X. And G., P. (2016). Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks. IEEE Transactions on Geo Science and Remote Sensing Vol. 54, No. 10, ISSN: 1558-0644.
- Chouhan S., Singh, U., Kaul, A., Jain, S. (2019). A Data Repository of Leaf Images: Practice towards Plant Conservation with Plant Pathology. 2019 4th International Conference on Information Systems and Computer Networks (ISCON).
- Deng, J., Dong, W., Socher, R., Li, L., Li, K., Fei, L. (2009). ImageNet: A Large-Scale Hierarchical Image Database. 2009 IEEE Conference on Computer Vision and Pattern Recognition.
- Demir, B., Ertürk, S. (2010). Empirical Mode Decomposition of Hyperspectral Images for Support Vector Machine Classification. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING, VOL. 48, NO. 11, NOVEMBER 2010.
- Hewitt, C., Mahmoud, M. (2018). Shape-only Features for Plant Leaf Identification. arXiv:1811.08398.
- Hossain, J., Amin, M. (2010). Leaf Shape Identification Based Plant Biometrics. 2010 13th International Conference on Computer and Information Technology (ICCIT)..
- Howard, A., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andretto, M. And Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. arXiv: 1704.04861.
- Hu, G., Wang, K., Peng, Y., Qiu, M., Shi, J. And Liu, L. (2018). Deep Learning Method for Underwater Target Feature Extraction and Recognition. Hindawi Computational Intelligence and Neuroscience Volume 2018, Article ID: 1214301.
- Huang, G., Zhu, Q., Siew, C. (2006). Extreme Learning Machine: Theory and Applications. Science Direct Neurocomputing 70 p:489-501.
- Izadpanahkakhk, M., Razavi, S., Taghipur-Gorjikoalaie, M., Zahiri, S. And Uncini, A. (2018). Deep Region of Interest and Feature Extraction Models for Palmprint Verification Using Convolutional Neural Networks Transfer Learning. MDPI Advanced Intelligent Imaging Technology Appl. Sci. 2018,8(7), 1210.
- Kadir, A., Edi, L., Susanto, A., Santosa, P. (2011). Leaf Classification Using Shape, Color and Texture Features. International Journal of Computer Trends and Technology (IJCTT), V1(3):306-311.
- Keivani, M., Mazloun, J., Sedaghatfar, E., Tavakoli, M. (2020). Automated Analysis of Leaf Shape, Texture and Color Features for Plant Classification. International Information and Engineering Technology Association, Traitement du Signal Vol 37, No 1, pp. 17-28.

- Kaur, T., Gandhi, T. (2020). Deep Convolutional Neural Networks with Transfer Learning for Automated Brain Image Classification. *Machine Vision and Applications* 31, Article Number 20.
- Kır, B., Öz, C., Gülbağ, A. (2012). K-NN Sınıflandırma Algoritması Kullanılarak Yaprak Tanıma. 20. *Signal Processing and Communications Applications Conference*, . 1-4.
- Krause, J., Baek, K., Lim, L., Sugita, G. (2018) WTPlant (What's That Plant?): A Deep Learning System for Identification Plants in Natural Images. *International Conference on Multimedia Retrieval*, 517-520.
- Kulkarni, A., Rai, A., Upparamani, P. (2013). A Leaf Recognition Technique for Plant Classification Using RBPNN and Zernike Moments. *Int. J. Adv. Res. Comput. Commun. Eng.* Vol. 2, No. 1, pp. 984-988.
- Kumar, M., Gupta, S., Gao, X., Singh, A. (2019). Plant Species Recognition Using Morphological Features and Adaptive Boosting Methodology. *IEEE Access* Vol. 7. Pp. 163912- 163918.
- Kumar, N., Belhumeur, P., Biswas, A., Jacobs, D., Kress, W., Lopez, I., and Soares, V. (2012). Leafsnap: A Computer Vision System for Automatic Plant Species Identification. *European Conference on Computer Vision (ECCV 2012)*, 502-516.
- KUTLU, Y. (2010). Multi-stage classification of abnormal patterns in EEG and e-ECG using model-free methods (Doctoral dissertation, DEÜ Fen Bilimleri Enstitüsü).
- Kutlu, Y., Yayık, A., Yildirim, E., Yildirim, S. (2017). LU Triangularization Extreme Learning Machine In EEG Cognitive Task Classification. *Neural Computing and Applications* 31, no. 4 (2019): 1117-1126.
- Kutlu, Y., Yayık, A., Yildirim, E., Yildirim, S. (2015). Orthogonal Extreme Learning Machine Based P300 Visual Event-Related BCI. In *International Conference on Neural Information Processing*, pp. 284-291. Springer, Cham, 2015.
- Lavana, S., Matey, P. (2014). Leaf Recognition using Contour Based Edge Detection and SIFT Algorithm. *2014 IEEE International Conference on Computational Intelligence and Computing Research*.
- Lee, S., Chan, C., Mayo, S., Remagnino, P. (2017). How Deep Learning Extract and Learns Leaf Features for Plant Classification. *Pattern Recognition* 71 (2017) , 1-13.
- Mostafa, S., El-Latif, Y., Reda, N. (2020). Fast and Accurate System for Leaf Recognition. *International Journal of Computer Sciences and Engineering* Vol. 8, Iss 8, pp. 73-79.
- Padao, F., Maravillas, E. (2015). Using Naive Bayesian Method for Plant Leaf Classification Based on Shape and Texture Features. *8th IEEE International Conference Humanoid, Nanotechnology, Communication and Control, Environment and Management*.

- Pearline, A., Raj, S., Vajravelu, S. (2019a). DDLA: Dual Deep Learning Architecture for Classification of Plant Species. *IET Image Process*, 2019, Vol 3 Iss. 12, pp. 2176-2182.
- Pearline, S., Kumar, V., Harini, S. (2019b). A Study on Plant Recognition using Conventional Image Processing and Deep Learning Approaches. *Journal of Intelligence & Fuzzy Systems* Vol, 36, No, 3, pp. 1997-2004.
- Shah, M., Singha, S., Awate, S. (2017). Leaf Classification using Marginalized Shape Context and Shape + Texture Dual-Path Deep Convolutional Neural Network. 2017 *IEEE International Conference on Image Processing*.
- Silva, P., Marcal, A., Silva, R. (2013). Evaluation of Features for Leaf Discrimination. *Springer Lecture Notes in Computer Science*, Vol. 7950, 197-204.
- Simonyan K., Zisserman, A. (2015). Very Deep Convolutional Neural Networks for Large-Scale Image Recognition. arXiv: 1409.1556.
- Söderkvist, O. (2001). Computer Vision of Leaves from Swedish Trees. Master's thesis, Linköping University 2001.
- Srinivas, M., Roy, D., Mohan, C. (2016). Discriminative Feature Extraction from X-Ray Images using Deep Convolutional Neural Networks. *IEEE International Conference on Acoustic, Speech and Signal Processing*.
- Sujith, A., Neethe, R. (2020). Classification of Plant Leaf Using Shape and Texture Features. *Inventive Communication and Computational Technologies* pp. 269-282.
- Szegedy, C., Vanhocke, V., Ioffe, S., Shlens, J. (2015). Rethinking the Inception Architecture for Computer Vision. arXiv: 1512.00567v3.
- Tan, S. (2006). An Effective Refinement Strategy for KNN Text Classifier. *Expert Systems with Applications* 30, pp. 290 – 298.
- Tang, J., Deng, C. (2016). Extreme Learning Machine for Multilayer Perceptron. *IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS*, VOL. 27, NO. 4, APRIL 2016.
- Tomar, D., Agarwal, S. (2016). Leaf Recognition for Plant Classification Using Direct Acyclic Graph Based Multi-Class Least Squares Twin Support Vector Machines. *International Journal of Image and Graphics* Vol. 16, No. 3, pp. 1650012-1 – 1650012-17.
- Tsolakidis, D., Kosmopoulos, D., Papadourakis, G. (2014). Plant Leaf Recognition Using Zernike Moments and Histogram of Oriented Gradients. *SETN 2014: Artificial Intelligence: Methods and Applications* 406-417.
- Ukil, A. (2007). Support Vector Machine. *Intelligent Systems and Signal Processing in Power Engineering* pp. 161 – 226.

- Varshni, D., Thakral, K., Agarwal, L., Nijhawan, R. and Mittal, A. (2019). Pneumonia Detection using CNN Based Feature Extraction. IEEE International Conference on Electrical, Computer and Communication Technologies,
- Vo, A., Dand, H., Nguyen, B., Pham, V. (2019). Vietnamese Herbal Plant Recognition Using Deep Convolutional Features. International Journal of Machine Learning and Computing, Vol 9, No. 3.
- Yamashita, R., Nishio, M., Do, R., Togashi, K. (2018). Convolutional Neural Networks: An Overview and Application in Radiology. Insights into Imaging, 9, 611 – 629.
- Wang, Z., Lu, B., Chi, Z., Feng, D. (2011). Leaf Image Classification with Shape Context and SIFT Descriptors. 2011 International Conference on Digital Image Computing: Techniques and Applications pp. 650-654.
- Wang, Z., Sun, X., Ma, Y., Zhang, H., Ma, Y., Xie, W. (2014). Plant Recognition Based on Intersecting Cortical Model. 2014 International Joint Conference on Neural Networks (IJCNN).
- Wang, Z., Sun, X., Yang, Z., Zhang, Y., Ying, Z., Ma, Y. (2017). Leaf Recognition Based on DPCNN and BOW. Neural Processing Letters 47, 99 – 115.
- Wang, X., Du, W., Guo, F., Hu, S. (2020). Leaf Recognition Based on Elliptical Half Gabor and Maximum Gap Local Line Direction Pattern. IEEE Access Volume 8, Pages 39175 – 39183.
- Westerhuis, J., Hoefsloot, C., Smit, S., Vis, D., Smilde, A., Velzen, J., Duijnhoven, J., Dorsten, F. (2008). Assessment of PLS-DA Cross Validation. Metabolomics 4, pp 81-89.
- Wu, S., Bao, F., Xu, E., Wang, Y., Chang, Y. And Xiang, Q. (2007). A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network. 2007 IEEE Int. Symp. SignalProcess. Inf. Technol. 11-16.
- Zhang, X., Hao, Y. (2019). A Method Combining CNN and ELM for Feature Extraction and Classification of SAR Image. Journal of Sensor Volume 2019 Article ID: 6134610.
- Zhang, Y., Cui, J., Wang, Z., Kang, J., Min, Y. (2020). Leaf Image Recognition Based on Bag of Features. Applied Sciences 2020, 10, 5177.
- Zhu, H., Liu, Q., Qi, Y. (2018). Plant Identification Based on Very Deep Convolutional Neural Networks. Multimedia Tools and Applications 77, 29779-29797.
- Zhu, P., Isaacs, J., Fu, B. and Ferrari, S. (2017). Deep Learning Feature Extraction for Target Recognition and Classification in Underwater Sonar Images. IEEE 56th Annual Conference on Decision and Control.



## EKLER

<b>Tür Adı</b>	<b>Görüntü Sayısı</b>	<b>Bulunduğu Veri Seti</b>
Abies Concolor	204	Leafsnap
Abies Nordmanniana	182	Leafsnap
Acca Sellowiana	264	UCL
Acer	200	Swedish Leaf
Acer Buergerianum	209	Flavia
Acer Campestre	212	Leafsnap
Acer Ginnala	208	Leafsnap
Acer Griseum	219	Leafsnap
Acer Negundo	320	Farklı Veri Setleri Birleşik
Acer Palmatum	500	Farklı Veri Setleri Birleşik
Acer Pensylvanicum	202	Leafsnap
Acer Platanoides	207	Leafsnap
Acer Pseudoplatanus	203	Leafsnap
Acer Rubrum	246	Leafsnap
Acer Saccharinum	201	Leafsnap
Acer Saccharum	198	Leafsnap
Aesculus Californica	240	UCL
Aesculus Chinensis	198	Flavia
Aesculus Flava	190	Leafsnap
Aesculus Glabra	204	Leafsnap
Aesculus Hippocastamon	209	Leafsnap
Aesculus Pavi	225	Leafsnap
Ailanthus Altissima	320	Leafsnap
Albizia Julibrissin	205	Leafsnap
Alnus incana	200	Swedish Leaf
Alnus Sp	192	UCL
Alstonia Scholaris	240	Mendeley
Amelanchier Arborea	204	Leafsnap
Amelanchier Canadensis	199	Leafsnap
Amelanchier Laevis	202	Leafsnap
Arisarum Vulgare	216	UCL
Arjun	221	Mendeley
Asimina Triloba	225	Leafsnap
Bael	230	Mendeley
Basil	207	Mendeley
Berberis Anhwieensis	201	Flavia
Betula Alleghaniensis	201	Leafsnap
Betula Jacqemontii	200	Leafsnap
Betula Lenta	202	Leafsnap
Betula Nigra	206	Leafsnap
Betula Populifolia	202	Leafsnap
Betula Pubescens	411	Farklı Veri Setleri Birleşik
Bougainvillea Sp	312	UCL
Broussonettia Papyrifera	204	Leafsnap
Buxus Sempervirens	288	UCL
Carpinus Betulus	200	Leafsnap
Carpinus Caroliniana	205	Leafsnap

<i>Carya Cordiformis</i>	201	Leafsnap
<i>Carya Glabra</i>	200	Leafsnap
<i>Carya Ovata</i>	206	Leafsnap
<i>Carya Tomentosa</i>	201	Leafsnap
<i>Castanea Dentata</i>	202	Leafsnap
<i>Castanea Sativa</i>	288	UCL
<i>Catalpa Bignonioides</i>	188	Leafsnap
<i>Catalpa Speciosa</i>	200	Leafsnap
<i>Cedrus Atlantica</i>	200	Leafsnap
<i>Cedrus Deodara</i>	245	Farklı Veri Setleri Birleşik
<i>Cedrus Libani</i>	201	Leafsnap
<i>Celtis Occidentalis</i>	202	Leafsnap
<i>Celtis Sp</i>	288	UCL
<i>Celtis Tenuifolia</i>	202	Leafsnap
<i>Cercidiphyllum Japonicum</i>	205	Leafsnap
<i>Cercis Canadensis</i>	208	Leafsnap
<i>Cercis Chinensis</i>	192	Flavia
<i>Chamaecyparis Pisifera</i>	202	Leafsnap
<i>Chamaecyparis Thyoides</i>	207	Leafsnap
<i>Chelidonium Majus</i>	240	UCL
<i>Chimonanthus Praecox</i>	202	Flavia
<i>Chinar</i>	239	Mendeley
<i>Chionanthus Retusus</i>	202	Leafsnap
<i>Chionanthus Virginicus</i>	205	Leafsnap
<i>Cinnamomum Camphora</i>	199	Flavia
<i>Cinnamomum Japonicum</i>	206	Flavia
<i>Citrus Reticulata</i>	208	Flavia
<i>Cladrastis Lutea</i>	229	Leafsnap
<i>Comus Florida</i>	205	Leafsnap
<i>Comus Kousa</i>	201	Leafsnap
<i>Comus Mas</i>	202	Leafsnap
<i>Corylus Avellana</i>	312	UCL
<i>Corylus Colurna</i>	218	Leafsnap
<i>Crataegus Crus-Galli</i>	206	Leafsnap
<i>Crataegus Laevigata</i>	208	Leafsnap
<i>Crataegus Monogyna</i>	192	UCL
<i>Crataegus Phaenopyrum</i>	206	Leafsnap
<i>Crataegus Pruinosa</i>	207	Leafsnap
<i>Crataegus Viridis</i>	203	Leafsnap
<i>Cryptomeria Japonica</i>	212	Leafsnap
<i>Diospyros Virginiana</i>	219	Leafsnap
<i>Erodium</i>	264	UCL
<i>Eucommia Ulmoides</i>	204	Leafsnap
<i>Euonymus Japonicus</i>	288	UCL
<i>Evodia Daniellii</i>	218	Leafsnap
<i>Fagus Grandifolia</i>	203	Leafsnap
<i>Fagus Silvatica</i>	221	Swedish Leaf
<i>Ficus Carica</i>	212	Leafsnap
<i>Fragaria Vesca</i>	264	Leafsnap
<i>Fraxinus Americana</i>	218	Leafsnap

Fraxinus Nigra	210	Leafsnap
Fraxinus Pennsylvanica	240	Leafsnap
Fraxinus	248	UCL
Gauva	240	Mendeley
Geranium	244	UCL
Ginkgo Biloba	207	Farklı Veri Setleri Birleşik
Gleditsia Triacanthos	215	Leafsnap
Gymnocladus Dioicus	222	Leafsnap
Halesia Tetraptera	264	Leafsnap
Hydrangea	240	UCL
Ilex Aquifolium	227	UCL
Ilex Macrocarpa	238	Flavia
ilex Opaca	264	Leafsnap
Ilex Perado Ssp Azorica	229	UCL
Indigofera Tinctoria	260	Flavia
Jamun	219	Mendeley
Jatropha	214	Mendeley
Juglans Cinerea	217	Leafsnap
Juglans Nigra	231	Leafsnap
Juniperus Virginiana	206	Leafsnap
Kalopanax Septemlobus	206	Flavia
Koelretureia Paniculata (Çok Yapraklı)	215	Leafsnap
Koelreuteria Paniculata (Tek Yapraklı)	209	Flavia
Lagerstroemia Indica	204	Flavia
Larix Decidua	216	Leafsnap
Lemon	206	Mendeley
Ligustrum Lucidum	217	Flavia
Liquidambar Styraciflua	209	Leafsnap
Liriodendron Chinense	246	Flavia
Liriodendron Tulipifera	243	Leafsnap
Maclura Pomifera	217	Leafsnap
Magnolia Acuminata	218	Leafsnap
Magnolia Denudata	381	Leafsnap
Magnolia Grandiflora	215	Farklı Veri Setleri Birleşik
Magnolia Macrophylla	288	Leafsnap
Magnolia Soulangeana	256	UCL
Magnolia Soulangiana	214	Leafsnap
Magnolia Stellata	226	Leafsnap
Magnolia Tripetala	219	Leafsnap
Magnolia Virginiana	217	Leafsnap
Mahonia Bealei	240	Flavia
Malus Angustifolia	218	Leafsnap
Malus Baccata	217	Leafsnap
Malus Coronaria	223	Leafsnap
Malus Floribunda	242	Leafsnap
Malus Hupenensis	222	Leafsnap
Malus Pumila	209	Leafsnap
Manglietia Fordiana	245	Flavia

Mango	227	Mendeley
Metasequoia yptostrobooides	216	Leafsnap
Morus Alba	330	Leafsnap
Morus Rubra	217	Leafsnap
Nerium Oleander	207	Farklı Veri Setleri Birleşik
Nyssa Sylvatica	238	Leafsnap
Osmanthus Fragrans	221	Flavia
Ostrya Virginiana	288	Leafsnap
Oxydendrum Arboreum	205	Leafsnap
Papaver	225	UCL
Paulownia Tomentosa	214	Leafsnap
Phellodendron Amurense	208	Leafsnap
Phoebe Nanmu	222	Flavia
Phyllostachys Edulis	220	Flavia
Picea Abies	219	Leafsnap
Picea Orientalis	215	Leafsnap
Picea Pungens	217	Leafsnap
Pinus Bungeana	217	Leafsnap
Pinus Cembra	221	Leafsnap
Pinus Densiflora	204	Leafsnap
Pinus Echinata	211	Leafsnap
Pinus Flexilis	217	Leafsnap
Pinus Koraiensis	213	Leafsnap
Pinus Nigra	216	Leafsnap
Pinus Parviflora	215	Leafsnap
Pinus Peucea	202	Leafsnap
Pinus Pungens	214	Leafsnap
Pinus Resinosa	288	Leafsnap
Pinus Rigida	217	Leafsnap
Pinus	209	Flavia
Pinus Strobus	221	Leafsnap
Pinus Sylvestris	233	Leafsnap
Pinus Taeda	205	Leafsnap
Pinus Thunbergii	215	Leafsnap
Pinus Virginiana	205	Leafsnap
Pinus Wallichiana	226	Leafsnap
Pittosporum Tobira	212	Flavia
Platanus Acerifolia	212	Leafsnap
Platanus Occidentalis	264	Leafsnap
Podocarpus Macrophyllus	312	Flavia
Podocarpus	131	Flavia
Polypodium Vulgare	221	Flavia
Pomegranate	210	Mendeley
Pongamia Pinnata	240	Mendeley
Populus	211	Swedish Leaf
Populus Alba	210	Flavia
Populus Canadensis	209	Flavia
Populus Deltoides	240	Leafsnap
Populus Grandidentata	205	Leafsnap
Populus Nigra	204	Flavia

Populus Tremula	228	Swedish Leaf
Populus Tremuloides	219	Leafsnap
Primula Vulgaris	222	Flavia
Prunus Pensylvanica	214	Leafsnap
Prunus Persica	284	Flavia
Prunus Sargentii	210	Leafsnap
Prunus Serotina	209	Leafsnap
Prunus Serrulata	206	Farklı Veri Setleri Birleşik
Prunus Subhirtella	205	Leafsnap
Prunus Virginiana	264	Leafsnap
Prunus Yedoensis	221	Leafsnap
Pseudolarix Amabilis	212	Leafsnap
Pseudosasa Japonica	208	Flavia
Ptelea Trifoliata	206	Leafsnap
Pyrus Calleryana	210	Leafsnap
Quercus	208	Swedish Leaf
Quercus Acutissima	205	Leafsnap
Quercus Alba	205	Leafsnap
Quercus Bicolor	205	Leafsnap
Quercus Cerris	209	Leafsnap
Quercus Coccinea	206	Leafsnap
Quercus imbricaria	205	Leafsnap
Quercus Macrocarpa	216	Leafsnap
Quercus Marilandica	212	Leafsnap
Quercus Michauxii	208	Leafsnap
Quercus Montana	223	Leafsnap
Quercus Muehlenbergii	208	Leafsnap
Quercus Nigra	346	Leafsnap
Quercus Palustris	228	Leafsnap
Quercus Phellos	208	Leafsnap
Quercus Robur	210	Farklı Veri Setleri Birleşik
Quercus Rubra	288	Leafsnap
Quercus Shumardii	208	Leafsnap
Quercus Stellata	213	Leafsnap
Quercus Suber	212	Flavia
Quercus Velutina	205	Leafsnap
Quercus Virginiana	240	Leafsnap
Robinia Pseudo-Acacia	210	Leafsnap
Salix Alba	208	Swedish Leaf
Salix Atrocinerea	208	Flavia
Salix Aurita	208	Swedish Leaf
Salix Babylonica	208	Leafsnap
Salix Carolinianan	195	Leafsnap
Salix Matsudana	204	Leafsnap
Salix Nigra	240	Leafsnap
Salix Sinerea	205	Swedish Leaf
Sassafras Albidum	212	Leafsnap
Schinus Terebinthifolius	208	Flavia
Sorbus Aucuparia	208	Swedish Leaf
Sorbus Intermedia	212	Swedish Leaf

Staphylea Trifolia	369	Leafsnap
Stewartia Pseudocamellia	280	Leafsnap
Styrax Japonica	240	Leafsnap
Styrax Obassia	251	Leafsnap
Syringa Reticulata	320	Leafsnap
Taxodium Distichum	306	Leafsnap
Taxus Bacatta	306	Flavia
Tilia	372	Swedish Leaf
Tilia Americana	329	Leafsnap
Tilia Cordata	240	Leafsnap
Tilia Europaea	340	Leafsnap
Tilia Tomentosa	456	Farklı Veri Setleri Birleşik
Tonna Sinensis	341	Leafsnap
Toona Sinensis	393	Leafsnap
Tsuga Canadensis	272	Leafsnap
Ulmus Americana	272	Leafsnap
Ulmus Carpinifolia	306	Swedish Leaf
Ulmus Glabra	532	Farklı Veri Setleri Birleşik
Ulmus Parvifolia	288	Leafsnap
Ulmus Procera	272	Leafsnap
Ulmus Pumila	306	Leafsnap
Ulmus Rubra	369	Leafsnap
Urtica Dioica	280	Flavia
Viburnum Awabuki	240	Flavia
Zelkova Serrata	251	Leafsnap

**Hobiler**



## DİZİN

---

### **A**

AÖM · 29

---

### **B**

Başarım · 45, 46, 47, 48, 49, 50,  
51, 52, 53

---

### **Ç**

Çapraz Doğrulama · 31

---

### **D**

Düzleme · 21

---

### **E**

Evrişimli Sınır Ağı · 17, 18, 19,  
20, 21, 22, 23

EYKA · 24

---

### **F**

Flavia · 11

Filtre Boyutları · 36, 37, 38

---

### **G**

Görüntü İşleme · 15, 16, 17

---

### **H**

Havuzlama · 20, 21

---

### **K**

Konvolüsyon · 18,19

---

### **L**

Literatür · 4, 5, 6, 7, 8

Leafsnap · 9,10

---

### **M**

Mendeley · 11,12

---

### **O**

Oluşturulan Model · 42, 43

---

### **Ö**

Öznitelik · 23

Ön İşlemler · 34, 35

Önceden Eğitilmiş Hazır

Modeller · 23, 24, 25, 26, 27

---

### **S**

Swedish Leaf · 13

Sınıflandırma · 22, 26, 32

---

### **T**

Tür Dağılımları · 46, 47, 48, 49,  
50

---

### **U**

UCL · 14

---

### **V**

Veri Seti Birleşimi · 15





**TEKNOVERSITE**



teknoversite **AYRICALIĞINDASINIZ**

**İSTE**

