

T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÖRÜNTÜ İŞLEME TABANLI BİTKİ TÜRLERİ VE HASTALIKLARI
TANIMA

Muammer TÜRKOĞLU

DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

KASIM 2019

Tezin Başlığı: Görüntü İşleme Tabanlı Bitki Türleri Ve Hastalıkları Tanıma

Tezi Hazırlayan: Muammer TÜRKOĞLU

Sınav Tarihi: 27/11/2019

Yukarıda adı geçen tez jürimizce değerlendirilerek Bilgisayar Mühendisliği Ana Bilim Dalında Doktora Tezi olarak kabul edilmiştir.

Sınav Jüri Üyeleri

Tez Danışmanı: Prof. Dr. Davut HANBAY
İnönü Üniversitesi

Prof. Dr. Ali KARCI
İnönü Üniversitesi

Prof. Dr. Abdulkadir Şengür
Fırat Üniversitesi

Doç. Dr. Muhammed Fatih TALU
İnönü Üniversitesi

Dr. Öğr. Üyesi Ömer Faruk ALÇİN
Bingöl Üniversitesi

Prof. Dr. Kazım TÜRK
Enstitü Müdürü

ONUR SÖZÜ

Doktora Tezi olarak sunduđum ‘‘Görüntü İşleme Tabanlı Bitki Türleri ve Hastalıkları Tanıma’’ başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla dođrularım.

Muammer TÜRKÖĐLU



ÖZET

Doktora Tezi

Görüntü İşleme Tabanlı Bitki Türleri Ve Hastalıkları Tanıma

Muammer TÜRKOĞLU

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
xx+177 sayfa
2019

Danışman: Prof. Dr Davut HANBAY

Son zamanlarda, bilgisayar teknolojisindeki gelişmeler ile birlikte görüntü işleme tabanlı örüntü tanıma ve sınıflandırma konularına olan ilgi artmıştır. Bu bağlamda, görüntü işleme teknolojisi; tıp, tarım, coğrafi bilimler, güvenlik sistemleri, uzay bilimleri, endüstriyel üretimler ve savunma sanayisi gibi daha birçok alanda yenilikler ve kolaylıklar sağlamıştır.

Bu tez çalışmasında; bitki türlerinin tanınması, yeni türlerin tespit edilmesi, zararlı bitkilerin belirlenmesi ve bitki hastalıklarının erken tespiti gibi konular esas olmak üzere tarımsal problemlerin çözümü için yapay zekâ ve görüntü işleme tabanlı sistemler geliştirilmesine odaklanılmıştır. Bu amaç doğrultusunda, bitki türlerinin tanınması ve hastalıkların tespiti için var olan yöntemler geliştirilmiş ve yeni yöntemler önerilmiştir. Bu geliştirilen ve önerilen yöntemler aşağıda belirtilmiştir:

- Bitki yaprağının geometrik şekline dayalı Kenar Adım (KA) yöntemi,
- Yaprak tabanlı bitki türlerinin sınıflandırılması için bölme yaklaşımı kullanılarak şekil, renk ve doku tabanlı hibrit bir sistem,
- Doku özellikleri çıkarmak için kullanılan YİÖ yönteminin geliştirilmiş versiyonu olarak BOG-YİÖ yöntemi,
- Bitki yaprak türlerinin tanınması için derin-dokusal tabanlı özellik çıkarıcı bir model,
- Bitki türlerinin tanınması ve sınıflandırılması için Çok-Bölmeli Derin Evrimsel Sinir Ağı (ÇB-DESA) modeli,
- Gerçek zamanlı görüntüler kullanılarak önceden eğitilmiş derin sinir ağları ile geleneksel sınıflandırıcılara dayalı yeni bir sınıflandırma mimarisi,
- Kayısı hastalıklarının tespiti için Derin Sinir Ağlarına (DSA) dayalı farklı evrim filtrelerini içeren derin bir model,
- Derin Öğrenme Tabanlı Bitki Hastalıkları ve Zararlıları Tespit Sistemi (Çoklu-ESA PlantDiseaseNet)

Önerilen bu yöntemlerin başarımını değerlendirmek amacıyla literatürde var olan veri setleri kullanılmıştır. Bunun yanı sıra, gerçek zamanlı olarak elde edilmiş 15 farklı bitki hastalık görüntülerinden oluşan yeni bir veri seti inşa edilmiş ve bu veri seti kullanılarak deneysel çalışmalar yapılmıştır. Yapılan kapsamlı deneysel çalışmalardan elde edilen sonuçlara göre, bitki türlerinin ve hastalıklarının sınıflandırılmasında geliştirilen ve önerilen yöntemler yüksek başarı sağlamıştır. Bu yöntemler, gelecekte

tarımsal problemlerin çözümü ile ilgili yapılacak olan otomatik tanı ve tespit sistemlerine temel oluşturacaktır.

Bu tez çalışmasında, doğal ortamdan elde edilen bitki hastalık görüntüleri kullanılarak gerçek zamanlı otomatik Bitki Hastalık Tespit Yazılımı geliştirilmiştir. Bu sistem, MATLAB GUI platformu kullanılarak tasarlanmış ve masaüstü uygulaması olarak herkes tarafından kolaylıkla kullanılabilme imkânı sağlanmıştır. Bu yazılım, uzman kişilere destek olacak, kolay ve kısa sürede bitki hastalıklarının erken tespit edilmesine olanak sağlayacak, yeni enfeksiyonların oluşması ve hastalıkların neden olduğu verim kaybını önleyecektir.

ANAHTAR KELİMELER: Bitki Tanıma, Bitki Hastalık Tespiti, Özellik Çıkarımı, Derin Öğrenme, Yapay Zeka, Sınıflandırma.



ABSTRACT

Ph.D.Thesis

Image Processing Based Plant Species and Diseases Recognition

Muammer TÜRKOĞLU

Inonu University
Graduate School of Nature and Applied Sciences
Department of Computer Engineering

xx+177 pages
2019

Supervisor: Assoc. Prof.Dr. Davut HANBAY

Recently, interest in image processing-based pattern recognition and classification has increased with advances in computer technology. In this context, image processing technology; has provided innovations and conveniences in many areas such as medicine, agriculture, geographic sciences, security systems, aerospace, industrial production, and defense industry.

In this thesis; The aim of study is to focus on the development of artificial intelligence and image processing based systems for the solution of agricultural problems, mainly on the recognition of plant species, the identifying of new species, the identification of harmful plants and the early detection of plant diseases. For this purpose, existing methods for the identification of plant species and diseases have been developed and new methods have been proposed. These developed and proposed methods are as follows:

- Edge Step (ES) method based on the geometric shape of the plant leaf,
- A shape, color and texture-based hybrid system using a divided approach to classify leaf-based plant species,
- The ROM-LBP method as an improved version of the LBP method used to extract tissue properties.
- A deep-textural-based feature extractor model for the recognition of plant leaf species.
- Multi-Division Deep Convolutional Neural Network (MD-DCNN) model for identification and classification of plant species,
- A new classification architecture based on traditional classifiers with pre-trained deep neural networks using real-time images,
- A deep model including different convolution filters based on Deep Neural Networks (DNNs) for the detection of apricot diseases,
- Deep Learning Based Plant Diseases and Pests Detection System (Multi-CNN PlantDiseaseNet)

In order to evaluate the performance of these proposed methods, existing datasets in the literature were used. In addition, a new dataset consisting of 15 different plant disease images obtained in real-time was constructed and experimental studies were conducted using this dataset. According to the results obtained from the comprehensive experimental studies, the methods developed and proposed for the classification of plant species and diseases have achieved high success. These methods will form the basis for

automatic diagnosis and detection system which will be held regarding the solution of agricultural problems in the future.

In this thesis, real-time automated Plant Disease Detection Software has been developed by using plant disease images obtained from the natural environment. This system has been designed by using MATLAB GUI platform and it can be easily used by everyone as a desktop application. This software; will support experts, will allow easy and early detection of plant diseases in a short time, will prevent the formation of new infections and loss of efficiency that caused diseases.

KEYWORDS: Plant recognition, plant disease detection, feature extraction, deep learning, artificial intelligence, classification



TEŞEKKÜR

Doktora eğitimimin ve hayatımın her anında bana destek olan akademik bilgi ve tecrübelerinin yanı sıra hayat tecrübelerini ve bilgi birikimini sabır ve cömertlikle benimle paylaşan kıymetli danışman hocam Prof. Dr. Davut HANBAY'a,

Akademik eğitimim boyunca bana destek olan ve tez yazımım süresince bilgi ve birikimlerini benden esirgemeyen kıymetli hocalarım Prof. Dr. Abdulkadir ŞENGÜR, Prof. Dr. İbrahim TÜRKOĞLU, Prof. Dr. Berrin A. YANIKOĞLU, Dr. Öğr. Üyesi Ömer Faruk ALÇİN, Dr. Öğr. Üyesi Kazım HANBAY, Dr. Türker Tuncer ve Arş. Gör. Işıl S. Sivrikaya,

İnönü Üniversitesi Bilgisayar Mühendisliği Bölümü akademisyenleri kıymetli hocalarıma ve idari personellerine,

Tez yazımım boyunca sürekli olarak beni motive eden, bana destek olan arkadaşlarım Dr. Anıl İMAK, Andaç İMAK, Fahrettin B. DEMİR, Murat AYDOĞAN ve Ali ARI,

Doktora eğitimim boyunca yoğunluğumu, sıkıntımı, stresimi anlayan hayatım boyunca aldığım her karar da yanımda olan Ahmet TÜRKOĞLU, Ayşe TÜRKOĞLU, Hatice KAPLAN, Fadime ÖZER ve sevgili yeğenlerime,

Bugünlere gelmem de büyük emekleri olan, hayatımın her anında bana destek olan, haklarını hiçbir zaman ödeyemeyeceğim kıymetli annem ve babama,

Şükranlarımı sunuyor teşekkür ediyorum.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	xi
ŞEKİLLER DİZİNİ	xv
ÇİZELGELER DİZİNİ	xviii
1. GİRİŞ	1
1.1. Literatür İncelemesi	2
1.1.1. Bitki Türleri ile ilgili yapılan çalışmalar	2
1.1.2. Bitki Hastalıkları ile ilgili yapılan çalışmalar	12
1.2. Önerilen Sistemin Genel Çerçevesi	20
1.2.1. Tezin Amacı	21
1.2.2. Tezin Gerekçeleri	22
1.2.3. Tezin Çıktıları	23
1.2.4. Tezin yenilikçi yönü ve ar-ge niteliği	24
1.2.5. Tezin Organizasyonu	24
2. BİTKİ TÜRLERİNİN TANINMASI VE HASTALIKLARININ SINIFLANDIRILMASI İÇİN KULLANILAN YÖNTEMLER	26
2.1. Ön-İşlem	26
2.1.1. Gri Tona Dönüştürme	26
2.1.2. Eşikleme İşlemi	27
2.1.2.1. Klasik (Tekli) Eşikleme	27
2.1.2.2. Çoklu Eşikleme	28
2.1.2.3. Otsu Eşikleme	29
2.1.3. Aşındırma İşlemi	30
2.1.4. Genleşme İşlemi	31
2.1.5. Açma İşlemi	31
2.1.6. Kapama İşlemi	32
2.2. Özellik Çıkarma Aşaması	33
2.2.1. Geleneksel yöntemler	33
2.2.1.1. Şekil tabanlı yöntemler	33

2.2.1.1.1.	Morfolojik Özellikler.....	34
2.2.1.1.2.	Hu Değişmez Momentler.....	35
2.2.1.1.3.	Merkez Kenar Uzunluğu	36
2.2.1.1.4.	Fourier Tanımlayıcıları.....	37
2.2.1.1.5.	Damar özellikleri	38
2.2.1.1.6.	Shearlet Dönüşüm Yöntemi.....	38
2.2.1.2.	Renk Tabanlı yöntemler	39
2.2.1.3.	Doku tabanlı yöntemler	40
2.2.1.3.1.	Gri Seviye Eş-Oluşum Matrisi	40
2.2.1.3.2.	Yönlü Gradyan Histogramı	42
2.2.1.3.3.	Yerel İkili Örüntü	43
2.2.2.	Derin öğrenme	44
2.2.2.1.	Evrişimsel Sinir Ağları	45
2.2.2.1.1.	Giriş Katmanı	45
2.2.2.1.2.	Evrişim Katmanı.....	45
2.2.2.1.3.	Havuzlama Katmanı	46
2.2.2.1.4.	Aktivasyon Fonksiyonu.....	47
2.2.2.1.5.	Normalizasyon Katmanı	47
2.2.2.1.6.	Tam Bağlı Katman.....	47
2.2.2.1.7.	Dropout Katmanı	47
2.2.2.1.8.	Sınıflandırma Katmanı	48
2.2.2.2.	ESA Mimarileri	48
2.2.2.2.1.	AlexNet.....	49
2.2.2.2.2.	VGGNet.....	49
2.2.2.2.3.	SqueezeNet	50
2.2.2.2.4.	GoogleNet.....	50
2.2.2.2.5.	InceptionV3	51
2.2.2.2.6.	InceptionResNetV2	51
2.2.2.2.7.	ResNet	52
2.2.2.2.8.	DenseNet201	53
2.3.	Sınıflandırma	54
2.3.1.	Destek Vektör Makinesi	55
2.3.1.1.	Doğrusal olarak Ayrılabilme Durumu	55
2.3.1.2.	Doğrusal olarak Ayrılamama Durumu	57

2.3.1.3.	En-Küçük Kareler Destek Vektör Makinesi.....	58
2.3.2.	Aşırı Öğrenme Makinesi	60
2.3.3.	K-En Yakın Komşu Algoritması	61
2.4.	Özellik İndirgeme	61
2.5.	Normalizasyon.....	62
2.5.1.	Z-skor normalizasyon Yöntemi	63
2.5.2.	Min-Max normalizasyon Yöntemi	63
2.6.	Eğitim-Test verilerine Ayırma.....	63
2.7.	Performans Ölçütleri.....	64
3.	BİTKİ TÜRLERİNİN SINIFLANDIRILMASI İÇİN LİTERATÜRDE KULLANILAN VERİ SETLERİ.....	66
3.1.	Flavia Yaprak Veri Seti	66
3.2.	Swedish Yaprak Veri Seti.....	66
3.3.	ICL Yaprak Veri Seti.....	67
3.4.	Foliage Yaprak Veri Seti	67
3.5.	Folio Yaprak Veri Seti.....	68
3.6.	LeafSnap Yaprak Veri Seti.....	68
3.7.	Flower17 ve Flower102 Veri Seti	69
4.	BİTKİ HASTALIKLARIN TESPİTİ İÇİN VERİ TABANI OLUŞTURULMASI	70
4.1.	Zararlılar (Böcek)	73
4.2.	Hastalıklar.....	75
5.	BİTKİ TANIMA İLE İLGİLİ ÖNERİLEN YENİ YAKLAŞIMLAR.....	77
5.1.	Shearlet Dönüşümü ve Yeni Geometrik Özellikler Kullanılarak Aşırı Öğrenme Makinesi Tabanlı Bitki Tanıma Sistemi	77
5.1.1.	Önerilen Sistem	77
5.1.1.1.	Ön-İşlem Aşaması	78
5.1.1.2.	Kenar Adım Yöntemi	79
5.1.2.	Deneysel Sonuçlar	81
5.1.2.1.	Benzetim Sonuçları.....	82
5.1.2.2.	Önerilen KA yöntemi ile MKU yönteminin karşılaştırılması	85
5.1.2.3.	Önerilen KA yöntemi ile diğer şekil tabanlı yöntemlerin karşılaştırılması.....	86
5.1.2.4.	Önerilen hibrit sistem ile mevcut yöntemlerin performanslarının karşılaştırılması.....	87

5.2.	Bitki türlerinin sınıflandırılması için bölme yaklaşımına dayalı hibrit bir sistem.....	88
5.2.1.	Önerilen Hibrit Sistem.....	89
5.2.1.1.	Önerilen Ön-işlem sistemi.....	90
5.2.1.2.	Önerilen Döndürme ve Bölme İşlemi.....	90
5.2.2.	Deneysel Çalışmalar.....	92
5.3.	Geliştirilen yerel ikili örüntü yöntemine dayalı yaprak tabanlı bitki türlerinin tanınması.....	97
5.3.1.	Önerilen Yaklaşım.....	98
5.3.1.1.	Bölgesel Ortalama-YİÖ.....	98
5.3.1.2.	Genel Ortalama-YİÖ.....	100
5.3.1.3.	Bölgesel/Genel Ortalama-YİÖ.....	101
5.3.2.	Deneysel Sonuçlar.....	101
5.3.2.1.	Önerilen yöntemler ile YİÖ yönteminin Sonuçlarının Karşılaştırılması.	102
5.3.2.2.	Önerilen yöntemler ile önceki çalışmalar ve görüntü tanımlayıcılarının karşılaştırılması.....	103
5.3.2.3.	Önerilen yöntemler ile geliştirilen YİÖ yönteminin Karşılaştırılması	104
5.3.2.4.	Gürültüye karşı önerilen ve yöntemlerin karşılaştırılması	105
5.4.	Derin Özellik ve Renkli-YİÖ Yöntemine Dayalı Bitki Tanıma Sistemi.	109
5.4.1.	Önerilen Derin-Yerel Tabanlı Model.....	109
5.4.2.	Deneysel Çalışmalar.....	110
5.5.	Bitki Türlerinin Sınıflandırılması için Çok-Bölmeli ESA.....	111
5.5.1.	Önerilen Model.....	112
5.5.2.	Deneysel Çalışmalar.....	113
5.5.2.1.	Benzetim Sonuçları.....	113
5.5.2.2.	Önerilen sistemin önceki çalışmalar ile karşılaştırılması	115
6.	BİTKİ HASTALIKLARININ TESPİTİ İLE İLGİLİ ÖNERİLEN YENİ YAKLAŞIMLAR	117
6.1.	Derin öğrenme tabanlı derin özellikler kullanarak bitki hastalık ve zararlı tespiti	117
6.1.1.	Önerilen Yaklaşımlar.....	117
6.1.1.2.	Transfer Öğrenme.....	117
6.1.1.2.	Derin Özellik Çıkarma.....	118
6.1.1.3.	Önerilen Yaklaşımların İşlem Adımları	119

6.1.2.	Deneysel Çalışmalar	120
6.1.2.1.	AlexNet, VGG16 ve VGG19 Modelleri kullanılarak derin özellik çıkarmaya dayalı performans sonuçları	121
6.1.2.2.	Diğer derin öğrenme mimarileri kullanılarak derin özellik çıkarmaya dayalı performans sonuçları	123
6.1.2.3.	Derin öğrenme modelleri kullanılarak transfer öğrenme yaklaşımına dayalı performans sonuçları	125
6.1.2.4.	Geleneksel yöntemlere dayalı performans sonuçları	127
6.1.2.5.	Benzetim sonuçlarının karşılaştırılması	127
6.2.	Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması	131
6.2.1.	Önerilen Derin Model	131
6.2.2.	Deneysel Çalışmalar	132
6.3.	Elma Hastalık Tespiti İçin Derin Mimariler Kullanılarak Transfer Öğrenmeye Dayalı Optimum Ağ Parametreleri	136
6.3.1.	Önerilen Yaklaşım	136
6.3.2.	Deneysel Çalışmalar	136
6.4.	Derin Öğrenme Tabanlı Bitki Hastalıkları ve Zararlıları Tespit Sistemi	139
6.4.1.	Önerilen Çoklu-ESA PlantDiseaseNet Modeli	140
6.4.2.	Deneysel Çalışmalar	141
7.	BİTKİ HASTALIKLARININ SINIFLANDIRILMASI İÇİN GELİŞTİRİLEN GERÇEK ZAMANLI YAZILIM UYGULAMASI	145
8.	SONUÇLAR VE ÖNERİLER	149
8.1.	Sonuçların değerlendirilmesi	149
8.2.	Öneriler	154
9.	KAYNAKLAR	156
	ÖZGEÇMİŞ	174

SİMGELER VE KISALTMALAR

AÖM	: Aşırı Öğrenme Makineleri
AİK	: Alıcı İşletim Karakteristiği
BKB	: Bire-karşı-bir
BKH	: Bire-karşı-hepsi
ÇKA	: Çok Katmanlı Algılayıcı
ÇMM	: Çok-Boyutlu Mesafe Matrisi
ÇÜA	: Çekişmeli Üretici Ağı
DAA	: Doğrusal Ayırt Edici Analiz
DESA	: Derin Evrişimsel Sinir Ağı
DVM	: Destek Vektör Makinaları
EEE	: En Az Eylemsizlik Eksenini
EK-DVM	: En Küçük Kareler Destek Vektör Makinesi
ESA	: Evrişimsel Sinir Ağları
FT	: Fourier Tanımlayıcıları
GİÜ	: Grafikselle İşleme Ünitesi
GKA	: Grafikselle Kullanıcı Ara Yüzü
GSEM	: Gri Seviye Eş Oluşum Matrisleri
HFD	: Hızlı Fourier Dönüşümü
İHA	: İnsansız Hava Aracı
k-EYK	: k-En Yakın Komşu
KDA	: Kuadratik Diskriminant Analizi
MKU	: Merkez Kenar Uzunluğu
MRMR	: En Küçük Artıklık En Büyük İlgililik

NFC	: Nöro-bulanık Denetleyici
OSA	: Olasılıksal Sinir Ağı
ÖBÖD	: Ölçekten Bağımsız Özellik Dönüşümü
RO	: Rastgele Orman
SDA	: Stokastik Dereceli Alçalma
SDAM	: Stokastik Dereceli Alçalma ile Momentum
TBA	: Temel Bileşen Analizi
TGKİB	: Tek-Gizli Katmanlı İleri Beslemeli
YGH	: Yönlendirilmiş Gradyan Histogramı
YİÖ	: Yerel İkili Örüntü
YSA	: Yapay Sinir Ağları
μ	: Ortalama
σ^2	: Varyans
γ	: Basıklık
θ	: Çarpıklık
Kov	: Kovaryans matris
ω	: Sınıf olasılığı
T	: Eşik değeri
t^*	: Eşik değeri
Θ	: Aşınma işlemi
\emptyset	: Boş küme
\oplus	: Genleşme işlemi
\circ	: Açma işlemi
\cdot	: Kapama işlemi

$f(x, y)$: Görüntünün yoğunluk dağılımı
$C(a, b)$: Nesnenin ağırlık merkezi
d	: Oklid uzaklığı
$p(i, j)$: Eş oluşum matrisi
I_x	: Görüntünün yatay yöndeki birinci türevi
I_y	: Görüntünün dikey yöndeki birinci türevi
m	: Gradyan büyüklüğü
ϑ	: Gradyan yönü
P	: Komşu piksellerin sayısı
R	: Komşu piksellerin mesafesi
M	: Komşu pikseller
ψ	: Shearlet kesme fonksiyonu
α_i	: Lagrange çarpanı
K	: Çekirdek fonksiyonu
$\Phi(x_i)$: Çekirdek fonksiyonu
$\varphi()$: Yüksek boyutlu özellik alanına taşıma fonksiyonu
w	: Ağırlık vektörü
b	: Bias değerini
e	: Hata teriminin
C	: Düzgünleştirme parametresi
w_i	: Giriş ağırlıklarını,
b_i	: Gizli katman eşliğini
β_i	: Çıkış ağırlıklarını
H	: Gizli katman çıkış matrisi

H^\dagger	: H'n Moore Penrose genelleştirilmiş tersini
Y	: Ağın çıkışı
z	: Z-skor normalizasyon
x'_i	: Normalize edilmiş değer
DP	: Doğru Pozitifler
DN	: Doğru Negatifler
YP	: Yanlış Pozitifler
YN	: Yanlış Negatifler



ŞEKİLLER DİZİNİ

Şekil 1.1.	Bitki türü ve hastalık sınıflandırma sistemlerinin genel aşamaları.....	21
Şekil 2.1.	Önerilen çalışmasının genel işlem adımları.....	26
Şekil 2.2.	Gri bir görüntü ve örnek bir piksel değerlerinin gösterimi.....	27
Şekil 2.3.	Klasik (tekli) eşiklemeye dayalı örnek bir uygulama	28
Şekil 2.4.	Çoklu eşiklemeye dayalı bir uygulama	29
Şekil 2.5.	Otsu eşikleme ile ilgili bir uygulama.....	30
Şekil 2.6.	Aşınma işlemine dayalı bir uygulama	31
Şekil 2.7.	Genleşme işlemine dayalı bir uygulama.....	31
Şekil 2.8.	Açma işlemine dayalı bir uygulama	32
Şekil 2.9.	Kapama işlemine dayalı bir uygulama	32
Şekil 2.10.	Özellik Çıkarım yöntemleri	33
Şekil 2.11.	Örnek bir yaprak için MKU yaklaşımı	37
Şekil 2.12.	Yaprak damar özelliklerine dayalı örnek bir gösterim	38
Şekil 2.13.	GSEM yönteminin örnek bir gösterimi	41
Şekil 2.14.	YİÖ yöntemine dayalı bir uygulama	44
Şekil 2.15.	Evrişim işlemi ile ilgili örnek bir uygulama.....	46
Şekil 2.16.	Havuzlama işlemi ile ilgili örnek bir gösterim	47
Şekil 2.17.	Derin ağ yapısı ve dropout uygulanması	48
Şekil 2.18.	AlexNet Mimarisi	49
Şekil 2.19.	VGG16 Mimarisi	50
Şekil 2.20.	GoogleNet Mimarisi	50
Şekil 2.21.	Inceptionv3 modeli	51
Şekil 2.22.	InceptionResNetv2 modülü	52
Şekil 2.23.	ResNet Artık Modülü	52
Şekil 2.24.	ESA Modelleri	54
Şekil 2.25.	DVM hiperdüzlem ayrımı	55
Şekil 2.26.	DVM hiperdüzlem ayrımı (1).....	56
Şekil 2.27.	Doğrusal olmayan bir DVM sınıflandırma örneği	58
Şekil 2.28.	DVM ve EK-DVM'nin mimarisi	59
Şekil 2.29.	AÖM yönteminin sözde kodu.....	61
Şekil 2.30.	k-EYK algoritmasının basit bir gösterimi.	61
Şekil 2.31.	10-kat çapraz doğrulama modeli	64

Şekil 3.1.	Flavia veri setindeki örnek görüntüleri.....	66
Şekil 3.2.	Swedish veri setindeki örnek görüntüler	67
Şekil 3.3.	ICL veri setindeki örnek görüntüler	67
Şekil 3.4.	Foliage veri setindeki örnek görüntüler.....	68
Şekil 3.5.	Folio veri setindeki örnek görüntüler	68
Şekil 3.6.	LeafSnap veri setindeki örnek görüntüler	69
Şekil 3.7.	Flower17 ve Flower102 veri setindeki örnek görüntüler	69
Şekil 4.1.	Veri tabanı oluşturmak için görüntü alma cihazları	70
Şekil 5.1.	Önerilen Sistemin Genel Akış Şeması.....	78
Şekil 5.2.	Bölütleme işlem adımları.....	78
Şekil 5.3.	Örnek bir yaprak için KA yaklaşımı.....	80
Şekil 5.4.	KA yönteminin performans sonuçları	82
Şekil 5.5.	Shearlet Dönüşüm - TBA yönteminin Doğruluk skorları	84
Şekil 5.6.	Önerilen sistemin akış şeması.....	89
Şekil 5.7.	Döndürme işlemi için basit bir gösterim	91
Şekil 5.8.	Bölme İşleminin uygulanması	92
Şekil 5.9.	10 kat çaprazlama modelinin her iterasyon için AİK diyagramı.....	95
Şekil 5.10.	Önerilen sistemin genel akış şeması.....	98
Şekil 5.11.	BO-YİÖ yönteminin uygulanması.....	99
Şekil 5.12.	GO-YİÖ yönteminin uygulanması	100
Şekil 5.13.	Dört veri seti için ortalama performans sonuçları	105
Şekil 5.14.	Gürültü eklenmiş örnek resimler	106
Şekil 5.15.	Önerilen yaklaşımın akış şeması	109
Şekil 5.16.	Önerilen modelin karmaşıklık matrisi	110
Şekil 5.17.	ÇB-ESA modelinin genel akış şeması.....	112
Şekil 5.18.	Kırpma işlemi uygulaması.....	112
Şekil 5.19.	Flower17 veri seti için karmaşıklık matrisi	114
Şekil 6.1.	Transfer Öğrenme yaklaşımı ile ilgili örnek bir gösterim.	118
Şekil 6.2.	Derin özellik çıkarma yaklaşımı ile ilgili örnek bir gösterim.....	119
Şekil 6.3.	AlexNet, VGG16 and VGG19 modellerinin genel akış şeması.	119
Şekil 6.4.	ResNet50 modeli ile DVM sınıflandırılmasına dayalı her bir sınıf için performans ölçütleri.....	125
Şekil 6.5.	Artan iterasyon sayısının etkileri.....	126
Şekil 6.6.	Kullanılan yöntem ve modellerin doğruluk skorlarının karşılaştırılması	128

Şekil 6.7.	Önerilen derin model	132
Şekil 6.8.	Önerilen modelin performans gösterimleri.....	133
Şekil 6.9.	Doğruluk skorlarının karşılaştırılması	135
Şekil 6.10.	Çoklu-ESA PlantDiseaseNet sisteminin genel akış şeması.....	140
Şekil 6.11.	Birleştirilmiş Çoklu-ESA sisteminin genel akış şeması	142
Şekil 7.1.	Matlab ara yüz program görüntüsü.....	146
Şekil 7.2.	Önerilen bitki hastalık sınıflandırma sisteminin genel aşamaları.....	146
Şekil 7.3.	Geliştirilen Matlab arayüz program görüntüsü.....	147
Şekil 7.4.	Hastalık-Zararlı Tespiti butonu aktif iken arayüz programı	148



ÇİZELGELER DİZİNİ

Çizelge 1.1. Bitki tanıma çalışmaları.....	7
Çizelge 1.2. Bitki hastalık tespiti ile ilgili çalışmalar	15
Çizelge 2.1. Morfolojik özelliklerin matematiksel ifadeleri.....	35
Çizelge 2.2. Açık değişkenine bağlı olarak öznelik sayıları.....	37
Çizelge 2.3. Derin Mimarilerin Karakteristikleri.....	49
Çizelge 2.4. DVM için kullanılan temel kernel fonksiyonları.....	58
Çizelge 2.5. DVM ile EK-DVM yöntemlerinin karşılaştırılması.....	58
Çizelge 2.6. Karışıklık Matrisi.....	64
Çizelge 4.2. Bitki hastalık ve zararlı görüntüleri	71
Çizelge 5.1. İstatistiksel Denklemler	81
Çizelge 5.2. KA yönteminin farklı adımlara karşı doğruluk skorları (%).....	83
Çizelge 5.3. Shearlet dönüşüm yöntemine dayalı doğruluk skorları (%).....	83
Çizelge 5.4. Önerilen çalışmanın doğruluk skorları ve öznelik sayıları.....	85
Çizelge 5.5. Önerilen sistemin gerçekleştirme süresi (saniye).....	85
Çizelge 5.6. MKU-KA yöntemleri ile hibrit sistemin doğruluk skorlarının (%) ve öznelik sayılarının karşılaştırılması.....	86
Çizelge 5.7. KA yöntemi ile diğer yöntemlerin doğruluk skorlarının (%) karşılaştırılması.....	86
Çizelge 5.8. Önerilen sistemin mevcut yöntemler ile doğruluk skorlarının (%) karşılaştırılması.....	87
Çizelge 5.9. Önerilen bölütleme işlemi	90
Çizelge 5.10.Özellik çıkarım yöntemlerinin bireysel öznelik sayıları	93
Çizelge 5.11.Özellik çıkarma yöntemlerinin doğruluk skorları (%) ve gerçekleştirme süreleri (saniye)	93
Çizelge 5.12.Önerilen hibrit sistemin doğruluk skorları, gerçekleştirme zamanı ve öznelik sayıları	94
Çizelge 5.13.10 kat çaprazlama modelinin her iterasyon için başarı oranı (%)	94
Çizelge 5.14.Farklı sınıflandırıcılar kullanılarak performans oranları (%)	95
Çizelge 5.15.Önerilen model ile diğer çalışmaların karşılaştırılması.....	96
Çizelge 5.16.Önerilen yöntemler ile YİÖ yönteminin doğruluk skorları (%).....	102
Çizelge 5.17.Önerilen yöntemler ile orijinal YİÖ yönteminin gerçekleştirme zamanları (saniye)	103

Çizelge 5.18.Önerilen yöntemler ile YİÖ tabanlı önceki çalışmaların doğruluklarının (%) karşılaştırılması.....	103
Çizelge 5.19.Önerilen yöntemler ile Görüntü tanımlayıcıların doğruluk skorlarının (%) karşılaştırılması.....	104
Çizelge 5.20.Önerilen yöntemler ile diğer yöntemlerin doğruluk skorlarının karşılaştırılması (%).....	104
Çizelge 5.21.Salt & pepper gürültüsüne dayalı önerilen ve diğer yöntemlerin doğruluk skorlarının karşılaştırılması	106
Çizelge 5.22.Gaussian gürültüsüne karşı önerilen yöntemlerin ve diğer yöntemlerin doğruluk skorlarının karşılaştırılması	107
Çizelge 5.23.Önerilen yaklaşımların doğruluk skorları ve öznelilik sayıları	110
Çizelge 5.24.Önerilen model ile önceki çalışmalarda elde edilen doğruluk skorlarının karşılaştırılması.....	111
Çizelge 5.25.ÇB-ESA modelinin performans sonuçları	114
Çizelge 5.26.ÇB-ESA modeli ile önceki çalışmaların doğruluk skorlarının karşılaştırılması (%).....	115
Çizelge 6.1. Önceden eğitilmiş derin mimarilerin özellik çıkarıcı katmanları ve elde edilen özellik sayıları.....	119
Çizelge 6.2. Deneysel çalışmalar için eğitim ve test sayıları.....	121
Çizelge 6.3. Derin özelliklere dayalı doğruluk skorları (%).....	122
Çizelge 6.4. Derin özelliklere dayalı performans ölçütleri (%).....	122
Çizelge 6.5. Derin özelliklere dayalı gerçekleştirme süreleri.....	122
Çizelge 6.6. Derin özelliklere dayalı derin mimarilerinin doğruluk skorları (%).....	123
Çizelge 6.7. Derin özelliklere dayalı derin mimarilerinin performans ölçütleri (%)...	124
Çizelge 6.8. Derin özelliklere dayalı derin mimarilerinin gerçekleştirme süreleri.....	124
Çizelge 6.9. En iyi doğruluk modelinin karışıklık matrisi (gri gölgeleme doğru sınıflandırmayı gösterir)	124
Çizelge 6.10.Transfer öğrenmeye dayalı derin mimariler için doğruluk skorları.	125
Çizelge 6.11.Transfer öğrenmeye dayalı derin mimariler için performans ölçütleri....	126
Çizelge 6.12.Transfer öğrenmeye dayalı mimarilerin gerçekleştirme süreleri.....	126
Çizelge 6.13.Geleneksel yöntemler için doğruluk skorları (%).....	127
Çizelge 6.14.Deneysel çalışmalar için eğitim ve test sayıları.....	132
Çizelge 6.15.Deneysel çalışmalar için kullanılan ağ parametreleri.....	132
Çizelge 6.16.Önerilen derin modelin performans sonuçları	133

Çizelge 6.17.Önceden eğitilmiş derin mimarilerin sınıflandırma sonuçları (%).....	134
Çizelge 6.18.Geleneksel yöntemlerin sınıflandırma sonuçları (%)	134
Çizelge 6.19.Deneysel çalışmalar için eğitim ve test sayıları.....	137
Çizelge 6.20.Derin mimarilerin sınıflandırma sonuçları (%)	137
Çizelge 6.21.Epoch ve batch değerlerindeki değişimlerin performansa etkileri.	139
Çizelge 6.22.Deneysel çalışmalar için eğitim ve test sayıları.....	141
Çizelge 6.23.Derin mimarilerin doğruluk skorları (%).....	142
Çizelge 6.24.Birleştirme işlemi kullanılarak farklı kombinasyonlar için doğruluk skorları	143
Çizelge 6.25.Çoklu-ESA PlantDiseaseNet modeline dayalı farklı kombinasyonlar için doğruluk skorları.....	143



1. GİRİŞ

Bitkiler, çevre ve insanođlu için hayati bir öneme sahiptir. Bitki olmaksızın dünya ekolojisi var olamaz. Ayrıca bitkiler; enerji, endüstri, gıda ve ilaç gibi birçok alanda da yoğun bir şekilde kullanılmaktadır [1-3]. Yapılan arařtırmalara göre dünya üzerinde yaklaşık 500.000 bitki türü olduđu bilinmektedir. Bitki konusunda uzmanların arařtırmaları neticesinde yeni türler ortaya çıkmakta ve var olan bitki türü sayısı gün geçtikçe artmaktadır. Bunun yanı sıra, mevsimsel kořullar ve çevre kirliliđi gibi nedenlerden dolayı bazı bitki türlerinin nesilleri tükenme tehlikesi altındadır. Bu yüzden, bitkilerin korunması ve yeni bitki türlerinin belirlenmesi için bitki tanınması ve bitkilerin korunması ile ilgili çalışmalar büyük önem taşımaktadır [1-5].

Bitkilerde olumsuz çevresel ve mevsimsel kořullara bađlı olarak çok sayıda hastalık oluřmaktadır. Bu hastalıklar her yıl büyük oranda verim düşüklüđüne ve ekonomik kayıplara neden olmaktadır. Bu durum, bitki hastalıklarının erken tespit edilerek gerekli tedbirlerin zamanında alınması ihtiyacını ortaya çıkarmaktadır [6-9].

Bitki türlerinin veya hastalıklarının tespit edilmesi görevini ziraat veya botanik üzerine ihtisaslařmış kişiler üstlenmektedir. Bitki türü ve hastalık tanıma süreci, önemli olmakla birlikte zor bir görevdir. Uzmanlar tarafından bu tür işlemlerin gerçekleştirilmesi için genel olarak görsel muayene ve daha sonrasında laboratuvar ortamında incelemeler yapılmaktadır. Bu geleneksel yöntemler zaman alıcı, yorucu ve karmařık süreçler içermektedir. Örneđin, bir bitkinin türünü binlerce bitki arasından belirlemek için birçok biyolojik test ve mikroskopik arařtırma yapılmaktadır. Özellikle aynı familyadan olan bitkiler benzer karakteristiklere sahip olduđu için kapsamlı analizlerin yapılması gerekmektedir [4,5,10].

Günümüzde bitki türlerinin ve hastalıklarının sınıflandırılması geleneksel yöntemler kullanılarak yapılmaktadır. Fakat bu tür işlemlerin zor, zaman alıcı ve karmařık süreçler içerdii bilinmektedir. Bilgisayar teknolojisindeki gelişmeler ile birlikte görsellik önem kazanmış ve buna bađlı olarak nesne tanımaya yönelik çok sayıda çalışma/uygulama yapılmıştır. Bu bağlamda, önceden tek tek insanlar tarafından incelenen veriler günümüzde görüntü işleme teknikleri sayesinde daha kolay, hatasız ve zaman kaybına uğramadan otomatik olarak yapılabilmektedir [1,3,4,10].

Bu tez çalışmasında, bitki türlerinin veya hastalıklarının sınıflandırılması için şekil, renk, doku ve derin özelliklere dayalı algoritmalar ve hibrit sistemler geliştirilmiştir.

Buna ek olarak, var olan yöntemler kapsamlı bir şekilde incelenmiş, yeni alternatif yaklaşımlar önerilmiştir.

Bu tez çalışmasının birinci bölümünde bitki türlerinin tanınması ve bitki hastalıklarının tespiti ile ilgili genel bilgiler verilmiştir. Alt başlıklarda literatürde yapılan çalışmalar detaylandırılarak önerilen çalışmaların genel çerçevesi (amaç, kapsam vs.) açıklanmıştır.

1.1. Literatür İncelemesi

Bu bölümde, bitki türleri ve bitki hastalıklarının sınıflandırılması ile ilgili literatürde yapılan çalışmalar kapsamlı bir şekilde incelenmiştir.

1.1.1. Bitki Türleri ile ilgili yapılan çalışmalar

Bitki sınıflandırma, bitki çeşitliliğinin çok sayıda olması ve bitki aileleri arasındaki benzerliklerden dolayı zor bir problemdir [5,10]. Son yıllarda, bitki tanıma problemi için makine öğrenmesi ve görüntü işleme algoritmalarına dayalı çok sayıda çalışma yapılmıştır. Bu çalışmaların büyük bir kısmında, Flavia [11], Swedish [12], ICL [13], Foliage [14], Folio [15] ve LeafSnap [16] gibi yaprak görüntülerini içeren bitki veri setleri kullanılmıştır. Diğer çalışmalarda ise, gerçek zamanlı elde edilmiş bitki görüntülerini içeren Flower17 [17-19] ve Flower102 [19] veri setleri yaygın olarak kullanılmıştır. Bu veri setleri kullanılarak şekil, doku ve renk özelliklerine dayalı gerçekleştirilen akademik çalışmalar aşağıda özetlenmiştir.

Wu ve diğ. yaptıkları çalışmada [11], bitki türlerinin sınıflandırılması için temel geometrik özelliklere dayalı yeni özellikler önerilmiştir. Geliştirilen yöntemler ile Bitki yaprakları kullanılarak elde edilen öznelikler, OSA (Olasılıksal Sinir Ağı) yöntemi ile sınıflandırılmıştır. Önerilen yaklaşımı test etmek için Flavia veri seti kullanılmıştır. Deneysel çalışmalarda elde edilen sonuçlara göre %90 doğruluk skoru elde edilmiştir.

Du ve diğ. yaptıkları çalışmada [20], bitki türlerinin hızlı bir şekilde sınıflandırılması için MMC (Move Median Centers) hiperküre olarak adlandırılan yeni bir sınıflandırıcı yöntemi önermişlerdir. Öncelikle bitki yapraklarından özellik çıkarmak için geometrik özellikler ve Hu değişmez moment yöntemi kullanılmıştır. Daha sonra elde edilen bu öznelik vektörleri, MMC ile k-EYK (k-En Yakın Komşu) yöntemi kullanılarak test edilmiş ve performans sonuçları karşılaştırılmıştır. Deneysel sonuçlarda,

MMC sınıflandırıcısı k-EYK yöntemine göre sınıflandırma zamanı düşük ve hafıza gereksinimi daha az olduğu tespit edilmiştir.

Kumar ve diğ. yaptıkları çalışmada [16], gerçek zamanlı elde edilmiş yaprak tabanlı bitki türlerinin tanınması için Leafsnap olarak adlandırılan bir mobil uygulama sistemi geliştirmişlerdir. Bu sistemde, öncelikle görüntüdeki yaprak nesnesini arka plandan ayırmak için segmentasyon işlemi uygulanmış ve daha sonra bölütlenmiş görüntüdeki yaprağın şeklini temsil eden çok ölçekli eğrilik histogramı kullanılarak özellikler çıkartılmıştır. Son olarak, yaprağın eğriliğini temsil eden özellikler, DVM (Destek Vektör Makinesi) yöntemi ile sınıflandırılmıştır. Önerilen yaklaşım, 184 sınıf ve 7719 yaprak görüntüsü içeren veri seti kullanılarak test edilmiştir. Deneysel çalışmalar, önerilen yaklaşımın döndürmeye ve çevirmeye karşı sağlam olduğunu ve yüksek sınıflandırma performansına sahip olduğunu göstermiştir.

Mahdikhanlou ve diğ. yaptıkları çalışmada [21], yaprak şeklinin sınır eğrileri temel alınarak EEE (En Az Eylemsizlik Ekseni) ve MKU (Merkez Kenar Uzunluğu) yöntemlerine dayalı bir yaklaşım önermişlerdir. Bu yöntemlerden elde edilen özneliklerin bireysel ve hibrit performansları, OSA sınıflandırıcısı kullanılarak hesaplanmıştır. Deneysel çalışmalarda elde edilen sonuçlara göre, Swedish yaprak veri seti için %82.05 iken Flavia yaprak veri için ise %80.10 doğruluk skorları elde edilmiştir.

Kadir ve diğ. yaptıkları çalışmada [14], şekil, doku, renk ve damar gibi yaprağın tüm özelliklerini içeren bir bitki tanıma sistemi geliştirmişlerdir. Önerilen sistemde, yaprak görüntülerinden özellik çıkarmak için geometrik, renk ve damar özelliklerinin yanı sıra GSEM (Gri Seviye Eş-Oluşum Matrisi) yöntemi ile Fourier tanımlayıcılarını kullanmıştır. OSA sınıflandırıcı yöntemi kullanılarak bu yöntemlerin farklı kombinasyonlarına dayalı sınıflandırma performansları hesaplanmıştır. Foliage ve Flavia veri setlerine dayalı gerçekleştirilen deneysel çalışmalarda sırasıyla %93.08 ve %94.68 doğruluk skorları elde edilmiştir.

Lee ve diğ. yaptıkları çalışmada [22], bitki yaprağının damar ve şeklini temel alan bir bitki tanıma sistemi önermişlerdir. Önerilen yaklaşımda, yaprağın sınır eğrisindeki pikseller ile merkez noktası arasındaki mesafeler kullanılarak HFD (Hızlı Fourier Dönüşümü) gerçekleştirilmiştir. Bu yöntem ek olarak, istatistiksel denklemlere dayalı geometrik ve damar özellikleri çıkartılmış ve tüm özellikler birleştirilmiştir. Önerilen sistemin geçerliliğini doğrulamak için Flavia veri seti kullanılmıştır. Deneysel

sonuçlarda, önerilen yaprak tanıma sistemi kullanılarak %97.19 doğruluk skoru elde edilmiştir.

Kadir ve diğ. yaptıkları çalışmada [23], bitki tanımlama sistemi geliştirmek için Zernike moment yöntemine dayalı kapsamlı deneysel çalışmalar gerçekleştirmişlerdir. Bu yöneme ek olarak, doku özellikleri için GSEM yöntemi, renk momentleri ve şekil özellikleri kullanılarak bitkiye ait öznelik vektörleri oluşturulmuştur. Elde edilen öznelikler birleştirilmiştir ve daha sonra Oklid Uzaklığı ve OSA sınıflandırıcıları ile performansları hesaplanmıştır. Foliage ve Flavia veri setlerine dayalı gerçekleştirilen deneysel çalışmalarda sırasıyla %93.33 ve %94.69 doğruluk skoru elde edilmiştir.

Sari ve diğ. yaptıkları çalışmada [24], otomatik yaprak tanıma problemi için farklı görüntü ve şekil tanımlayıcıları ile ilgili kapsamlı bir çalışma yapmışlardır. Bu çalışmada, şekil tanımlayıcıları, FT (Fourier Tanımlayıcıları) ve ÇMM (Çok-Boyutlu Mesafe Matrisi) yöntemlerinin birlikte kullanılmasına yönelik bir yaklaşım önerilmiştir. Bu yöntemlerin bireysel ve hibrit modelleri, KDA (Kuadratik Diskriminant Analizi), DVM ve KNN sınıflandırıcıları kullanılarak performansları hesaplanmıştır. SLID ve Flavia veri setlerine dayalı gerçekleştirilen deneysel çalışmalarda en yüksek doğruluk skoru sırasıyla %96.67 ve %94.62 olarak elde edilmiştir.

Naresh ve diğ. yaptıkları çalışmada [25], yaprak tabanlı bitki türlerini sınıflandırmak için doku özelliklerine dayalı sembolik bir yaklaşım önermişlerdir. Geliştirilmiş doku tabanlı YİÖ (Yerel İkili Örüntü) yöntemi kullanılarak bitki yapraklarından özellikler çıkartılmıştır. Elde edilen bu özellikler, sınıf içi varyasyonu artırmak için kümeleme tabanlı k-EYK yöntemi kullanılarak performansı hesaplanmıştır. Önerilen yöntemin geçerliliğini doğrulamak için Foliage, Swedish ve Flavia veri setleri kullanılmıştır ve yapılan deneysel çalışmalarda sırasıyla %90.62, %96.83 ve %97.55 doğruluk skorları elde edilmiştir.

Elhariri ve diğ. yaptıkları çalışmada [26], renk özellikleri, damar özellikleri, şekil özellikleri ve doku özelliklerinin kombinasyonuna dayalı bir sistem önermişlerdir. Farklı türde bitkileri sınıflandırmak için RO (Rastgele Ormanlar) ve DAA (Doğrusal Ayırt Etme Analizi) algoritmalarına dayalı sınıflandırıcı yöntemleri kullanılmıştır. Önerilen sistemin geçerliliğini doğrulamak için 340 yaprak görüntüsünden oluşan bir veri seti kullanılarak gerçekleştirilen deneysel çalışmalarda DAA sınıflandırıcısı ile %92.65 olarak en yüksek doğruluk skoru elde edilmiştir.

Tsolakidis ve diğ. yaptıkları çalışmada [27], yaprak tabanlı bitki türlerinin sınıflandırılması için Zernike Momentleri ve YGH (Yönlendirilmiş Gradyanların Histogramı) yöntemlerinin kombinasyonuna dayalı bir sistem önermişlerdir. Bölütleme işlemi uygulandıktan sonra Zernike Momentler kullanılarak şekil özellikleri ile YGH yöntemi kullanılarak doku özellikleri çıkartılmıştır. Her iki yöntemden elde edilen öznitelikler birleştirilmiş ve daha sonra DVM sınıflandırıcısı ile performansı hesaplanmıştır. Swedish ve Flavia veri setlerine dayalı gerçekleştirilen deneysel çalışmalarda sırasıyla %98.13 ve %97.18 doğruluk skorları elde edilmiştir.

Kadir ve diğ. yaptıkları çalışmada [28], şekil, renk ve doku tabanlı bir bitki tanıma sistemi geliştirmişlerdir. TBA (Temel Birleşen Analizi) yöntemi kullanılarak önerilen bu sistemin sınıflandırma performansının artırılması amaçlanmıştır. TBA yöntemi kullanılmasıyla elde edilen seçkin özellikler, OSA sınıflandırıcısı kullanılarak test edilmiştir. Önerilen yöntemin geçerliğini doğrulamak için Flavia ve Foliage veri setleri kullanılmış ve gerçekleştirilen deneysel çalışmalarda sırasıyla %95.00 ve %93.75 doğruluk skorları elde edilmiştir.

Wang ve diğ. yaptıkları çalışmada [29], bitki yaprağı görüntülerinden ayırt edici özelliklerin çıkarılması ve gürültüyle bozulma olasılığını azaltmak için, çift ölçekli ayrıştırma ve yerel ikili örüntü yöntemlerine dayalı yeni bir algoritma önermişlerdir. Elde edilen bu öznitelikler k-EYK yöntemi kullanılarak sınıflandırma performansı hesaplanmıştır. Önerilen yöntemin geçerliğini doğrulamak için Flavia ve ICL veri setleri kullanılmış ve gerçekleştirilen deneysel çalışmalarda sırasıyla %99.25 ve %98.03 doğruluk skorları elde edilmiştir.

Herdiyeni ve diğ. yaptıkları çalışmada [30], bitki tanıma için doku, şekil ve renk özelliklerine dayalı bir kombine sistem önermişlerdir. Yaprığın doku özelliklerini çıkarmak için önerilen Yerel İkili Örtüntü Varyansı ile yaprağın renk ayırt ediciliğini çıkarmak için renk istatistiksel momentleri kullanılmıştır. Daha sonra elde edilen bu öznitelik parametreleri birleştirilmiş ve OSA yöntemi kullanılarak sınıflandırma performansı hesaplanmıştır. Önerilen sistemi test etmek için 51 sınıflı 2448 yaprak görüntüsünü içeren veri seti kullanılmıştır. Deneysel çalışmalara göre, önerilen sistem kullanılarak %72.18 doğruluk skoru elde edilmiştir.

Le ve diğ. yaptıkları çalışmada [31], yaprağın dokusal özelliklerinin çıkarılması için YİÖ yöntemi ile DVM sınıflandırıcısının kombinasyonuna dayalı çok sınıflı bir bitki

tanıma sistemi önermişlerdir. YİÖ yöntemi için komşu sayısı ve yarıçap gibi değişken parametreler kullanılarak %91.85 olarak en iyi sınıflandırma performansı elde edilmiştir.

Saleem ve diğ. yaptıkları çalışmada [32], bitki yapraklarından geometrik özellikler ile doku özelliklerini çıkarmak için çeşitli yöntemlerin kombinasyonuna dayalı bir sistem önermişlerdir. Geliştirilen modelin performansını test etmek için k-EYK, Karar Ağacı, Naive Bayes ve DVM gibi farklı sınıflandırıcılar kullanılmıştır. Flavia veri setine dayalı gerçekleştirilen deneysel çalışmalarda %98.75 doğruluk skoru elde edilmiştir.

Aakif ve diğ. yaptıkları çalışmada [33], morfolojik özellikler, Fourier tanımlayıcıları ve yeni önerilen şekil tanımlayıcılarına dayalı farklı yaprak özelliklerini içeren bir sistem geliştirmişlerdir. Bitki yapraklarından elde edilen ayırt edici özellikler YSA (Yapay Sinir Ağları) yöntemi kullanılarak sınıflandırılmıştır. Önerilen sistemin geçerliliğini doğrulamak için Flavia ve ICL veri setleri kullanılmış ve yapılan deneysel çalışmalarda iki veri seti için de yaklaşık %96 doğruluk skoru elde edilmiştir.

Munisami ve diğ. yaptıkları çalışmada [34], yaprak görüntüleri kullanılarak bitki türlerinin sınıflandırılması için bir tanıma sistemi geliştirilmiştir. Morfolojik ve renk özelliklerine dayalı önerilen sistem için sınıflandırıcı olarak k-EYK yöntemi kullanılmıştır. Önerilen sistemi test etmek için Folio veri seti kullanılmıştır. Gerçekleştirilen deneysel çalışmalarda, %87.3 doğruluk skoru elde edilmiştir.

Chaki ve diğ. yaptıkları çalışmada [35], bitki yapraklarını tanımak için doku ve şekil özelliklerinin kombinasyonuna dayalı yeni bir yaklaşım önerilmiştir. Geliştirilen sistemde, yaprağın doku ve şekil özellikleri için Gabor filtresi, GSEM yöntemi, değişmez momentler ve curvelet özellikleri kullanılmıştır. Önerilen yaklaşımı test etmek için NFC (Nöro-Bulanık Denetleyici) ve ÇKA (Çok Katmanlı Algılayıcı) gibi iki nöral sınıflandırıcı yöntemleri kullanılmıştır. Deneysel sonuçlar, önerilen yaklaşımın çeşitli doku ve şekillere sahip 31 yaprak türünü ayırt etmede etkili olduğunu göstermiştir.

Hu ve diğ. yaptıkları çalışmada [36], döndürme, ölçeklendirme, yansıtma ve çevirme gibi işlemlere karşı değişmez çok ölçekli uzaklık matrisi olarak adlandırılan yeni bir şekil tanımlayıcısı önermişlerdir. Geliştirilen bu yöntemin ayırt etme gücünü artırmak için TBA yöntemi kullanılmıştır. Önerilen yöntemi test etmek için yaprak tabanlı Swedish ve ICL veri setleri kullanılmış ve DAA sınıflandırıcısı kullanılarak her iki veri seti için de performansı hesaplanmıştır. Deneysel sonuçlar, önerilen tanımlayıcının etkinliğini ve verimliliğini açıkça göstermiştir.

Yukarıda şekil, doku ve renk tabanlı literatürde yapılan temel ve güncel çalışmalardan bahsedilmiştir. Bu çalışmaların dışında bitki türlerinin sınıflandırılması için yapılan diğer çalışmalar Çizelge 1.1’de sunulmuştur.

Çizelge 1.1. Bitki tanıma çalışmaları

Referans	Özellik çıkarım yöntemi	Sınıflandırıcı Yöntemi	Veri seti	Doğruluk skoru
Yasar vd. [37]	Şekil ve doku özellikleri	YSA	ICL	%92
Kadir vd. [38]	Polar Fourier Tanımlayıcısı, renk momentleri ve damar özellikleri	Öklid Uzaklık	Flavia Foliage	%93.13 %90.80
Priya vd. [39]	Geometrik özellikler	DVM	Flavia	%94.5
Ghasab vd. [40]	Şekil, renk, GSEM ve damar özellikleri	DVM	Flavia	%96.25
Hsiao vd. [41]	Ölçekten Bağımsız Özellik Dönüşümü (ÖBÖD)	DVM	Flavia	%95.94
Ren vd. [42]	Örtüşen blok tabanlı YİÖ	DVM	Swedish	%96.67
Sulc vd. [43]	YİÖ tabanlı döndürme ve ölçeklendirmeye karşı değişmez tanımlayıcılar	DVM	Flavia	%99.5
			Foliage	%99
			Swedish	%99.8
			Folio	%99.2
Qi vd. [44]	Çift Yönlü Döndürmeye karşı Değişmeyen Eş-oluşumlu YİÖ	DVM	Flower102	%84.2
			Swedish	%99.38
Laga vd. [45]	Geometrik özelliklere dayalı kombinasyon özellikler	k-EYK	Flavia	%92.37
			Swedish	%99.18
Wang vd. [46]	Şekil tabanlı özellikler (Çok ölçekli eğim yüksekliği (MARCH))	k-EYK	Swedish	%97.3
Silva vd. [13]	Şekil özellikleri	DAA	ICL	%87
Prasad vd. [47]	Geometrik ve renk özellikleri ile FT yöntemi	k-EYK	Flavia	%91.34
			Flavia	%96.6
			Foliage	%93.1
			Folio	%91.4
Hewitt vd. [48]	Şekil özellikleri ve yerel alan integral değişmez yöntemine dayalı çıkartılan sinyal özellikleri	DVM	Swedish	%97.8
			LeafSnap	%64.9
			Flower102	%73.3
Khan vd. [49]	Renk ve şekil özelliklerinin kombinasyonu	DVM	Flower102	%73.3
Zhu vd. [50]	Şekil özellikleri ve Renk tabanlı yeni bir yaklaşım	DVM	Flower17	%91.9
			Flower102	%73.1
Elnemr vd. [51]	GSEM, YİÖ ve Curvulet Dönüşüm yöntemleri	k-EYK	Flavia	%98

Bitki türlerinin tanınması için yapılan önceki çalışmaların çoğu şekil, doku ve renk özellikleri kullanılarak gerçekleştirilmiştir. Bu mevcut yöntemlerin en büyük dezavantajı, ön-işlem aşamasına ihtiyaç duyması ve gerçek zamanlı sistemlerde başarısız olmasıdır. Son zamanlarda, ESA (Evrişimsel Sinir Ağı) kullanılarak klasik öğrenmenin sebep olduğu problemler giderilmiş ve sınıflandırma performansı büyük ölçüde artırılmıştır. Bitki türlerinin sınıflandırılması için derin öğrenme kullanılarak yapılan çalışmalar aşağıda özetlenmiştir.

Beikmohammadi ve diğ. yaptıkları çalışmada [52], yaprak tabanlı bitki türlerinin sınıflandırılması için transfer öğrenme yaklaşımı kullanılarak önceden eğitilmiş derin sinir ağlarına dayalı etkili bir yöntem sunulmuştur. Bu amaç için önceden eğitilmiş MobileNet mimarisi kullanılarak bitki yapraklarından derin özellikler çıkartılmıştır. Daha

sonra elde edilen parametreler, lojistik regresyon yöntemi kullanılarak test edilmiştir. Flavia ve LeafSnap veri setlerine dayalı gerçekleştirilen deneysel çalışmalarda sırasıyla %99.6 ve %90.54 olarak en iyi sınıflandırma performansları elde edilmiştir.

Grinblat ve diğ. yaptıkları çalışmada [53], bitki tanımlama problemi için yaprağın damar özellikleri kullanılarak Derin ESA dayalı bir yaklaşım önermişlerdir. Önerilen modelin performansını test etmek için üç farklı bakliyat türüne ait veri seti kullanılmıştır. Geliştirilen sistem ile DVM gibi makine öğrenmesi algoritmalarına kıyasla daha iyi hassasiyet ve doğruluk skoru elde edilmiştir.

Ghazi ve diğ. yaptıkları çalışmada [54], bitki türlerini tanımlamak için derin sinir ağlarının ve bu ağların performanslarını etkileyen parametreleri değerlendirmişlerdir. Bu amaçla, GoogleNet, AlexNet ve VGGNet gibi önceden eğitilmiş güçlü derin mimariler kullanılmıştır. Bu derin mimarileri bitki sınıflandırılma problemine adapte etmek için transfer öğrenme yaklaşımına dayalı ince ayar işlemleri uygulanmıştır. Bu derin mimarilerinin kombinasyonuna dayalı ağ parametreleri ve veri artırma gibi işlemler kullanılarak en iyi kombine sistem elde edilmiştir. Deneysel çalışmalardan elde edilen sonuçlara göre, füzyon tekniği kullanılarak VGGNet ve GoogleNet mimarileri birleştirilmiş ve %80.18 olarak en iyi doğruluk skoru elde edilmiştir.

Prasad ve diğ. yaptıkları çalışmada [55], yaprak tabanlı bitki türlerinin sınıflandırılması için derin özelliklere dayalı transfer öğrenme yaklaşımı önerilmiştir. Önceden eğitilmiş VGG16 mimarisi kullanılarak yaprak görüntülerinden derin özellikler çıkartılmıştır. Daha sonra sınıflandırma performansını optimize etmek için TBA yöntemi kullanılarak etkili ve ayırt edici özellikler elde edilmiştir. Son olarak, her bir yaprak görüntüsüne ait öznitelik vektörleri DVM yöntemi kullanılarak sınıflandırılmıştır. Yaprak tabanlı ICL veri setine dayalı yapılan deneysel çalışmalara göre, %98.2 doğruluk skoru hesaplanmıştır.

Sun ve diğ. yaptıkları çalışmada [56], çok sınıflı bitki türlerini sınıflandırmak için ResNet modeline dayalı 26 katlı bir derin öğrenme modeli tasarlamışlardır. Bu model 8 artık yapı bloklarından oluşmaktadır. Önerilen modeli test etmek için, doğal ortamdan elde edilmiş ve cep telefonu kullanılarak çekilen 100 süs bitkisi türüne ait toplam 10000 görüntü kullanılmıştır. Yapılan deneysel çalışmalara göre, %91.78 doğruluk skoru elde edilmiştir.

Lee ve diğ. yaptıkları çalışmada [57], yaprak görüntülerine dayalı bitki tanımlama için evrişimsel sinir ağlarına dayalı bir yaklaşım değerlendirmişlerdir. Önerilen yaklaşım, önceden eğitilmiş AlexNet mimarisinin tam bağlı katmanı kullanılarak bitki yaprak görüntülerini temsilen derin özellikler çıkartılmıştır. Elde edilen derin özellikler, ÇKA ve DVM gibi sınıflandırıcı yöntemleri kullanılarak performansları hesaplanmıştır. Bu sonuçlara göre, %99.5 doğruluk skoru elde edilmiş ve geleneksel yöntemlere kıyasla daha yüksek performansa sahip olduğu gözlenmiştir.

He ve diğ. yaptıkları çalışmada [58], bitki türlerinin sınıflandırılması için bitkiye ait tek bir organ kullanmak yerine çeşitli organların (meyve, dal, yaprak, vs.) kombinasyonuna dayalı etkili ve yüksek performanslı bir yaklaşım önermişlerdir. Geliştirilen bu sistem, önceden eğitilmiş derin mimari kullanılarak bitkiye ait organların her birinden derin özellikler çıkartılmış ve daha sonra tek bir bitki türü için çok sütunlu öznelik vektörleri elde edilmiştir. Yapılan deneysel çalışmalarda, önerilen yaklaşımın üstünlüğü gözlenmiştir.

Cıbuk ve diğ. yaptıkları çalışmada [59], bitki türlerinin sınıflandırılması için derin ESA'ya dayalı hibrit bir sistem önermişlerdir. Geliştirilen sistemde, özellik çıkarmak için önceden eğitilmiş AlexNet ve VGG16 mimarileri kullanılmıştır. Daha sonra, iki güçlü mimariden elde edilen derin özellikler birleştirilmiş ve MRMR (En Küçük Artıklık En Büyük İlgililik) özellik seçim algoritması kullanılarak daha verimli ve etkili öz vektörler seçilmiştir. Elde edilen bu özellikler, Radyal Baz Fonksiyonlu çekirdeğe sahip DVM yöntemi kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Deneysel çalışmalarda çok sınıflı bitki görüntülerini içeren Flower17 ve Flower102 veri setleri kullanılarak, sırasıyla %96.39 ve %95.70 doğruluk skorları elde edilmiştir.

Nguyen ve diğ. yaptıkları çalışmada [60], bitki türlerinin otomatik olarak tanımlamak için önceden eğitilmiş derin mimarilerin sağlamlığını ve performanslarını değerlendirmişlerdir. Bu çalışmada, büyük veri setleri kullanılarak eğitilmiş AlexNet, CaffeNET ve GoogleNet mimarileri için transfer öğrenme yaklaşımı kullanılarak bitki türlerinin sınıflandırılması için adapte edilmiştir. Yapılan kapsamlı deneysel sonuçlara göre, en yüksek performans GoogleNet mimarisi kullanılarak elde edilmiştir.

Pawara ve diğ. yaptıkları çalışmada [61], derin öğrenme tabanlı çeşitli veri artırma teknikleri kullanılarak bitki sınıflandırma problemleri üzerindeki etkilerini incelemişlerdir. Bu amaç için, önceden eğitilmiş evrişimsel sinir ağlarından AlexNet ve

GoogleNet mimarileri kullanılmıştır. Bu derin mimariler sıfırdan ve önceden eğitilmiş ağırlıkları kullanılarak üç bitki veri seti için performansları hesaplanmıştır. Buna ek olarak, dönme, bulanıklaştırma, kontrast, ölçeklendirme, aydınlatma ve yansıtma gibi veri artırma tekniklerinin kombinasyonları değerlendirilmiştir. Yapılan kapsamlı deneysel çalışmalarda, veri artırma teknikleri kullanılarak elde edilen veri setleri ile ESA mimarileri, üç veri setinde de önceki çalışmalara göre en yüksek doğruluğu sağladığı gözlenmiştir. Ayrıca sıfırdan eğitilen ESA modelleri, transfer öğrenme yaklaşımı kullanılarak ince ayarlanmış ESA modellerine göre daha düşük performans göstermiştir. Sonuç olarak, GoogleNet mimarisi kullanılarak Swedish, AgrilPlant ve Folio veri setleri için sırasıyla %99.92, %99.42 ve %98.60 olarak en yüksek doğruluk skorları elde edilmiştir.

Dyrmann ve diğ. yaptıkları çalışmada [62], evrişimsel sinir ağları kullanılarak bitki türlerinin sınıflandırılması için bir model sunulmuştur. Önerilen model, 22 bitki türüne ait 10413 görüntü üzerinde eğitilmiş ve test edilmiştir. Bu model, evrişim katmanları ile artık bloklardan oluşmakta ve birinci evrişim katmanı önceden eğitilmiş olan VGG16 mimarisinin ağırlıkları ile başlatılmıştır. Deneysel çalışmalardan elde edilen sonuçlara göre, önerilen model kullanılarak %86.2 doğruluk skoru elde edilmiştir.

Zhang ve diğ. yaptıkları çalışmada [63], yaprak tabanlı bitki türlerini tanımlamak için yedi katmanlı bir ESA mimarisi önerilmiştir. Geliştirilen model uygulanmadan önce, veri setini büyütme için döndürme ve çevirme gibi veri artırma yöntemleri kullanılmıştır. Önerilen modelin doğruluğunu test etmek için, Flavia veri seti kullanılmış ve %94.6 doğruluk skoru hesaplanmıştır.

Zhu ve diğ. yaptıkları çalışmada [64], bitki görüntülerinden ayırt edici özellikleri çıkarmak ve bitki tanımlamak için derin bir ESA modeli önerilmiştir. Bu model genel olarak 13 evrişim katmanı ile tam bağlı katmandan oluşmaktadır. Çeşitli bitki veri kümelerinde yapılan kapsamlı deneysel çalışmalarda, önerilen model geleneksel yöntemlere kıyasla daha yüksek bir performans sağladığı gözlenmiştir. Ayrıca bu çalışmada, Relu aktivasyon fonksiyonunun etkileri incelenmiş ve elde edilen sonuçlara göre önerilen model ile birlikte bu katman kullanılarak üstün performans sağladığı tespit edilmiştir.

Liu ve diğ. yaptıkları çalışmada [65], bitki yapraklarının ayırt edici özelliklerini çıkarmak için Autoencoder ve ESA dayalı yeni bir sinir ağı önerilmiştir. Bu çalışmada,

hibrit derin öğrenmenin bitki sınıflandırma problemi için performansı incelenmiştir. Önerilen sistem için öncelikle yaprak görüntülerinden hibrit derin öğrenmeye dayalı özellikler çıkartılmış ve daha sonra DVM yöntemi kullanılarak sınıflandırma ve test işlemi yapılmıştır. Deneysel çalışmalarda elde edilen sonuçlara göre, önerilen hibrit derin öğrenme bireysel olarak DVM, Autoencoder ve ESA yöntemlerinin her birinden daha iyi performans sağladığı gözlenmiştir.

Wick ve diğ. yaptıkları çalışmada [66], yaprak tabanlı bitki türlerini sınıflandırmak için dokuz katmanlı bir ESA mimarisi önermişlerdir. Genellikle ESA modelleri büyük veri setleri kullanılarak eğitilmektedir. Bu nedenden dolayı, Wick ve arkadaşları veri artırma teknikleri kullanılarak görüntü sayısını artırmışlardır. Önerilen model kullanılarak Flavia ve Foliage veri setlerinde %99'un üzerinde tanıma oranı elde edilmiştir ve önceki çalışmalara göre daha iyi performans göstermiştir.

Jeon ve diğ. yaptıkları çalışmada [67], bitki türlerini sınıflandırmak için önceden eğitilmiş GoogleNet mimarisinin ağ derinliklerine dayalı değiştirilmiş versiyonlarını önermişlerdir. Geliştirilen modeller, ham görüntüler dışında deforme olmuş yaprak görüntüleri kullanılarak test edilmiştir. Elde edilen sonuçlara göre, ham görüntülerin yanı sıra deforme olmuş yaprak görüntülerinde de tanıma oranları %94'ten daha yüksek olduğu gözlenmiştir.

Yalcın ve diğ. yaptıkları çalışmada [68], akıllı tarım istasyonlarından toplanan görüntüler kullanılarak bitki türlerinin sınıflandırılması için önceden eğitilmiş AlexNet mimarisi kullanılmasına dayalı bir yaklaşım sunmuşlardır. Önerilen yaklaşımın performansını değerlendirmek için, YİÖ ve GIST gibi özellik çıkarım yöntemleri ile DVM sınıflandırıcının kombinasyonuna dayalı elde edilen performans sonuçları ile karşılaştırılmıştır. Bu sonuçlara göre, önerilen sistem diğer geleneksel yöntemlere göre daha yüksek performans sağladığı gözlenmiştir.

Barre ve diğ. yaptıkları çalışmada [69], yaprak tabanlı bitki türlerini sınıflandırmak için 2x2'lik havuzlama katmanlarından oluşan 17 katmanlı bir ESA modeli önermişlerdir. Bu modelin geçerliliğini doğrulamak için yaprak tabanlı üç veri seti kullanılmıştır. Ayrıca veri artırma teknikleri kullanılarak veri setlerindeki görüntüler artırılmış ve önerilen model bu genişletilmiş veri setleri üzerinden eğitilmiştir. Deneysel çalışmalardan elde edilen sonuçlara göre, önerilen LeafNet modeli kullanılarak LeafSnap,

Foliage ve Flavia veri setleri için sırasıyla %86.3, %95.60 ve %97.9 doğruluk skorları elde edilmiştir.

Lee ve diğ. yaptıkları çalışmada [70], bitki türlerinin sınıflandırılması için evrişimsel sinir ağları kullanılarak ham görüntülerden derin özellikler elde edilmesine dayalı bir yaklaşım önerilmiştir. Bu çalışmada, önceden eğitilmiş AlexNet mimarisinin fc8 tam bağlı katmanı kullanılarak derin özellikler çıkartılmıştır. Daha sonra, elde edilen derin özellikler, DVM ve ÇKA sınıflandırıcıları kullanılarak performansları hesaplanmıştır. Deneysel çalışmalardan elde edilen sonuçlara göre, Folio ve Flavia veri setleri için sırasıyla %99.5 ve %99.4 doğruluk skorları elde edilmiştir.

Sulc ve diğ. yaptıkları çalışmada [71], bitki tanıma problemi için doku analizi ve derin öğrenme tabanlı bir yaklaşım geliştirilmiştir. Önerilen bu yaklaşımda, öncelikle parçalanmış veya bozulmuş yaprak görüntülerini tanımak ve iyileştirmek için döndürme ve ölçeklendirmeye karşı değişmez doku özellikleri kullanılmıştır. Daha sonra, ESA'ya dayalı geliştirilen derin ResNet152 ve Inception-ResNetv2 mimariler kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yaklaşımı test etmek için 6 farklı veri seti kullanılmıştır. Yapılan kapsamlı deneysel çalışmalarda, AFF [72], Flavia, Foliage, Swedish, MEW [73] ve LeafSnap veri setleri için sırasıyla %100, %99.8, %99.3, %99.8, %99.5 ve %83.7 olarak doğruluk skorları elde edilmiştir.

Kaya ve diğ. yaptıkları çalışmada [74], bitki türlerinin otomatik sınıflandırılması için derin sinir ağlarına dayalı kapsamlı bir çalışma yapmışlardır. Önceden eğitilmiş derin mimarilerden AlexNet ve VGG16 modelleri kullanılarak transfer öğrenme yaklaşımına dayalı ince ayar işlemi gerçekleştirilmiştir. Buna ek olarak, bu derin mimarilerden elde edilen öznelik vektörleri, DAA ve DVM sınıflandırıcıları kullanılarak performansları hesaplanmıştır. Deneysel sonuçlara göre, Flavia, Swedish ve UCI yaprak veri setleri için sırasıyla %99.10, %99.11 ve %96.20 doğruluk skorları elde edilmiştir.

1.1.2. Bitki Hastalıkları ile ilgili yapılan çalışmalar

Literatür incelendiğinde, bitki hastalık tespitine yönelik görüntü işleme tabanlı birçok çalışma bulunmaktadır. Bu çalışmalar genellikle 3 temel adımdan oluşmaktadır. Bunlar;

1. Renk dönüşüm, eşikleme ve segmentasyon gibi yöntemler kullanılarak hastalık görüntülerini bölütleme.
2. Şekil, doku ve renk tabanlı özellik çıkarım yöntemleri kullanılarak elde edilen bölütlenmiş görüntülerden temsili özellik çıkarma.
3. Geleneksel makine öğrenme yöntemleri kullanılarak hastalık tespiti gerçekleştirilmesi.

Bu işlem adımlarına dayalı gerçekleştirilen çalışmalar aşağıda özetlenmiştir.

Wang ve diğ. yaptıkları çalışmada [75], üzüm ve buğday hastalıkları tespiti için görüntü tanımlayıcılarına dayalı hibrit bir sistem önermişlerdir. Öncelikle, görüntü kırpma, görüntü dengeleme ve k-ortalama kümeleme algoritması kullanılarak hastalık görüntülerden hastalıklı olan kısımlar bölütlenmiştir. Daha sonra, şekil, renk ve doku tabanlı yöntemler kullanılarak hastalık görüntülerinden 50 özellik vektörü çıkartılmıştır. Son olarak, geri yayılma ağları kullanılarak elde edilen özneliklerin performansları hesaplanmıştır. Deneysel sonuçlara göre, buğday ve üzüm hastalıkları tespiti için %100 doğruluk skoru elde edilmiştir.

Arivazhagan ve diğ. yaptıkları çalışmada [76], bitki hastalık tespiti için 4 aşamalı bir model önermişlerdir. Öncelikle, RGB görüntüsü için renk dönüşümü uygulanır, yeşil pikseller maskelenir ve daha sonra bir eşik değeri belirlenerek segmentasyon işlemi gerçekleştirilir. Daha sonra elde edilen bölütlenmiş görüntülerden dokusal özellikler çıkartılır. Son olarak, DVM sınıflandırıcısı kullanılarak önerilen modelin performansı hesaplanmıştır. Yaklaşık 500 hastalıklı bitki yapraklarından oluşan bir veri tabanı kullanılarak önerilen model test edilmiş ve bu sonuçlara göre %94.74 doğruluk skoru elde edilmiştir.

Kulkarni ve diğ. yaptıkları çalışmada [77], bitki hastalıklarının erken ve doğru tespiti için bir sistem önerilmiştir. Öncelikle, renk uzayına dayalı CIELAB yöntemi kullanılarak segmentasyon işlemi yapılmıştır. Gabor filtresi kullanılarak bölütlenmiş bu görüntülerden özellikler çıkarılmış ve ardından YSA yöntemi ile sınıflandırma ve test işlemleri gerçekleştirilmiştir. Bu sonuçlara göre, önerilen sistem kullanılarak yaklaşık %91 tanıma oranı elde edilmiştir.

Bashir ve diğ. yaptıkları çalışmada [78], Malus Domestica hastalık tespiti için ve renk analizi ile K-ortalama kümeleme yöntemlerine dayalı bir hibrit sistem

geliştirilmiştir. Önerilen sistem için kullanılan özelliklerin kombinasyonları hastalık tespitinde çok etkili olduğu ve performansı arttırdığı tespit edilmiştir.

Prashar yaptığı çalışmada [79], pamuk hastalık tespiti için değişmez görüntü tanımlayıcılara dayalı bir sistem geliştirilmiştir. Önerilen bitki hastalık tanıma sistemi, YGH ve ÖBÖD özellik çıkarım yöntemleri ile DVM sınıflandırıcısının kullanılmasına dayalıdır. Deneysel sonuçlarda, önerilen yaklaşım kullanılarak hastalık tanımlama için %85 ve üzeri doğruluk skoru elde edilmiştir.

Athanikar ve diğ. yaptıkları çalışmada [80], yaprak görüntülerinden oluşan patates hastalık tespiti için sinir ağı tabanlı bir yaklaşım geliştirilmiştir. Öncelikle, yaprak hastalık görüntüleri için gauss filtreleme yöntemi ve ardından K-ortalama kümeleme algoritması uygulanmış ve bölütleme işlemi gerçekleştirilmiştir. Daha sonra, GSEM yöntemi ile Renk özellikleri kullanılarak bölütlenmiş görüntülerden öznitelikler çıkartılmıştır. Son olarak elde edilen öznitelikler geri yayılım algoritması kullanılarak sınıflandırılmış ve test edilmiştir. Bu sonuçlara göre, %92 doğruluk skoru elde edilmiştir.

Waghmare ve diğ. yaptıkları çalışmada [81], otomatik olarak üzüm hastalık tespiti için çok sınıflı DVM sınıflandırıcısına dayalı bir yaklaşım sunmuşlardır. Önerilen bu yaklaşımda, öncelikle HSV renk dönüştürücüsü ve daha sonra Otsu eşikleme yöntemi kullanılarak segmentasyon işlemi gerçekleştirilmiştir. Daha sonra, YİÖ yöntemi kullanılarak elde edilen bölütlenmiş görüntülerden öznitelikler çıkartılmış ve DVM sınıflandırıcı ile performansları hesaplanmıştır. Önerilen yaklaşımı test etmek için sağlıklı, hastalıklı ve zararlı olmak üzere üç sınıfa ait 450 üzüm görüntüsü kullanılmıştır. Deneysel sonuçlara göre, önerilen yaklaşım ile %96.6 doğruluk skoru elde edildiği gözlenmiştir.

Dubey ve diğ. yaptıkları çalışmada [82], renk, doku ve şekil tabanlı özellikler kullanılarak elma hastalığı sınıflandırmasına yönelik bir yaklaşım sunmuşlardır. Önerilen yaklaşımda, öncelikle elma meyvesinin enfekte olmuş kısmını tespit etmek için k-ortalamar kümeleme yöntemi kullanılmıştır. Daha sonra, global renk histogrtamı, renk momentleri, YİÖ yöntemi ve Zernike moment yöntemleri kullanılarak elde edilen hastalıklı görüntülerden özellikler çıkartılmış ve elde edilen özellikler çok sınıflı DVM yöntemi kullanılarak sınıflandırılmıştır. Önerilen yaklaşımı test etmek için hastalık ve sağlıklı elma görüntülerinden oluşan dört sınıflı bir veri seti kullanılmıştır. Deneysel sonuçlara göre, %95.94 doğruluk skoru elde edilmiştir.

Mohan ve diğ. yaptıkları çalışmada [83], otomatik çeltik hastalık tespiti ve sınıflandırılması için iki aşamalı bir yaklaşım önermişlerdir. İlk aşamada, hastalık tespiti için çeltik bitkisinin hastalıktan etkilenen kısmı, Haar-like yöntemi kullanılarak özellikler çıkartılmış ve daha sonra AdaBoost yöntemi ile sınıflandırılmıştır. Sonuç olarak, çeltik hastalık tespiti için %83.33 doğruluk skoru elde edilmiştir. İkinci aşamada ise, hastalık sınıflandırılması için ÖBÖD yöntemi kullanılarak hastalıklı görüntülerden elde edilen özellikler k-EYK ve DVM yöntemleri ile sınıflandırılmıştır. Deneysel çalışmalarda, k-EYK ve DVM sınıflandırıcıları kullanılarak sırasıyla %93.33 ve %91.10 doğruluk skorları elde edilmiştir.

Yukarıda bitki hastalık sınıflandırılması için görüntü bölütleme yöntemleri ile şekil, doku ve renk tabanlı özellik çıkarım yöntemlerinin kullanılmasına dayalı literatürde yapılan temel ve güncel çalışmalardan bahsedilmiştir. Bitki hastalıklarının sınıflandırılması için yapılan diğer çalışmalar Çizelge 1.2’de detaylandırılmıştır.

Çizelge 1.2. Bitki hastalık tespiti ile ilgili çalışmalar

Referans	Ön-işlem Yöntemi	Özellik çıkarım yöntemi	Sınıflandırıcı Yöntemi	Hastalık türü	Doğruluk skoru
Padol vd. [84]	K-ortalama kümeleme yöntemi	Renk momentleri ve GSEM yöntemi	DVM	Üzüm	%88.89
Tippannavar vd. [85]	Filtreleme, eşikleme ve morfolojik işlemler	Renk ve doku özellikleri	k-EYK OSA	Ispanak	%80.22 %73.47
Sabrol vd. [86]	Otsu eşikleme	Renk, doku ve şekil özellikleri	Sınıflandırma ağacı	Domates	%97.3
Thilagavathi vd. [87]	Renk dönüşümü (YCbCr, CIELAB)	ÖBÖD yöntemi	k-EYK DVM	Guava	%92 %97.1
Tilwani vd. [88]	Renk dönüşümü (HSV) ve K-ortalama kümeleme yöntemi	GSEM yöntemi	DVM	Çilek	-
Pujari vd. [89]	K-ortalama kümeleme yöntemi	Renk özellikleri ve GSEM yöntemi	YSA DVM	Mantar hastalıkları	%77.75 %83.83
Singh vd. [90]	Morfolojik işlemler ve Genetik algoritma	GSEM yöntemi	DVM	Beş Hastalık türü	%95.7
Kurniawati vd. [91]	Entropi eşikleme yöntemi ve Otsu algoritması	Renk ve şekil özellikleri	-	Çeltik	%94.7
Biswas vd. [92]	Bulanık K-ortalama kümelemesi	Doku özellikleri	Geri yayılım sinir ağı	Patates	%93
Dandawate vd. [93]	Renk dönüşümü (HSV) ve çoklu eşikleme yöntemi	ÖBÖD	DVM	Soya fasülyesi	%93.79
Yun vd. [94]	Morfolojik işlemler, kontur çıkarma ve bölge büyütme algoritmaları	Renk, doku ve şekil özellikleri	OSA	Salatalık	%91.08
Ramakrishnan vd. [95]	Renk dönüşümü (HSV) yöntemi	Renk ve doku özellikleri	Geri yayılım sinir ağı	Yer fıstığı	%97.41
Rothe vd. [96]	Aktif kontur segmentasyon yöntemi	Hu değişmez momentler	İleri beslemeli geri yayılma sinir ağı	Pamuk	%85.52
Kaur vd. [97]	Renk dönüşüm (Lab) yöntemi ve K-ortalama kümeleme yöntemi	Renk ve doku özellikleri	DVM	Üç hastalık türü	%90
Hossain vd. [98]	Morfolojik işlemler	Doku özellikleri	DVM	Çay	%93.33

Gelişen teknoloji ile birlikte büyük verilerin oluşturulması ve büyük ölçekli hafızalara sahip daha hızlı bilgisayarların üretilmesiyle derin sinir ağlarına dayalı modeller geliştirilmiştir. Son zamanlarda bitki hastalıklarının tespitine yönelik birçok derin öğrenme tabanlı çalışmalar yapılmıştır. Bu çalışmalar aşağıda özetlenmiştir.

Walleign ve diğ. yaptıkları çalışmada [99], soya bitkisi hastalıklarını sınıflandırmak ve tespit etmek için derin sinir ağlara dayalı bir model önerilmiştir. Bu model, her biri havuzlama katmanını izleyen üç evrişim katmanından ve tam bağlı katmandan oluşmaktadır. Buna ek olarak, her evrişim katmanının ve tam bağlı katmanın çıkışlarına Relu aktivasyon fonksiyonu uygulanmıştır. Önerilen model gerçek-doğal ortamdan çekilen görüntüler kullanılarak eğitilmiş ve %99.32 oranında doğruluk skoru elde edilmiştir.

Liu ve diğ. yaptıkları çalışmada [100], elma hastalıklarının tespiti için derin evrişimsel sinir ağlarına dayalı bir yaklaşım önermişlerdir. Bu çalışmada, önceden eğitilmiş AlexNet ve GoogleNet mimarilerinin kombinasyonuna dayalı yeni bir mimari tasarlanmıştır. Geliştirilen model, 4 sınıflı 13.689 elma hastalık görüntülerinden oluşan veri seti kullanılarak test edilmiştir. Deneysel sonuçlara göre, %97.92 doğruluk skoru elde edilmiş ve diğer mimarilere kıyasla daha yüksek performans sağlamıştır.

Amara ve diğ. yaptıkları çalışmada [101], muz yaprak hastalıklarını sınıflandırmak için derin öğrenme temelli bir yaklaşım geliştirmişlerdir. Önerilen bu yaklaşım için ESA tabanlı önceden eğitilmiş LeNet mimarisi kullanılmıştır. Önerilen yaklaşımın geçerliliğini doğrulamak için aydınlatma, arka plan, çözünürlük ve boyut gibi farklı senaryolardan oluşan gerçek zamanlı görüntüler kullanılmış ve %99.72 doğruluk skoru elde edilmiştir.

Sapkal ve diğ. yaptıkları çalışmada [102], yaprak hastalık tespiti için geleneksel görüntü tanımlayıcıları ile derin özelliklerin performansları karşılaştırmışlardır. GSEM yöntemi ile önceden eğitilmiş Alexnet mimarisinin fc8 katmanı kullanılarak yaprak görüntülerinden özellikler çıkartılmıştır. Daha sonra, geri yayılım sinir ağları sınıflandırıcısı kullanılarak elde edilen özelliklerin performansları ayrı ayrı hesaplanmıştır. Deneysel sonuçlara göre, derin özellikler doku tabanlı özelliklere kıyasla daha yüksek performans sağladığı tespit edilmiştir.

Ramcharan ve diğ. yaptıkları çalışmada [103], üç hastalık ve iki zararlı olmak üzere manyok hastalığının tespiti için derin evrişimsel sinir ağlarına dayalı transfer

öğrenme yaklaşımı kullanmışlardır. Bu amaç için önceden eğitilmiş Inception-v3 modeli kullanılarak hastalık görüntülerinden özellikler çıkartılmıştır. Elde edilen derin özellikler, DVM ve k-EYK sınıflandırıcıları kullanılarak performansları hesaplanmıştır. Deneysel çalışmalarda, önerilen yaklaşım kullanılarak DVM sınıflandırıcısı ile %93 olarak en yüksek doğruluk skoru elde edilmiştir.

Wang ve diğ. yaptıkları çalışmada [104], elma hastalıklarının tespiti için önceden eğitilmiş derin mimariler kullanmışlardır. Transfer öğrenme yaklaşımı kullanılarak bu derin mimariler elma hastalık tespit problemi için adapte edilmiştir. Önceden eğitilmiş VGG16, VGG19, Inception-v3 ve Resnet50 mimarileri kullanılarak gerçekleştirilen deneysel çalışmalarda, VGG16 modeli ile %90.4 olarak en yüksek doğruluk skoru elde edilmiştir.

Ferentinos yaptığı çalışmada [105], bitki hastalık tespiti için AlexNet, VGGNet, AlexNetOWTBn, Overfeat ve GoogleNet gibi önceden eğitilmiş ESA mimarilerine dayalı bir derin öğrenme metodolojisi önermiştir. Bu derin mimarilerin eğitimi ve test işlemleri, hastalıklı ve sağlıklı olmak üzere 58 sınıfa ait toplam 87848 görüntüden oluşan bir veri seti kullanılarak gerçekleştirilmiştir. Deneysel sonuçlara göre, VGGNet mimarisi kullanılarak %99.53 doğruluk skoru elde edilmiştir.

Brahimi ve diğ. yaptıkları çalışmada [106], bitki hastalık tespiti için önceden eğitilmiş AlexNet ve GoogleNet mimarilerine dayalı farklı yaklaşımlar önermişlerdir. Bu derin mimariler, özellik çıkarıcı, transfer öğrenme ve ağırlık sıfırdan eğitilmesi gibi 3 farklı yaklaşım kullanılarak performansları hesaplanmış ve karşılaştırılmıştır. Önerilen yaklaşımları test etmek için dokuz domates hastalığına ait toplam 14238 yaprak görüntüsü kullanılmıştır. Deneysel sonuçlara göre, GoogleNet mimarisine dayalı transfer öğrenme yaklaşımı ile %99.18 olarak en yüksek doğruluk skoru elde edilmiştir.

Lu ve diğ. yaptıkları çalışmada [107], pirinç hastalıkları için Derin Evrimsel Sinir Ağlarına dayalı yeni bir hastalık tanımlama yaklaşımı önermişlerdir. Geliştirilen model, üçer tane evrişim ve havuzlama katmanlarından oluşmaktadır. Ayrıca havuzlama katmanı olarak ortalama, maksimum ve stokastik yöntemleri kullanılmış ve performansları karşılaştırılmıştır. Hastalıklı ve sağlıklı olmak üzere 10 sınıflı pirinç hastalık görüntülerinden oluşan veri seti kullanılarak gerçekleştirilen deneysel çalışmalarda, stokastik havuzlama yöntemi ile %95.48 olarak en yüksek doğruluk skoru elde edilmiştir.

Mohanty ve diğ. yaptıkları çalışmada [108], bitki hastalık tespiti için DESA'ya dayalı farklı yaklaşımlar sunmuşlardır. Bu çalışmada, önceden eğitilmiş AlexNet ve GoogleNet mimarilerine dayalı transfer öğrenme ve sıfırdan eğitime yaklaşımları değerlendirilmiştir. Önerilen yaklaşımları test etmek için hastalıklı ve sağlıklı bitki türlerini içeren 38 sınıflı toplam 54.306 yaprak görüntüsü kullanılmıştır. Deneysel sonuçlara göre, transfer öğrenme yaklaşımına dayalı olarak GoogleNet mimarisi ile %99.35 olarak en yüksek doğruluk skoru elde edilmiştir.

Fujita ve diğ. yaptıkları çalışmada [109], evrişimsel sinir ağı kullanılarak salatalık hastalıkları tespiti için bir sınıflandırıcı yaklaşımı önermişlerdir. Önerilen ESA modeli, 4 adet evrişim katmanı, maksimum havuzlama, normalleştirme ve çıkış (softmax) katmanlarından oluşmaktadır. Bu çalışmada, 7 hastalık türü ve sağlıklı olmak üzere 8 sınıfa ait 7520 salatalık yaprak görüntüsü kullanılmıştır. Bu veri setinin boyutunu artırmak için döndürme ve yansıtma gibi teknikler uygulanmıştır. Önerilen modelin geçerliğini test etmek için 4 kat çapraz doğrulamak yöntemi kullanılmış ve %82.3 doğruluk skoru elde edilmiştir.

Sladojevic ve diğ. yaptıkları çalışmada [110], bitki hastalıklarını yaprak görüntülerinden otomatik olarak tespit etmek ve sınıflandırmak için derin evrişimsel sinir ağına dayalı yeni bir yaklaşım önermişlerdir. Geliştirilen bu yaklaşım, bitki hastalık tespiti için önceden eğitilmiş CaffeNet mimarisine dayalı transfer öğrenme yaklaşımına dayanmaktadır. Bu çalışmada, büyütme ve dönüşüm gibi çeşitli veri artırma teknikleri kullanılarak veri seti genişletilmiştir. Deneysel sonuçlarda, önerilen yaklaşımla %96.3 olarak iyi bir tanıma performansı elde etmiştir.

Picon ve diğ. yaptıkları çalışmada [111], çok sınıflı bitki hastalık tespiti için adapte edilmiş Derin Artık Sinir Ağına dayalı yeni bir algoritma sunulmuştur. Önerilen model, önceden eğitilmiş Resnet50 mimarisinin geliştirilmiş versiyonudur. Bu modeli test etmek için yapay veri artırma tekniği kullanılarak genişletilen buğday hastalık görüntülerine ait veri seti kullanılmıştır. Gerçekleştirilen deneysel çalışmalarda, %98 olarak yüksek doğruluk skoru elde edilmiştir.

Barbedo ve diğ. yaptıkları çalışmada [112], bitki hastalık tespiti için derin sinir ağlarının tasarımını ve performansını etkileyen ana faktörler araştırılmıştır. Bu amaç için, transfer öğrenme yaklaşımına dayalı olarak önceden eğitilmiş GoogleNet mimarisi kullanılmıştır [113]. Önerilen model, mısır hastalık görüntülerinden oluşan veri seti

kullanılarak test edilmiştir. Ayrıca, deneysel çalışmalarda önerilen ESA modelinin bitki hastalıklarının tanınması için veri setinin genişletilmesi için kullanılan veri teknikleri ile görüntü varyasyonları değerlendirilmiştir.

Altuntaş ve diğ. yaptıkları çalışmada [114], otomatik bitki hastalık tespiti için derin evrişimsel sinir ağlarına dayalı önceden eğitilmiş AlexNet, VGGNet, GoogleNet ve ResNet mimarileri kullanmışlardır. Önerilen çalışma, 1230 haploid ve 1770 diploid mısır tohumu görüntülerinden oluşan yeni bir veri seti kullanılarak gerçekleştirilmiştir. Deneysel sonuçlara göre, mısır hastalık tespiti için transfer öğrenme yaklaşımına dayalı VGG19 modeli ile %94.22 olarak en yüksek doğruluk skoru elde edilmiştir.

Özgüven ve diğ. yaptıkları çalışmada [115], şeker pancarına dayalı yaprak hastalık tespiti için DESA'ya dayalı bir model geliştirilmiştir. Dört evrişim katmanından oluşan bu modelin parametrelerinin değiştirilmesi ile geliştirilmiş daha hızlı bölgesel ESA modeli önerilmiştir. Görüntüleme tabanlı uzman sistemler tarafından hastalık tespiti için önerilen model kullanılarak %95.48 doğruluk skoru elde edilmiştir.

Geetharamani ve diğ. yaptıkları çalışmada [116], yaprak tabanlı bitki hastalık tespiti için 9 katmanlı derin evrişimsel bir sinir ağı önermişlerdir. Bu çalışmada, altı tür veri büyütme teknikleri kullanılarak veri seti genişletilmiştir. Daha sonra, değişken derin ağ parametreleri kullanılarak önerilen model için en iyi parametreler seçilmiştir. Önerilen modeli test etmek için 38 sınıflı 54.305 bitki hastalık görüntüsünü içeren bir veri seti kullanılmıştır. Kapsamlı gerçekleştirilen deneysel çalışmalara göre, önerilen model kullanılarak %96.46 doğruluk skoru elde edilmiş ve önceden eğitilmiş derin mimarilere göre üstün performans sağladığı tespit edilmiştir.

Too ve diğ. yaptıkları çalışmada [117], bitki hastalıklarının sınıflandırılması için derin öğrenme modellerinin karşılaştırılmasına yönelik kapsamlı bir çalışma yapmışlardır. Bu çalışmada, transfer öğrenme yaklaşımına dayalı VGG16, Inception-v4, ResNet50, ResNet101, ResNet152 ve DenseNet121 olmak üzere önceden eğitilmiş derin mimariler kullanılmıştır. Bu derin mimariler, 38 sınıflı 54306 hastalıklı yaprak görüntüsünden oluşan veri seti kullanılarak test edilmiştir. Deneysel sonuçlara göre, DenseNet201 modeli ile %99.75 olarak en yüksek doğruluk skoru elde edilmiştir.

Hu ve diğ. yaptıkları çalışmada [118], çay hastalıklarının sınıflandırılması için DVM ve derin öğrenme ağı kullanılmasına dayalı bir model önermişlerdir. Öncelikle, renk ve doku özelliklerine dayalı DVM yöntemi kullanılarak segmentasyon işlemi yapılır.


Daha sonra, bu bölütlenmiş görüntüler kullanılarak Derin Konvolüsyon ÇÜA (Çekişmeli Üretici Ağlar) yöntemi ile veri seti genişletilmiştir. Son olarak, elde edilen veri seti kullanılarak transfer öğrenme yaklaşımına dayalı önceden eğitilmiş VGG16 modeli uygulanmış ve test edilmiştir. Deneysel sonuçlarda, geleneksel makine öğrenme yöntemlerinin ve derin öğrenme yöntemlerinin kombinasyonunun, çay yaprağının hastalıklarını sınıflandırılmasında yüksek bir performans sağladığı gözlenmiştir.

Zhang ve diğ. yaptıkları çalışmada [119], yaprak tabanlı domates hastalıklarının sınıflandırılması için renk bilgisinden yararlanarak üç kanallı yeni bir ESA modeli geliştirmişlerdir. Önerilen model, dört evrişim katmanı, üç havuzlama katmanı, dört Relu katmanı ve iki tam bağlı katmandan oluşmaktadır. Buna ek olarak, hastalıklı yaprak görüntülerinin her bir kanalı (R, G, B) için önerilen model uygulanmış ve tam bağlı fusion katmanı ile elde edilen öğrenilmiş ağırlıklar birleştirilmiştir. Bu çalışmada, önerilen modeli test etmek için 8 sınıflı toplam 15.817 renkli yaprak görüntüsü kullanılmıştır. Deneysel sonuçlar, önerilen model bitki yaprak hastalık tanıma problemi için geliştirilen son yöntemlerden daha iyi performans gösterdiğini doğrulamaktadır.

Arsenovic ve diğ. yaptıkları çalışmada [120], otomatik bitki hastalık tespiti için derin evrişimsel sinir ağlarına dayalı önceden eğitilmiş AlexNet, VGG19, Inceptionv3, DenseNet201 ve ResNet152 mimarileri kullanılarak kapsamlı bir çalışma yapmışlardır. Önerilen çalışma için yaprak tabanlı 79.265 bitki hastalık görüntülerinden oluşan yeni bir veri seti kullanılmıştır. Buna ek olarak, veri setindeki görüntülerin sayısını artırmak için ÇÜA yöntemine dayalı bir yaklaşım sunulmuştur. Deneysel sonuçlara göre, önerilen yaklaşım kullanılarak %93.67 olarak en yüksek doğruluk skoru elde edilmiştir.

1.2. Önerilen Sistemin Genel Çerçevesi

Bitki türlerinin ve hastalıklarının sınıflandırılması için önerilen sistemin genel aşamaları Şekil 1.1’de gösterilmektedir. Yapılan çalışmalarda geliştirilen her bir sistem ön-işlem, özellik çıkarım ve sınıflandırma bölümlerini içermektedir. Eğitim aşamasında, özellik çıkarım yöntemleri kullanılarak bitki tür veya hastalık görüntülerinden öznitelikler elde edilir. Daha sonra, bu parametreler sınıflandırıcı yöntemleri kullanılarak eğitim işlemi gerçekleştirilir. Eğitilmiş modeller kullanılarak yeni gelen görüntüden elde edilen öznitelikler test edilir ve sınıf etiketi belirlenir.



Şekil 1.1. Bitki türü ve hastalık sınıflandırma sistemlerinin genel aşamaları

Günümüzde bitki türleri ile ilgili birçok veri seti bulunmakta ve bu veri setleri kullanılarak bitki türlerinin sınıflandırılmasına dayalı çok sayıda çalışma yapılmaktadır. Gerçekleştirilen bu çalışmaların ortalama olarak performansları %85-90 aralığında değişmektedir.

Bitki hastalıkları ile ilgili araştırmacıların erişimine açık doğal ortamlardan elde edilmiş bir veri seti bulunmamaktadır. Bitki hastalıkları ile ilgili yapılan çalışmaların çoğunda, laboratuvar ortamında elde edilmiş yaprak tabanlı görüntüler kullanılmıştır. Bu yüzden, geliştirilen yöntemlerin gerçek zamanlı uygulamalarda kullanılması elverişli değildir. Bu tez çalışmasında ise gerçek zamanlı elde edilmiş 15 sınıflı 4400 hastalık ve zararlı görüntülerinden oluşan bir veri seti oluşturulmuştur. Deneysel çalışmalarda, doğal ortamdan elde edilen bu veri seti kullanılmıştır.

Tez çalışmasında ortaya konulan gerekçeler, hedefler ve beklenen çıktılar bu bölümde alt başlıklar halinde detaylı şekilde verilmiştir. Ayrıca bitki türlerinin ve hastalıklarının sınıflandırılmasına yönelik geliştirilen sistemin amaçları, Ar-Ge niteliği ve teknolojik yönü ve tez çalışmasının organizasyonu ile ilgili bilgilerde sunulmuştur.

1.2.1. Tezin Amacı

Bu tez çalışmasının temel amacı, gerçek zamanlı ve yüksek doğrulukta bitki türleri ve hastalıklarının sınıflandırılması için yeni yöntemler ve algoritmalar geliştirmektir.

Tez çalışmasının diğer bir amacı ise, gerçek zamanlı elde edilen görüntüler kullanılarak bitki hastalıklarının tespit işlemlerinin gerçekleştirilmesidir. Bu amaç doğrultusunda geliştirilecek hastalık tespit sistemleri, hastalıkların neden olduğu verim kaybının önlenmesi için uzman kişilere yardımcı olacak ve hastalık tespitinin daha kolay ve daha kısa sürede gerçekleştirilmesine imkân sağlayacaktır.

Literatürde yer alan bitki türleri ve hastalıklarının sınıflandırılmasında kullanılan makine öğrenmesi yöntemleri kapsamlı bir şekilde incelenmiş ve bu yöntemlerin güçlü ve zayıf yönleri ortaya çıkarılmıştır. Tez süresince yapılan çalışmalar ile kullanılan mevcut renk, doku ve şekil tabanlı öznelik çıkarma yöntemlerine ek olarak yeni yöntemler geliştirilip literatüre kazandırılması amaçlanmıştır. Bunun yanı sıra, son zamanlarda nesne tanıma alanındaki başarılarından dolayı popüler olan derin öğrenme kullanılarak bitki türleri ve hastalıklarının sınıflandırılması için yeni modeller ve derin mimarilere dayalı hibrit sistemler geliştirilmesi amaçlanmıştır.

Literatürde, herkesin erişimine açık bitki türleri ile ilgili birçok veri seti bulunmaktadır. Fakat bitki hastalıkları ile ilgili doğal görüntülere dayalı bir veri seti bulunmamaktadır. Bu nedenle ülkemizde yaygın olarak görülen bitki hastalık türlerini içeren bir veri seti hazırlanmıştır. Elde edilen veri seti bu alanda çalışmak isteyen araştırmacıların çalışmalarında kolaylıklar sağlayacaktır.

1.2.2. Tezin Gereçekçeleri

Tez kapsamında bitki türlerinin sınıflandırılması ve bitki hastalıkları tespiti olmak üzere iki farklı alanda çalışma gerçekleştirilmiştir. Tarımsal alan ile ilgili bu problemlerin çözümü büyük önem taşımaktadır. Bu problemlerin önemi ve günümüzdeki çözümleri şunlardır:

- Bitkiler, dünyadaki yaşamın önemli bir parçasını oluşturmaktadır. Endüstri, beslenme, oksijen, tıp ve daha birçok alanlarda yaygın olarak kullanılmaktadırlar. Bitki tanıma süreci, önemli ve zor bir görevdir. Bir bitkinin hangi türe ait olduğunu belirlemek uzman olmayan kişiler için neredeyse imkânsızdır. Bu tür işlemlerde uzman olarak en önemli rolü botanik veya ziraat üzerine ihtisaslaşmış kişiler üstlenmektedir. Uzmanlar tarafından bitki türlerinin belirlenmesi genel olarak görsel muayene ve daha sonrasında laboratuvar ortamında incelemeler olmak üzere iki ana aşamadan oluşmaktadır. Nihayetinde bu geleneksel yöntemler zaman alıcı, yorucu ve karmaşık süreçler içermektedir. Çünkü binlerce bitki arasından bir bitkinin türünü belirlemek için birçok biyolojik test ve mikroskopik araştırma yapılmaktadır. Özellikle aynı aileden olan bitkiler benzer karakteristiklere sahip olduğu için kapsamlı analizlerin yapılması gerekmektedir.

- Bitki hastalıkları, sosyal, ekolojik ve ekonomik kayıplara sebep olmaktadır. Bu tür kayıpların önlenmesi için bitki hastalıklarının erken teşhisi önemlidir. Bitki hastalık tespiti, günümüzde uzman kişiler tarafından geleneksel yöntemlerle gerçekleştirilir. Bu tür işlemler karmaşık süreçler içermesinin yanı sıra fazla iş yükü ve zaman kaybına neden olmaktadır.

Yukarıda belirtilen bitki türleri ve hastalıkları ile ilgili problemlerin günümüzdeki çözümlerinin dezavantajları genel olarak şunlardır:

- Uzman kişilere ihtiyaç duyulması,
- İşlem süresinin uzaması ile birlikte zaman kaybına neden olması,
- Karmaşık süreçler içermesi.

Tüm bu nedenlerden dolayı, bitki türlerinin ve hastalıklarının otomatik olarak tanımlanması önem kazanmıştır. Bu bağlamda, bu problemlerin giderilme ihtiyacı tez çalışmasının ortaya çıkma gerekçesini oluşturmuştur.

1.2.3. Tezin Çıktıları

Bu tez çalışmasında makine öğrenmesine dayalı farklı yöntemler ve modeller geliştirilmiştir. Önerilen bu yöntemler, bitki türleri ve hastalıklarının sınıflandırılmasına yönelik uygulamalarda performansın yükseltilmesi hedeflenmiştir. Bu sayede uzman kişilere yardımcı olunacak böylece bitki türlerinin veya hastalıklarını daha hızlı ve doğru sınıflandırılması sağlanacaktır.

Tez çalışmaları sonucunda önemli çıktılar ve gerçek zamanlı uygulamalar elde edilmiştir. Ayrıca bitki türleri ve hastalıklarının sınıflandırılması için geliştirilen yeni öznetelik çıkarım yöntemleri ise tezin akademik çıktıları olarak görülmektedir. Tez çalışmaları sonucu altı önemli çıktı elde edilmiştir. Bu çıktılar aşağıda verilmiştir:

- 1) Gerçek zamanlı Bitki Hastalık Tespit Yazılımı
- 2) Bitki Hastalık Veri Tabanı
- 3) Bitki türü ve hastalık tanıma ile ilgili literatüre kazandırılan yeni öznetelik çıkartma yöntemleri ve modelleri
 - a) Kenar Adım Yöntemi,

- b) Bölme yaklaşımına dayalı geliştirilen algoritmalar,
- c) Bölgesel ve Genel ortalamaya dayalı geliştirilmiş Yerel İkili Örüntü yöntemi,
- d) Derin-dokusal tabanlı özellik çıkarıcı bir model,
- e) Çok-Bölmeli Derin Evrışimsel Sinir Ağı (ÇB-DESA) modeli,
- f) Derin sinir ağları ile geleneksel sınıflandırıcılara dayalı yeni bir sınıflandırma mimarisi,
- g) Evrışimsel Sinir Ağlarına (ESA) dayalı farklı evrişim filtrelerini içeren derin bir model,
- h) Derin Öğrenme Tabanlı Gerçek zamanlı Bitki Hastalık ve Zararlı Tespit Sistemi (Çoklu-ESA PlantDiseaseNet)

1.2.4. Tezin yenilikçi yönü ve ar-ge niteliği

- 1) Tez çalışmasında geliştirilen yöntem ve hibrit sistemler, literatürde var olan veri setleri kullanılarak test edilmiştir ve önceki çalışmalar ile performansları karşılaştırılmıştır. Elde edilen performans sonuçlarına göre, önerilen yöntem ve hibrit sistemler var olan yöntemlerden daha başarılı olduğu tespit edilmiştir. Gerçekleştirilen deneysel çalışmalar sonucunda, tez kapsamında geliştirilen yöntem ve hibrit sistemlerin güvenilir, kullanılabilir ve etkili olduğu gözlenmiştir.
- 2) Bitki türleri ve hastalık tespiti, gerçek zamanlı olarak gerçekleştirilecek olması önemli bir yenilik olarak değerlendirilmektedir.
- 3) Bitki hastalık tespiti ile ilgili ülkemizde gerçek zamanlı bir uygulama bulunmaması ile birlikte bir veri tabanı yoktur. Bunun için ülkemizde yaygın olarak görülen bitki hastalık türlerini içeren bir veri tabanının inşa edilmesine ihtiyaç duyulmaktadır. Tez kapsamında kapsamlı bir bitki hastalık veri tabanı inşa edilmiş ve araştırmacıların kullanımına sunulmuştur.

1.2.5. Tezin Organizasyonu

Bu tez çalışması yedi bölümden oluşmaktadır. Birinci bölümde, tez konusuyla ilgili kapsamlı bir literatür araştırması ve incelemesi gerçekleştirilmiştir. Tezin amacı, gerekçeleri ve çıktıları ortaya konarak literatüre yapılan katkıları belirtilmiştir. Son olarak tezin organizasyonu yine bu bölümde verilmiştir.

Bölüm 2’de, bitki türlerinin veya hastalıklarının sınıflandırılması ile ilgili olarak temel adımlar ve bu adımlarda kullanılan ön-işlem aşaması ile özellik çıkarım ve sınıflandırıcı yöntemleri hakkında detaylı bilgiler verilmiştir.

Bölüm 3’de, tez kapsamında kullanılan bitki türleri ile ilgili veri setleri detaylandırılmıştır.

Bölüm 4’de, tez çalışması süresince bitki hastalık ve zararlı tespiti için inşa edilen veri seti ile ilgili detaylı bilgiler verilmiştir.

Bölüm 5’de, bitki türlerinin sınıflandırılması ile ilgili literatürde var olan özellik çıkarma yöntemlerine katkı sunmak amacıyla yeni geliştirilen algoritmalar ve hibrit sistemler verilmiştir. Bu algoritmaların matematiksel temelleri yine bu bölümde detaylandırılmıştır. Önerilen bu algoritmalar ve hibrit sistemler, bitki türleri ile ilgili literatürde var olan mevcut veri setleri (Bölüm 3’de detaylandırılmıştır) ile test edilmiştir. Daha sonra elde edilen performans sonuçları, literatürde yapılan önceki çalışmaların performansları ile detaylı olarak karşılaştırılmıştır. Bu bölümdeki çalışmaların değerlendirilmesi sonucunda üç SCI makale [10, 121,122], bir ulusal makale [123] ve dört bildiri [1,5,124-126] yayınlanmıştır.

Bölüm 6’da, bitki hastalıklarının sınıflandırılması ile ilgili literatürde var olan özellik çıkarma yöntemlerine katkı sunmak amacıyla yeni geliştirilen algoritmalar ve hibrit sistemler verilmiştir. Bu algoritmaların matematiksel temelleri yine bu bölümde detaylandırılmıştır. Önerilen bu algoritmalar ve hibrit sistemler, bitki hastalıkları ile inşa ettiğimiz veri setleri (Bölüm 4’de detaylandırılmıştır) kullanılarak test edilmiştir. Daha sonra elde edilen performans sonuçları, literatürde var olan yöntemlerin performansları ile detaylı olarak karşılaştırılmıştır. Bu bölümdeki çalışmaların değerlendirilmesi sonucunda bir SCI makale [9] ve bir bildiri [8] yayınlanmıştır.

Bölüm 7’de, tez kapsamında geliştirilen algoritmaya dayalı gerçek zamanlı bitki hastalıklarının sınıflandırılması için arayüz uygulaması yapılmıştır.

Bölüm 8’de, tez kapsamında önerilen yaklaşımlar ile yapılan çalışmalardan elde edilen sonuçlar tartışılmıştır ve özgün katkıları belirtilmiştir. Ayrıca gelecekte yapılması düşünülen çalışmalara yer verilmiştir.

2. BİTKİ TÜRLERİNİN TANINMASI VE HASTALIKLARININ SINIFLANDIRILMASI İÇİN KULLANILAN YÖNTEMLER

Görüntü işleme ve makine öğrenmesi temelli örüntü tanıma problemleri için geliştirilen yöntemler genellikle üç ana adımdan oluşmaktadır. Bu adımlar sırasıyla; ön işlem, özellik çıkarımı ve sınıflandırma işlemleridir. Bu tez çalışmasında, bitki türleri ve hastalıklarını sınıflandırabilmek için genel işlem adımları Şekil 2.1’ de verilmiştir.



Şekil 2.1. Önerilen çalışmanın genel işlem adımları

Bu bölümde her üç temel adım için literatürde var olan ve bu tez çalışmasında kullanılan yöntemler alt başlıklar halinde detaylandırılmıştır. Ayrıca tez çalışmasının süresince geliştirilen yöntemler ve modeller ilgili bölümde anlatılmıştır.

2.1. Ön-İşlem

Ön-işlem, bir görüntü üzerindeki şekillerin analiz edilmesinde, bozuk görüntüleri iyileştirmede, kenar sınır eğrilerini çıkarmada ve nesne tespiti gibi birçok işlemler için kullanılmaktadır. Bu tez çalışmasında, nesne tanıma alanında kullanılan öznelik çıkarım yöntemlerinin çalışma prensibine göre görüntüyü istenilen hale getirilmesi için bir takım ön-işlem yöntemleri kullanılmıştır. Bu yöntemler alt başlıklar halinde detaylandırılmıştır.

2.1.1. Gri Tona Dönüştürme

Renkli görüntülerin (imge) her bir kanal için farklı katsayılar kullanılarak gri tona dönüştürülme işlemi gerçekleştirilir. Bu işlemlere ait denklemler Denklem (2.1-2.4)’deki gibi listelenmiştir:

$$R = imge(:, :, 1) \quad (2.1)$$

$$G = imge(:, :, 2) \quad (2.2)$$

$$B = imge(:, :, 3) \quad (2.3)$$

$$Gri_{imge} = R * 0.2989 + G * 0.5870 + B * 0.1140 \quad (2.4)$$

Bir gri ton görüntüde 256 tane farklı gri değeri bulunmaktadır. Bu değerler 0,1,2, ..., 255 şeklinde ifade edilmektedir. Sıfır gri değeri siyah renk değerine ve 255 gri değeri ise beyaza karşılık gelmektedir. Diğer değerler ise 0 ile 255 arasında gri değerlerden

oluşmaktadır. Renkli bir görüntünün gri tona dönüştürülmüş hali ve örnek bir 3×3'lük piksel değerlerinin gösterimi Şekil 2.2'de verilmiştir.



Şekil 2.2. Gri bir görüntü ve örnek bir piksel değerlerinin gösterimi

2.1.2. Eşikleme İşlemi

Makine öğrenmesi yöntemleri kullanılarak görüntüden bilgi ya da özellik çıkarımı için en çok ihtiyaç duyulan konular arasında eşikleme yöntemleri gelmektedir. Eşikleme, görüntüyü bölütleme için kullanılan en önemli yaklaşımlardan biridir. Bu işlemin temel amacı, görüntü içerisindeki nesnelere arka plandan ayırmaktır [127].

Piksel tabanlı bir yöntem olan eşikleme işlemindeki ilk aşama, bir eşik değeri belirlemektir. Bu eşik değerinin belirlenmesi için geliştirilen yöntemlerin çoğu yoğunluk histogramının kullanılmasına dayalıdır [127-130].

Bu tez çalışmasında, literatürdeki çalışmalarda yaygın olarak uygulanan klasik, çoklu ve otsu eşikleme yöntemleri kullanılmıştır. Bu yöntemlerin teorik alt yapısı aşağıda verilmiştir.

2.1.2.1. Klasik (Tekli) Eşikleme

Klasik eşikleme yöntemi gri düzeyli bir görüntüden ikili görüntü (siyah-beyaz) oluşturmak için kullanılan en basit eşikleme yöntemlerinden biridir. Bu yöntem, Şekil 2.3'te gösterildiği gibi, tek bir eşik değeri kullanarak görüntü bölütleme işlemini gerçekleştirir. Eşik değeri belirleme işlemi gerçekleştirilirken, her bir piksel için gri değerlerinin belirlenen bir T eşik değerinden küçük ya da büyük olup olmadığına bakılır (Denklem (2.5)).

$$g(x,y) = \begin{cases} 1 & ; \text{eger } f(x,y) > T \\ 0 & ; \text{eger } f(x,y) \leq T \end{cases} \quad (2.5)$$

Klasik eşikleme yöntemi, Denklem (2.5) eşitliğini kullanarak görüntüdeki piksellerin nesne ya da arka plan olarak etiketlenmesini sağlar. Bu yöntemin başarımı, görüntü histogramına bağlı olarak iyi bir eşik değeri seçilmesine dayanmaktadır. Ayrıca, görüntülerdeki aydınlatma veya parlaklık bu yöntemin başarımını önemli ölçüde etkilemektedir [127,131,132].

Şekil 2.3’de, klasik eşikleme yönteminin bir yaprak görüntüsüne uygulanmış hali verilmiştir. Bu uygulama için öncelikle, orijinal görüntü gri görüntüye dönüştürülür. Daha sonra bir eşik değeri ($T=160$) seçilir ve ardından görüntünün her pikseli için Denklem (2.5) eşitliği uygulanır.



Şekil 2.3. Klasik (tekli) eşiklemeye dayalı örnek bir uygulama

2.1.2.2. Çoklu Eşikleme

Çoklu eşikleme yönteminde, görüntüdeki pikselleri ikiden fazla gri seviye grubuna ayırma işlemi yapılır ve iki farklı eşik değeri seçilir (Şekil 2.4). Bu yöntem, tekli eşikleme yöntemine göre daha az güvenilirdir. Bunun nedeni, birden fazla bölgeyi etkili bir şekilde bölütleme için çoklu eşik değerlerinin belirlenmesidir [127,131-132].

$$g(x, y) = \begin{cases} 0 & ; \quad T_1 \geq f(x, y) \\ a & ; \quad T_1 < f(x, y) \leq T_2 \\ b & ; \quad T_2 < f(x, y) \end{cases} \quad (2.6)$$

Denklem (2.6) eşitliğine göre, görüntüdeki herhangi bir (x,y) pikseli için; $T_1 \geq f(x, y)$ aralığındaki pikseller görüntünün arka planını, $T_1 < f(x, y) \leq T_2$ aralığındaki pikseller bir nesneyi (a) ve $T_2 < f(x, y)$ aralığındaki pikseller diğer bir nesneyi (b) oluşturur [127,131-132].

Şekil 2.4’de, çoklu eşikleme yönteminin bir yaprak görüntüsüne uygulanmış hali verilmiştir. Bu uygulama için öncelikle, orijinal görüntü gri görüntüye dönüştürülür. Daha sonra çoklu eşik değeri için; $T_1 = 100$ eşik ve $T_2 = 130$ olarak seçilmiştir. Son olarak, Denklem (2.6) eşitliği kullanılarak; T_1 eşik değerinden küçük olan pikseller 0,

T_1 ile T_2 eşik değerleri arasında olan pikseller 128 ve T_2 eşik değerinden büyük pikseller ise 255 değerlerini almışlardır.



Şekil 2.4. Çoklu eşiklemeye dayalı bir uygulama

2.1.2.3. Otsu Eşikleme

Otsu eşikleme, gri seviyeli görüntüler üzerinde uygulanabilen bir eşik değeri belirleme yöntemidir. Otsu [133] tarafından önerilen Otsu yöntemi, görüntü üzerinden eşik değerini hesaplamaktadır. Bu yöntem, görüntünün arka plan ve ön plan olmak üzere iki ayrı sınıf olduğunu varsayarak, tüm eşik değerleri için bu iki sınıfın sınıf içi varyans değerini minimum yapacak değeri bulmaya çalışır. Sınıf içi varyans değerini minimum yapan eşik değeri, sınıflar arası varyans değerini maksimum yapar. Varyans belirli bir dizinin elemanlarının, bu dizinin aritmetik ortalaması etrafındaki dağılımın analizini sağlayan bir istatistiksel ölçüdür. Bu değere bakılarak, dizi içerisindeki değerlerin ne derecede dağınık oldukları yorumu yapılabilmektedir [133-135]. Varyans, Denklem (2.7) kullanılarak hesaplanır:

$$\sigma^2 = \sum_{i=0}^{N-1} (x_i - \mu_x) \text{Pr}\{x_i\} \quad (2.7)$$

Denklem (2.7)'de, σ^2 varyans değeri, $\text{Pr}\{x_i\}$ olasılık fonksiyonu ve μ ise aritmetik ortalamayı temsil etmektedir. Sınıflar arası varyans Denklem (2.8) kullanılarak hesaplanır:

$$\sigma_y^2 = w_1(t) w_2(t) (\mu_1(t) - \mu_2(t))^2 \quad (2.8)$$

Burada ω sınıf olasılığını, μ sınıf ortalamasını ve t ise eşik değerinin temsil etmektedir. Bu değerler:

$$\begin{aligned}\omega_1(t) &= \sum_{i=0}^t \Pr\{i\} & \omega_2(t) &= \sum_{i=t+1}^L \Pr\{i\} \\ \mu_1(t) &= \sum_{i=0}^t \Pr\{i\} X(i) & \mu_2(t) &= \sum_{i=t+1}^L \Pr\{i\} X(i) \\ t^* &= \text{ArgMax}\{\sigma_B^2(t)\} & & 1 \leq t \leq L\end{aligned}\quad (2.8)$$

olarak hesaplanır. Burada t^* , sınıflar arası varyansı maksimum yapacak en iyi eşik değeridir. $X(i)$ ise i . renk değeridir [133-136]. Şekil 2.5’de, Otsu yönteminin bir gri seviyeli yaprak görüntüsüne uygulanması örnek gösterilmiştir.




Şekil 2.5. Otsu eşikleme ile ilgili bir uygulama

2.1.3. Aşındırma İşlemi

Aşındırma işlemi, ikili imgedeki nesneyi küçültmeye ya da inceltmeye yarayan temel morfolojik işlemlerden biridir. Aşındırma işlemi genellikle görüntüde ele alınan nesnenin sınır bölgelerinin aşındırılmasında kullanılmaktadır. Aşındırılmış görüntü orijinal görüntüye oranla daha az piksele sahiptir. Buna ek olarak, aşındırma işlemi uygulanmış görüntü içerisindeki nesnelere küçülür, delik varsa genişler ve birbirine bağlı nesnelere ayrılma eğilimleri gösterirler [137-138]. Aşındırma işleminin matematiksel gösterimi Denklem (2.9)’da verilmiştir.

$$A \ominus B = \{z | (B)_z \subseteq A\} \quad (2.9)$$

Burada A işlenecek görüntüyü ve B ise yapısal elemanı temsil etmektedir. Ayrıca Şekil 2.6’da yapısal eleman kullanılarak aşındırma işlemi uygulanmış bir örnek verilmiştir.




Şekil 2.6. Aşınma işlemine dayalı bir uygulama

2.1.4. Genleşme İşlemi

Genleşme işlemi, ikili imgedeki nesneyi genişletmeye veya büyütmeye yarayan temel morfolojik işlemlerden biridir. Genleşme işlemi, görüntüyü yapısal elemanla kesiştiği bölümler kadar genişletmek olarak tanımlanabilir. Bu işlem genellikle görüntüde ele alınan nesnenin sınır bölgelerinin genişlemesinde ya da yayılmasında kullanılmaktadır. Genleşmiş görüntü orijinal görüntüye göre daha fazla piksele sahiptir. Buna ek olarak, genleşme işlemi uygulanmış görüntü içerisindeki nesnelere büyür ve delik varsa daralır [137-138]. Genleşme işleminin matematiksel gösterimi Denklem (2.10)'da verilmiştir.

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\} \quad (2.10)$$

Burada \hat{B} , B'nin bire tümleyini olarak tanımlanır. Ayrıca Şekil 2.7'de yapısal eleman kullanılarak genleşme işlemi uygulanmış bir örnek verilmiştir.



Şekil 2.7. Genleşme işlemine dayalı bir uygulama


2.1.5. Açma İşlemi

Açma işlemi, görüntü üzerinde aşınma ve genleşme işlemlerinin ardışık olarak uygulanmasına dayanmaktadır. Açma işlemi uygulanmış görüntü içerisindeki nesnelere

arasındaki boşluklar yapısal elemanın büyüklüğüne bağlı olarak temizlenebilir. Buna ek olarak, açma işlemi kullanılarak görüntüde fazla değişime sebebiyet vermeden birbirine yakın iki nesne ayrılabilir [137-139]. Açma işleminin matematiksel gösterimi Denklem (2.11)'de verilmiştir.

$$A \circ B = (A \ominus B) \oplus B \quad (2.11)$$

Burada A işlenecek görüntüyü ve B ise yapısal elemanı temsil etmektedir. Ayrıca Şekil 2.8'de yapısal eleman kullanılarak açma işlemi uygulanmış bir örnek verilmiştir.




Şekil 2.8. Açma işlemine dayalı bir uygulama

2.1.6. Kapama İşlemi

Kapama işlemi, görüntü üzerinde genleşme ve aşınma işlemlerinin ardışık olarak uygulanmasına dayanmaktadır. Kapama işlemi uygulanmış görüntü içerisindeki noktalar, yapısal elemanın büyüklüğüne bağlı olarak birbirlerini kapatırlar, imgedeki ana hatlar daha da dolgunlaşır. Buna ek olarak, kapama işlemi kullanılarak görüntüde fazla değişime sebebiyet vermeden birbirine yakın iki nesne birbirine bağlanmış olur [137-139]. Kapama işleminin matematiksel gösterimi Denklem (2.12)'de verilmiştir.

$$A \cdot B = (A \oplus B) \ominus B \quad (2.12)$$

Burada A işlenecek görüntüyü ve B ise yapısal elemanı temsil etmektedir. Ayrıca Şekil 2.9'da yapısal eleman kullanılarak kapama işlemi uygulanmış bir örnek verilmiştir.

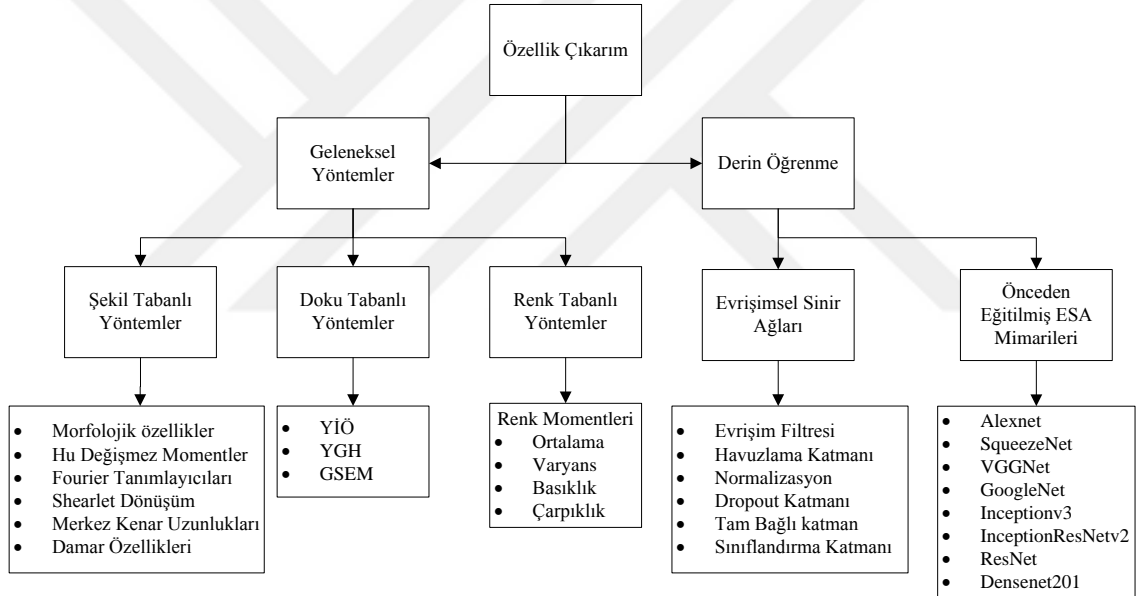


Şekil 2.9. Kapama işlemine dayalı bir uygulama

2.2. Özellik Çıkarma Aşaması

Özellik çıkarım işlemi, nesne tanıma alanında çok önemli bir rol oynamaktadır. Nesneden çıkarılacak özellikler, nesne tanıma sistemlerinin performansında önemli bir etkiye sahiptir. Başka bir deyişle, özellik çıkarma, nesnenin daha küçük boyutlardaki ayırt edici parametreler tarafından temsil edilmesini sağlamaktadır [140].

Son zamanlarda, görüntü tabanlı nesne tanınması için çok sayıda özellik çıkarım yöntemleri geliştirilmiştir. Bu önerilen yöntemler; biyomedikal, tıp, tarım ve daha birçok alandaki problemlerin çözümünde kullanılmaktadır. Bu tez çalışmasında, geleneksel ve derin öğrenme algoritmalarına dayalı yöntemler bitki türlerinin ve hastalıklarının tanınması için kullanılmıştır. Kullanılan yöntemler alt başlıklar halinde detaylandırılmış ve bu yöntemler Şekil 2.10'da özetlenmiştir.



Şekil 2.10. Özellik Çıkarma yöntemleri

2.2.1. Geleneksel yöntemler

Bu tez çalışmasında, şekil, doku ve renk tabanlı olmak üzere literatürde sıklıkla kullanılan geleneksel yöntemler incelenmiştir. Bu yöntemlerin teorik yapıları aşağıda detaylandırılmıştır.

2.2.1.1. Şekil tabanlı yöntemler

Şekil, bir nesnenin tanınması için önemli bir özelliktir. Görüntüdeki nesnenin şekil özelliklerinin çıkartılabilmesi için öncelikle ön-işlem yöntemleri kullanılarak

nesnenin arka plandan ayırma işlemi gerçekleştirilir. Görüntünün segmentasyon işleminden sonra nesnenin sınır eğrileri ve sınır çevresindeki alan pikselleri elde edilir. Bu bağlamda, şekil özelliklerinin çıkartılması için sınır eğrilerine veya bölgeye (alana) dayalı yöntemler geliştirilmiştir. Bu yöntemler alt başlıklar halinde verilmiştir.

2.2.1.1.1. Morfolojik Özellikler

Şekil özelliklerinin doğru çıkartılması, görüntü bölütlenmesine dayanmaktadır. Nesne bölütlendikten sonra, sınır ve sınırla çevrili bölge pikselleri kullanılarak morfolojik özellikler çıkartılır. Literatürde yaygın olarak kullanılan morfolojik özellikler maddeler halinde aşağıda verilmiştir [1,5, 123,126,141-142]:

- **Alan**, görüntüdeki nesnenin (beyaz kısım) piksel sayısını temsil eder. İkili görüntüde genellikle arka plan siyah ve nesne beyaz renktir. Alan, A sembolü ile ifade edilir.
- **Çevre**, nesnenin sınır eğrisinin uzunluğudur. Başka bir deyişle, nesnenin çevresi, nesnenin kenarlarını oluşturan piksellerin toplamıdır. Çevre, Ç sembolü ile temsil edilir.
- **Dairesellik**, görüntüdeki nesne ile daire arasındaki farkı (düzensizliği) göstermektedir. Bu özelliğin matematiksel ifadesi Denklem 2.13'te verilmiştir.

$$R = \frac{(4 * \pi * A)}{\Ç^2} \quad (2.13)$$

- **Ana eksen uzunluğu**, görüntüdeki nesnenin sınır eğrilerinin düşey olarak birbirine en uzak iki noktası arasındaki mesafedir. Ana eksen uzunluğu, L sembolü ile temsil edilir.
- **Küçük eksen uzunluğu**, görüntüdeki nesnenin sınır eğrilerinin yatay olarak birbirine en uzak iki noktası arasındaki mesafedir. Küçük eksen uzunluğu, W sembolü ile temsil edilir.
- **Çap**, nesnenin sınır noktaları arasındaki birbirine en uzak mesafedir ve D sembolü ile ifade edilir.
- **Dışbükey alan**, görüntüdeki nesnenin tüm sınır noktalarını içeren en küçük dışbükey küme anlamına gelmektedir. DC sembolü ile temsil edilir.
- **Dikdörtgenlik**, nesnenin alanı ile nesneyi çevreleyen dikdörtgen arasındaki benzerliği açıklamaktadır ve D_R sembolü ile gösterilir. Buna ek olarak, nesnenin

sınır noktalarına bağlı olarak nesneyi çevreleyen minimum dikdörtgenin alanı A_R olarak temsil edilir. Bu özelliğin matematiksel ifadesi aşağıda tanımlanmıştır:

$$D_R = \frac{A}{A_R} \quad (2.14)$$

- **Dışmerkezlilik**, elipsin odak noktası ile ana eksen uzunluğu arasındaki mesafenin oranıdır. Bu oran, yuvarlak bir nesne için 0 değeri alırken düz bir çizgi için ise 1 değerini alır.

Yukarıdaki morfolojik özellikler literatürde en yaygın olarak kullanılan geometrik özellik tabanlı yöntemlerdir. Bu yöntemlere bağlı olarak diğer geliştirilen morfolojik özellikler Çizelge 2.1’de verilmiştir.

Çizelge 2.1. Morfolojik özelliklerin matematiksel ifadeleri

Morfolojik özellikler	Matematiksel Formülleri	Morfolojik özellikler	Matematiksel Formülleri
En-boy Oranı (EB)	$EB = \frac{L}{W}$	Eşdeğer Çap (EC)	$EC = \sqrt{\frac{4A}{\pi}}$
Dar Faktör (DF)	$DF = \frac{D}{L}$	Uzunluk-Çevre (R_{LP})	$R_{LP} = \frac{L}{\zeta}$
Yoğunluk (Y)	$Y = \frac{\zeta^2}{A}$	Çevre/Genişlik-Uzunluk (R_{LWP})	$R_{LWP} = \frac{\zeta}{L + W}$

2.2.1.1.2. Hu Değişmez Momentler

Momentler, genellikle istatistik teorisinde ve klasik mekanikte kullanılmakla beraber verilerin ortalaması, değişimi, eğriliği ve basıklığı olarak tanımlanmaktadır [127, 143]. 1960 yılında Hu ve arkadaşları, iki boyutlu nesne tanıma problemleri için matematiksel moment teorisine dayalı olarak 7 değişmez moment geliştirmişlerdir [144]. Bu geliştirilen yöntem, nesne tanıma alanındaki birçok problem için araştırmacılar tarafından uygulanmış ve yüksek bir performans sağlamıştır [127, 145-147].

Klasik mekanikte tanımlanan momentlere benzer $f(a, b)$ dağılımlı bir görüntü için moment Denklem (2.15) kullanılarak tanımlanır.

$$m_{ab} = \iint x^a y^b f(x, y) \partial x \partial y \quad (2.15)$$

Denklem (2.15)’de, iki boyutlu x, y dereceli değişkenler 0, 1, 2, ... değerlerini alabilir. Bu moment değerlerine bağlı olarak merkez momentler Denklem (2.16) kullanılarak tanımlanır.

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad \bar{y} = \frac{m_{01}}{m_{00}} \quad (2.16)$$

$$m_{ab} = \iint (x - \bar{x})^a (y - \bar{y})^b f(x, y) \partial(x - \bar{x}) \partial y (y - \bar{y})$$

x ve y değerleri görüntünün x ve y koordinatlarının ortalama değerleridir. Elde edilen merkez momentler genellikle görüntünün boyutlarına göre momentleri normalize etmek için kullanılmaktadır. Bu işlem;

$$r = 1 + \frac{(a + b)}{2} \quad n_{ab} = \frac{\mu_{ab}}{\mu_{00}^r} \quad (2.17)$$

olarak normalize edilmiş merkez moment hesaplanır. Son olarak, normalize edilmiş merkez momentler kullanılarak yedi değişmez moment geliştirilmiştir. Bu momentlerin matematiksel ifadeleri Denklem (2.18)'de verilmiştir.

$$\begin{aligned} \varphi_1 &= \eta_{20} + \eta_{02} \\ \varphi_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \\ \varphi_3 &= (\eta_{30} - \eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\ \varphi_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\ \varphi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ &\quad + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ \varphi_6 &= (\eta_{20} - 3\eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} \\ &\quad - \eta_{12})(\eta_{21} + \eta_{03}) \\ \varphi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ &\quad - (\eta_{30} - 3\eta_{12})(\eta_{03} + \eta_{12})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{aligned} \quad (2.18)$$

Geliştirilen Hu değişmez moment değerleri, ölçeklendirme, döndürme, parlaklık ve yer değişimi gibi işlemlerden etkilenmezler [127].

2.2.1.1.3. Merkez Kenar Uzunluğu


MKU, şeklin ağırlık merkezinin sınır eğrilerine olan uzaklıkları olarak tanımlanmaktadır [5,10]. Şeklin sınır eğrileri;

$$(x(i), y(i)), \quad i = 0, 1, 2, \dots, M - 1 \quad (2.19)$$

olarak tanımlansın. Buradaki M sınır eğrisi sayısını, (x, y) değerleri ise sınır eğrilerinin koordinatlarını ifade etmektedir. Bu nesnenin ağırlık merkezi C(a, b) olarak tanımlansın. Bir sınır eğrisinin ağırlık merkezine olan uzaklığı Denklem (2.20) kullanılarak hesaplanır.

$$d = \sqrt{(x(i) - g(a))^2 + (y(i) - g(b))^2} \quad (2.20)$$

Şekil 2.11’de gösterildiği gibi, ağırlık merkezi temel alınarak koordinat düzleminin x eksenine hizasından α derece artırımla toplamda n ($n=360/\alpha$) adet olmak üzere sınır eğrilerine uzaklık değerleri ($d_1, d_2, d_3, \dots, d_n$) hesaplanır. Elde edilen bu değerler görüntünün öznitelikleri olarak kabul edilir. Ayrıca Çizelge 2.2’de, α dereceye bağlı olarak elde edilen öznitelik sayıları verilmiştir.



Şekil 2.11. Örnek bir yaprak için MKU yaklaşımı [5,10]

Çizelge 2.2. Açılı değişkenine bağlı olarak öznitelik sayıları

Açılı	5	8	9	10	12	15	18	20	24	30	40	45
Öznitelik Sayısı	72	45	40	36	30	24	20	18	15	12	9	8

2.2.1.1.4. Fourier Tanımlayıcıları

FT, Fourier dönüşümü kullanılarak bir nesnenin ana hatlarını (kontur) temsil etmektedir. Fourier öznitelikleri, nesnenin sınır noktaları kullanılarak çıkartılır [121,148-149]. Bu yöntemin çalışma prensibine dayalı işlem adımları şunlardır;

- İlk olarak, renkli görüntüler gri tona dönüştürülür.
- Daha sonra, ön-işlem yöntemleri kullanılarak gri görüntü ikili (siyah-beyaz) görüntüye dönüştürülür.
- Her bir ikili görüntü için, nesnenin sınır koordinatları (x, y) oluşturulur.
- Her x ve y koordinatları için, HFD (Hızlı Fourier Dönüşümü) uygulanır. HFD aşağıdaki gibi tanımlanmaktadır:

$$F(i) = FFT\{p\}_i \quad (2.21)$$

Denklem (2.21)’de, yarıçapın vektörü olarak ifade edilen p değeri;

$$p(j) = \sqrt{(x(j) - x_c)^2 + (y(j) - y_c)^2} \quad (2.22)$$

olarak hesaplanmaktadır. Denklem (2.22)’de, (x_c, y_c) merkez koordinatı ve (x_j, y_j) sınır koordinatları temsil etmektedir. Fourier tanımlayıcıları, görüntülerin ölçeklendirme ve döndürme gibi işlemlere karşı değişmezler [121,149].


2.2.1.1.5. Damar özellikleri

Damar (Vein) özellikleri, görüntüdeki açma, kapama ve mantıksal işlemler gibi morfolojik işlemler ile bunlara bağlı olarak matematiksel işlemlere dayanmaktadır [10,123]. Bu işlemlerin genel işlem adımları sırasıyla aşağıda verilmiştir:

- Renkli görüntü gri tona dönüştürülür.
- Yarıçapı 1, 2, 3, 4 olan disk şeklindeki yapısal elemanlar oluşturulur.
- Elde edilen yapı elemanları kullanılarak açma işlemi gerçekleştirilir.
- Otsu eşikleme yöntemi kullanılarak ikili (siyah-beyaz) görüntü elde edilir.
- Son olarak, her bir yarıçapa ait elde edilen görüntülerin toplam piksel sayısı hesaplanır. Bu değerler kullanılarak 5 özellik elde edilir. Bunlar;

$$V_1 = \frac{A_1}{A} \quad V_2 = \frac{A_2}{A} \quad V_3 = \frac{A_3}{A} \quad V_4 = \frac{A_4}{A} \quad V_5 = \frac{A_4}{A_1} \quad (2.23)$$

Denklem (2.23)'de, A nesnenin alanını, A1, A2, A3 ve A4 ise her bir yarıçapa ait toplam piksel sayısını temsil etmektedir. Şekil 2.12'de, bu işlem adımlarına dayalı bir örnek gösterilmiştir.



Şekil 2.12. Yaprak damar özelliklerine dayalı örnek bir gösterim [10]

2.2.1.1.6. Shearlet Dönüşüm Yöntemi

Shearlet dönüşümü [150-151], basit bir matematiksel yaklaşım kullanarak görüntülerin analiz edilmesini sağlamaktadır. Bu yöntem, görüntülerin istenilen ölçek ve yöndeki frekans bileşenlerini, matematiksel bir yaklaşımla, daha esnek geometrik yapılarla dayalı detaylı bir analiz imkânı sağlamaktadır [10]. Shearlet fonksiyonu kutupsal koordinat sisteminde Denklem (2.24)'de gösterildiği gibi tanımlanır.

$$\psi_{a,s,t}(x) = |\det M_{a,s}|^{-\frac{1}{2}} \Psi(M_{a,s}^{-1} x - t) \quad (2.24)$$

$a > 0, s \in R, t \in R^2$ için $M_{a,s} = \begin{pmatrix} a & \sqrt{as} \\ 0 & \sqrt{a} \end{pmatrix}$ olarak ifade edilir. Bu eşitlikler kullanılarak $M_{a,s} = B_s A_a$ elde edilir. Burada, $A_a = \begin{pmatrix} a & 0 \\ 0 & \sqrt{a} \end{pmatrix}$ parabolik ölçme matrisi, $B_s = \begin{pmatrix} 1 & s \\ 0 & 1 \end{pmatrix}$ kesme matrisi ve t çevirme parametresidir [10, 150-154].

Shearlet dönüşümünün görüntü işleme uygulamalarında kullanılabilmesi için dönüşümün kartezyen koordinat sisteminde tanımlanması gerekmektedir [152-154]. $j, l \in Z$ olmak üzere, $a = 2^{-j}$ ve $s = -l$ olarak seçilir. Buradan Denklem (2.25) elde edilir:

$$M_{2^{-j}, -l}^{-1} = M_{2^j, l} = \begin{pmatrix} 2^j & l2^{j/2} \\ 0 & 2^{j/2} \end{pmatrix} = B_0^l A_0^j \quad (2.25)$$

Denklem (2.25)'de $A_0 = \begin{pmatrix} 2 & 0 \\ 0 & \sqrt{2} \end{pmatrix}$ ve $B_0 = \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix}$ olarak alınır. $j, l \in Z, k \in Z^2$ olmak üzere Shearlet dönüşümünün ayrık sistemi Denklem (2.26) kullanılarak aşağıdaki gibi elde edilebilir [151]:

$$\psi_{j,l,k} = |\det A_0|^j \Psi(B_0^l A_0^j x - k) \quad (2.26)$$

Doku tanımada iyi hassasiyet göstermesi ve yön bağımsızlığı gibi özelliklere sahip olan Shearlet Dönüşüm yöntemi, nesne tanıma alanında yaygın olarak kullanılmaktadır [10,150-155].

2.2.1.2. Renk Tabanlı yöntemler

Renk özellikleri, nesneye ait görsel özellikler için önemli bir ayırt edici etmendir. Bu özellikler, basit ve etkilidir. Bu tez çalışmasında, bitki görüntülerinin renk dağılımları; ortalama, varyans, çarpıklık ve basıklık gibi istatistiksel momentler kullanılarak elde edilmiştir [10, 122]. Bu özellikler hesaplanırken, yaprak görüntüleri dışındaki renkli/renksiz kısımlar elimine edilmiştir. Ayrıca, yaprak görüntülerinin her bir kanalı için (R, G ve B) renk özellikleri çıkartılmıştır. Renk özelliklerinin çıkartılması için kullanılan istatistiksel formüller aşağıda verilmiştir [38, 26];

- Ortalama, görüntüdeki renk dağılımının ortalama değeridir. Matematiksel ifadesi:

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i \quad (2.27)$$

- Standart sapma, ortalamanın çevresindeki yoğunluk değişimidir. Matematiksel ifadesi:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N |A_i - \mu|^2} \quad (2.28)$$

- Çarpıklık, görüntü renk dağılımının asimetriğini belirler. Matematiksel ifadesi:

$$\theta = \frac{\sum_{i=1}^N (A_i - \mu)^3}{N\sigma^3} \quad (2.29)$$

- Basıklık, görüntü renk dağılımının simetriği ya da düzgünlüğüdür. Matematiksel ifadesi:

$$\gamma = \frac{\sum_{i=1}^N (A_i - \mu)^4}{N\sigma^4} \quad (2.30)$$

Denklem (2.27-2.30)'de, M x N boyutundaki (tek boyutlu) görüntülerine dayalı istatistiksel formüller gösterilmiştir. Burada M ve N resmin boyutunu, i ve j sırasıyla satır ve sütun renk değerlerini belirtir.

2.2.1.3. Doku tabanlı yöntemler

Doku, belirli bir nesnenin yüzeyini karakterize etmek için kullanılan bir terimdir. Doku özellikleri ise görüntünün belirli bir değişim dağılımına dayalı gri ton ve renk uzayı olarak tanımlanır. Görüntünün doku özelliklerinin çıkartılması için birçok yöntem geliştirilmiştir. Bu yöntemlerin teorik alt yapısı aşağıda verilmiştir.

2.2.1.3.1. Gri Seviye Eş-Oluşum Matrisi

GSEM, gri ölçekli bir görüntünün özelliklerini çıkarmak için iki komşu piksel arasındaki ilişkiyi temel alan istatistiksel bir yöntemdir [10, 121, 156-158]. GSEM yöntemi, matematiksel olarak belirli bir ofset değeri ile görüntünün gradyan yönelimlerinin dağılımlarını ortaya çıkarır. Bu dağılımlar, pikseller arasındaki mesafe ve açıya göre ayarlanabilmektedir. $A \times b$ boyutundaki bir görüntünün (x, y) değeri için gri ölçekli eş oluşum matrisi denklem (2.31)'de verilmiştir [S4].

$$C_{x,y}(i,j) = \sum_m^k \sum_n^l \begin{cases} 1, & \text{Eğer } I(m,n) \text{ ve } I(m+x,n+y) = j \\ 0, & \text{değilse} \end{cases} \quad (2.31)$$

GSEM yöntemi kullanılırken pikseller arasındaki uzaklıklar $d=1,2, \dots$ ve piksel çiftlerinin yönleri $\alpha=0,45,90,135$ gibi değerler alabilmektedir. Şekil 2.13'de gri seviye sayısı 5, pikseller arası uzaklık $d=1$ ve yön açısı $\alpha=0$ olarak hesaplanmış bir eş-oluşum matrisi örneği verilmiştir.

	1	2	3	4	5
1	1	1	2	5	
2	4	2	1	1	
3	5	3	3	2	
4	1	2	4	5	
5					

	1	2	3	4	5
1	2	2	0	0	0
2	1	0	0	1	1
3	0	1	1	0	0
4	0	1	0	0	1
5	0	0	1	0	0

Şekil 2.13. GSEM yönteminin örnek bir gösterimi

Gri ölçekli eş oluşum matrisi kullanılarak görüntünün dokusal özellikleri ile ilgili bilgiler elde edilebilmektedir. 1970'lerde Haralick tarafından görüntünün farklı özelliklerini tanımlanmak için 14 tane doku özelliği önerilmiştir [153,159]. Bu dokusal özellikler arasından kontrast, korelasyon, enerji, entropi ve homojenlik en çok kullanılan özelliklerdir. Bu özelliklerin tanımları ve matematiksel ifadeleri aşağıda maddeler halinde verilmiştir.

- Kontrast, görüntüdeki piksel ve onun komşusu arasındaki yerel değişimlerin miktarını gösterir. Başka bir deyişle, kontrast görüntünün netliğini yansıtır [142,156]. Bu özelliğin matematiksel ifadesi aşağıda tanımlanmıştır.

$$Kon = \sum_{i=1}^M \sum_{j=1}^M (i - j)^2 P(i, j) \quad (2.32)$$

- Korelasyon, görüntüdeki gri seviye değerlerinin lineer bağımlılıklarının bir ölçüsüdür. Başka bir deyişle, korelasyon özelliği bir piksel ile onun komşusunun birbirleriyle nasıl ilişkili olduğunu gösterir [156, 160]. Bu özelliğin matematiksel ifadesi aşağıda tanımlanmıştır.

$$Kor = \sum_{i=1}^M \sum_{j=1}^M \frac{i * j * p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.33)$$

- Enerji, görüntünün homojenlik ölçüsüdür. Enerji değeri, görüntünün homojenlik ölçüsü ile doğru orantılıdır [156]. Ayrıca enerji, gri görüntünün tekdüzelik derecesini yansıtan ikinci moment olarak da adlandırılır [142]. Bu özelliğin matematiksel ifadesi aşağıda tanımlanmıştır.

$$Enj = \sum_{i=1}^M \sum_{j=1}^M [p(i,j)]^2 \quad (2.34)$$

- Entropi, gri seviyeli görüntü dokusunun karmaşıklığını veya bütünlüğünü yansıtır [142]. Bu özelliğin matematiksel ifadesi aşağıda tanımlanmıştır.

$$Ent = - \sum_{i=1}^M \sum_{j=1}^M p(i,j) \log_2 p(i,j) \quad (2.35)$$

- Homojenlik, gri seviyeli görüntünün farklı bölgelerindeki benzerliğinin ölçüsünü yansıtır. Bu özelliğin matematiksel ifadesi aşağıda tanımlanmıştır.

$$H = \sum_{i=1}^M \sum_{j=1}^M \frac{p(i,j)}{1 + |i-j|} \quad (2.36)$$

Denklem (2.32-2.36)'da, μ_i, μ_j, σ_i ve σ_j değerleri, eş oluşum matrisi olan $p(i,j)$ 'nin satır ve sütunlarının ortalamasını ve standart sapmasını ifade etmektedir. M ise görüntünün farklı piksel sayısını göstermektedir.

2.2.1.3.2. Yönlü Gradyan Histogramı

Gradyan tabanlı bir özellik çıkarım yöntemi olan YGH, Shashua ve Dalal tarafından önerilmiştir [161-162]. YGH yöntemindeki temel amaç, görüntüyü bir grup yerel histogramların serisi olarak tanımlamaktır. Yerel histogramlar, görüntünün lokal bir bölgesindeki gradyan yönelimlerinin (gradyanların büyüklükleri) sayısını içermektedir [163-165]. YGH yönteminin uygulama adımları şunlardır:

a) *Görüntünün gradyanın hesaplanması;*

İlk olarak, görüntü üzerindeki her bir nokta için Sobel filtresine dayalı yatay ve dikey gradyan değerleri Denklem (2.37) kullanılarak hesaplanır.

$$\begin{aligned} f_x(x,y) &= I(x+1,y) - I(x-1,y) \\ f_y(x,y) &= I(x,y+1) - I(x,y-1) \end{aligned} \quad (2.37)$$

Denklem (2.37)'de, $I(x,y)$ ifadesi (x,y) noktasındaki piksel yoğunluğunu (parlaklığını) temsil etmektedir.

b) *Belirlenen lokasyonlar için yönelim histogramlarının oluşturulması;*

Denklem (2.37)'de elde edilen f_x ve f_y değerleri kullanılarak gradyan büyüklüğü (m) ve gradyan yönü (ϑ)

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2}$$

$$\vartheta(x, y) = \tan^{-1}\left(\frac{f_y(x, y)}{f_x(x, y)}\right)$$
(2.38)

olarak hesaplanır. Gradyanın işaretli ya da işaretsiz olmasına ve 0-180 ya da 0-360 derece aralığında eşit olarak yayılmasına bağlı olarak imgenin gradyan yönelimi hesaplanır. Daha sonra, yönelim histogramını oluşturmak için her bir pikselin gradyan büyüklüğüne karşılık gelen gradyan yönelim açısına dayalı bloklara ayırma işlemi gerçekleştirilir [163-165].

c) *Oluşturulan lokasyon grupları içindeki histogramların normalize edilmesi.*

Son olarak, oluşturulan blok içerisindeki tüm histogramlar birleştirilir ve büyük bir histogram elde edilir. Bu histogramın normalize edilmesi için aşağıdaki matematiksel ifadeler kullanılır:

$$L1 - norm : V = \frac{V_k}{||V_k|| + \varepsilon}$$
(2.39)

$$L1 - sqrt : V = \sqrt{\frac{V_k}{||V_k|| + \varepsilon}}$$
(2.40)

$$L2 - norm : V = \frac{V_k}{\sqrt{||V_k||^2 + \varepsilon}}$$
(2.41)

Denklem (2.39-2.41)'de V_k her bir bloktaki tüm histogramları içeren normalleştirilmemiş değerleri ve ε ise sıfıra bölünmeye karşı kullanılarak sabit bir değişkeni göstermektedir. Ayrıca, histogramların normalize edilmesi için Denklem (2.39-2.41) kullanılabilir ve yapılan çalışmalara göre L2-norm ile normalleştirmenin daha iyi sonuçlar verdiği gözlenmiştir[166-167].


2.2.1.3.3. Yerel İkili Örüntü

He ve Wang [168] tarafından özellik çıkarım yöntemi olarak geliştirilen YİÖ algoritması, örüntü tanıma çalışmalarında yaygın olarak kullanılmaktadır [122,169]. Bu algoritma, merkez piksel ile komşu piksellerini karşılaştırır ve görüntünün her pikseli için 0 ile 1 değerlerini içeren etiketler oluşturur. Denklem (2.42-2.43) kullanılarak bir pikselin etiketi elde edilir.

$$Y = \begin{cases} 1 & (M_i - M_c) \geq 0 \\ 0 & (M_i - M_c) < 0 \end{cases} \quad (2.42)$$

$$Y\ddot{O}_{P,R} = \sum_{i=0}^{P-1} Y * 2^i \quad (2.43)$$

Denklem (2.42)'de, M_i komşu pikselleri, R komşu piksellerin mesafesini, P komşu piksellerin sayısını ve C merkez pikseli ifade etmektedir. Görüntüdeki tüm pikseller için etiketler hesaplanır ve daha sonra Denklem (2.43) kullanılarak 0 ile 255 aralığında herhangi bir sayı elde edilir (Şekil 2.14). Bu değerlerin histogramı hesaplanır ve sonuç olarak $1 \times N$ boyutunda öznitelik vektörü elde edilir.



Şekil 2.14. YİÖ yöntemine dayalı bir uygulama [122]

2.2.2. Derin öğrenme

Beynin yapısal ve işlevsel özelliklerinden esinlenilerek tasarlanmış, çok katmanlı ağ yapıları olan bir makine öğrenmesi algoritmasıdır. Derin Öğrenme, yapısal olarak yapay sinir ağlarından daha karmaşıktır. İnsandaki öğrenme işleyişine dayalı olarak geliştirilen YSA, biyolojik sinir sisteminde bulunan nöronların birbirleri ile olan ilişkisini ve bu nöronların birbirleri ile bağlantılarına dayanmaktadır [138,170-171].

Derin öğrenme, nesne tanıma problemlerin çözümü için gerçekleştirilen özellik çıkarma ve sınıflandırma işlemlerinde çok sayıda doğrusal olmayan gizli katman kullanmaktadır [138,170-171]. Derin Öğrenmenin YSA gibi makine öğrenmesi algoritmalarından farkı; büyük miktarda verilere ve hesaplama gücü yüksek donanımlara ihtiyaç duymasındır. Etiketli veri sayısı son zamanlarda görüntü işleme alanında milyon mertebelerini aşmıştır. Bunun yanı sıra, üretilen güçlü GIÜ (Grafiksel İşleme Ünitesi) kartları sayesinde bu tür sorunlar çözülmeye başlanmıştır. Gelecekte bu iki problemin giderilmesi için daha güçlü ürünler üretilmesi yönünde çalışmalar hız kazanmıştır [138,170-172].

Makine öğrenmesine dayalı geliştirilen geleneksel algoritmalarda, önceden bir insan tarafından belirlenen özelliklerin hesaplanması ile eğitim aşaması gerçekleştirilmektedir. Derin öğrenmede ise eğitim aşamasında ayırt edici özelliklerin

insandan bağımsız olarak öğrenmesidir. Derin öğrenmede, özellik öğrenme aşaması alt ve üst seviyelerden veya katmanlardan oluşmaktadır. Üst düzey katmanlar, alt düzey katmanların birleşmesinden oluşmaktadır. Bunun yanı sıra, alt seviye katmanları üst seviye katmanlarından daha ayırt edici özelliklere sahiptir. Sonuç olarak, bu tarz bir öğrenme yöntemi, elle çıkarılan özelliklere dayalı geliştirilen geleneksel algoritmalarından farklıdır. Bu durum, derin öğrenme yaklaşımlarının başarımında çok önemli bir etkidir.

2.2.2.1. Evrişimsel Sinir Ağları

Son zamanlarda, popüler derin öğrenme yöntemlerinden olan ESA, çok katmanlı algılayıcı ağ yapısına dayalı geliştirilmiştir. ESA, günümüzde nesne tanıma ve sınıflandırma alanında başarılı sonuçlar elde etmektedir. Derin Evrişimsel Sinir Ağlarına dayalı geliştirilen modeller birçok avantaja sahiptir [9,125]. Bunlar;

- Bölütleme ve nesneyi arka plandan ayırma gibi ön-işlem aşaması uygulanmaksızın ileri düzey görevler gerçekleştirilebilmektedir.
- Geleneksel görüntü tanımlayıcılara göre daha yüksek performans sağlamaktadır.
- Geliştirilen mimariler tek bir nesnenin özelliklerine bağlı olmadan tüm nesnelerin sınıflandırılması için kullanılabilir.

Evrişimsel sinir ağlarının yapısını oluşturan katmanlar ve ESA'ya dayalı geliştirilen mimariler alt başlıklar halinde detaylandırılmıştır.


2.2.2.1.1. Giriş Katmanı

Bu katman ESA modelinin ilk katmanını oluşturur. Bu katmanda veri herhangi bir ön-işlem aşaması uygulanmaksızın ham olarak ağa verilmektedir. Eğitim süresinin uzamaması için giriş görüntü boyutu yüksek seçilmemelidir. Uygun bir giriş görüntü boyutu seçilerek geliştirilecek modelin başarımının yüksek olması ve donanımsal hesaplama maliyetinin düşük olması sağlanabilir [138].

2.2.2.1.2. Evrişim Katmanı

Evrişim katmanı, derin evrişimsel sinir ağlarının temelini oluşturur. Bu katman, $n \times n$ boyutlu filtrelerin (2×2 , 3×3 , 5×5 , vb.) tüm görüntü üzerinde gezdirilmesine dayanmaktadır. Bu sayede, görüntüdeki ayırt edici öznitelikler çıkartılır ve yeni bir

görüntü elde edilir [172,173]. Evrişim filtresinin görüntü üzerinde uygulanması ile ilgili Şekil 2.15’de bir örnek verilmiştir.




Şekil 2.15. Evrişim işlemi ile ilgili örnek bir uygulama

Şekil 2.15’de, tek kanallı ve 5×5 boyutlu görüntü matrisine 3×3 boyutlu evrişim filtresinin uygulanması ve elde edilen çıkış görüntüsü (3×3 boyutlu) verilmiştir. Evrişim filtresi giriş görüntüsünün tüm pikselleri üzerinde sağa-sola ve aşağı-yukarı kaydırılır. Daha sonra görüntünün içerisindeki eşit boyutlu pencereler kullanılarak çarpma ve toplama işlemleri yapılır. Sonuç olarak belirgin yüksek seviyeli öz niteliklere dayalı çıkış görüntüsü elde edilir.

2.2.2.1.3. Havuzlama Katmanı

Derin öğrenme modellerinde boyut azaltmak için havuzlama katmanı kullanılmaktadır. Genel olarak, boyut azaltma işlemi bilgilerin kaybolmasına ve sınıflandırma performansının düşmesine neden olduğu bilinmektedir [172]. Literatürde yapılan çalışmalarda, havuzlama işlemi modelin ezberlemesini önlemesi ve daha az hesaplama yükü oluşturması gibi avantajlara sahip olduğu gözlenmiştir. Bu işlemin çalışma prensibi; belirli filtre çeşitleri kullanılarak görüntünün tüm pikselleri üzerinde gezdirilir ve görüntüdeki piksellerin maksimum, ortalama veya minimum değerleri alınarak gerçekleştirilir [174]. Şekil 2.16’da 6×6 boyutundaki görüntü üzerinde 3×3 pencere boyutunda ortalama, minimum ve maksimum havuzlama işlemlerinin uygulanışı ile ilgili bir örnek verilmiştir.



Şekil 2.16. Havuzlama işlemi ile ilgili örnek bir gösterim

2.2.2.1.4. Aktivasyon Fonksiyonu

Derin sinir ağlara dayalı geliştirilen modeller için aktivasyon fonksiyonu önemli bir etkidir. Sinir ağlarına doğrusal olmayan görüntü, video ve ses gibi gerçek dünya özelliklerini tanıtmak için aktivasyon fonksiyonlarına ihtiyaç duyulur. Literatürde yapılan çalışmalarda yaygın olarak Relu aktivasyon fonksiyonu kullanılmaktadır [172-174]. Denklem (2.44)'de, Relu fonksiyonunun matematiksel ifadesi verilmiştir.

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (2.44)$$

Denklem (2.44)'den anlaşılacağı üzere, Relu fonksiyonu giriş verisindeki negatif değerleri sıfıra çeker ve bu sayede ağı daha hızlı öğrenmesi sağlanır.

2.2.2.1.5. Normalizasyon Katmanı

Normalizasyon katmanı, evrişim katmanından elde edilen verileri düzenli hale getirmek için kullanılmaktadır. Bu işlem giriş verilerinin belirli bir aralıkta olmasını ve ağı performansının artırılmasını sağlamaktadır [174].

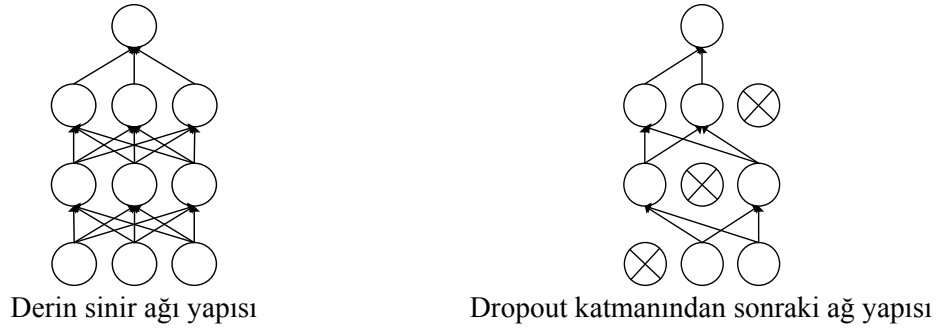
2.2.2.1.6. Tam Bağlı Katman

Tam bağlı katman kendinden önce gelen katmanın tüm nöronlarına bağlıdır ve $1 \times N$ boyutlu bir matrisden oluşmaktadır. Bu katman genellikle ESA'ya dayalı geliştirilen mimarilerin sınıf skorlarını optimize etmek için kullanılmaktadır [172,174].

2.2.2.1.7. Dropout Katmanı

Dropout katmanı, ağı aşırı öğrenmesini veya ağı veriyi ezberlemesini önlemek için kullanılmaktadır. Bu katmanın çalışma prensibi, belirli bir eşik değeri kullanarak

bazı düğümlerin kaldırılmasına dayanır. Bu sayede gereksiz ve zayıf bilgiler unutulur ve ağın performansının yükseltilmesi sağlanır [174]. Şekil 2.17’de normal bir sinir ağı ile Dropout uygulanmış ağ yapısı gösterilmiştir.



Şekil 2.17. Derin ağ yapısı ve dropout uygulanması

2.2.2.1.8. Sınıflandırma Katmanı

ESA’ya dayalı geliştirilen modellerde sınıflandırma işleminin yapıldığı katmandır. Bu katmanın çıkış değeri toplam sınıf etiket sayısına eşittir. Bu katmanda yaygın olarak softmax sınıflandırıcısı kullanılmakta ve bu sınıflandırıcı her bir sınıf için 0-1 arasında olasılıksal değerler üretmektedir. Sonuç olarak en yüksek olasılık değeri modelin tahmin edildiği sınıf etiketini vermektedir [172-174].

2.2.2.2. ESA Mimarileri


Derin Evrimsel Sinir Ağlarına dayalı ve büyük veri setleri kullanılarak geliştirilen birçok derin öğrenme mimarileri bulunmaktadır. Bu mimariler, ILSVRC yarışmasındaki ImageNet veri setinin bir alt kümesi kullanılarak eğitilmiştir. Bu veri seti, klavye, fare, kalem ve birçok hayvan gibi 1000 sınıflı olmak üzere bir milyondan fazla görüntü içermektedir. Bu çalışmada, önceden eğitilmiş ESA modellerinden AlexNet, GoogleNet, VGG16, VGG19, Resnet18, ResNet50, ResNet101, InceptionV3, InceptionResNetV2, DenseNet201 ve SqueezeNet mimarileri kullanılmıştır. Bu mimarilerinin karakteristikleri Çizelge 2.3’de verilmiş ve bu mimariler ile ilgili bilgiler alt başlıklarda detaylandırılmıştır.

Çizelge 2.3. Derin Mimarilerin Karakteristikleri

Algoritmalar	Derinlik	Boyut	Parametre (Milyon)	Görüntü giriş boyutu
AlexNet [175]	8	227	61	227x227
VGG16 [176]	16	515	138	224x224
VGG19 [176]	19	535	144	224x224
SqueezeNet [177]	18	4.6	1.24	227x227
GoogleNet [178]	22	27	7	224x224
Inceptionv3 [179]	48	89	23.9	299x299
InceptionResNetv2 [180]	164	209	55.9	299x299
ResNet18 [181]	18	44	11.7	224x224
ResNet50 [181]	50	96	25.6	224x224
ResNet101 [181]	101	167	44.6	224x224
DenseNet201 [182]	201	77	20.0	224x224

2.2.2.2.1. AlexNet

Alex ve diğ. tarafından geliştirilen ve ILSVRC 2012 yarışmasını kazandıran derin öğrenme algoritmasıdır [175]. AlexNet, sekiz katman üzerinde eğitilebilen ağırlıkları olan ve 25 katmandan oluşan derin bir mimaridir. Bu mimari, 5 adet konvolüsyon katmanı, 7 adet relu katmanı, 3 adet tam bağlı katman, 3 adet maxpool katmanı, 2 adet normalizasyon katmanı, 2 adet dropout katmanı ve softmax katmanlarından oluşmaktadır. Bu mimarinin çalışma prensibi Şekil 2.18’de gösterilmiştir. Ayrıca, AlexNet ağına giriş katmanındaki görüntü boyutları 227x227x3’tür [8].




Şekil 2.18. AlexNet Mimarisi

2.2.2.2.2. VGGNet

ILSVRC-2014 yarışmasında başarı sağlayan VGG ağı, Oxford Görsel Geometri Grubunun geliştirilmiş olduğu bir derin ağıdır [176]. Bu mimarinin mevcut modellerden farkı derinliği ve genişliğidir. VGG ağına dayalı VGG16 ve VGG19 modelleri geliştirilmiştir. Bu iki model havuzlama, tam bağlı, Relu katmanı, Dropout ve Softmax katmanlarını içermektedir. VGG16 ağı, 16 adet konvolüsyon katmanı olmak üzere 41 katmana sahip iken, VGG19 mimarisi ise 19 konvolüsyon katmanı olmak üzere 47

katmandan oluşmaktadır. Ayrıca, her iki modelin giriş katmanındaki görüntü boyutları $224 \times 224 \times 3$ 'tür [8]. Bu iki mimariden VGG16 modelinin genel gösterimi Şekil 2.19'da gösterilmiştir.



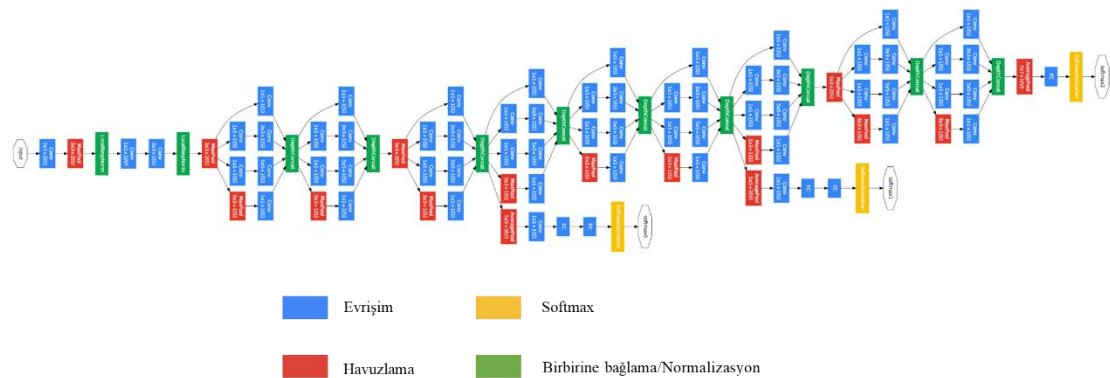
Şekil 2.19. VGG16 Mimarisi

2.2.2.2.3. SqueezeNet

SqueezeNet, Landola vd. tarafından ImageNet veri seti kullanılarak 50 kat daha az parametre ile AlexNet seviyesinde performans sağlayan, akıllı bir mimari olarak geliştirilmiştir [177]. Bu mimaride, 75 bağlantı ve 68 katman mevcuttur. Ayrıca, giriş katmanındaki görüntü boyutları $227 \times 227 \times 3$ 'tür.

2.2.2.2.4. GoogleNet


Inception modülü ile birlikte farklı boyutlarda filtreleme işlemlerine dayalı geliştirilen GoogleNet mimarisi, çeşitli özellik noktalarını çıkarmak için paralel olarak birden çok evrişim kullanılmasına dayanmaktadır [178, 182-184]. Inception modülünde yer alan filtre elemanları 1×1 , 3×3 , 5×5 boyutundadır. Bu model, sayım havuzlaması dışında 22 katman derinliğe sahip olmak üzere 144 katmandan oluşmakta ve 6.8 milyon parametreye sahiptir. GoogleNet algoritması, evrişim, maksimum havuzlama, softmax katman, tam bağlı katman, relu ve çıkış katmanlarından oluşur. Ayrıca giriş katmanındaki görüntülerin boyutları $224 \times 224 \times 3$ 'tür. Bu iki mimarinin genel gösterimi Şekil 2.20'de gösterilmiştir.



Şekil 2.20. GoogleNet Mimarisi [178]

2.2.2.2.5. InceptionV3

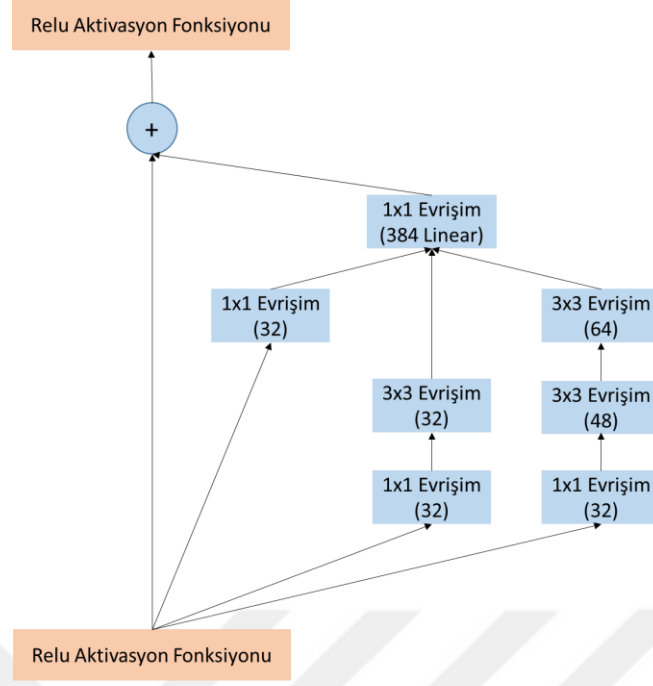
Inception ağı, Szegedy vd. tarafından bir ESA modeli olarak önerilmiştir [179]. Bu ağ çok sayıda evrişim ve maksimum havuzlama katmanlarından oluşmaktadır. Son aşamada ise tamamen bağlantılı bir sinir ağına sahiptir. Bu tez çalışmasında, Inception ağına dayalı geliştirilen versiyonlardan biri olan Inception V3 modeli kullanılmış ve Şekil 2.21'de gösterilmiştir. Bu modelin ağırlıkları hem VGGNet hem de ResNet mimarilerinden daha küçüktür. Inceptionv3 mimarisi, 350 bağlantı ve 316 katmandan oluşan bir ağıdır. Bununla birlikte, bu modelin giriş katmanındaki görüntü boyutları $299 \times 299 \times 3$ 'tür.



Şekil 2.21. Inceptionv3 modeli [179]

2.2.2.2.6. InceptionResNetV2


InceptionResNetV2 ağı [180], Inception tabanlı ağ yapısına ve artık bağlantılara dayanmaktadır (Şekil 2.22). InceptionResNetV2, Inception mimarileriyle neredeyse aynı şekilde çalışır, fakat bu mimari artık bağlantıları kullanarak eğitim aşamasında önemli bir hız kazandırmaktadır. Bu modelin genel yapısı oldukça basit olmasına rağmen, ağın bireysel bileşenleri oldukça karmaşıktır [186]. Bu mimaride, 922 bağlantı ve 825 katman mevcuttur. Ayrıca, bu modelin giriş katmanındaki görüntü boyutları $299 \times 299 \times 3$ 'tür.



Şekil 2.22. InceptionResNetv2 modülü

2.2.2.2.7. ResNet

ResNet mimarisi, daha derinlikli ağları eğitmek için He vd. tarafından geliştirilmiştir [181]. Mikro mimari modülüne dayanan bu mimari, VGGNet ve AlexNet gibi ardışık geleneksel ağ mimarilerinden farklıdır. Bu mimarinin VGGNet ağından çok daha derin olmasına rağmen, ağın boyutu ve parametre sayısı daha düşüktür. Residual bloklarından oluşan ResNet mimarisi, artık değerlerin sonraki katmanları besleyen blokların modele eklenmesine dayalıdır (Şekil 2.23). Bu yapı ile ResNet mimarisi klasik bir model olmaktan çıkmış ve derinlik artmasına rağmen öğrenme daha hızlı şekilde gerçekleştirilmektedir.



Şekil 2.23. ResNet Artık Modülü

Artık blokta x girişinin sırasıyla evrişim-Relu-evrişim katmanlarından sonra bir $f(x)$ sonucu elde edilir. Şekil 2.23'den anlaşılacağı üzere, bu sonuç orijinal x girişine eklenir ve bir sonraki katmana $f(x)+x$ olarak kaybolmadan geçilmesi sağlanır [138,174,185].

ResNet modeli temel alınarak ResNet-18, ResNet-50 ve ResNet-101 olmak üzere birçok mimari geliştirilmiştir. Bu mimarilerin yanındaki rakamlar derinliklerini temsil etmektedir. Buna ek olarak, bu geliştirilen mimarilerin bağlantı ve katman sayıları şunlardır;

- ResNet18 mimarisi; 79 bağlantı ve 72 katmandan oluşur.
- ResNet50 mimarisi; 192 bağlantı ve 177 katmandan oluşur.
- ResNet101 mimarisi, 379 bağlantı ve 347 katmandan oluşur.

Bununla birlikte, her üç model için giriş katmanındaki görüntü boyutları $224 \times 224 \times 3$ 'tür.


2.2.2.2.8. DenseNet201

Her katmanın ileriye doğru bir şekilde (her yoğun blok içerisinde) doğrudan diğer tüm katmanlara bağlandığı bir ağ mimarisi olan DenseNet modeli, Huang ve arkadaşları tarafından önerilmiştir [182]. Her katman için, önceki tüm katmanların özellik haritaları ayrı girişler olarak değerlendirilirken, kendi özellik haritaları sonraki tüm katmanlara girdi olarak aktarılır. Buna ek olarak, DenseNet mimarisinde, model karmaşıklığı azaltmak ve özellik parametreleri daha verimli yapmak için geçiş katmanlarında (yoğun bloklardan sonra) darboğaz yapısı ve havuzlama katmanı kullanılır [186-190].

DenseNet ve ResNet modelleri birbirine benzer mimarilerdir (Şekil 2.24). Fakat ResNet mimarisi, her ResNet modülü sadece bir önceki modülden bilgi alırken, DenseNet mimarisinde ise her katman, önceki katmanlardan bilgi almasına dayalıdır. DenseNet mimarisindeki bu farklılık, her katmanı ileri beslemeli bir şekilde yoğun biçimde birleştirir [186-189]. DenseNet mimarisinin, ResNet mimarisine göre avantajları şunlardır [190].

- Güçlü gradyan akışı sağlar.
- Parametre ve hesaplamada verimliliği artırır.
- Daha çeşitlendirilmiş özellikler elde edilir.
- Düşük karmaşıklık özelliklerini korur.
- Sınıflandırma performansı daha yüksektir.

Bununla birlikte, DenseNet mimarisi için giriş katmanındaki görüntülerin boyutları $224 \times 224 \times 3$ olmalıdır.



Şekil 2.24. ESA Modelleri

Şekil 2.24’de normal ESA modeli, ResNet modeli ve DenseNet modeline ait temsili birer örnek gösterilmiştir. Şekil 2.24 (a)’da gösterilen normal ESA modelinde, giriş görüntüsü birden fazla evrişim katmanından geçerek derin özellikler elde edilir. Şekil 2.24 (b)’de gösterilen ResNet modelinde, eleman bazlı ekleme mantığına dayalı olarak her katman bir önceki katmandan ek girdiler alır. Şekil 2.24 (c)’de gösterilen DenseNet modelinde ise, kanal bazlı ekleme mantığına dayalı olarak her katman önceki tüm katmanlardan ortak bilgi almaktadır [191].

2.3. Sınıflandırma

Bilinmeyen bir nesneyi tanımlayabilmek için özellik çıkarım aşamasından sonra sınıflandırma işlemi gerçekleştirilir. Sınıflandırma işleminde performansı etkileyen en önemli faktör özellik çıkarım aşamasıdır. Bu aşamada ne kadar etkili özellikler elde edilir ise sınıflandırıcının performansı o derecede yüksek olur.

Bu tez çalışmasında, özellik çıkarım aşamasında elde edilen özellikleri sınıflandırmak ve test etmek için literatürdeki çalışmalarda en yaygın olarak kullanılan

ve performansları yüksek olan DVM, AÖM ve k-EYK sınıflandırıcı yöntemleri kullanılmıştır. Bu sınıflandırıcılar ile ilgili teorik bilgi aşağıda verilmiştir.


2.3.1. Destek Vektör Makinesi

Vapnik tarafından geliştirilen DVM, bir istatistiksel öğrenme algoritmasıdır [191-192]. DVM yöntemi, sınıfları birbirinden ayırabilmek için en geniş marjin seçilmesi veya en uygun hiperdüzlemin tahmin edilmesi esasına dayanmaktadır [1,194,128]. Son yıllarda, DVM yöntemi kullanılarak görüntü işleme ve makine öğrenmesine dayalı yapılan çalışmalarda başarılı sonuçlar elde edilmiştir [1,39,27].

Destek Vektör Makinesi, doğrusal olarak ayrılabilen veya doğrusal olarak ayrılabilen verileri sınıflandırabilmektedir. Veri kümesinde oluşacak bu iki problem için DVM' nin çözümleri alt başlıklar halinde detaylandırılmıştır.

2.3.1.1. Doğrusal olarak Ayrılabilme Durumu

DVM sınıflandırıcısının temel amacı, iki veri sınıfını ayırabilmek için bir hiperdüzlemi veya karar sınırını bulmaktır [127, 194-196]. Şekil 2.25'de, hiperdüzlem (M) ara bölgenin tam ortasına yerleştirilmiştir. Bunun yapılmasındaki amaç ayırma sınırını maksimum yapmaktır. Başka bir deyişle, DVM algoritmasının amacı, sınıfları birbirinden ayıran en geniş marji seçmektir. Destek vektör; bu marjine en yakın verilerdir.



Şekil 2.25. DVM hiperdüzlem ayrımı

İki sınıflı ve doğrusal olarak ayrılabilen bir sınıflandırma probleminde n elemandan oluşan eğitim verisinin $X = \{x_i, y_i\}$, $i=1, 2, \dots, n$ olduğunu varsayalım. Burada $x \in \mathbb{R}^N$ olup N boyutunda sınıflara ait özelliklerin olduğu giriş vektörü ve $y_i \in \{-1, 1\}$ ise sınıf etiketlerinin göstermektedir [127].

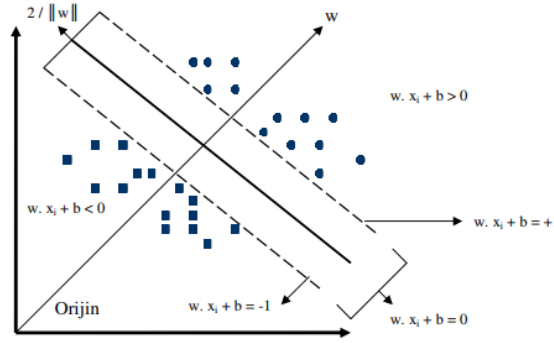
Pozitif ve negatif verileri birbirinden ayıran bir hiperdüzlem olduğunu varsayarsak, bu hiperdüzlemin ayırdığı verilerden her biri bir sınıf belirtir. Her eğitim örneği ya da her sınıf aşağıdaki eşitsizliği sağlamalıdır:

$$\begin{aligned} y_i = +1 \text{ için, } wx_i + b &\geq +1 \\ y_i = -1 \text{ için, } wx_i + b &\leq -1 \end{aligned} \quad (2.45)$$

Burada $w \cdot x = w$ ile x arasındaki iç çarpımını, w hiperdüzlemin normal (ağırlık) vektörünü ve b ise eğilim değerini göstermektedir. Bu eşitsizlikler $i=1,2, \dots, n$ için Denklem 2.46'deki gibi yazılabilir.

$$y_i(wx_i + b) \geq +1 \quad (2.46)$$

Denklem 2.46'yı sağlayan en iyi hiperdüzlemin belirlenebilmesi için bu düzleme paralel ve sınırlarını oluşturacak hiperdüzlemin belirlenmesi gerekir (Şekil 2.26). Bu hiperdüzlemi bulabilmek için en uygun w ve b değerleri hesaplanmalıdır [127, 196].



Şekil 2.26. DVM hiperdüzlem ayrımı (1) [128]

İki veri kümesi arasındaki uzaklık $2/\|w\|$ kadardır. Bu iki hiperdüzlem arasındaki uzaklığı maksimuma çıkarılması için $\|w\|$ 'nin aşağıda verilen şartlara göre minimum hale getirmek gerekmektedir [127, 196]:

$$\frac{\min \|w\|^2}{2} \text{ için } \forall_i, y_i(wx_i + b) \geq +1 \quad (2.47)$$

Bu problem ikinci dereceden optimizasyon problemidir ve Lagrange denklemleri kullanılarak çözülebilir. Bu yöntem sonucunda elde edilen formülasyon oldukça karmaşık bir denklemi meydana getirir. Bu karmaşıklığı giderebilmek ve daha da kolaylaştırabilmek için lagrange problemini dual problemine dönüştürmek gerekir [127]. Bu işlemler sonrasında;

$$L(w, b, \alpha) = \frac{\|w\|^2}{2} - \sum_{i=1}^k \alpha_i y_i(wx_i + b) + \sum_{i=1}^k \alpha_i \quad (2.48)$$

eşitliği elde edilir. Böylelikle, doğrusal olarak ayrılabilen veriler için karar fonksiyonu aşağıdaki şekilde olur [127, 194-196];

$$f(x) = \text{sign}\left(\sum_{i=1}^k \gamma_i y_i (x * x_i) + b\right) \quad (2.49)$$

2.3.1.2. Doğrusal olarak Ayrılamama Durumu

Gerçek hayatta genellikle veri kümeleri doğrusal olarak ayrılamazlar (Şekil 2.27). Doğrusal olarak ayrılabilir olmadığı durumlar da problemin çözümü için yapay bir ξ değişkeni, bir düzgünleştirme parametresi (C) ve $i = 1, 2, \dots, n$ kullanılır [127,194-196]. Denklem (2.45-2.49) eşitliklerini, bu sapmalar ile yeniden tanımlayacak olursak;

$$\begin{aligned} y_i = +1 \text{ için, } wx_i + b &\geq +1 - \delta \\ y_i = -1 \text{ için, } wx_i + b &\leq -1 + \delta \\ \delta &\geq 0, \forall_i \end{aligned} \quad (2.50)$$

eşitlikleri elde edilir. Daha sonra, düzgünleştirme parametresi (C) ve yapay değişken (ξ) kullanılarak doğrusal olmayan veriler için:

$$\min\left[\frac{\|w\|^2}{2} + C * \sum_{i=1}^r \xi_i\right] \quad (2.51)$$

eşitlikleri elde edilir. Bundan sonraki işlemler ise doğrusal ayrılabilir de yapılan işlemler ile aynıdır. Başka bir deyişle, bu optimizasyon probleminin çözümü için Lagrange denklemleri kullanılır. Bu işlemten sonra aşağıdaki denklemler elde edilir [127,194-196]:

$$\begin{aligned} \text{maksimuma çıkarmak } \sum_i \alpha_i \pm \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j k(x_i, x_j) \\ \text{sınırlama } \sum_i \alpha_i y_i &= 0 \\ 0 \leq \alpha_i \leq C, i &= 1, 2, \dots, M \end{aligned} \quad (2.52)$$

Burada α_i Lagrange çarpanlarını ve K çekirdek fonksiyonu temsil etmektedir. $\Phi(x_i) \cdot \Phi(x_j)$ çekirdek fonksiyonu olup K şeklinde ifade edilen bir kernel fonksiyonu yardımıyla verilerin yüksek boyutlu uzayda doğrusal olarak ayrılabilir duruma gelmektedir. Literatürdeki farklı alanlar için yapılan çalışmalarda çeşitli kernel fonksiyonları kullanılmaktadır [127,194-196]. En yaygın olarak kullanılan kernel fonksiyonları ve matematiksel ifadeleri Çizelge 2.4'de verilmiştir.


Çizelge 2.4. DVM için kullanılan temel kernel fonksiyonları

Çekirdek Fonksiyonları	Matematiksel İfadeleri
Doğrusal Fonksiyon	$K(x, y) = x^T y + c$
Polinom Fonksiyonu	$K(x, y) = (x^T y + c)^d$
Sigmoid Fonksiyonu	$K(x, y) = \tanh(x^T y + c)$
Radyal tabanlı fonksiyon	$K(x, y) = \exp(-\gamma \ x - y\ ^2)$
Laplace fonksiyonu	$K(x, y) = \exp(-\frac{\ x - y\ }{\sigma})$

Sonuç olarak, çekirdek (kernel) fonksiyonları kullanılarak doğrusal olarak ayrılamayan veriler için karar fonksiyonu aşağıdaki şekilde yazılabilir:

$$f(x) = \text{sign}\left(\sum_{i=1}^M \alpha_i y_i K(x_i, x) + b\right) \quad (2.53)$$

Çok sınıflı (İkiden daha fazla) sınıflandırma işlemleri için en yaygın olarak kullanılan bire-karşı-bir (BKB) ve bire-karşı-hepsi (BKH) ayrıştırma yöntemleri kullanılarak verileri sınıflandırılma işlemi yapılabilmektedir. BKB yöntemi, her bir sınıfın diğer sınıflardan ayırt edilmesine dayalıdır. BKH yöntemi ise bir sınıf ile geriye kalanlar bir sınıf olarak kabul edilir ve eğitim işlemi gerçekleştirilir [127, 195, 197-199].




Şekil 2.27. Doğrusal olmayan bir DVM sınıflandırma örneği

2.3.1.3. En-Küçük Kareler Destek Vektör Makinesi

Sınıflandırma problemlerinin çözümü için geliştirilen DVM algoritması, Vapnik ve arkadaşları tarafından önerilmiştir [192]. Daha sonra, Suykens ve Vandewalle [200] tarafından EK-DVM (En Küçük Kareler Destek Vektör Makinesi) yöntemi olarak adlandırılan DVM yönteminin geliştirilmiş versiyonu önerilmiştir [127,202-203]. Genel olarak DVM ile EK-DVM arasındaki farklar Çizelge 2.5’de ve her iki yöntemin genel mimarileri Şekil 2.28’de verilmiştir.

Çizelge 2.5. DVM ile EK-DVM yöntemlerinin karşılaştırılması

DVM	EK-DVM
Eşitsizlik sınırları vardır.	Eşitlik sınırları vardır.
DVM, sınıflandırmak için ikinci dereceden programlama kullanır.	EK-DVM, sınıflandırmak için doğrusal denklem kullanır.



Şekil 2.28. DVM ve EK-DVM'nin mimarisini [203]

Şekil 2.28'de α_m ile α_m^* değerleri Lagrange çarpanlarını ve $(\alpha_m - \alpha_m^*)$ değeri ise destek vektörü temsil etmektedir. Standart DVM sınıflandırıcısı, EK-DVM sınıflandırıcısı biçimine şu şekilde dönüştürülür;

Minimizasyon,

$$J(w, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{m=1}^n e_m^2 \quad (2.54)$$

Kısıtlamalar,

$$y_m = w^T \varphi(x_m) + b + e_m, \quad m = 1, 2, \dots, n \quad (2.55)$$

burada $\varphi()$, yüksek boyutlu özellik alanına taşıma fonksiyonu, y_m çıkış değerini, x giriş değerini, w ağırlık vektörü ve b bias değerini göstermektedir. Denklem (2.55)'deki problemin çözümü için Lagrange yöntemi kullanılarak,

$$J(w, b, e, a) = J(w, e) - \sum_{m=1}^n a_m \{w^T \varphi(x_m) + b + e_m - y_m\} \quad (2.56)$$

eşitliği elde edilir. Burada a_m değeri, Lagrange çarpanıdır. Bu çarpanlar negatif değerler de alabilmektedir. Denklem (2.56)'daki optimizasyondan sonra, kısmi türev uygulanarak w ve hata teriminin (e) elenmesiyle, EK-DVM yöntemi için fonksiyon tahmini (Denklem (2.57)) ve karar fonksiyonu (Denklem (2.58)) şu şekilde tanımlanır [126,201-203];

$$y(x) = \sum_{k=1}^m \alpha_m K(x, x_m) + b \quad (2.57)$$

$$f(x) = \text{sign} \left[\sum_{m=1}^n \alpha_m y_m K(x, x_m) + b \right] \quad (2.58)$$

Burada $K(x, x_m)$ fonksiyonu kernel fonksiyonunu olarak ifade edilir. Literatürde yaygın olarak kullanılan Kernel fonksiyonları Çizelge 2.4’de detaylı olarak bahsedilmiştir.

2.3.2. Aşırı Öğrenme Makinesi

AÖM yöntemi, TGKİB (Tek-Gizli Katmanlı İleri Beslemeli) sinir ağı için Huang ve arkadaşları tarafından önerilen bir makine öğrenme algoritmasıdır [10, 204-206]. AÖM yapısında, gizli katman ağırlıkları rastgele üretilirken, çıkış ağırlıklarının hesaplanmasında en küçük kareler yöntemi kullanılır. Bu yöntem sayesinde geleneksel geri yayılım algoritmaları ile öğrenen ileri beslemeli ağlara göre öğrenme süreci daha hızlı ve daha iyi genelleme başarımına sahip olmaktadır [10,122,204,207]. AÖM matematiksel olarak aşağıdaki gibi modellenir;

$$\sum_{i=1}^M \beta_i g(w_i \cdot x_j + b_i) = y_j, \quad j = 1, \dots, N \quad (2.59)$$

Burada $[x_j, y_j]$ giriş-çıkış ikilisini, N eğitim örnek sayısını, M gizli nöron sayısı, w_i giriş ağırlıklarını, b_i gizli katman eşiğini ve β_i çıkış ağırlıklarını ifade etmektedir. Ağın çıkışı gerçek değerleri 0 hata ile yakınsadığı kabul edilirse Denklem (2.59), $Y = H\beta$ matris formunda yazılabilir. Denklem (2.59) matris formunda aşağıdaki gibi ifade edilebilir.

$$Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_N^T \end{bmatrix}_{Nx1} \quad \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{Mx1} \quad (2.60)$$

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_M \cdot x_1 + b_M) \\ \vdots & \cdots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_M \cdot x_N + b_M) \end{bmatrix}_{NxM}$$

Burada H gizli katman çıkış matrisi, Y ağın çıkışını ve β çıkış ağırlıklarını temsil etmektedir. β parametresi Denklem (2.60) tarafından belirlenebilir.

$$\beta = H^\dagger Y \quad (2.61)$$


Burada H^\dagger , H 'ın Moore Penrose genelleştirilmiş tersini göstermektedir [10,121,122,204-206,208]. AÖM algoritmasının sözde kodu, Şekil 2.29'da gösterildiği gibi tanımlanır.

Giriş: Eğitim Seti ve N gizli nöron sayısı
Çıkış: β çıkış ağırlık matrisi
1: Başlangıçtaki giriş ağırlıklarını (w) ve biası (b) rastgele başlat.
2: Denklem 2.60 kullanılarak gizli katman çıkış matrisini (H) hesapla.
3: Denklem 2.61 kullanılarak sözde ters matrisi (β) hesapla.

Şekil 2.29. AÖM yönteminin sözde kodu

2.3.3. K-En Yakın Komşu Algoritması

Sınıflandırma yöntemleri arasında yer alan k-EYK algoritması, istatistiksel öğrenme metoduna bağlı olarak geliştirilmiştir. Bu sınıflandırıcı, nesne tanıma ve görüntü işleme alanlarına dayalı gerçekleştirilen uygulamalarda sıkça kullanılmaktadır. k-EYK algoritmasının çalışma prensibi; yeni aktarılan verinin mevcut olan bir kümedeki verilere en yakın (k) mesafedeki sınıfa eklenmesidir. Mevcut küme ile yeni veri arasındaki mesafe Öklid, Minkowski ve Manhattan olmak üzere çeşitli uzaklık denklemleri kullanılarak hesaplanılır [8,210]. k-EYK algoritmasının örnek gösterimi Şekil 2.30'da verilmiştir.



Şekil 2.30. k-EYK algoritmasının basit bir gösterimi [8].

2.4. Özellik İndirgeme

Özellik indirgeme, özellik vektörlerinin sınıflandırma aşamasında işlem yükünün azaltılmasını ve sınıflandırma performansının artırılmasını amaçlamaktadır. Bu işlem sonucunda, özellik kümesinden en önemli özellikler seçilmesine dayalı daha az boyutta bir özellik vektörleri tanımlanır [210]. Özellik indirgeme işleminin genel avantajları şunlardır [211]:

- Özellik vektörlerinin boyutu düşürülerek sınıflandırma ve test zamanı hızı artırılır,

- Özellik kümesinden seçkin özellikler elde edilir,
- Sınıflandırma performansı artırılır.

Literatürdeki çalışmalarda çok sayıda geliştirilen özellik indirgeme yöntemleri bulunmaktadır. Bu tez çalışmasında; hızlı, performansı yüksek ve kullanışlı olan Temel Bileşenler Analizi yöntemi kullanılmıştır. İstatistiksel bir yöntem olan TBA, çok değişkenli veri tabanlarının analizinde ve verilerin daha düşük boyutlara indirgenmesinde kullanılmaktadır. Öznitelik indirgeme yöntemleri arasında popüler olan TBA, veri madenciliği ve makine öğrenmesi alanlarında yaygın olarak kullanılmaktadır [10, 212-213].

$\mathbf{M} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$, d boyutlu ve n örnekli bir veri setleri olsun.

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (2.62)$$

Buradaki $\bar{\mathbf{x}}$, veri dizisinin ortalamasını temsil etmektedir. Denklem (2.63) kullanılarak Kovaryans matris hesaplanır:

$$\mathbf{Kov} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (2.63)$$

Kovaryans matris kullanılarak öz değer ve öz vektörlerin hesaplanılmasının ardından indirgenen öznitelik sayısı kadar eşdeğer öz vektörler seçilir. Son olarak, temel bileşen değerlerinin bulunması için veri matrisi ile her bir öz vektörün transpozu çarpılır. Bu tez çalışmasında TBA yönteminin kullanılmasındaki amaç, özellik indirgemesini hızlı bir şekilde yaparak sınıflandırma performansını yükseltmektir [10].

2.5. Normalizasyon

Normalizasyon, örüntü tanıma sistemlerinin sınıflandırma performansını artırmak için kullanılan bir veri işlemedir. Birden fazla öznitelik çıkarım yöntemi kullanıldığı zaman bazı özellikler aşırı büyük veya küçük değerlerden oluşabilmektedir. Bu durum, ağırlıklı yönlendirerek sınıflandırma performansının düşmesine neden olmaktadır [10].

Bu tez çalışmasında, öznitelik çıkarım yöntemlerinden elde edilen özellik kümesinin dağılımını düzenli hale getirmek için z-skor ve min-max normalizasyon yöntemleri kullanılmıştır.

2.5.1. Z-skor normalizasyon Yöntemi

Bütün girdilerin belirli aralıkta ölçeklendirilmesi için gerçekleştirilen z-skor normalizasyon işleminde, verinin ortalama ve standart sapma değerleri kullanılarak bu tür farklılıkların ortadan kaldırılması sağlanmıştır [10,214,215]. Z-skor normalizasyon değeri Denklem (2.64) kullanılarak hesaplanmaktadır.

$$z = \frac{x - \mu}{\sigma} \quad (2.64)$$

Burada x veriyi, μ ham verinin sütunlarının ortalamasını ve σ sütunların standart sapmasını temsil etmektedir.

2.5.2. Min-Max normalizasyon Yöntemi

Min-Max yöntemi, özellik kümesindeki verileri doğrusal olarak normalleştirmek için kullanılır. Bu yöntem, özellik kümesindeki verilerin en küçük değeri ile en büyük değeri kullanılarak bütün verileri 0-1 aralığına yaymayı amaçlamaktadır [216]. Denklem (2.65) kullanılarak Min-Max normalizasyon işlemi gerçekleştirilir.

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (2.65)$$


Burada x'_i normalize edilmiş değeri, x_i giriş değeri, x_{\max} özellik kümesindeki en büyük sayıyı ve x_{\min} özellik kümesindeki en küçük sayıyı temsil etmektedir.

2.6. Eğitim-Test verilerine Ayırma

Makine öğrenmesi çalışmalarında, uygulanan yöntemin performansını hesaplamak için veri setini eğitim ve test kümelerine ayırma işlemi gerçekleştirilmektedir. 10-kat çapraz-doğrulama yöntemi, Literatürde yapılan çalışmalarda yaygın olarak kullanılmakta ve güvenilirliği yüksektir [10]. Bu yöntemin uygulama adımları sırasıyla aşağıda verilmiştir:

- Öznitelik kümesi 10 parçaya bölünür.
- Her bir adımda parçalardan biri test için, geriye kalan dokuzu eğitim için kullanılır.
- Bu işlem on kez tekrarlanır.
- Son olarak, ortalamaları alınarak sistemin performansı hesaplanmaktadır

10-kat çapraz doğrulama yönteminin genel çalışma prensibi Şekil 2.31’de gösterilmiştir.



Şekil 2.31. 10-kat çapraz doğrulama modeli [10]

Şekil 2.31’de, K_i değerleri her kat için performansı ve K_{ort} ise genel performansı temsil etmektedir.

2.7. Performans Ölçütleri

Bu tez çalışmasında, önerilen sistemlerin performanslarını değerlendirmek için karışıklık matrisi kullanılmıştır. Test verilerinin ne ölçüde sınıflandırıldığına dair bilgileri içermektedir (Çizelge 2.6).

Çizelge 2.6. Karışıklık Matrisi

GERÇEK DEĞERLER	TAHMİN EDİLEN DEĞERLER		
	POZİTİF	POZİTİF	NEGATİF
	DP	YP	YN
	DN	YP	DN

Çizelge 2.6’da gösterilen satırlar test kümesindeki verilere ait gerçek sayıları, sütunlar ise modelin tahmin sayılarını temsil etmektedir. Buna ek olarak, DP doğru sınıflandırılmış pozitif örnekler, DN doğru sınıflandırılmış negatif örnekler, YP yanlış sınıflandırılmış pozitif örnekler ve YN ise yanlış sınıflandırılmış negatif örneklerdir.

Bu tez çalışmasında, karışıklık matrisi kullanılarak duyarlılık, özgüllük, kesinlik ve F1-skor gibi performans ölçütleri kullanılmıştır. Bu başarımlar ölçütleri ile ilgili matematiksel ifadeler aşağıda verilmiştir [10]:

$$\text{Doğruluk} = (DP + DN)/(DP + DN + YP + YN) \quad (2.66)$$

$$\text{Duyarlılık} = DP/(DP + YN) \quad (2.67)$$

$$\text{Özgüllük} = DN/(DN + YP) \quad (2.68)$$

$$\text{Kesinlik} = DP/(DP + YP) \quad (2.69)$$

$$\text{F1 - Skor} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (2.70)$$




3. BİTKİ TÜRLERİNİN SINIFLANDIRILMASI İÇİN LİTERATÜRDE KULLANILAN VERİ SETLERİ

Bu tez çalışması süresince önerilen yöntemleri test etmek için, bitki yaprak görüntülerinden oluşan ICL, Flavia, Folio, Foliage, Swedish ve LeafSnap veri setleri kullanılmıştır. Ayrıca doğal ortamlardan elde edilmiş Flower17 ve Flower102 veri setleri de bu tez kapsamında kullanılmıştır. Bu veri setleri ile ilgili detaylı bilgiler devam eden alt başlıklarda verilmiştir.

3.1. Flavia Yaprak Veri Seti

Flavia yaprak veri seti [11], her bir türden 50 ile 77 arası yaprak görüntüsü olmak üzere 32 bitki türünü içeren toplam 1907 renkli görüntülerden oluşmaktadır. Bu veri setindeki her bir görüntü; 1600×1200 çözünürlüklü ve arka plan beyaz görüntülerden oluşmaktadır. Deneysel çalışmalar gerçekleştirilirken bu veri setinin tüm görüntüleri kullanılmıştır. Şekil 3.1’de, Flavia yaprak veri setindeki bazı yaprak örnekleri gösterilmektedir.



Şekil 3.1. Flavia veri setindeki örnek görüntüleri

3.2. Swedish Yaprak Veri Seti

Swedish veri seti [12], her bir türden 75 yaprak görüntüsü olmak üzere 15 bitki türünü içeren toplam 1125 renkli görüntülerden oluşmaktadır. Bu yaprak görüntüleri değişik çözünürlükte ve arka zemini beyazdır. Deneysel çalışmalar gerçekleştirilirken bu veri setinin tüm görüntüleri kullanılmıştır. Şekil 3.2’de, Swedish yaprak veri setindeki bazı yaprak örneklerini gösterilmektedir.



Şekil 3.2. Swedish veri setindeki örnek görüntüler

3.3. ICL Yaprak Veri Seti

ICL veri seti [13], her bir türden 8 ile 16 arası yaprak örneği olmak üzere 40 bitki türünü içeren 443 renkli yaprak görüntülerinden oluşmaktadır. Bu veri setindeki her bir görüntü; 960×720 çözünürlüklü ve arka plan sabit renktir. Şekil 3.3’de, ICL yaprak veri setindeki bazı yaprak örnekleri gösterilmektedir.



Şekil 3.3. ICL veri setindeki örnek görüntüler

3.4. Foliage Yaprak Veri Seti

Foliage yaprak veri seti [14], her bir türden 120 yaprak görüntüsü olmak üzere 60 bitki türünü içeren toplam 7200 renkli yaprak görüntüsü bulunmaktadır. Bu veri setindeki her bir görüntü farklı çözünürlükte ve arka zemini beyazdır. Deneysel çalışmalar gerçekleştirilirken bu veri setinin tüm görüntüleri kullanılmıştır. Şekil 3.4’de, Foliage yaprak veri setindeki bazı yaprak örneklerini gösterilmektedir.



Şekil 3.4. Foliage veri setindeki örnek görüntüler

3.5. Folio Yaprak Veri Seti

Folio veri seti [15], her bir türden 20 yaprak görüntüsü olmak üzere 32 farklı bitki türünü içeren toplam 640 renkli yaprak görüntüsünden oluşmaktadır. Bu veri setindeki her bir görüntü; 2322×4128 çözünürlüklü ve arka zemini beyazdır. Şekil 3.5’de, Folio veri setindeki bazı yaprak örneklerini gösterilmektedir.



Şekil 3.5. Folio veri setindeki örnek görüntüler

3.6. LeafSnap Yaprak Veri Seti

Leafsnap veri kümesi (Şekil 3.6), Kuzeydoğu Amerika Birleşik Devletleri’nde elde edilen 185 ağaç türünü içermektedir [16]. Mobil cihazlar aracılığıyla elde edilen bu


veri kümesi 7719 görüntüden oluşmaktadır. Leafsnap veri kümesinde görüntüler netlik, aydınlatma düzeni, gürültü, bulanıklık ve gölgeler gibi önemli farklılıklar göstermektedir.



Şekil 3.6. LeafSnap veri setindeki örnek görüntüler

3.7. Flower17 ve Flower102 Veri Seti

Oxford Flower 17 ve 102 veri setleri, Nilsback ve Zisserman [17-19] tarafından doğal ortamlardan elde edilen iki çiçek veri kümesi oluşturdular. Oxford Flower17 veri kümesi (Şekil 3.7(a)), her biri 80 görüntü ile temsil edilen 17 çiçek türünden oluşmaktadır. Bu veri kümesi, benzersiz ve benzer görünlere sahip türleri içermektedir. Oxford Flower102 veri kümesi, Oxford Flower17 veri kümesinden daha büyüktür ve benzer çiçek türleri bulunmamaktadır. Oxford Flower102 veri kümesi (Şekil 3.7(b)), her bir sınıf 40 ile 258 görüntüden oluşan 102 çiçek türü içermektedir. Ayrıca her iki veri setindeki görüntüler ölçek ve aydınlatmada büyük farklılıklar göstermektedir.



Flower17 veri seti

Flower102 veri seti

Şekil 3.7. Flower17 ve Flower102 veri setindeki örnek görüntüler

4. BİTKİ HASTALIKLARIN TESPİTİ İÇİN VERİ TABANI OLUŞTURULMASI

Önerilen çalışma kapsamında Malatya ve Bingöl illerinde yaygın olarak görülen bitki hastalık görüntüleri fotoğraf makinesi ve İHA ile kaydedilmiştir. Meyve ağaçlarının üst dalları ve geniş ölçüde görüntü almak için DjiPhantom 4 Advanced İHA sistemi kullanılmıştır. Bu sistem geliştirmiş 4 k / 60fps video ve 13 fps'de seri çekim modu çekimi yapabilen 1 inç 20 megapiksel sensöre sahip dâhili bir kameraya sahiptir. Fotoğraf makinesi ise Nikon 7200d modeli olup, DX biçiminde 6 fps, 1.3x kesme modunda ise 7 fps hıza kadar çekim yapan ve 24.2 megapiksel çözünürlüğe sahiptir. Şekil 4.1'de kullanılan İHA sistemi ve fotoğraf makinesi görülmektedir.



Bitki hastalık görüntüleri almak için İnönü ve Bingöl Üniversitelerinin Ziraat Fakültelerinin deneysel çalışma yaptıkları alanlar kullanılmıştır. Ziraat Fakülteleri akademik çalışmalar yapmak için arazilerine farklı türlerde ve yaşlarda meyve ağaçları dikmişlerdir. Bu tez çalışmasında, Malatya ve Bingöl illerinde yaygın olarak görülen bitki hastalıkları incelenmiştir. Yapılan araştırmalar sonucunda bitki hastalık ve zararlılardan oluşan bir veri tabanı inşa edilmiştir. Bu veri seti hakkında detaylı bilgiler Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Bitki hastalık ve zararlı veri seti özellikleri


Etiket	Bitki türü	Görünen hastalık/zararlı	Latincesi	Görüntü Sayısı
1	Armut	Ateş Yanıklığı	Erwinia amylovora	215
2	Ceviz	Antraknozu	Gnomonia leptostyla	180
3	Ceviz	Gal Akarı	Eriophyes erineus	69
4	Kiraz	Yaprak Biti	Aphis spp.	356
5	Şeftali	Koşnil	Parthenolecanium corni	427
6	Şeftali	Monilya	Monillia laxa	314
7	Elma	Karaleke	Venturia inaequalis	633

Çizelge 4.1. (devamı)





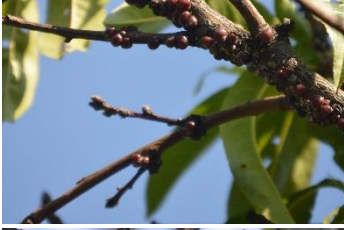

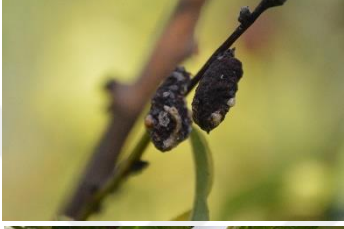














Etiket	Bitki türü	Görünen hastalık/zararlı	Latincesi	Görüntü Sayısı
8	Elma	Pamuklu Bit	Eriosoma lanigerum	366
9	Elma	Yaprak Biti	Aphis spp.	162
10	Elma	Monilya		255
11	Erik	Yaprak Biti	Aphis spp.	70
12	Kayısı	Çil	Coryneum beijerinckii	1100
13	Kayısı	Monilya	Monillia laxa	85
14	Meyve ağaçları	Kanser Belirtisi	-	76
15	Meyve ağaçları	Kuruma belirtisi	-	139

Çizelge 4.1'den anlaşılacağı üzere, bu tez çalışmasında elde ettiğimiz veri seti 15 sınıflı olmak üzere toplam 4400 hastalık ve zararlı görüntülerinden oluşmaktadır. Bu görüntülerin büyük bir kısmı normal fotoğraf makinesi kullanılarak elde edilirken diğer kısmı ise İHA kullanılarak çekilmiştir. İHA kullanılarak elde edilen görüntüler için kırılma işlemi uygulanmıştır. Çizelge 4.2'de, hastalıklı ve zararlı bitki türlerinin her biri için örnek görüntüler verilmiştir.



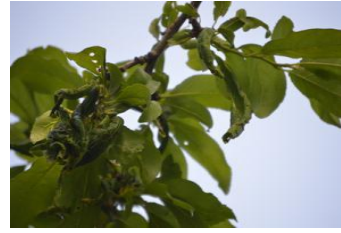











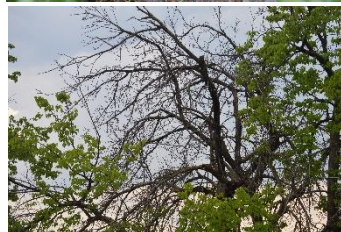
Çizelge 4.2. Bitki hastalık ve zararlı görüntüleri

Etiket	Hastalık ve zararlı tür örnek görüntüleri		
1			
2			
3			

Çizelge 4.2. (devamı)

Etiket	Hastalık ve zararlı tür örnek görüntüleri		
4			
5			
6			
7			
8			
9			
10			

Çizelge 4.2. (devamı)

Etiket	Hastalık ve zararlı tür örnek görüntüleri		
11			
12			
13			
14			
15			

Not: 1) Armut Ateş Yanıklığı, 2) Ceviz Antraknozu, 3) Ceviz Gal Akarı, 4) Kiraz Yaprak Biti, 5) Şeftali Koşnil, 6) Şeftali Monilya, 7) Elma Karaleke, 8) Elma Pamuklu Bit, 9) Elma Yaprak Biti, 10) Elma Monilya, 11) Erik Yaprak Biti, 12) Kayısı Çil, 13) Kayısı Monilya, 14) Kanser Belirtisi, 15) Kuruma Belirtisi.

Bu tez çalışmasında kullanılan bitki hastalık ve zararlı türleri hakkında detaylı bilgiler alt başlıklar halinde verilmiştir [217].

4.1. Zararlılar (Böcek)

Elma pamuklu bit: Zararlının üzerindeki beyaz pamuklar kendi salgıları olup, onları korumaya yarar. Bu pamuklu örtüden dolayı adı pamuklu bittir. Zararlı kışı ağaçların kabukları arasında, kök boğazı ve kalın köklerde ergin dişi veya çeşitli larva

dönemlerinde geçirirler. Bitki özsuğunu emerek beslenirler. Bu esnada bitkiye verdikleri toksik maddeler urların ve şişkinlerin meydana gelmesine ve ağaçlarda şekil bozukluklarına neden olur.

Elma yaprak biti: yumurtalarını sonbaharda elma ağaçlarının bir yıllık sürgünlerinin genellikle uca yakın kısımlarına bırakır. Bu yumurtalar ertesi yıl tomurcukların uyanmasıyla birlikte uyanmaya başlar. İlk koloniden itibaren görülen kanatlılar, öteki elma ağaçlarına uçarak bulaşmayı yaygınlaştırır. Yazın yüksek sıcaklıklarda, bitkideki gelişmenin yavaşlaması ve kısmende doğal düşmanların etkisiyle çoğalmaları yavaşlar veya durur. Bitki özsuğunu emerek beslenirler. Daha çok fidanlıklarda ve genç ağaçlarda zararlı olur. Yaprakları enine kıvrır. Yüksek yoğunluklarda sürgünler kurur. Yazın fumajin oluşmasına neden olur.

Kiraz yaprak biti: kirazlarda önemli zarar meydana getirirler. Kiraz siyah yaprakbitinin erginleri ve nimfleri, yapraklarda ve sürgünlerde özsuğunu emerek zarar yapar. Ayrıca salgıladıkları tatlımsı maddeler nedeniyle, fumajine neden olurlar. Erginler ve nimfler, yaprakların alt yüzeyinde koloniler oluşturarak beslenirler. Bunun sonucu yapraklar kıvrılıp, sürgünler gelişmez.

Kahverengi Koşnil: Ergin dişinin kabuğu yarım küre şeklindedir. Rengi başlangıçta koyu kahverengi olup üzerinde siyah ve sarı bantlar bulunur. Haziran başında yumurtadan çıkmaya başlayan hareketli larvalar ağaçların taze yapraklarına geçer ve özellikle yaprakların alt yüzlerine damarlar boyunca yerleşir. Kahverengi koşnilin larvaları yaprak, dal ve sürgünlerde, dişileri de dal ve sürgünlerde bitki özsuğunu emmek suretiyle zarar yaparlar. Salgıladıkları ballı maddeler üzerinde saprofit mantarların gelişmesi sonucu “karaballık” denilen zarara neden olurlar. Sürgün ve dallar gelişmez, yapraklar zamanından önce dökülür, sonunda ağaçlar zayıf kalır, meyve verimi ve kalitesi düşer.

Ceviz Gal Yaprak Akarı (Ceviz Yaprak Uyuzu): Ceviz yaprak gal akarı yaprak dokusu içerisinde yaşar. Bulunduğu yerde yaprağın her iki tarafında kabaran gal oluşturur. Kahverengileşir ve siyaha dönüşür. Yoğun bulaşmalarda meyvenin şekli bozulur ve olgunlaşmadan dökülür.

4.2. Hastalıklar

Farklı etmenlerin etkisiyle bitkilerin gövde, korteks ve kabuk dokularında oluşan sınırlı nekrozlara kanser adı verilmektedir. Nekrotik yaralar kallusla çevrili olmakta bu şekilde de etrafındaki sağlıklı dokulardan ayrılmaktadır. Bitki patojenlerinin yol açtığı kanserlerde, yaranın kapanmasını sağlayan kallus ve patojenin karşılıklı etkinlikleri sonucunda iç içe şişkinlikler şeklinde derin ve açık kanser yaraları oluşmaktadır.

Çok yıllık bitkilerde sürgün ve gövdede görülen geniş nekrozlar kuruma belirtileridir. Sürgün uçlarından başlayıp, gövdeye doğru ilerlerse buna geriye doğru ölüm denilmektedir. Bazı patojenler ve kuraklık gibi çevresel etkiler bu kuruma ve ölümleri oluşturabilir. Özellikle sert çekirdekli meyvelerde monilya hastalıkları bu belirtilere neden olmaktadır.

Monilya hastalıklarında etmen, genellikle meyve enfeksiyonları yapmaktadır. Fakat çiçek ve yaprak enfeksiyonlarına da sebep olabilmektedir. Hastalık etmeni olan fungus, meyveyi kuş, rüzgâr, böcek vb. Vasıtasıyla açılan yaralardan penetre edebilir veya meyvedeki doğal açıklıklardan doğrudan giriş yapabilmektedir. Enfeksiyonlar meyve olgunlaşmaya başladığında, meyve kabuğunda oluşan kahverengi lekelerle başlar. Enfeksiyondan başladıktan sonra bir kaç gün içinde çürüme meydana gelir. Meyve dokusu su kaybederek buruşur, hastalığın tipik belirtisi olarak mumyalaşır dalda asılı kalır.

Çil hastalığı sert çekirdekli meyve ağaçlarının yaprak, meyve, tomurcuk ve genç dalları üzerinde belirti oluşturmaktadır. Öncelikle genç yapraklar üzerinde 1 mm çapında oluşan kırmızı lekeler giderek büyümekte ve 5 ila 10 gün içerisinde dökülmektedir. Bu dökülmelerin ardından yaprakta saçma deliği şeklinde semptomlar oluşmaktadır. Meyvelerde ise genellikle meyvenin sapa yakın kısmında 1-2 mm çapında yuvarlak kırmızı lekeler oluşmaktadır. Bu lekeler giderek şişkinleşip, ortaları çökmekte ve daha koyu renge dönüşmektedir.

Sert çekirdekli meyve yetiştiriciliği yapılan alanlarda ağaçların çiçeklenme döneminde monilya, çiçeklenme sonrasında çil hastalıkları ile mücadele edilmeden yetiştiricilik yapmak mümkün olmamaktadır. Ağaç ölümlerine neden olan fungal hastalık etmenleri önemli boyutlarda ekonomik kayıplar oluşturmaktadır. Sert çekirdekli meyve yetiştiriciliği yapan üreticilerin sertifikalı fidan tercih etmeleri ve dayanıklı çeşit kullanmaları hastalıktan korunmada önemli rol oynamaktadır. Ayrıca üreticilerin kültürel

önlemler ve diğler mücadele yöntemlerine gerekli önemi vermesi fungal hastalıkların önlenmesine büyük katkı sağlamaktadır.

Ceviz Antraknozu Hastalığı: Ceviz Antraknozu etmeni *Gnomonia leptostyla* adlı fungustur, cevizlerde zarar yapan mantari bir hastalıktır. Gerekli önlemler alınmadığı ya da mücadele edilmediği takdirde ciddi verim kaybına neden olur. Hastalık ağaçların meyve, genç sürgün ve yaprak saplarında görülür. Hastalık özellikle yapraklarda görülmesine rağmen hasta meyvelerin yeşil meyve kabuğunda meyve içine de geçer. Hastalık belirtileri, genç yapraklar yarı büyüklüklerine geldiği zaman görülmeye başlar. Yani bu dönemde fungus enfeksiyon yapmaktadır. Fungusun giriş noktasının çevresinde gözle görülür şekilde renk açılmaları oluşmaktadır. Daha sonra bu renk açılmaları sarımsı bir hale ile çevrilerek, orta kısımlar açık kahverengiden, koyu kahverengine değişen 3-5 mm çapında nekrotik lekeler dönüşür bir yaprakçıkta ortalama olarak bu lekelerden beşer tane bulunur ve bu nekrotik lekeler zamanla birleşerek büyük lekeler halini alır. Kurak yerlerde ağaçlarda hastalıktan dolayı lekenin bulunduğu yaprak kenarlardan başlayarak kurur, erken yaprak dökümü başlar. Bazen sonbahar gelmeden ağaç tamamen yapraksız kalabilir. Meyvelerdeki belirtilerde tipik birer nekrozdur. İçeri çökük lekeler meyvenin kabuğunu kaplar, erken dönemde hastalığa yakalanan meyvelerde dökülmeler gerçekleşebilir. Ülkemizde yaygın görülen bir hastalıktır. Hastalık etmeni yere düşen enfekteli yapraklarda kışı geçirdiği için, hastalıklı yapraklar toplanıp imha edilmelidir.

5. BİTKİ TANIMA İLE İLGİLİ ÖNERİLEN YENİ YAKLAŞIMLAR

Bu bölümde, bitki türlerinin sınıflandırılması için şekil, renk, doku ve derin özelliklere dayalı önerilen yaklaşım ile deneysel sonuçlar yer almaktadır. Bitki türleri ile ilgili gerçekleştirilen çalışmalarda Bölüm 3’de bahsedilen veri setleri kullanılmıştır.

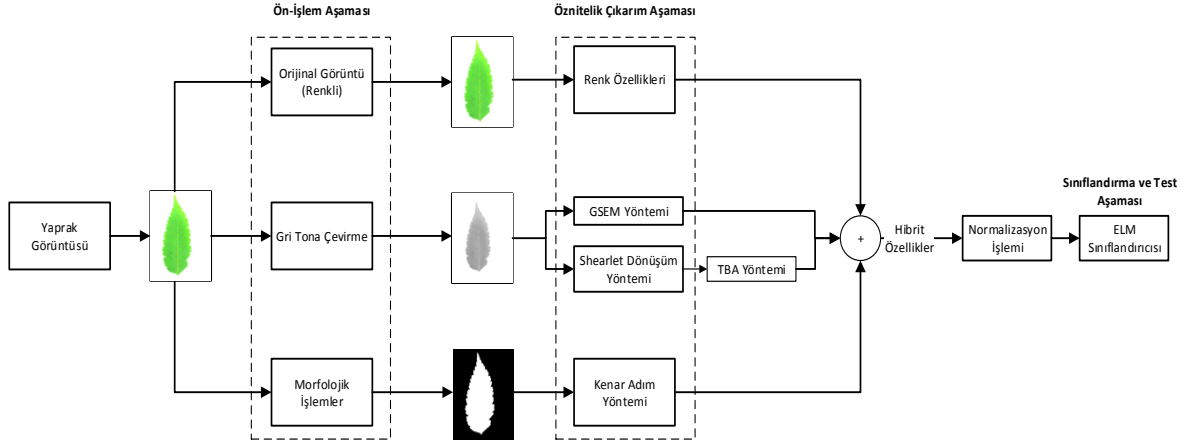
5.1. Shearlet Dönüşümü ve Yeni Geometrik Özellikler Kullanılarak Aşırı Öğrenme Makinesi Tabanlı Bitki Tanıma Sistemi

Bu bölümde, açıdan bağımsız olarak yaprağın geometrik özelliklerine dayalı yeni bir yaklaşım önerilmiştir. KA (Kenar Adım) olarak adlandırılan bu yaklaşım kullanılarak şeklin sınır eğrilerindeki kenar noktaları temel alınarak açı, merkez-kenar uzunluğu ve kenar mesafesi gibi özelliklere sahip parametreler elde edilir. Bu önerilen şekil tabanlı yöntem ek olarak, yaprak görüntülerinden ayırt edici renk ve doku özelliklerini elde edebilmek için Renk Özellikleri ile GSEM ve Shearlet Dönüşümü yöntemleri kullanılmıştır. AÖM sınıflandırıcısı kullanılarak, tüm bu yöntemlerden elde edilen parametrelerin bireysel ve bileşik performansları hesaplanmıştır.

Önerilen hibrit sistemi test etmek için Flavia, Swedish, ICL ve Foliage gibi dört farklı bitki yaprak veri seti kullanılmıştır. Geliştirilen modelin başarımını hesaplamak için kapsamlı deneysel çalışmalar gerçekleştirilmiş ve literatürde yer alan en son çalışmalar ile performansları kıyaslanmıştır.

5.1.1. Önerilen Sistem

Bu bölümde, geliştirilen görüntü tabanlı yaprak tanımlama sisteminin çalışma prensibi verilmiştir. Bu işlemler sırasıyla ön-işlem, öznelik çıkarımı ve sınıflandırma aşamalarını içermektedir. Önerilen hibrit sistemin genel işlem adımları Şekil 5.1’de gösterilmiştir.




Şekil 5.1. Önerilen Sistemin Genel Akış Şeması

5.1.1.1. Ön-İşlem Aşaması

Bu bölümde, görüntü işleme teknikleri kullanılarak yaprak görüntülerini bölütleme ve belirginleştirme işlemleri için bir sistem önerilmiştir. Geliştirilen bu yaklaşım için kullanılan görüntü işleme teknikleri sırasıyla aşağıda verilmiştir:

- Renkli yaprak görüntüleri gri tona dönüştürülür.
- Normalizasyon işlemi kullanılarak net ve belirgin bir görüntü elde edilir.
- Bölütleme işlemi için bir eşikleme değeri (ampirik yoluyla) seçilir.
- Son olarak, görüntüdeki boşlukları doldurma, gürültüleri temizleme ve görüntüyü belirginleştirmek için sırasıyla aşınma, dolum ve mantıksal işlemler kullanılır.

Yaprak görüntülerini bölütlemek için yukarıda verilen işlem adımları kullanılarak Şekil 5.2' de temsili bir örnek gösterilmiştir.



Şekil 5.2. Bölütleme işlem adımları

Önerilen bölütleme sisteminin matematiksel ifadelerle dayalı işlem adımları şunlardır:

Adım 1: Görüntü yükle (imge).

Adım 2: Renkli görüntüyü gri tona dönüştür.

$$R = \text{imge}(:, :, 1) \quad (5.1)$$

$$G = \text{imge}(:, :, 2) \quad (5.2)$$

$$B = \text{imge}(:, :, 3) \quad (5.3)$$

$$g = R \times 0.2989 + G \times 0.5870 + B \times 0.1140 \quad (5.4)$$

Denklem (5.1-4)'de R, G ve B değişkenleri sırasıyla kırmızı, yeşil ve mavi renk katmanlarıdır.

Adım 3: Gri görüntüyü 0-1 aralığında normalize et.

$$g^N = \frac{g - \min(g)}{\max(g) - \min(g)} \quad (5.5)$$

Denklem 5.5'de, g^N normalize edilmiş gri görüntüyü, $\min(g)$ ve $\max(g)$ gri görüntünün en küçük ve en büyük değerlerini temsil etmektedir.

Adım 4: Görüntü histogramını kullanarak eşik değerini (t) belirle. (Deneysel yaklaşımla; Flavia, ICL, Swedish ve Foliage veri setleri için sırasıyla 210, 130, 160 ve 185 eşik değerleri belirlenmiştir.)

Adım 5: t değeri kullanarak normalize edilmiş gri görüntüyü siyah beyaz forma dönüştür.

$$sb_{i,j} = \begin{cases} 0, & g_{i,j}^N < t \\ 1, & g_{i,j}^N \geq t \end{cases}, i = \{1, 2, \dots, M\}, j = \{1, 2, \dots, N\} \quad (5.6)$$

Denklem 5.6'da, sb siyah beyaz imgeyi, M ve N gri imgenin genişliğini ve uzunluğunu, i ve j değerleri ise indisleri temsil etmektedir.

Adım 6: 3 x 3 pencere boyutunda çakışan bloklar kullanılarak dolum, aşınma ve mantıksal işlemlerini uygula.

$$sb = ((sb \oplus k) \ominus k) \odot k \quad (5.7)$$

Denklem 5.7'de, dolum, aşınma ve mantıksal operatörler sırasıyla \oplus , \ominus ve \odot olarak ifade edilmektedir. k ise 3 x 3 pencere boyutundaki blokları temsil etmektedir.

5.1.1.2. Kenar Adım Yöntemi


KA yöntemi, MKU yönteminden ilham alınarak geliştirilmiştir. MKU yöntemi, nesnenin ağırlık merkezinin sınır eğrilerine olan uzaklığıdır. KA yöntemi ise şeklin sınır eğrilerindeki kenar noktaları temel alınarak açığı, merkez-kenar uzunluğu ve kenar mesafe

gibi deęişkenlere dayalıdır. Açıdan bağımsız olarak geliştirilen KA yöntemi, şeklin sınır eğrisindeki piksel uzunlukları dikkate alınarak özellik çıkarımı gerçekleştirilir.

KA yönteminde öncelikle, adım deęeri olarak x deęişkeni temel alınarak nesnenin sınır eğrileri arasında eşit piksel uzunluklarındaki kenar noktaları belirlenir (Denklem (5.8)).

$$n = \frac{P}{x}, \quad K = k_1, k_2, k_3, \dots, k_n \quad (5.8)$$

Burada P şeklin çevresi, n toplam kenar sayısı ve K ise kenar noktalarını temsil etmektedir. $k_1, k_2, k_3, \dots, k_n$ gibi ardışık kenar noktaları arasındaki mesafeler eşit piksel uzunluğuna sahiptir. Şekil 5.3’de örnek bir yaprak için KA yönteminin çalışma prensibi verilmiştir.



Şekil 5.3. Örnek bir yaprak için KA yaklaşımı

Şekil 5.3’de belirtilen $k_1, k_2, k_3, \dots, k_n$ kenar noktaları tespit edildikten sonra istatistiksel formüllere dayalı üç farklı deęişken (açı, merkez-kenar uzunluğu ve kenar mesafe) kullanılarak nesneye ait şekil tabanlı özellikler elde edilir. Bu istatistiksel parametreler Çizelge 5.1’de verilmiştir.

- Açı (α): Şeklin ağırlık merkezi ile $k_1 - k_2, k_2 - k_3, \dots, k_n - k_1$ gibi kenar noktaları arasındaki açı deęerleri $\alpha_1, \alpha_2, \dots, \alpha_n$ olarak hesaplanır (Şekil 5.3(a)). Bu deęerden; ortalama, standart sapma, varyans, basıklık, çarpıklık ve en büyük deęerin en küçük deęere oranı (mm) gibi istatistiksel formüller kullanılarak 6 öznitelik elde edilir.
- Merkez-Kenar Uzunluğu (d): Şeklin ağırlık merkezi ile $k_1, k_2, k_3, \dots, k_n$ gibi kenar noktaları arasındaki uzaklıklar Öklid formülü kullanılarak $d_1, d_2, d_3, \dots, d_n$ hesaplanır (Şekil 5.3(b)). Bu deęerden; ortalama, standart sapma, varyans, basıklık, çarpıklık ve en büyük deęerin en küçük deęere oranı gibi istatistiksel formüller kullanılarak 6 öznitelik elde edilir.

- Kenar mesafesi (p): $k_1 - k_2, k_2 - k_3, \dots, k_n - k_1$ gibi kenar noktaları arasındaki uzaklıklar Öklid formülü kullanılarak $p_1, p_2, p_3, \dots, p_n$ hesaplanır (Şekil 5.3(c)). Bu değerden; ortalama, standart sapma ve ortalama kenar mesafesi (k) gibi istatistiksel formüller kullanılarak 3 öznitelik elde edilir.

Çizelge 5.1. İstatistiksel Denklemler

Ortalama:	$\mu = \frac{1}{N} \sum_{i=1}^N A_i$
Standart Sapma:	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N A_i - \mu ^2}$
Varyans:	$\sigma^2 = \frac{1}{N} \sum_{i=1}^N A_i - \mu ^2 = \sigma^2$
Basıklık:	$\gamma = \frac{\sum_{i=1}^N (A_i - \mu)^4}{N\sigma^4} - 3$
Çarpıklık:	$\theta = \frac{\sum_{i=1}^N (A_i - \mu)^3}{N\sigma^3}$
En Büyük Değerin En Küçük Değere Oranı:	$mm = \text{Max}(A)/\text{Min}(A)$
Ortalama Kenar Mesafesi:	$m = \left(\sum_{i=1}^N A_i \right) / P$

Çizelge 5.1’de, A, açı ($\alpha_1, \alpha_2, \dots, \alpha_n$), merkez-kenar uzunluğu ($d_1, d_2, d_3, \dots, d_n$) veya kenar mesafesi ($p_1, p_2, p_3, \dots, p_n$) değerlerini içeren diziyi, N dizinin boyutunu, P şeklin çevresini ve i ise satır değerlerini temsil etmektedir. En Büyük Değerin En Küçük Değere Oranı (mm); açı, merkez-kenar uzunluğu veya kenar mesafesi değişkenlerinden elde edilen $1 \times N$ boyutundaki dizinin maksimum ve minimum değerlerinin birbirlerine oranıdır. Ortalama Kenar Mesafesi (m) ise sadece kenar mesafelerinin ($p_1, p_2, p_3, \dots, p_n$) her birinin şeklin çevresine oranlarının toplamıdır.

5.1.2. Deneysel Sonuçlar

Bu bölümde, bitki türlerinin sınıflandırılması için şekil, renk ve doku tabanlı hibrit bir sistem geliştirilmiştir. Bitki yaprağının sınır eğrileri ve geometrik şekilleri arasındaki farklılıkları ortaya çıkarmak için şekil tabanlı yeni bir yaklaşım önerilmiştir. KA olarak adlandırılan bu yaklaşım; açı, merkez-kenar uzunluğu ve kenar mesafe özelliklerine dayalı değişkenlerden oluşmaktadır. Bununla birlikte, doku tanımda iyi hassasiyet göstermesi, hızlı hesaplama yapması ve yön bağımsızlığı gibi özelliklere sahip olan Shearlet Dönüşüm yöntemi kullanılmıştır. Bu yöntemden elde edilen yüksek boyuttaki öznitelik vektörleri için boyut azaltılması, ayırt edici özelliklerin seçilmesi ve başarımlar


oranının yükseltilmesi amacıyla TBA yöntemi kullanılmıştır. Bu yöntemlere ek olarak, bitki yaprak görüntülerinden renk ve doku özelliklerinin çıkartılması için renk özellikleri ile GSEM yöntemi kullanılmıştır. Son olarak, tüm özellik çıkarım yöntemleri için AÖM yöntemi kullanılarak bireysel ve genel sınıflandırma performansları hesaplanmıştır ve bu deneysel çalışmalarda doğruluğu test etmek için 10-kat çapraz doğrulama yöntemi kullanılmıştır.

Önerilen hibrit sistemi test etmek için literatürde yaygın olarak kullanılan 4 veri seti üzerinde kapsamlı deneysel çalışmalar yapılmıştır. Bu çalışmalar yapılırken, Flavia, ICL, Swedish ve Foliage veri setlerindeki yaprak görüntülerinin boyutları sırasıyla 600×800 , 960×720 , 896×512 ve 250×200 olarak ayarlanmıştır.

Deneysel çalışmalardan elde edilen sonuçlar ve önceki çalışmalar ile performans karşılaştırmaları alt başlıklarda verilmiştir.

5.1.2.1. Benzetim Sonuçları

Bitki türlerinin sınıflandırılması için önerilen şekil tabanlı KA yönteminin performansı, adım sayısı ardışık olarak 1 ile 500 arasındaki değerler kullanılarak hesaplanmıştır. Gerçekleştirilen deneysel çalışmalarda, adım sayısı 100'den sonra önerilen yöntemin performansında büyük bir düşüş olduğu gözlenmiştir. Şekil 5.4'de, ICL, Flavia, Foliage ve Swedish veri setleri için 3, 5, 7, 10, 12, 15, 18, 20, 25, 30, 36, 40, 45, 50, 60, 80 ve 100 gibi rastgele seçilen 20 farklı adım değerleri kullanılarak her bir adımın doğruluk skoru verilmiştir.



Şekil 5.4. KA yönteminin performans sonuçları

Şekil 5.4’de her bir veri seti için verilen KA yönteminin en yüksek doğruluk skorları şunlardır:

- Flavia veri seti için 45 adım aralığında %90.31,
- ICL veri setinde 15 adım aralığında %76.28,
- Swedish veri setinde 25 adım aralığında %94.55,
- Foliage veri setinde 10 adım aralığında %81.04 olarak en yüksek başarımları tespit edilmiştir.

Buna ek olarak, Şekil 5.4’de gösterilen bilgiler Çizelge 5.2’de sayısal olarak verilmiştir.

Çizelge 5.2. KA yönteminin farklı adımlara karşı doğruluk skorları (%)


	Adım Değerleri													
	3	5	7	10	12	15	20	25	30	36	40	45	50	60
Flavia	85.47	86.73	88.52	89.21	88.78	89.15	89.57	89.63	89.57	89.52	89.47	90.31	90.05	90.15
ICL	73.42	72.00	73.14	74.28	74.00	76.28	73.42	73.71	74.57	74.57	73.42	72.57	72.57	71.14
Swedish	90.71	90.44	93.21	93.75	93.48	93.03	94.19	94.55	92.94	93.75	93.30	92.50	92.94	92.50
Foliage	78.05	78.81	79.84	81.04	80.11	80.08	79.94	78.90	78.47	77.20	77.13	76.75	75.00	73.75

Daha sonra öznelik çıkarım yöntemlerinden bir diğeri olan Shearlet Dönüşüm yöntemi uygulanmıştır. Bu yöntem kullanılarak ICL, Swedish ve Foliage veri setleri için 122 öznelik elde edilirken, Flavia veri seti için ise 250 öznelik elde edilmiştir. Bu yöntem kullanılarak her bir veri seti için doğruluk skorları Çizelge 5.3’de verilmiştir.

Çizelge 5.3. Shearlet dönüşüm yöntemine dayalı doğruluk skorları (%)

Flavia	ICL	Swedish	Foliage
59.47	34.57	75	30.38

Shearlet Dönüşüm yönteminden elde edilen öznelikler kullanılarak TBA yöntemi uygulanmıştır. Bu yöntemin kullanılmasının sebebi, yüksek sayıdaki öznelik kümesi içinden ayırt etme gücü yüksek öznelikler seçilerek öznelik sayısının azaltılması ve başarımlarının yükseltilmesi amaçlanmıştır. Bu çalışmada, Shearlet Dönüşüm yönteminden elde edilen parametreler TBA yöntemi kullanılarak 10, 15, 20, 25, 30, 35, 40, 45, 50, 60, 70, 80, 90 ve 100 gibi öznelik sayılarına indirildikten sonra doğruluk skorları hesaplanmış ve Şekil 5.5’de verilmiştir.



Şekil 5.5. Shearlet Dönüşüm - TBA yönteminin Doğruluk skorları

Şekil 5.5’de gösterildiği gibi, Shearlet Dönüşüm - TBA yönteminin kullanılmasına dayalı elde edilen sonuçlara göre:

- Flavia veri seti için öznitelik sayısı 45 sayısına düşürüldüğünde, %84.63 olarak en yüksek başarımlar elde edilmiştir. TBA yöntemi uygulanmaksızın Shearlet Dönüşüm yöntemi tek başına kullanılarak %59.47 olarak başarımlar hesaplanmıştır. (Çizelge 5.3). Bu sonuçlara göre TBA yöntemi kullanılarak %25.16 performans artışı sağlanmıştır.
- ICL veri seti için öznitelik sayısı 20 sayısına düşürüldüğünde, %56.28 olarak en yüksek doğruluk skoru elde edilmiş ve %21.71 performans artışı sağlanmıştır.
- Swedish veri seti için öznitelik sayısı 35 sayısına düşürüldüğünde %90.98 olarak en yüksek başarımlar elde edilmiş ve %15.98 artış sağlanmıştır.
- Foliage veri seti için öznitelik sayısı 35 sayısına düşürüldüğünde %58.93 olarak en yüksek başarımlar elde edilmiş ve %28.55 artış sağlanmıştır.

Bu sonuçlara göre, Shearlet Dönüşüm yönteminden elde edilen yüksek sayıda özniteliklerden daha az sayıda ve daha anlamlı öznitelikler elde edilerek daha yüksek performans elde edildiği gözlenmiştir.

Bu çalışmada, Kenar Adım ve Shearlet Dönüşüm yöntemlerine ek olarak, yaprak görüntülerinden doku ve renk özelliklerini çıkarmak için GSEM yöntemi ve Renk özellikleri kullanılmıştır. Bu çalışmada kullanılan tüm özellik çıkarım yöntemlerinin bireysel ve hibrit olarak performans sonuçları ve öznitelik sayıları Çizelge 5.4’de verilmiştir.

Çizelge 5.4. Önerilen çalışmanın doğruluk skorları ve öznitelik sayıları

Yöntemler	Flavia		ICL		Swedish		Foliage	
	Doğruluk	Öznitelik Sayısı	Doğruluk	Öznitelik Sayısı	Doğruluk	Öznitelik Sayısı	Doğruluk	Öznitelik Sayısı
KA Yöntemi	90.31	15	76.28	15	94.55	15	81.04	15
Shearlet Dönüşüm-TBA	84.63	45	56.28	20	90.98	35	58.93	35
GSEM	63.21	5	37.71	5	75.98	5	53.51	5
Renk Özellikleri	85.31	12	68.28	12	84.91	12	82.88	12
Hibrit Özellikler	98.31	42	93.71	42	99.46	57	96.62	42

Çizelge 5.4’de anlaşılacağı üzere, önerilen hibrit sistem kullanılarak Flavia, ICL, Swedish ve Foliage veri setleri için sırasıyla %98.31, %93.71, %99.46 ve %96.62 doğruluk skorları elde edilmiştir. Bunun yanı sıra, Flavia, ICL ve Foliage veri setleri için Shearlet Dönüşüm ile TBA yöntemleri kullanılarak tek başına (bireysel) en yüksek performansı sırasıyla 45, 20 ve 35 öznitelikte elde edilirken, diğer öznitelik çıkarım yöntemleri ile beraber (hibrit) kullanılarak en yüksek performans 10 öznitelikte elde edilmiştir. Swedish veri setinde ise Shearlet Dönüşüm ile TBA yöntemleri kullanılarak bireysel olarak en yüksek performans 35 öznitelikte elde edilirken, hibrit olarak kullanıldığında en yüksek performans 25 öznitelikte elde edilmiştir.

Önerilen hibrit sistemin çalışma zamanı tüm aşamalarıyla birlikte Çizelge 5.5’de verilmiştir ve bu süreler bir imge için hesaplanmıştır. Bununla birlikte, kullanılan veri setlerindeki imgelerin boyutları farklı olduğu için her birinin çalışma süreleri verilmiştir.

Çizelge 5.5. Önerilen sistemin gerçekleştirme süresi (saniye)

	Flavia	ICL	Swedish	Foliage
Ön-İşlem	0.1256	0.0773	0.0763	0.0217
KA	0.0755	0.0976	0.0718	0.0178
Shearlet + TBA	2.4669	2.1916	2.1978	0.2523
GSEM	0.0586	0.7996	0.0552	0.0051
Renk Özellikleri	0.1485	0.1105	0.1057	0.0153
Özellik birleştirme	0.0001	0.0001	0.0001	0.0001
Toplam	2.9099	2.5314	2.5123	0.3183

5.1.2.2. Önerilen KA yöntemi ile MKU yönteminin karşılaştırılması

Bu çalışmada önerilen KA yöntemi, MKU yönteminin geliştirilmiş versiyonu olarak benimsenmiştir. Bitki yaprak görüntüleri için, MKU yönteminde açığa bağımlı olarak özellikler elde edilirken, KA yönteminde ise açıdan bağımsız olarak şeklin sınır eğrilerindeki kenar noktalarına dayalı özellikler elde edilir. MKU ve KA yöntemlerinin bireysel performansları ile Shearlet Dönüşümü, Renk Özellikleri ve GSEM yöntemi ile beraber kullanılarak hibrit performansları ve öznitelik sayıları Çizelge 5.6’da verilmiştir.

Çizelge 5.6. MKU-KA yöntemleri ile hibrit sistemin doğruluk skorlarının (%) ve öznitelik sayılarının karşılaştırılması

YÖNTEMLER	Flavia		Swedish		ICL		Foliage	
	Doğruluk	Öznitelik Sayısı	Doğruluk	Öznitelik Sayısı	Doğruluk	Öznitelik Sayısı	Doğruluk	Öznitelik Sayısı
MKU yöntemi	82.31	20	78.92	36	64.00	30	71.18	20
KA yöntemi	90.31	15	94.55	15	76.28	15	81.04	15
MKU + Shearlet Dönüşüm + GSEM + Renk Özellikleri	97.57	47	98.12	68	87.42	57	94.51	47
KA + Shearlet Dönüşüm + GSEM + Renk Özellikleri	98.31	42	99.46	57	93.71	42	96.62	42

Çizelge 5.6'dan anlaşılacağı üzere, KA yöntemi kullanılarak MKU yöntemine göre, Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla yaklaşık olarak %8, %16, %12 ve %10'luk performans artışı elde edilmiştir. Elde edilen performans sonuçlarına göre, KA yöntemi MKU yöntemine göre, dört farklı veri seti için de bireysel ve hibrit olarak en yüksek başarı oranına sahip olduğu gözlenmiştir.

KA yöntemi kullanılarak her bir veri seti için 15 adet öznitelik elde edilirken, MKU yöntemi kullanılarak ise Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla 20, 36, 30 ve 20 adet öznitelik elde edilmiştir. Bu bağlamda, KA yöntemi bir görüntüye ait daha az sayıda öznitelik elde etmekle beraber MKU yönteminden daha yüksek performansa sahip olduğu kanıtlanmıştır.

5.1.2.3. Önerilen KA yöntemi ile diğer şekil tabanlı yöntemlerin karşılaştırılması

Önerilen Kenar Adım (KA) yöntemi, literatürde yapılan çalışmalarda geliştirilen şekil tabanlı yöntemler ile doğruluk skorları karşılaştırılmış ve Çizelge 5.7'de verilmiştir.

Çizelge 5.7. KA yöntemi ile diğer yöntemlerin doğruluk skorlarının (%) karşılaştırılması

YÖNTEMLER	Flavia	Swedish	ICL	Foliage
Alan	22.10	21.52	11.71	9.81
Çevre	4.05	6.25	4.57	2.05
Dış merkezlilik	30.78	32.41	20.57	10.82
En-Boy Oranı	28.53	31.87	20.28	10.86
Dairesellik	22.05	21.87	10.85	9.82
Dışbükey alan	22.36	27.50	9.14	9.14
Dikdörtgenlik	14.58	31.34	11.14	13.62
Eşdeğer çap	22.05	21.43	10.85	9.64
Dar Faktör	30.74	32.23	22.57	11.84
Çevre / (Uzunluk-Genişlik)	15.63	26.70	6.28	7.76
Çevre / Uzunluk	18.47	31.52	8.57	8.87
Hu değişmez momentler	57.21	53.05	31.42	33.16
Fourier Tanımlayıcıları	85.57	92.5	73.42	62.51
Önerilen KA yöntemi	90.31	94.55	76.28	81.04

Çizelge 5.7’de, dört farklı veri seti için şekil tabanlı geliştirilmiş yöntemleri kullanılarak hesaplanılan doğruluk skorları verilmiştir. Bu sonuçlara göre, KA yöntemi diğer şekil tabanlı yöntemlere göre daha yüksek performans sağlamıştır. Buna ek olarak, fourier tanımlayıcıları diğer şekil tabanlı yöntemlerden daha başarılı olduğu tespit edilmiştir.

5.1.2.4. Önerilen hibrit sistem ile mevcut yöntemlerin performanslarının karşılaştırılması

Flavia, ICL, Swedish ve Foliage veri setleri kullanılarak literatürde yapılan önceki çalışmalar ile önerilen hibrit sistemin performansları karşılaştırılmış ve Çizelge 5.8’de verilmiştir. Şekil, renk ve doku özelliklerine dayalı çalışmalar referans alınmıştır. Önerilen hibrit sistem, Renk özellikleri ile GSEM, Kenar Adım ve Shearlet Dönüşüm yöntemlerinden elde edilen öznelilik vektörlerinin birleştirilmesine dayalıdır.

Çizelge 5.8. Önerilen sistemin mevcut yöntemler ile doğruluk skorlarının (%) karşılaştırılması

	VERİ SETLERİ			
	Flavia	ICL	Swedish	Foliage
Önceki çalışmalar	82.05 [21]		96.31 [218]	
	92.37 [45]		96.53 [219]	
	94.50 [39]		97.33 [46]	90.80 [38]
	94.62 [24]	87.00 [13]	98.13 [27]	93.08 [14]
	94.68 [14]	92.00 [37]	98.40 [220]	93.33 [23]
	95.00 [28]	92.65 [26]	99.18 [45]	95.75 [28]
	97.18 [27]		99.25 [29]	
	97.19 [22]		99.38 [44]	
	97.55 [25]			
Önerilen hibrit sistem	98.31	93.71	99.46	96.62

Çizelge 5.8’de, literatürde dört veri seti için aynı sayıda tür ve yaprak resimleri kullanılarak yapılan çalışmalar ile önerilen hibrit sistemin doğruluk skorları karşılaştırılmıştır. Önerilen hibrit sistem kullanılarak Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla %98.31, %99.46, %93.71 ve %96.62 olarak en yüksek doğruluk skorları elde edilmiştir. Gerçekleştirilen çalışmada, sınıflandırma performansının önceki çalışmalardan daha yüksek olması, bitki yapraklarının ayırt edici özelliklerini daha iyi yansıtması için şekil, doku ve renk özelliklerini kullanarak aynı türe ait farklı yapraklar arasındaki benzerliğin artışı ile sağlanmıştır.

Bitki türlerinin sınıflandırılması için önerilen KA yöntemi ve geliştirilen hibrit sistemin literatüre katkıları ve avantajları şunlardır;

- Önerilen KA yöntemi MKU yönteminin geliştirilmiştir bir versiyonudur. MKU yönteminde parametre olarak girilen açıya bağlı olan merkez kenar uzunluğu özellik olarak kullanılırken, KA yönteminde ise adımlar parametre olarak girilmektedir. Adım parametresi kullanılarak açı, merkez kenar uzunluğu ve kenar mesafe uzunlukları hesaplanır. Bu değerlere istatistiksel yöntemler uygulanarak 15 özellik elde edilir. Yapılan deneysel çalışmalar sonucunda, KA yönteminin MKU yönteminden daha başarılı olduğu gözlenmiştir. Şekil tabanlı önerilen KA yöntemi, bitki sınıflandırılması için yeni, basit ve efektif bir yaklaşımdır. Buna ek olarak, önerilen KA yönteminin uygulanması basittir ve karmaşık bir matematik altyapısı yoktur.
- Yaprakların değişmez dokusal özelliklerini çıkarmak için Shearlet dönüşümü tabanlı bir özellik çıkarma yöntemi kullanılmıştır. Bu yöntem ek olarak, bitki sınıflandırılmasında önemli bir ayırt edici etken olan yaprak damar dokuları arasındaki farklılıkları ortaya çıkarabilmek için pikseller arasındaki değişimleri hesaplayan GSEM yöntemi ve renk özellikleri kullanılmıştır. KA özellikleri ve bu yöntemlerden elde edilen özellikler birleştirilerek yapraklar için derin bir özellik çıkarma sistemi geliştirilmiştir.
- Elde edilen özelliklerin sınıflandırılması için AÖM yöntemi seçilmiştir. Bu sınıflandırma yönteminin en önemli avantajı eğitim süresinin hızlı olması ve büyük veriler için uygun ve düşük maliyetli bir sınıflandırıcı olmasıdır.
- Bu çalışmada literatürde yaygın olarak kullanılan 4 veri seti kullanılmıştır. Önerilen yöntem, literatürde daha önceden yapılan çalışmalarla karşılaştırılmış ve en iyi doğruluk skoru elde etmiştir.
- Sonuç olarak, bu çalışmada bitki türlerini sınıflandırmak için yüksek performansa sahip, basit ve etkili bir sistem önerilmiştir.

5.2. Bitki türlerinin sınıflandırılması için bölme yaklaşımına dayalı hibrit bir sistem

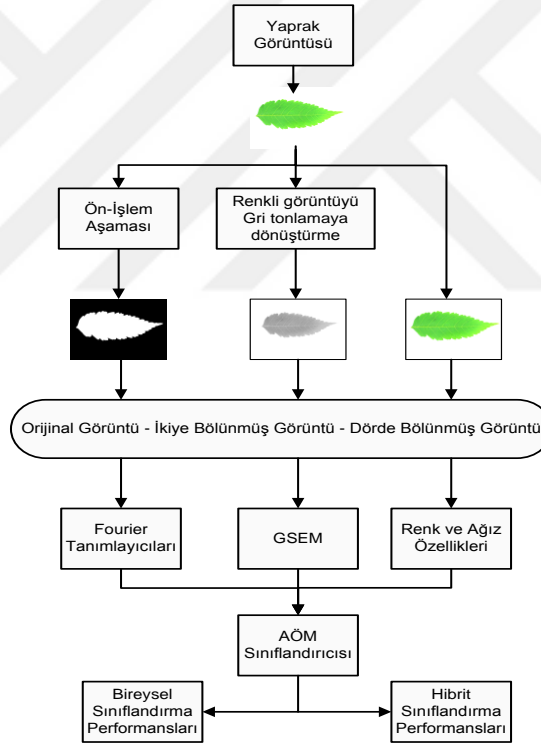
Bu bölümde, tüm bir yaprak görüntüsünden özellik çıkarmak yerine döndürme ve bölme yöntemlerine dayalı yaklaşımlar kullanılarak özellik çıkarma işlemi önerilmiştir. Bu yaklaşımda, yaprak görüntüsünün ağırlık merkezi dikkate alınarak ikiye ve dörde bölme işlemleri gerçekleştirilmiştir. Daha sonra, elde edilen her bir parça için öznelik

çıkarma yöntemleri aracılığıyla özellikler elde edilmiştir. Bu özellikler, tüm bir görüntüdeki nesneyi temsil etmek için birleştirilmiştir.

Bu çalışmada, özellik çıkarma yöntemlerinden; renk özellikleri, Fourier tanımlayıcıları, GSEM yöntemi ve Damar özneliklerine dayalı kombine bir hibrit sistem geliştirilmiştir. Son olarak, her bir özellik çıkarma yöntemlerinin bireysel ve bileşik olarak performansları AÖM sınıflandırıcısı kullanılarak test edilmiştir. Önerilen hibrit sistemi test etmek için Flavia yaprak veri seti kullanılmıştır. Geliştirilen modelin başarımını hesaplamak için kapsamlı deneysel çalışmalar gerçekleştirilmiş ve literatürde yer alan en son çalışmalar ile kıyaslanmıştır.

5.2.1. Önerilen Hibrit Sistem

Önerilen sistemin blok gösterimi Şekil 5.6'da verilmiştir.



Şekil 5.6. Önerilen sistemin akış şeması

Bu çalışma; ön-işlem, özellik çıkarması ve sınıflandırma aşaması olmak üzere 3 ana işlem adımından oluşmaktadır. Ön-işlem aşamasında, renkli görüntülerdeki yaprak nesnesi arka plandan ayırt edilmiştir. Daha sonra, önerilen döndürme ve bölme yaklaşımları kullanılarak GSEM, Fourier tanımlayıcıları, Damar öznelikleri ve Renk özellikleri gibi özellik çıkarma yöntemleri uygulanmıştır. Son olarak, geliştirilen hibrit sistemin performansını test etmek için AÖM sınıflandırıcısı kullanılmıştır.

Önerilen ön-işlem aşaması ve döndürme ile bölme yöntemi aşağıdaki bölümlerde detaylandırılmıştır.

5.2.1.1. Önerilen Ön-işlem sistemi

Bu aşamada, görüntü işleme yöntemleri kullanılarak renkli görüntülerdeki yaprak nesnesini arka plandan ayırma ve belirginleştirme işlemlerini kapsayan bir sistem önerilmiştir. Bu yaklaşım kullanılarak bölütleme işlemi için genel işlem adımları şunlardır:

- Gri tona çevirme,
- Eşikleme,
- Görüntüyü iyileştirmek ve belirginleştirme.

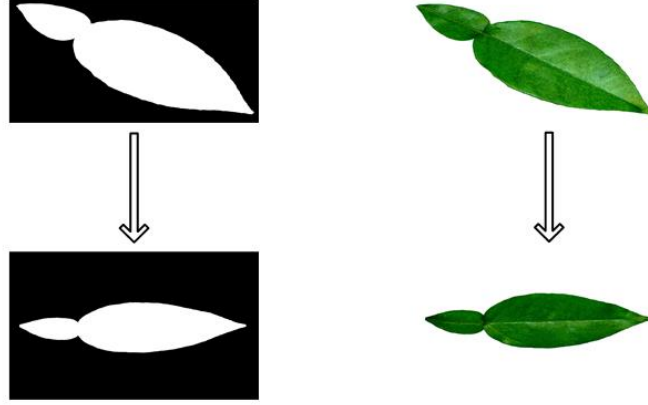
Yaprak nesnesinin arka plandan ayırmak için önerilen algoritma Çizelge 5.9'da ayrıntılı olarak verilmiştir.

Çizelge 5.9. Önerilen bölütleme işlemi

1: Resmi dosyadan oku.	
2: Renkli görüntüyü gri tona dönüştür	
3: Görüntüyü çift hassasiyete (double) dönüştür	
4: $imge = imge - \frac{\min(\min(imge))}{\max(\max(imge))}$ % Normalizasyon işlemi	
5: 8-bit işaretli tam sayıya dönüştür	
6: Elde edilen imge $< T$ % T en iyi eşik değeri	
7: Görüntüdeki boşlukları doldur	
8: Görüntüye aşınma işlemi uygula	
9: İkili görüntüdeki nesnelere seçme ve mantıksal işlemler	

5.2.1.2. Önerilen Döndürme ve Bölme İşlemi

Ön işleme aşamasından elde edilen yaprak görüntüleri kullanılarak döndürme ve bölme işlemleri uygulanır. Bölme işlemi gerçekleştirilmeden önce, renklendirilmiş ve bölütlenmiş yaprak görüntüleri, ana eksene göre döndürülerek yatay eksende hizalanır (Şekil 5.7). Buna ek olarak, yuvarlak nesnelere benzer yaprak şekilleri için herhangi bir döndürme işlemi uygulanmaz.



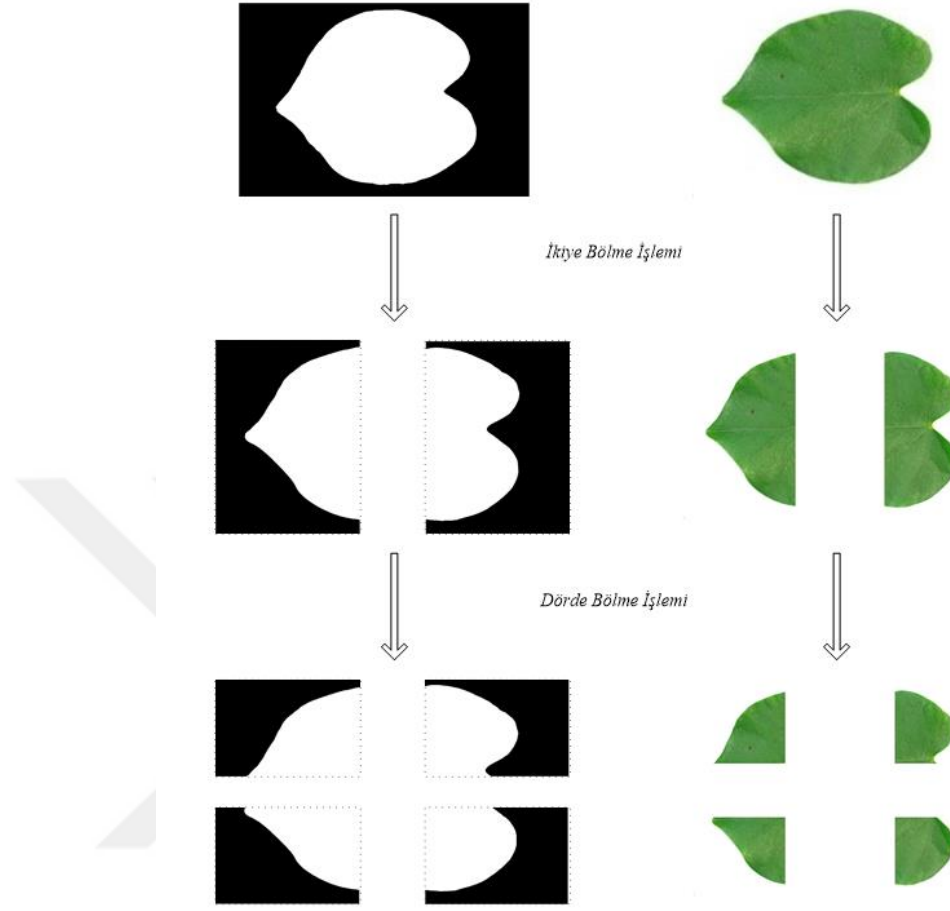
Şekil 5.7. Döndürme işlemi için basit bir gösterim

Önerilen döndürme yaklaşımının sözde kodu aşağıda verilmiştir:

Giriş: Bölütlenmiş görüntünün sınır eğrisine dayalı koordinat dizisi (A) ve yaprak görüntüsü
Çıkış: Döndürülmüş görüntü (imge)
Adım 1: A dizisini ve yaprak görüntüsünü (img) yükle
Adım 2: enb=0 %Maksimum uzaklık
Adım 3: for i=1:length(A) do
Adım 4: for j=1:length(A) do
Adım 5: x1=A(i,:)
Adım 6: x2=A(j,:)
Adım 7: d= (((x1(1)-x2(1))^2)+(x1(2)-x2(2))^2)^(1/2) % Oklid uzaklık
Adım 8: if (enb<d) then
Adım 9: enb=d, p1=i ve p2=j
Adım 10: end if
Adım 11: end for
Adım 12: end for
Adım 13: y1=A(p1,:)
Adım 14: y2=A(p2,:)
Adım 15: q=(y1(1,1)-y2(1,1))/ (y1(1,2)-y2(1,2))
Adım 16: $\theta = \text{atan}(q)$
Adım 17: imge=dondurme(img, θ)

Yaprak görüntüleri farklı yönlerde ve farklı açılarda olduğu için döndürme işlemi uygulanmaksızın bölme işleminin gerçekleştirilmesi kaçınılmaz hatalar ile sonuçlanır. Bu nedenle, iki ve dört bölme işleminin hatasız olarak gerçekleştirilebilmesi için yatay ekseninde döndürme işlemi kullanılır. Hizalama işleminden sonra, renklendirilmiş ve bölütlenmiş yaprak görüntüleri, Şekil 5.8’de gösterildiği gibi iki ve dört parçaya bölünür.

İkiye bölme işlemi yaprağın merkez noktasından dikey olarak uygulanır. Dörde bölme işlemi ise yaprağın merkez noktasından hem yatay hem dikey olarak gerçekleştirilir.



Şekil 5.8. Bölme İşleminin uygulanması

5.2.2. Deneysel Çalışmalar

Önerilen hibrit modelin başarımını test etmek için Flavia yaprak veri setleri kullanılmıştır. Kullanılan veri seti hakkında detaylı bilgiler Bölüm 4’de verilmiştir. Önerilen sistemin doğruluğunu test etmek için 10-kat çapraz doğrulama yöntemi kullanılmıştır. Geliştirilen hibrit sistemin performansını test etmek için AÖM sınıflandırıcısı kullanılmıştır.

Geliştirilen sistemde, yaprak görüntüleri ikiye ve dört bölüme ayrıldıktan sonra her bir yaprak parçası için, Renk ve damar özellikleri, FT ve GSEM yöntemleri kullanılarak öznelik parametreleri elde edilmiştir. Daha sonra, bütün bir yaprak görüntüsü için her bir parçadan elde edilen parametreler birleştirilmiştir. Çizelge 5.10’da, orjinal, ikiye bölünmüş ve dörde bölünmüş görüntüler için elde edilen öznelik sayıları verilmiştir.

Çizelge 5.10. Özellik çıkarım yöntemlerinin bireysel öznelik sayıları

Yöntemler	Orijinal	İkiye Bölme	Dörde Bölünmüş
Renk Özellikleri	12	24	48
FT	20	40	80
GSEM	5	10	20

Çizelge 5.10’da gösterildiği gibi, ikiye bölme yöntemi orijinal görüntüden elde edilen özneliklerin iki katı, dörde bölme yöntemi ise orijinal görüntüden elde edilen öznelik sayısının dört katı kadar fazla parametre içermektedir. Her bir özellik çıkarım yöntemlerinden elde edilen özellik vektörlerinin AÖM yöntemi kullanılarak bireysel sınıflandırma performansları ve gerçekleştirme zamanları Çizelge 5.11’de verilmiştir.

Çizelge 5.11. Özellik çıkarma yöntemlerinin doğruluk skorları (%) ve gerçekleştirme süreleri (saniye)

Yöntemler	Orijinal		İkiye Bölme		Dörde Bölme	
	Doğruluk	Süre	Doğruluk	Süre	Doğruluk	Süre
Renk Özellikleri	85.31	693	89.47	821	90.57	875
FT	84.78	405	92.73	614	92.10	818
GSEM	63.21	467	74.26	624	78.68	844

Çizelge 5.11’de görüldüğü gibi, özellik çıkarma yöntemlerinin doğruluk skorları ayrı ayrı sınıflandırılarak elde edilmiştir. Bu sonuçlara göre, dörde bölme yöntemi kullanılarak orijinal görüntüye göre renk özelliğinde %5 ve GLCM yöntemde ise %15 gibi önemli bir başarı artışı sağlanmıştır. İkiye bölme yöntemi kullanılarak FT yönteminde elde edilen doğruluk skoru, dörde bölme yöntemine göre daha yüksek olduğu gözlenmiştir. Bunlara ek olarak, orijinal görüntü kullanılarak gerçekleştirilen deneysel çalışmalarda, ikiye ve dörde bölme yöntemlerine göre daha düşük eğitim süresine sahiptir. Öte yandan ikiye bölme yöntemi eğitim süresi olarak dörde bölme yönteminden daha yavaştır.

Özellik çıkarım yöntemlerden bir diğeri olan Damar özellikleri, herhangi bir bölme işlemi kullanılmadan uygulanmıştır. Bu yöntem kullanılarak %48,21 doğruluk skoru elde edilmiştir. Son olarak, Renk ve damar özellikleri, FT ve GSEM yöntemleri kullanılarak elde edilen öznelikler birleştirilerek sınıflandırma performansları hesaplanmıştır ve bu sonuçlar Çizelge 5.12’de verilmiştir.

Çizelge 5.12. Önerilen hibrit sistemin doğruluk skorları, gerçekleştirme zamanı ve öznitelik sayıları

	Orijinal	İkiye Bölme	Dörde Bölme
Doğruluk (%)	97.68	99.10	98.36
Öznitelik Sayısı	42	79	153
Süre (saniye)	3132	3299	3779

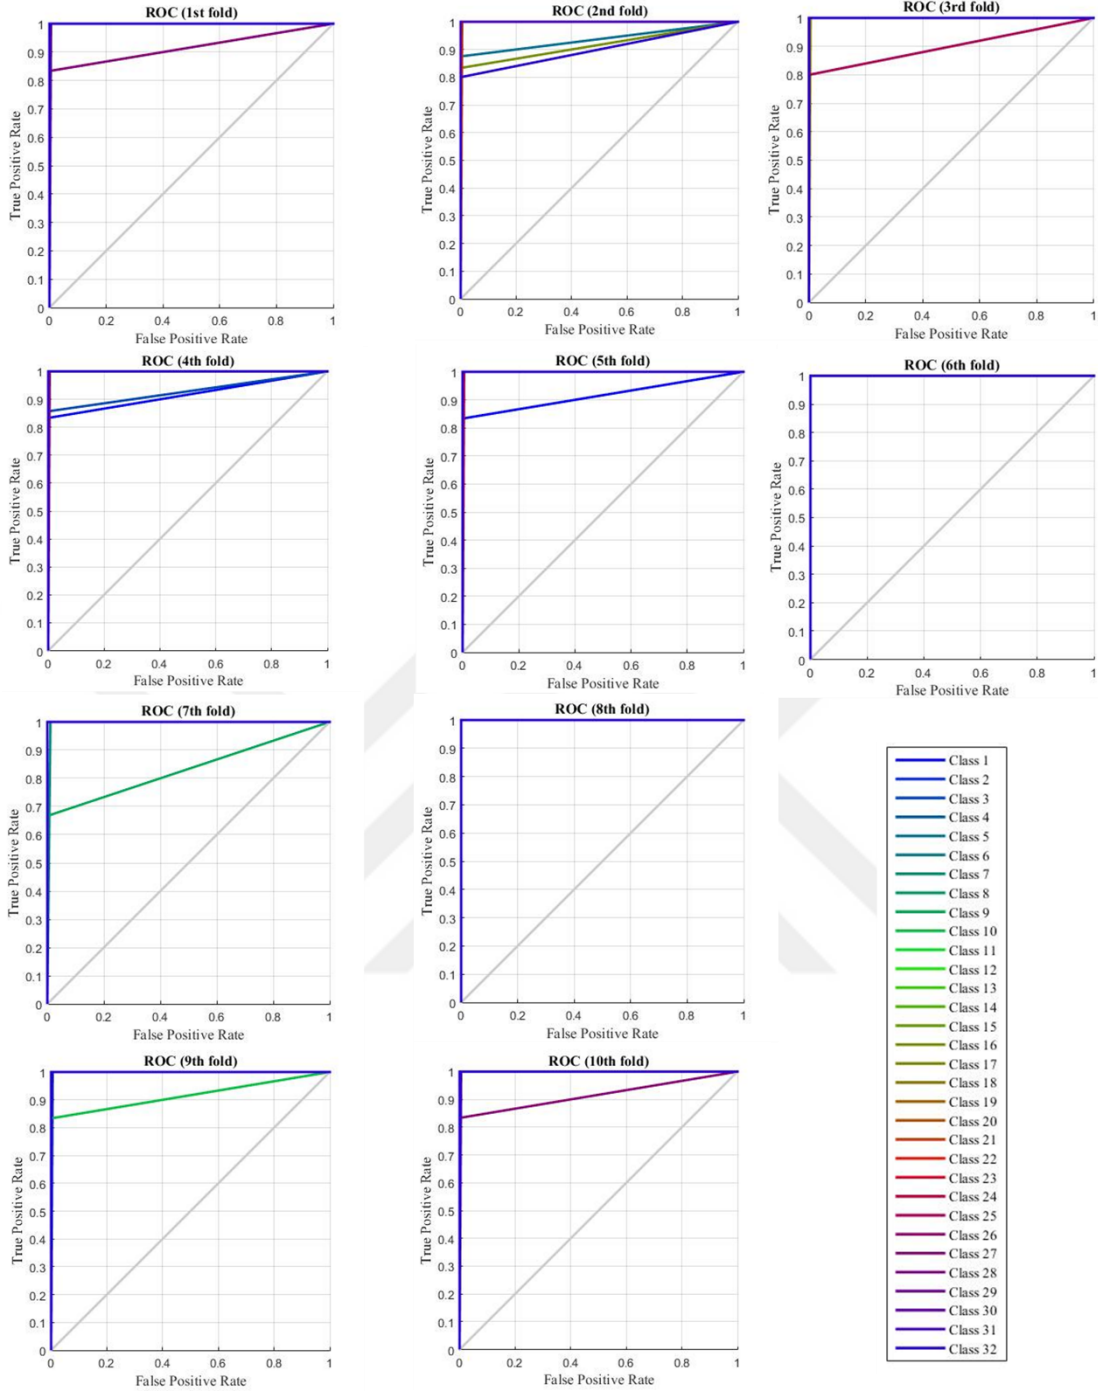
Çizelge 5.12'de gösterilen sonuçlara göre, hibrit özelliklere dayalı dörde bölme işleminin eğitim süresi orijinal ve ikiye bölme işlemlerine göre daha fazladır. Bunun yanı sıra, ikiye bölme işlemi ile orijinal görüntü kullanılarak gerçekleştirilen deneysel çalışmalarda eğitim süreleri yaklaşık olarak eşittir.

Çizelge 5.12'den anlaşılacağı üzere, en yüksek doğruluk ikiye bölme işlemi kullanılarak 79 öznitelik ile %99.10 olarak hesaplanmıştır. Genellikle, özellik çıkarım yöntemlerinin her biri için sınıflandırma performansları en yüksek dörde bölme işlemi ile elde edilirken, hibrit özelliklere dayalı önerilen model için en yüksek doğruluk ikiye bölme işlemi ile elde edilmiştir. Bu sonuçlara dayanarak, ikiye ve dörde bölme işlemleri her bir özellik çıkarım yöntemleri ile kullanılarak farklı sınıflandırma performansları göstermektedir.

Önerilen hibrit sistem ve geliştirilen ikiye bölme işlemi kullanılarak en yüksek doğruluk skoru %99.10 olarak elde edilmiştir. Önerilen hibrit sistemin kullanılarak 10 kat çapraz doğrulama modelinin tekrarlanan on işleminden her birinin performans oranı ile AİK (Alıcı İşletim Karakteristiği) diyagramı sırasıyla Çizelge 5.13 ve Şekil 5.9'da gösterilmiştir.

Çizelge 5.13. 10 kat çaprazlama modelinin her iterasyon için başarımları (%)

1. Kat	2. Kat	3. Kat	4. Kat	5. Kat	6. Kat	7. Kat	8. Kat	9. Kat	10. Kat	Ortalama
98.42	97.89	98.94	98.94	99.47	100	98.94	100	99.47	98.94	99.10



Şekil 5.9. 10 kat çaprazlama modelinin her iterasyon için AİK diyagramı

Önerilen hibrit sistemden elde edilen özellikler, YSA ve EK-DVM gibi farklı sınıflandırıcı yöntemleri kullanılarak doğruluk skorları hesaplanmış ve Çizelge 5.14'de gösterilmiştir.

Çizelge 5.14. Farklı sınıflandırıcılar kullanılarak performans oranları (%)

Yöntemler	Orijinal	İkiye Bölme	Dörde Bölme
YSA	97.42	98.73	98.31
EK-DVM	96.89	98.11	97.52

Çizelge 5.14’de verilen sonuçlara göre, YSA ve EK-DVM sınıflandırıcıları kullanılarak en yüksek performans ikiye bölme işlemi kullanılarak elde edilmiştir. YSA yöntemi kullanılarak EK-DVM yöntemine göre daha yüksek doğruluk elde edilmiştir. Bu sonuçlara göre, AÖM sınıflandırıcısı, YSA ve EK-DVM yöntemlerine göre daha başarılı olduğu tespit edilmiştir.

Flavia veri seti kullanılarak literatürde şekil, renk ve doku tabanlı çok sayıda çalışma yapılmıştır. Bu çalışmalar ile önerilen ikiye bölme işlemine dayalı hibrit modelin doğruluk skorları Çizelge 5.15’de karşılaştırılmıştır.

Çizelge 5.15. Önerilen model ile diğer çalışmaların karşılaştırılması

Yazar/Referans	Özellik Çıkarım Yöntemleri	Sınıflandırıcı Yöntemi	Tür sayısı	Yaprak sayısı	Doğruluk (%)
Kadir vd. [23]	Zernike Moment, Şekil özellikleri, Renk özellikleri, GSEM	OSA	32	1600	94.69
Lee vd. [22]	HFD, Şekil özellikleri	-	32	1907	97.19
Kadir vd. [221]	Polar Fourier Dönüşüm, Şekil, renk, damar ve doku özellikleri	OSA	32	1600	93.75
Kulkarni vd. [222]	Zernike Moment, GSEM, Şekil, renk ve damar özellikleri	OSA	32	1600	93.82
Priya vd. [39]	Şekil özellikleri	DVM	32	1907	94.50
Singh vd. [223]	Wavelet Dönüşüm ve Fraktal Boyut	ANN	32	1600	96.00
Uluturk vd. [224]	Şekil özellikleri	OSA	32	1120	92.50
Zhang vd. [225]	Şekil özellikleri	DVM	16	960	91.19
Wu vd. [11]	Şekil özellikleri	OSA	32	1800	90.00
Mahdikhanlou vd. [21]	MKU, EEE	OSA	32	1907	82.05
Kadir vd. [38]	Polar Fourier Dönüşüm, renk ve damar özellikleri	Oklid Uzaklık	32	1600	93.13
Sari vd. [24]	Şekil özellikleri, FT ve ÇMM	DVM, k-EYK, KDA	32	1907	94.62
Naresh vd. [25]	Geliştirilmiş YİÖ yöntemi	k-EYK	32	1907	97.55
Önerilen Model	FT, GSEM, Renk Özellikleri, Damar özellikleri	AÖM	32	1907	99.10

Çizelge 5.15’de verilen sonuçlara göre, Flavia yaprak veri seti için bitki tanıma sistemleri arasından en yüksek performans önerilen hibrit model kullanılarak elde edildiği gözlenmiştir. Önceki çalışmaların aksine, bu çalışmada bütün bir yaprak görüntüsünü

kullanmak yerine yaprak görünüsünün ağırlık merkez noktasına göre bölümlere ayrılarak öznelikler çıkartılmıştır. Geliştirilen ikiye bölme yaklaşımına dayalı hibrit sistemin literatüre katkıları ve avantajları şunlardır;

- İkiye ya da dörde bölme yaklaşımları kullanılarak literatürde yaygın olarak kullanılan özellik çıkarım yöntemlerinin bireysel performansları artırılmıştır.
- Aynı türe ait farklı yapraklar arasındaki benzerlik oranının artışı sağlanmıştır.
- Genellikle, bitki yapraklarının herhangi bir kenarında meydana gelen bozulmalar, bitki tanıma için geliştirilen sistemlerin performanslarını olumsuz etkilemektedir. Önerilen bölme işlemi kullanılarak yaprağın herhangi bir kenarında meydana gelen bozulmalar, diğer parçalara ayrılan sağlam kısımlardan elde edilen özellikleri etkilemez. Yaprığın her bir bölümünden elde edilen parametrelerin birleştirilmesi, herhangi bir deforme olmuş bölümden elde edilen parametrelerin etkisini azaltır. Önerilen bölme işlemi sayesinde, deforme olmuş yaprakların bitki sınıflandırma performansına olumsuz etkisi en aza indirgenmiştir.

5.3. Geliştirilen yerel ikili örüntü yöntemine dayalı yaprak tabanlı bitki türlerinin tanınması

Bu bölümde, nesne tanıma alanında yüksek performans sağlayan YİÖ yöntemine dayalı farklı yaklaşımlar kullanılarak bitki yapraklarının tanınması için bir yöntem geliştirilmiştir. Önerilen yöntem, Genel/Bölgesel ortalama-YİÖ olarak adlandırılmıştır. Geliştirilen yaklaşımın performansı ve gürültüye karşı sağlamlığı orjinal YİÖ yöntemine, geliştirilen diğer YİÖ yöntemlerine ve geleneksel görüntü tanımlayıcılarına göre üstünlükleri incelenmiştir.


YİÖ yöntemi, ön işleme aşamasına gerek olmadan görüntülerden dokusal özellikler elde etmek için kullanılır. Bunun yanı sıra, orijinal YİÖ yönteminin uygulanması için renkli görüntüler gri tona dönüştürülürken, önerilen yöntemde ise görüntülerin R ve G kanalları kullanılarak uygulanır. Buna ek olarak, YİÖ yöntemi 3x3 lük blokların sadece merkez noktası kullanılarak özellikler elde edilirken, Geliştirilen YİÖ yönteminde ise 3x3 lük bolokların ortalaması ile görüntünün genel ortalaması dikkate alınarak özellikler çıkartılır.

Önerilen yöntemlerin performansını test etmek için AÖM sınıflandırıcısı kullanılmıştır. Deneysel çalışmalar, Flavia, Swedish, ICL ve Foliage gibi çeşitli bitki

yaprak veri setleri kullanılarak gerçekleştirilmiştir. Elde edilen sonuçlara göre, önerilen yöntem orijinal YİÖ, geliştirilmiş YİÖ yöntemleri ve diğer görüntü tanımlayıcılarla karşılaştırıldığında hem gürültülü hem de gürültüsüz görüntülerde daha başarılı olduğu gözlenmiştir.

5.3.1. Önerilen Yaklaşım

Bu çalışmada, orijinal YİÖ yönteminden ilham alınarak farklı yaklaşımları içeren yöntemler önerilmiştir. Bu yöntemler, bölgesel ve genel ortalamaya dayalı filtreleme işlemlerini içermektedir. Bununla birlikte, orijinal YİÖ yöntemi gri görüntüye uygulanırken, Genel Ortalama-YİÖ yöntemi R renk kanalına ve Bölge Ortalama-YİÖ yöntemi ise G renk kanalını uygulanılır. Daha sonra, önerilen Bölgesel Ortalama-YİÖ ve Genel Ortalama-YİÖ yöntemlerinden elde edilen parametreler birleştirilerek Bölgesel/Genel Ortalama-YİÖ olarak adlandırılan yöntem elde edilmiştir. Önerilen sistemin genel işlem adımları, Şekil 5.10'da gösterilmiştir. Önerilen yaklaşımlar alt bölümlerde ayrıntılı olarak verilmiştir.



Şekil 5.10. Önerilen sistemin genel akış şeması

Geliştirilen yöntemler uygulanmadan önce, boyut değiştirme işlemi gerçekleştirilmiştir. Bu çalışmada kullanılan veri setleri için belirlenen görüntü boyutları aşağıdaki verilmiştir:

- Flavia veri setindeki görüntüler için 600x800 olarak boyutlandırılmıştır.
- Swedish veri setindeki görüntüler için 896x512 olarak boyutlandırılmıştır.
- ICL veri setindeki görüntüler için 960x720 olarak boyutlandırılmıştır.
- Foliage veri setindeki görüntüler için 256x256 olarak boyutlandırılmıştır.

5.3.1.1. Bölgesel Ortalama-YİÖ

Önerilen Bölgesel Ortalama-YİÖ yöntemi (BO-YİÖ), orijinal YİÖ'den farklı olarak görüntünün bölgesel ortalamasının merkez pikselle karşılaştırılmasına

dayanmaktadır. Bu yöntem, ilk önce merkez piksel ile bölgesel ortalama arasında bir karşılaştırma yaparak en büyük değeri seçer. Daha sonra, bu değer komşu pikseller ile karşılaştırılarak ikili bir sayı elde edilir.

Bölgesel ortalama Denklem (5.9) kullanılarak hesaplanır:

$$BO = \frac{\sum_{i=1}^n M_i}{n} \quad (5.9)$$

Denklem (5.9)'da, M_i komşu pikselleri ve n komşu sayısını temsil etmektedir. Bu çalışmada, n değeri 8 olarak belirlenmiştir. Başka bir deyişle, 3x3 lük filtreleme yapısı kullanılmıştır.


Bölgesel Ortalama-YİÖ'nin çalışma mantığı Denklem (5.10)'da verilmiştir:

$$BO - YİÖ = \sum_{i=1}^8 K * 2^{i-1} \quad (5.10)$$

Denklem (5.10)'de verilen K değeri:

$$K = \begin{cases} 1, & \text{Eğer } (BO \geq M_C) \text{ ve } (BO \leq M_i) \\ 0, & \text{Eğer } (BO \geq M_C) \text{ ve } (BO > M_i) \\ 1, & \text{Eğer } (BO < M_C) \text{ ve } (M_C \leq M_i) \\ 0, & \text{aksi takdirde} \end{cases} \quad (5.11)$$

olarak hesaplanır. Burada M_C merkez pikseli temsil etmektedir. Denklem (5.11)'de anlaşılacağı üzere, BO ve merkez piksel (M_C) karşılaştırılarak maksimum değer seçilir. Daha sonra, bu elde edilen maksimum değer ile komşu pikselleri (M_i) karşılaştırılarak YİÖ etiketi oluşturulur. BO -YİÖ yönteminin uygulanmasına yönelik basit bir örnek Şekil 5.11'de verilmiştir.



Şekil 5.11. BO-YİÖ yönteminin uygulanması

Şekil 5.11, 3x3 lük pikseller için BO-YİÖ yönteminin uygulanmasından sonra elde edilen değer gösterilmiştir. BO-YİÖ yöntemi kullanılarak elde edilen bu değer, Şekil 5.10'da gösterildiği gibi orijinal YİÖ yöntemi kullanılarak elde edilen değerden farklı olduğu gözlenmiştir. Şekil 5.11'deki örnekte, BO değeri merkez pikselden daha büyük olduğu için BO değeri komşu pikseller ile karşılaştırılmıştır. Bunun aksine, merkez piksel BO değerinden büyük olursa, aynı işlemler merkez piksel dikkate alınarak gerçekleştirilir.

5.3.1.2. Genel Ortalama-YİÖ

Önerilen Genel Ortalama-YİÖ yöntemi (GO-YİÖ), orijinal YİÖ'den farklı olarak bütün görüntünün ortalamasının merkez pikselle karşılaştırılmasına dayanmaktadır. Bu yöntem, ilk önce merkez piksel ile genel ortalama arasında bir karşılaştırma yaparak en küçük değer seçilir. Daha sonra, bu değer komşu pikseller ile karşılaştırılarak ikili bir sayı elde edilir.

Genel ortalama Denklem (5.12) kullanılarak hesaplanır:

$$GO = \frac{\sum_{i=1}^P \sum_{j=1}^R N(i,j)}{P * R} \quad (5.12)$$


Denklem (5.12)'de, $N, P \times R$ boyutundaki görüntü matrisini temsil etmektedir. Genel Ortalama-YİÖ'nin çalışma mantığı Denklem (5.13)'de verilmiştir:

$$GO - YİÖ = \sum_{i=1}^8 K * 2^{i-1} \quad (5.13)$$

Denklem (5.13)'de verilen K değeri:

$$K = \begin{cases} 1, & \text{if } (GO < M_c) \text{ and } (GO < M_i) \\ 0, & \text{elseif } (GO < M_c) \text{ and } (GO \geq M_i) \\ 1, & \text{elseif } (GO \geq M_c) \text{ and } (M_c < M_i) \\ 0, & \text{otherwise} \end{cases} \quad (5.14)$$

olarak hesaplanır. Denklem (5.14)'den anlaşılacağı üzere, GO ve merkez piksel (M_c) karşılaştırılarak minimum değer seçilir. Daha sonra, bu elde edilen minimum değer ile komşu pikseller (M_i) karşılaştırılarak YİÖ etiketi oluşturulur. GO-YİÖ yönteminin uygulanmasına yönelik basit bir örnek Şekil 5.12'de verilmiştir.



Şekil 5.12. GO-YİÖ yönteminin uygulanması

Şekil 5.12'de, 3x3 lük pikseller için GO-YİÖ yönteminin uygulanmasından sonra elde edilen değer gösterilmiştir. GO-YİÖ yöntemi kullanılarak elde edilen bu değer, Şekil 5.10 ve Şekil 5.11'de gösterildiği gibi orijinal YİÖ ile BO-YİÖ yöntemleri kullanılarak elde edilen değerlerden farklı olduğu gözlenmiştir. Şekil 5.12'deki örnekte, OM değeri merkez pikselden daha küçük olduğu için OM değeri komşu pikseller ile

karşılaştırılmıştır. Bunun aksine, merkez piksel OM değerinden daha küçük olursa, aynı işlemler merkez piksel dikkate alınarak gerçekleştirilir.

5.3.1.3. Bölgesel/Genel Ortalama-YİÖ

Önerilen BGO-YİÖ yöntemi, BO-YİÖ ve GO-YİÖ yöntemlerinden elde edilen parametrelerin birleştirilmesine dayanmaktadır. Örneğin, Şekil 5.11-12’de gösterilen uygulamalarda, BO-YİÖ ve GO-YİÖ yöntemlerinden elde edilen YİÖ kodları birleştirilir ve [150 232] olarak BGO-YİÖ parametresi elde edilir. Bu yöntem, bir görüntünün R ve G kanallarını kullanarak farklı ve ayırt edici parametrelerin elde edilmesini sağlar. BGO-YİÖ yönteminin sözde kodu aşağıda verilmiştir:

Giriş: W x H boyutundaki Bitki görüntüsü (I)
Çıkış: Çıkarılan Özellikler (F)
1: I yükle
2: for i=1 to W-2 do
3: for j=1 to H-2 do
4: blok=I(i:i+2,j:j+2);
5: BOD(i,j) olan bloğun BO değerlerini hesaplamak için Denklem 5.9-11 uygula
6: GOD(i,j) olan bloğun GO değerlerini hesaplamak için Denklem 5.12-14 uygula
7: end for j
8: end for i
9: $H1 = hist(BOD)$ // BOD'nin histogramını hesapla.
10: $H2 = hist(OMV)$ // GOD'nin histogramını hesapla.
11: $F = H1 \oplus H2$ // Elde edilen özellikler için histogramları birleştir (BGO).

5.3.2. Deneysel Sonuçlar

Önerilen yöntemlerin başarımını test etmek için Flavia, Swedish, ICL ve Foliage yaprak veri setleri kullanılmıştır. Kullanılan veri setleri hakkında detaylı bilgiler Bölüm 4’de verilmiştir. Önerilen sistemin doğruluğunu test etmek için 10-kat çapraz doğrulama yöntemi kullanılmıştır. Geliştirilen yöntemin performansını test etmek için AÖM sınıflandırıcısı kullanılmıştır. AÖM sınıflandırıcısının parametreleri deneysel yaklaşımlarla belirlenmiştir. Bunlar; aktivasyon fonksiyonu olarak sigmoid ve gizli nöron sayısı ise 100 adım boyutu ile [1000-10000] aralığındaki sayılardır.

Deneysel sonuçlar ve performans karşılaştırmaları alt başlıklarda verilmiştir.

5.3.2.1. Önerilen yöntemler ile YİÖ yönteminin Sonuçlarının Karşılaştırılması

Bu bölümde, Flavia, Swedish, ICL ve Foliage yaprak veri setleri kullanılarak orjinal YİÖ, BO-YİÖ, GO-YİÖ ve BGO-YİÖ yöntemlerinin sınıflandırma performansları hesaplanmıştır. Bu yöntemlerin her biri ayrı ayrı AÖM yöntemi ile sınıflandırılmıştır ve doğruluk skorları Çizelge 5.16’da verilmiştir.

Çizelge 5.16. Önerilen yöntemler ile YİÖ yönteminin doğruluk skorları (%)

Yöntemler	Flavia	Swedish	ICL	Foliage
Orjinal YİÖ	98.05	98.12	70.57	87.86
BO-YİÖ	97.94	98.30	71.42	91.11
GO-YİÖ	97.89	99.46	76.57	88.75
BGO-YİÖ	98.94	99.19	83.71	92.92

Çizelge 5.16’da, önerilen yöntemler (BO-YİÖ, GO-YİÖ ve BGO-YİÖ) orjinal YİÖ yöntemine göre daha başarılı olduğu gözlenmiştir. Flavia, ICL ve Foliage veri setleri için en yüksek doğruluk BGO-YİÖ yöntemi kullanılarak elde edilirken, Swedish veri seti için ise BO-YİÖ yöntemi kullanılarak en yüksek doğruluk elde edilmiştir. Çizelge 5.16’da verilen sonuçlara göre:

- Flavia veri seti için elde edilen en yüksek doğruluk, BGO-YİÖ yöntemi kullanılarak %98.94 olarak hesaplanmıştır. BGO-YİÖ yöntemi kullanılarak orjinal YİÖ yöntemine göre yaklaşık %1 daha fazla doğruluk elde edilmiştir.
- Swedish veri seti için elde edilen en yüksek doğruluk, BO-YİÖ yöntemi kullanılarak %99.46 olarak hesaplanmıştır. BO-YİÖ yöntemi kullanılarak orjinal YİÖ yöntemine göre yaklaşık %2 daha fazla doğruluk elde edilmiştir.
- ICL veri seti için elde edilen en yüksek doğruluk, BGO-YİÖ yöntemi kullanılarak %83.71 olarak hesaplanmıştır. BGO-YİÖ yöntemi kullanılarak orjinal YİÖ yöntemine göre yaklaşık %12 daha fazla doğruluk elde edilmiştir.
- Foliage veri seti için elde edilen en yüksek doğruluk, BGO-YİÖ yöntemi kullanılarak %92.92 olarak hesaplanmıştır. BGO-YİÖ yöntemi kullanılarak orjinal YİÖ yöntemine göre yaklaşık %5 daha fazla doğruluk elde edilmiştir.

Önerilen yöntemlerin ve orjinal YİÖ yöntemlerin gerçekleştirme süreleri Çizelge 5.17’de verilmiştir ve bu süreler bir görüntü için hesaplanmıştır. Buna ek olarak, bu çalışmada kullanılan veri setlerindeki görüntülerin boyutları farklı olduğu için, her bir veri seti için ayrı ayrı gerçekleştirme süreleri verilmiştir.

Çizelge 5.17. Önerilen yöntemler ile orijinal YİÖ yönteminin gerçekleştirme zamanları (saniye)

	Flavia	ICL	Swedish	Foliage
Orijinal YİÖ	0.0914	0.1858	0.1059	0.0068
BO-YİÖ	0.0745	0.1766	0.0863	0.0064
GO-YİÖ	0.0693	0.1482	0.0788	0.0062
BGO-YİÖ	0.1313	0.2993	0.1632	0.0108

Çizelge 5.17’de gösterildiği gibi, GO-YİÖ yöntemi diğer üç yönteme göre daha düşük eğitim süresine sahipken, YİÖ yönteminin BGO-YİÖ yöntemine göre eğitim süresi daha yavaştır. Buna ek olarak, GO-YİÖ ve BO-YİÖ yöntemlerinin gerçekleştirme süreleri neredeyse eşittir.

5.3.2.2. Önerilen yöntemler ile önceki çalışmalar ve görüntü tanımlayıcılarının karşılaştırılması

Önerilen yöntemler, bitki türlerinin tanınması için geliştirilen YİÖ yöntemlerine dayalı önceki çalışmaların sınıflandırma doğrulukları ile karşılaştırılmıştır. Bu kıyaslamalar bu çalışmada kullanılan veri setleri dikkate alınarak yapılmış ve sonuçlar Çizelge 5.18’de verilmiştir.

Çizelge 5.18. Önerilen yöntemler ile YİÖ tabanlı önceki çalışmaların doğruluklarının (%) karşılaştırılması

		Flavia	Swedish	ICL	Foliage
Önceki Çalışmalar	[226]	84.78	88.89	-	90.88
	[227]	94.13	-	-	-
	[25]	97.55	96.83	-	90.62
	[29]	-	99.25	-	-
BO-YİÖ		97.94	98.30	71.42	91.11
GO-YİÖ		97.89	99.46	76.57	88.75
BGO-YİÖ		98.94	99.19	83.71	92.92

Çizelge 5.18’de, önerilen yöntemler kullanılarak önceki çalışmalara göre dört veri seti için de en yüksek sınıflandırma doğruluğu elde edildiği gözlenmiştir. Ayrıca, bu çalışmada Flavia, Swedish, ICL ve Foliage veri setleri kullanılarak GSEM, YGH, Renk özellikleri ve Shearlet Dönüşüm gibi görüntü tanımlayıcılarının sınıflandırma performansları hesaplanmıştır. Bu tanımlayıcılar yüksek sınıflandırma performansına sahiptirler, nesne tanıma çalışmalarında yaygın olarak kullanılmaktadırlar.

Çizelge 5.19. Önerilen yöntemler ile Görüntü tanımlayıcıların doğruluk skorlarının (%) karşılaştırılması

	Flavia	Swedish	ICL	Foliage
Shearlet Dönüşüm	59.47	75.00	34.57	30.38
GSEM	63.21	75.98	37.71	53.51
Renk Özellikleri	85.31	84.91	68.28	82.88
YGH	94.78	98.75	82.85	89.76
BO-YİÖ	97.94	98.30	71.42	91.11
GO-YİÖ	97.89	99.46	76.57	88.75
BGO-YİÖ	98.94	99.19	83.71	92.92

Çizelge 5.19’da, önerilen yöntemler dört veri seti içinde görüntü tanımlayıcılarına kıyasla daha başarılı olduğu gözlenmiştir. Bununla birlikte, görüntü tanımlayıcıları arasındaki en yüksek doğruluk, dört veri setinin tümü için YGH yöntemi kullanılarak elde edilmiştir.

5.3.2.3. Önerilen yöntemler ile geliştirilen YİÖ yönteminin Karşılaştırılması

Nesne tanıma ile ilgili literatürde YİÖ yöntemine dayalı birçok çalışma yapılmıştır. Bu çalışmalarda geliştirilen YİÖ tabanlı yöntemler, genellikle yüz tanıma ve parmak izi tanıma gibi farklı problemlerin çözümünde kullanılmıştır. Bu çalışmada, Flavia, Swedish, ICL ve Foliage veri setleri kullanılarak bu geliştirilmiş YİÖ tabanlı yöntemlerin performansları hesaplanmıştır ve Çizelge 5.20’de önerilen yöntemler ile karşılaştırılmıştır.

Çizelge 5.20. Önerilen yöntemler ile diğer yöntemlerin doğruluk skorlarının karşılaştırılması (%)


	Flavia	Swedish	ICL	Foliage
LQPAT [228]	96.57	98.48	69.71	88.33
LGS [229]	97.68	96.96	79.71	94.16
S-LGS [230]	98.47	97.41	82.28	94.13
VS-LGS [231]	98.21	97.76	82.00	93.90
V-LGS [231]	97.89	97.41	80.85	94.62
ZH-LGS [231]	98.26	97.94	75.71	88.62
ZV-LGS [231]	97.68	97.67	74.28	89.63
ZHM-LGS [231]	97.84	97.85	79.14	93.52
BO-YİÖ	97.94	98.30	71.42	91.11
GO-YİÖ	97.89	99.46	76.57	88.75
BGO-YİÖ	98.94	99.19	83.71	92.92

Çizelge 5.20’de, önerilen yöntemler, nesne tanıma alanında geliştirilen en iyi performans gösteren YİÖ tabanlı yöntemler ile karşılaştırılmıştır. Elde edilen sonuçlara göre,

- Flavia veri seti için en yüksek doğruluk (%98.94), BGO-YİÖ yöntemi kullanılarak elde edilmiştir.

- Swedish veri seti için en yüksek doğruluk (%99.46), GO-YİÖ yöntemi kullanılarak elde edilmiştir.
- ICL veri seti için en yüksek doğruluk (%83.71), BGO-YİÖ yöntemi kullanılarak elde edilmiştir.
- Foliage veri seti için en yüksek doğruluk (%94.62), V-LGS yöntemi kullanılarak elde edilmiştir.


Sonuç olarak, önerilen yöntemler Foliage veri seti haricinde diğer veri setleri için geliştirilmiş YİÖ yöntemlerine göre daha yüksek başarımlara sahip olduğu gözlemlenmiştir. Bu çalışmada kullanılan dört veri seti için önerilen yöntem (BGO-YİÖ), orijinal YİÖ yöntemi, geliştirilmiş YİÖ tabanlı yöntemler ve görüntü tanımlayıcılarının performans sonuçlarının ortalaması hesaplanmış ve bu sonuçlar Şekil 5.13’de gösterilmiştir.



Şekil 5.13. Dört veri seti için ortalama performans sonuçları

5.3.2.4. Gürültüye karşı önerilen ve yöntemlerin karşılaştırılması

Nesne tanıma ile ilgili çalışmalarda geliştirilen görüntü tanımlayıcıları genellikle gürültüsüz ve özel olarak elde edilen görüntüler kullanılarak test edilmektedir. Ancak gerçek zamanlı uygulamalarda telefon ya da kameralar gibi araçlar kullanılarak elde edilen görüntüler istenilen şekilde olmayabilir. Bu nedenle, çeşitli gürültü yöntemleri kullanılarak önerilen yöntemlerin etkinliği ve sağlamlığı değerlendirilir.



Şekil 5.14. Gürültü eklenmiş örnek resimler

Bu çalışmada, popüler gürültü ekleme yöntemlerinden olan Salt & pepper ve Gaussian gürültüleri kullanılmıştır (Şekil 5.14). Bu gürültü yöntemleri, Flavia, Swedish, ICL ve Foliage veri setleri için ayrı ayrı olarak uygulanmıştır. Daha sonra, önerilen yöntemler ile diğer yöntemlerin performansları hesaplanmıştır ve bu sonuçlar Çizelge 5.21-22’de verilmiştir.

Çizelge 5.21. Salt & pepper gürültüsüne dayalı önerilen ve diğer yöntemlerin doğruluk skorlarının karşılaştırılması

	Flavia	Swedish	ICL	Foliage
YİÖ	92.63%	94.19%	55.42%	70.06%
LQPAT	92.15%	92.85%	58.57%	67.43%
LGS	97.10%	95.26%	78.00%	90.54%
S-LGS	97.21%	95.44%	77.71%	90.76%
V-LGS	88.52%	90.71%	37.14%	87.55%
VS-LGS	97.26%	96.16%	79.14%	90.66%
ZH-LGS	85.42%	91.62%	31.42%	81.86%
ZV-LGS	87.36%	91.25%	32.85%	84.83%
ZHM-LGS	85.68%	92.41%	39.14%	85.63%
BO-YİÖ	96.10%	96.78%	66.28%	83.75%
GO-YİÖ	94.73%	98.30%	64.57%	79.79%
BGO-YİÖ	97.31%	98.48%	81.14%	87.84%

Çizelge 5.21’de, Salt & pepper gürültüsüne dayalı elde edilen görüntüler kullanılarak önerilen yöntem ile diğer yöntemlerin performansları karşılaştırılmıştır. Elde edilen sonuçlara göre:

- Flavia veri seti için en yüksek doğruluk (%97.31), BGO-YİÖ yöntemi kullanılarak elde edilmiştir.

- Swedish veri seti için en yüksek doğruluk (%98.48), BGO-YİÖ yöntemi kullanılarak elde edilmiştir.
- ICL veri seti için en yüksek doğruluk (%81.14), BGO-YİÖ yöntemi kullanılarak elde edilmiştir.
- Foliage veri seti için en yüksek doğruluk (%90.76), S-LGS yöntemi kullanılarak elde edilmiştir.

Çizelge 5.21’de verilen sonuçlara göre, genel olarak önerilen BGO-YİÖ yöntemi kullanılarak Salt & pepper gürültüsüne karşı en iyi performans elde edilmiştir.

Çizelge 5.22. Gaussian gürültüsüne karşı önerilen yöntemlerin ve diğer yöntemlerin doğruluk skorlarının karşılaştırılması

	Flavia	Swedish	ICL	Foliage
YİÖ	74.84%	77.67%	20.00%	28.22%
LQPAT	77.31%	80.71%	22.85%	38.76%
LGS	73.57%	67.50%	28.28%	34.86%
S-LGS	86.26%	76.96%	36.85%	47.75%
V-LGS	68.26%	70.08%	23.14%	27.93%
VS-LGS	86.58%	76.69%	32.57%	49.15%
ZH-LGS	64.94%	68.39%	18.85%	19.61%
ZV-LGS	66.89%	71.33%	19.62%	21.19%
ZHM-LGS	60.21%	72.23%	26.00%	26.33%
BO-YİÖ	69.73%	74.46%	19.42%	33.31%
GO-YİÖ	86.68%	85.62%	51.71%	46.33%
BGO-YİÖ	85.31%	84.73%	31.14%	49.52%

Çizelge 5.22’de, Gaussian gürültüsüne dayalı elde edilen görüntüler kullanılarak önerilen yöntem ile diğer yöntemlerin performansları karşılaştırılmıştır. Elde edilen sonuçlara göre:

- Flavia veri seti için en yüksek doğruluk (%86.68), GO-YİÖ yöntemi kullanılarak elde edilmiştir.
- Swedish veri seti için en yüksek doğruluk (%85.62), GO-YİÖ yöntemi kullanılarak elde edilmiştir.
- ICL veri seti için en yüksek doğruluk (%51.71), GO-YİÖ yöntemi kullanılarak elde edilmiştir.
- Foliage veri seti için en yüksek doğruluk (%49.52), BGO-YİÖ yöntemi kullanılarak elde edilmiştir.

Çizelge 5.21 ve Çizelge 5.22'de verilen sonuçlara göre, Salt & pepper gürültüsüne karşı en iyi performans BGO-YİÖ yöntemiyle elde edilirken, OM-YİÖ yöntemi kullanılarak Gaussian gürültüsüne karşı en iyi performans elde edilmiştir. Buna ek olarak, hem gürültülü hem de gürültüsüz Flavia, Swedish ve ICL veri setleri için en yüksek performansın önerilen yöntem kullanılarak elde edildiği tespit edilmiştir. Gürültüsüz Foliage veri seti için önerilen yöntem, diğer gelişmiş YİÖ tabanlı birkaç yöntemle kıyasla daha düşük performans göstermiştir. Bunun yanı sıra, önerilen yöntem tuz ve biber gürültüsüne karşı birçok yöntemin performansını aşarken, Gaussian gürültüsüne karşı önerilen yöntem diğer tüm yöntemlerle karşılaştırıldığında en yüksek performans elde edilmiştir. Sonuç olarak, önerilen yöntemlerin daha sağlam olduğu ve daha yüksek bir performans sağladığı tespit edilmiştir. Buna ek olarak, önerilen yöntem matematiksel karmaşıklığı, bitki türlerinin tanımlanması için geliştirilen YİÖ tabanlı yöntemlerden daha basittir.

Bitki türlerinin sınıflandırılması için geliştirilen yöntemlerin literatüre katkıları ve avantajları şunlardır;

- Önerilen yöntem, orjinal YİÖ yönteminden daha fazla öznetelik elde etmek için herhangi bir ek maliyet gerektirmez. Gerçekleştirme sürelerine ilişkin yapılan analiz, önerilen yöntemin kısa eğitim süresine sahip olduğunu açıkça göstermektedir.
- Önerilen yöntemler, bitki türlerinin sınıflandırılması için gerçek zamanlı olarak uygulanabilir.
- Önerilen yöntemin uygulanması basittir ve karmaşık bir matematik altyapısı yoktur.
- Önerilen yöntemler, geliştirilmiş YİÖ yöntemlerinden ve YGH, GSEM, Renk Özellikleri ve Shearlet Dönüşüm gibi yöntemlerden daha yüksek sınıflandırma doğruluğuna sahiptir.
- Önerilen yöntemler, bir sınıflandırma problemi olarak bitki türlerinin tanınması için yaprak görüntülerin R ve G renk kanalına dayalı bölgesel ve genel ortalama gibi filtreleme kullanarak çözüldüğünü göstermiştir.
- Gürültülü veya istenmeyen görüntüler, görüntü tanımlayıcıların performansını büyük ölçüde etkilemektedir. Bu çalışmada, önerilen yöntemlerin sağlamlığını

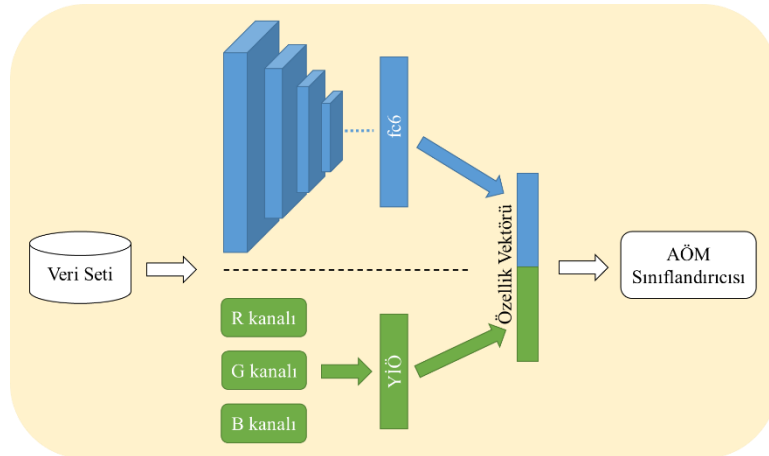
Salt & pepper ve Gaussian gibi gürültülere karşı değerlendirilmiş ve performansları mevcut yöntemlerle karşılaştırmıştır. Sonuç olarak, önerilen yöntemlerin gürültülü görüntülere karşı diğer yöntemlerden daha sağlam ve etkili olduğu tespit edilmiştir.

5.4. Derin Özellik ve Renkli-YİÖ Yöntemine Dayalı Bitki Tanıma Sistemi

Bu bölümde yaprak tabanlı bitki türlerinin sınıflandırılması için derin-dokusal tabanlı özellik çıkarıcı bir model geliştirilmiştir. Bu yaklaşım, ESA ve YİÖ yöntemlerinin kombinasyonlarından elde edilen derin-dokusal özellikler, DVM yöntemi kullanılarak sınıflandırılmış ve test edilmiştir. Derin-dokusal tabanlı geliştirilen modelin geçerliğini doğrulamak için yaprak görüntülerinden oluşan Folio ve ICL veri setleri kullanılmıştır. Önerilen model, en son teknolojiye sahip önceki çalışmalar ile karşılaştırılmış ve elde edilen sonuçlara göre daha başarılı olduğu gözlenmiştir.

5.4.1. Önerilen Derin-Yerel Tabanlı Model

Bu tez çalışmasında, bitki türlerinin sınıflandırılması için ESA mimarisi ile renkli YİÖ yöntemine dayalı derin-yerel özellik tabanlı bir yaklaşım önerilmiştir. ESA'ya dayalı geliştirilen AlexNet modelinin fc6 tam bağlı katmanından derin özellikler elde edilmiştir. Daha sonra, orijinal YİÖ yöntemi, renkli görüntüleri gri görüntülere dönüştürerek uygulanmakta iken, bu çalışmada YİÖ yöntemi kullanılarak renkli görüntülerin R, G ve B kanallarının her biri için öznelikler çıkartılmıştır. Bu renk kanallarından elde edilen özellikler birleştirilmiştir. Son olarak, derin ve yerel özellikler birleştirilmiş ve DVM yöntemi kullanılarak sınıflandırma performansı hesaplanmıştır. Derin-yerel özellik tabanlı yaklaşımın genel akış şeması Şekil 5.15'de verilmiştir.



Şekil 5.15. Önerilen yaklaşımın akış şeması

5.4.2. Deneysel Çalışmalar


Önerilen derin-yerel tabanlı modelin başarımını test etmek için yaprak görüntülerini içeren ICL ve Folio veri setleri kullanılmıştır. Kullanılan veri setleri hakkında detaylı bilgiler Bölüm 4’de verilmiştir. Deneysel çalışmalarda, iki veri seti için eğitim - test kümeleri sırasıyla %70 ile %30 olarak rastgele bir şekilde ayrılmış ve bu işlem sadece bir defa yapılmıştır. Rastgele ayrılan verilerin performansa etkilerini en aza indirmek için tüm uygulamalarda aynı eğitim ve test kümesi kullanılmıştır.

Bu çalışmada, orijinal ve önerilen YİÖ yöntemleri ile AlexNet mimarisinin bireysel ve hibrit doğruluk skorları hesaplanmış ve elde edilen sonuçlar Çizelge 5.23’de verilmiştir.

Çizelge 5.23. Önerilen yaklaşımların doğruluk skorları ve öznitelik sayıları

Yöntemler	Öznitelik sayısı	Veri Setleri	
		ICL	Folio
Gri-YİÖ	256	%59.40	%79.58
Renkli-YİÖ	768	%74.44	%86.39
AlexNet (fc6)	4096	%96.99	%97.91
AlexNet + Renkli-YİÖ	4864	%98.50	%99.48

Çizelge 5.23’de anlaşılacağı üzere, ICL ve Folio veri setleri için AlexNet ve Renkli-YİÖ yöntemine dayalı önerilen yaklaşım kullanılarak sırasıyla %98.50 ve %99.48 doğruluk skorları elde edilmiştir. Önerilen Renkli-YİÖ yöntemi kullanılarak orijinal YİÖ yöntemine göre Folio ve ICL veri setleri için sırasıyla yaklaşık olarak %7 ve %15’lik performans artışı sağlamıştır. Ayrıca derin özellikler yerel özelliklere göre daha yüksek performansa sahip olduğu tespit edilmiştir. AlexNet ve Renkli-YİÖ yöntemlerinin kombinasyonlarına dayalı önerilen yaklaşımının ICL ve Folio veri setleri için karmaşıklık matrisleri Şekil 5.16’da gösterilmiştir.



Şekil 5.16. Önerilen modelin karmaşıklık matrisi

Renkli YİÖ ve AlexNet mimarisinin kombinasyonuna dayalı önerilen model ile önceki çalışmaların doğruluk skorları karşılaştırılmış ve bu sonuçlar Çizelge 5.24’de verilmiştir. Bu karşılaştırmalarda, Folio ve ICL veri setlerinin kullanılmasına dayalı yapılan çalışmalar dikkate alınmıştır.

Çizelge 5.24. Önerilen model ile önceki çalışmalarda elde edilen doğruluk skorlarının karşılaştırılması

	Veri Setleri	
	ICL	Folio
Önceki çalışmalar	% 87.00 [13]	91.40 [48]
	% 92.00 [37]	97.67 [232]
	% 92.65 [26]	99.42 [63]
Önerilen yöntem	%98.50	%99.48

Çizelge 5.24’den anlaşılacağı üzere, Folio ve ICL veri setleri için önerilen yaklaşım kullanılarak diğer çalışmalara göre daha iyi başarı elde edilmiştir.

Bitki türlerinin sınıflandırılması için geliştirilen modelin literatüre katkıları ve avantajları şunlardır;

- Önerilen Renkli-YİÖ yöntemi kullanılarak orijinal YİÖ yönteminden daha başarılı olmuştur.
- Farklı yöntemlerden elde edilen özelliklerin kombinasyonları, sınıflandırma performansını olumlu yönde etkilemiştir.
- Önerilen derin-dokusal tabanlı yaklaşım kullanılarak bitki sınıflandırılması için yaklaşık %100 doğruluk skoru elde edilmiştir.

5.5. Bitki Türlerinin Sınıflandırılması için Çok-Bölmeli ESA


Bu bölümde, bitki türlerinin sınıflandırılması için Çok-Bölmeli Evrimsel Sınır Ağı (ÇB-ESA) tabanlı bir bitki tanıma sistemi geliştirilmiştir. Önerilen sistemde, bitki görüntüleri kullanarak eşit ölçüde $n \times n$ boyutunda parçalara bölünür ve daha sonra ESA kullanılarak her bir parça için derin özellikler çıkartılır. Elde edilen derin özelliklerin her bir parça için TBA yöntemi kullanılarak etkin özellikler seçilmiştir. Son olarak, her bir parça için elde edilen etkin ve seçkin derin özellikler birleştirilmiş ve DVM yöntemi kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

Önerilen derin tabanlı sistemin sağlamlığını ve performansını test etmek için Flavia, Swedish, ICL, Foliage, Folio, ICL, Flower17, Flower102 ve LeafSnap gibi 8 farklı bitki veri seti kullanılmıştır. Geliştirilen modelin başarımını hesaplamak için kapsamlı

deneysel çalışmalar gerçekleştirilmiş ve literatürde yer alan en son teknolojiye sahip çalışmalar ile karşılaştırılmıştır. Elde edilen sonuçlara göre, önerilen sistemin önceki çalışmalara göre üstün performans sağladığı tespit edilmiştir.

5.5.1. Önerilen Model

Bu çalışmada, bölme yaklaşımı kullanılarak derin evrişimsel sinir ağlarına dayalı bir sistem geliştirilmiştir. Önerilen derin tabanlı sistemin genel akış diyagramı Şekil 5.17’de verilmiştir.



Şekil 5.17. ÇB-ESA modelinin genel akış şeması

ÇB-ESA modeli uygulanmadan önce Flavia, Folio, ICL, Swedish, Foliage ve LeafSnap veri setleri için ön-işlem aşaması yapılmıştır. Bu veri setlerindeki görüntülerin arka planları tek renktir (beyaz-kırmızı). Bitki tanıma için yaprak görüntüsü dışındaki arka planın bir katkısı olmayacağı ve ayırt edici bilgiler elde edilmeyeceği için kırpma işlemi uygulanmıştır. Kırpma işlemi için öncelikle morfolojik işlemler (Bölüm 5.1.1.1) kullanılarak görüntüdeki yaprak görüntüsünü arka plandan ayırılır ve yaprağın sınır eğrileri elde edilir. Bu sınır eğrileri kullanılarak renkli görüntüdeki yaprak nesnesi için kırpma işlemi gerçekleştirilir. Bu işlemler ile ilgili Şekil 5.18’de bir örnek gösterilmiştir.



Şekil 5.18. Kırpma işlemi uygulaması

Şekil 5.18’de verilen ÇB-ESA modelinin genel akış şeması için uygulama adımları aşağıda detaylandırılmıştır:

- Adım 1:** Bitki görüntüsü elde et.
- Adım 2:** Bitki görüntüsünü $n \times n$ boyutunda matrislere böl.
- Adım 3:** Bölünmüş bitki görüntüsünü bilinear interpolation kullanılarak derin ağların yapısına göre yeniden boyutlandır.
- Adım 4:** Önceden eğitilmiş ESA mimarileri kullanılarak bölünmüş her bir görüntü için derin özellikler çıkart.
- Adım 5:** TBA yöntemi kullanılarak bölünmüş her bir görüntü için elde edilen derin özelliklerden etkin özellikler seç.
- Adım 6:** Bölünmüş her bir görüntü için seçilmiş özellikleri birleştir.
- Adım 7:** Normalizasyon işlemi uygula.
- Adım 8:** DVM yöntemi kullanılarak elde edilen özelliklerin sınıflandırma işlemi gerçekleştirilir.

Önerilen $n \times n$ 'lik bölme yaklaşımı için 2×2 , 3×3 , 4×4 ve 5×5 olmak üzere 4 farklı durum değerlendirilmiştir. Ayrıca, derin evrişimsel sinir ağlarına dayalı geliştirilen DenseNet201 ve ResNet101 mimarilerinin eğitilmiş ağırlıkları kullanılarak bölünmüş bitki görüntülerinden derin özellikler çıkartılmıştır. Bu derin özellikler için TBA yöntemi kullanarak ayırt edici özellikler seçilmiştir. Her bir parça için elde edilen seçkin özellikler birleştirilmiş ve z-skor yöntemi kullanılarak normalizasyon işlemi uygulanmıştır. Son olarak DVM sınıflandırıcısı kullanılarak önerilen sistemin performansı hesaplanmıştır.

5.5.2. Deneysel Çalışmalar

Önerilen ÇB-ESA modelinin performansını test etmek için literatürde yaygın olarak kullanılan 8 veri setleri üzerinde kapsamlı deneysel çalışmalar yapılmıştır. Kullanılan veri setleri hakkında detaylı bilgiler Bölüm 3'te verilmiştir. Önerilen sistemin geçerliğini doğrulamak için 10-kat çapraz doğrulama yöntemi kullanılmıştır.

Deneysel sonuçlar ve performans karşılaştırmaları alt başlıklarda verilmiştir.

5.5.2.1. Benzetim Sonuçları

Bitki türlerinin sınıflandırılması için önerilen derin tabanlı sistemin performansı, 2×2 , 3×3 , 4×4 ve 5×5 'lik matris şeklinde bölme işlemleri kullanılarak her biri için ayrı ayrı hesaplanmıştır. Gerçekleştirilen deneysel çalışmalarda kullanılan Flavia, Swedish, Flower17, Flower102 ve LeafSnap veri setleri için önerilen derin tabanlı 2×2 bölme yaklaşımı kullanılarak en yüksek doğruluk elde edilirken, ICL, Foliage ve Folio veri

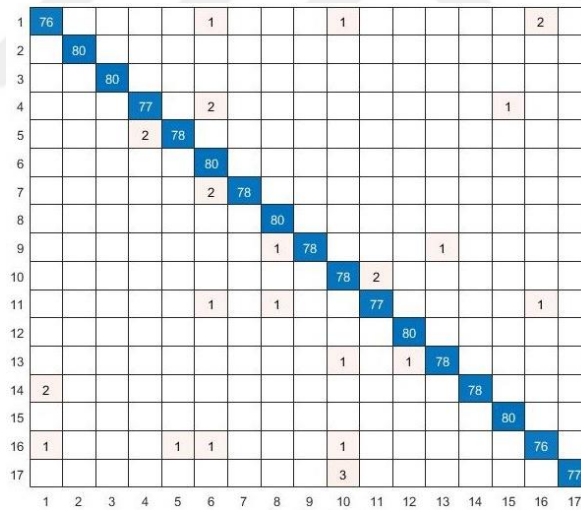
setleri için ise en yüksek doğruluk 3x3 bölme yaklaşımı kullanılarak elde edilmiştir ve bu sonuçlar Çizelge 5.25’de verilmiştir.

Çizelge 5.25. ÇB-ESA modelinin performans sonuçları

	Flavia	Swedish	ICL	Foliage	Folio	Flower17	Flower102	LeafSnap
Doğruluk	%100	%100	%99.77	%99.93	%100	%97.87	%98.03	%97.8
Özellik sayısı	30	40	90	150	45	220	200	180

Çizelge 5.25’de görüldüğü üzere, önerilen sistem kullanılarak yedi farklı veri seti için en yüksek doğruluk skorları verilmiştir. Bu sonuçlara göre, Flavia, Swedish ve Folio veri setleri için %100 doğruluk elde edilirken, ICL, Foliage, Flower17, Flower102 ve LeafSnap veri setleri için sırasıyla %99.77, %99.93, %97.87, %98.03 ve %97.8 doğrulukları elde edilmiştir. ÇB-ESA modeli kullanılarak Flower17 veri seti için elde edilen en yüksek doğruluk skorunun karmaşıklık matrisi Şekil 5.19’da verilmiştir.

Çizelge 5.25’de her bir veri seti için TBA yöntemi kullanılarak indirgenmiş öznelik parametre sayıları verilmiştir. Örneğin, Flavia veri seti için 2x2 bölme yaklaşımı kullanılarak ham bir görüntüden elde edilen dört bölümün her birinden 50 öznelik çıkartılmış ve toplamda 200 öznelik elde edilmiştir.



Şekil 5.19. Flower17 veri seti için karmaşıklık matrisi

Bölme yaklaşımına dayalı olarak her bir veri seti için kapsamlı deneysel çalışmalar yapılmıştır. Örneğin, Flavia veri seti için: 2x2, 3x3, 4x4 ve 5x5 bölme yaklaşımları için %100 doğruluk elde edilmiştir. Bunun yanı sıra, Foliage veri seti için 3x3 bölme yaklaşımı kullanılarak %99.93 doğruluk elde edilirken, 2x2, 4x4 ve 5x5 bölme yaklaşımları için ise sırasıyla %99.9, %99.87 ve %99.72 doğruluk skorları elde edilmiştir. Gerçekleştirilen deneysel çalışmalarda, her bir veri seti için en yüksek performanslar 2x2 ve 3x3 bölme yaklaşımlarından elde edildiği gözlenmiştir.

5.5.2.2. Önerilen sistemin önceki çalışmalar ile karşılaştırılması

Bu bölümde, önerilen ÇB-ESA modeli ile bitki türlerinin tanınması için literatürde yapılan önceki çalışmaların performansları karşılaştırılmış ve bu çalışmada kullanılan veri setleri dikkate alınarak yapılmıştır. Deneysel çalışmalardan elde edilen sonuçlar Çizelge 5.26'da verilmiştir.

Çizelge 5.26. ÇB-ESA modeli ile önceki çalışmaların doğruluk skorlarının karşılaştırılması (%)

Referanslar	Flavia	Swedish	ICL	Foliage	Folio	Flower17	Flower102	LeafSnap
[25]	97.55	96.83	-	90.62	-	-	-	-
[26]	-	-	92.65	-	-	-	-	-
[29]	99.25	-	98.03	-	-	-	-	-
[37]	-	-	92	-	-	-	-	-
[43]	99.5	99.8	-	99	99.2	-	-	-
[44]	-	99.38	-	-	-	-	84.2	-
[48]	96.6	97.8	-	93.1	91.4	-	-	64.9
[49]	-	-	-	-	-	-	73.3	-
[51]	-	-	-	-	-	91.9	73.1	-
[54]	99.6	-	-	-	-	-	-	90.54
[61]	-	-	-	-	-	96.39	95.7	-
[71]	97.9	-	-	95.6	-	-	-	86.3
[73]	99.8	99.8	-	99.3	-	-	-	83.7
ÇB-ESA modeli	%100	%100	%99.77	%99.93	%100	%97.87	%98.03	%97.8

Çizelge 5.26'da, bitki türlerinin sınıflandırılması için literatürde en son teknoloji kullanılarak gerçekleştirilen çalışmaların performansları verilmiş ve ÇB-ESA modelinin performansı ile karşılaştırılmıştır. Bu karşılaştırmalarda, literatürde en çok çalışma yapılan sekiz farklı veri seti kullanılmıştır. Bu sonuçlara göre, önerilen ÇB-ESA modeli kullanılarak önceki çalışmalara kıyasla tüm veri setleri için en yüksek performans elde edilmiştir.

Bitki türlerinin sınıflandırılması için bölme yaklaşımına dayalı geliştirilen ÇB-ESA modelinin literatüre katkıları ve avantajları şunlardır;

- Bu çalışmada, bölme yaklaşımı kullanılarak görüntüler $n \times n$ boyutunda parçalara ayrılmıştır. ESA dayalı önerilen model kullanılarak bölünmüş parçalardan derin özellikler çıkartılmış ve TBA yöntemi kullanılarak ayırt edici ve etkili özellikler seçilmiştir. Önerilen bu yaklaşım kullanılarak literatürde bugüne kadar yapılmış çalışmalardan daha iyi performans elde edilmiştir. Sonuç olarak, örüntü tanıma problemlerinin çözümü için geliştirilmiş yöntemlerin performanslarını artırılması

için kullanılabilir ve daha yüksek doğruluk skoru elde edilmesi amacıyla gerçekleştirilecek çalışmalar için önemli bir etken olacaktır.

- Bölme yaklaşımı kullanılarak derin mimarilerin bireysel performansları artırılmıştır. Bu bağlamda, performansı yükseltmek için katman sayısı artırılması yerine alternatif bir yol olarak bölme yaklaşımı kullanılabilirliği kanıtlanmıştır.
- Önerilen yöntemin uygulanması basittir ve karmaşık bir matematik altyapısı yoktur.
- Önerilen ÇB-ESA modeli, literatürde yaygın olarak kullanılan 8 farklı veri seti kullanılarak test edilmiştir. ÇB-ESA model, yapılan önceki çalışmalarla karşılaştırılmış ve tüm veri setlerinde daha başarılı olduğu gözlenmiştir.



6. BİTKİ HASTALIKLARININ TESPİTİ İLE İLGİLİ ÖNERİLEN YENİ YAKLAŞIMLAR

Bu bölümde, bitki hastalık tespiti için yerel ve derin özelliklere dayalı önerilen yaklaşımlar ve deneysel sonuçlar yer almaktadır. Bitki hastalıkları ile ilgili gerçekleştirilen çalışmalarda Bölüm 4’de bahsedilen inşa ettiğimiz veri seti kullanılmıştır.

6.1. Derin öğrenme tabanlı derin özellikler kullanarak bitki hastalık ve zararlı tespiti

Bu bölümde, bitki hastalıklarının tespiti için derin sinir ağlarına dayalı önceden eğitilmiş dokuz güçlü mimariler ile farklı yaklaşımlar kullanılarak performansları değerlendirilmiştir. Bu derin mimarileri, bitki hastalıkları tespiti ile ilgili probleme uyarlamak için transfer öğrenme ve derin özellik çıkarma gibi yaklaşımlar kullanılmıştır. Bu çalışmada, transfer öğrenmeye dayalı önceden eğitilmiş derin öğrenme mimarileri kullanılarak ince ayar işlemleri gerçekleştirilir. Derin özellik çıkarma yaklaşımı ise derin mimarilerin tam bağlı katmanlarından özellikler çıkartılır ve sınıflandırıcı yöntemleri kullanılarak test aşaması gerçekleştirilir. Bu çalışmada, elde edilen derin özellikler DVM, AÖM ve k-EYK sınıflandırıcıları kullanılarak en iyi performans elde edilmeye çalışılmıştır.

Deneysel çalışmalar, doğal hastalık ve zararlı bitki görüntülerinden inşa edilen veri seti kullanılarak gerçekleştirilmiştir.


6.1.1. Önerilen Yaklaşımlar

Bu bölümde, önceden eğitilmiş derin öğrenme mimarilerine dayalı transfer öğrenme ve derin özellik çıkarma yaklaşımları detaylandırılmıştır. Önerilen yaklaşımların genel şeması Şekil 6.1-2’de gösterilmiştir.

6.1.1.2. Transfer Öğrenme

Transfer öğrenme yaklaşımı, bir problemin çözümünde geliştirilen bir modelden elde edilen ağırlıklar ya da bilgiler kullanılarak farklı bir problemi çözmek için bir başlangıç noktası olarak yeniden kullanılmasına dayalıdır. Bu çalışmada, önceden eğitilmiş birçok derin öğrenme mimarileri için ince ayar işlemleri gerçekleştirilmiştir. Bitki hastalıklarının sınıflandırılması problemine adapte etmek için ince ayar işlemi uygulanmıştır ve bu işlem önceden eğitilmiş ağların son üç katmanı yerine yeni


katmanların transfer edilmesine dayalıdır. Buna ek olarak, bu çalışmada önceden eğitilmiş ESA modellerinin kullanılmasının sebebi, rasgele başlatılmış ağırlıkları olan bir ESA modelini eğitmekten daha hızlı ve daha kolay olmasıdır. Şekil 6.1’de, ince ayar işlemine dayalı transfer öğrenme yaklaşımı ile ilgili temsili bir örnek gösterilmiştir.



Şekil 6.1. Transfer Öğrenme yaklaşımı ile ilgili örnek bir gösterim.

6.1.1.2. Derin Özellik Çıkarma

Derin özellik çıkarma yaklaşımı, önceden eğitilmiş ESA mimarilerinin öğrenilen özelliklerinin ya da ağırlıklarının çıkartılmasına dayanmaktadır. Başka bir deyişle, bu yaklaşım kullanılarak önceden eğitilmiş mimarilerin tam bağlı katmanlarında derin özellikler elde edilir. Bu çalışmada, bitki hastalık tespiti için GoogleNet, ResNet50, ResNet101, InceptionV3, InceptionResNetV2, and SqueezeNet modellerinin belirli katmanlarından etkili derin özellikler çıkartılmıştır ve Çizelge 6.1’de bu katmanlar verilmiştir. Elde edilen derin özellikler, DVM, AÖM ve k-EYK yöntemleri kullanılarak sınıflandırma ve test işlemleri gerçekleştirilmiştir. Şekil 6.2’de, derin özellik çıkarma yaklaşımı ile ilgili temsili bir örnek gösterilmiştir.




Şekil 6.2. Derin özellik çıkarma yaklaşımı ile ilgili örnek bir gösterim.

Çizelge 6.1. Önceden eğitilmiş derin mimarilerin özellik çıkarıcı katmanları ve elde edilen özellik sayıları

	GoogleNet	ResNet50	ResNet101	Inceptionv3	InceptionResNetv2	SqueezeNet
Tam Bağlı Katman	pool5-drop_7x7_s1	fc1000	fc1000	predictions	predictions	pool10
Özellik Sayısı	1024	1000	1000	1000	1000	4096

Bu çalışmada, AlexNet, VGG16 ve VGG19 modellerinin her biri için üç tam bağlı katmanlarından elde edilen derin özellikler, DVM, AÖM ve k-EYK olmak üzere sınıflandırıcı yöntemleri kullanılarak performansları hesaplanmıştır. Daha sonra bu katmanların performansları karşılaştırılmış ve en iyi katmandan elde edilen derin özellikler belirlenmiştir. Buna ek olarak, AlexNet, VGG16 ve VGG19 modellerinin fc6 ve fc7 katmanlarından 4096 özellik vektörü elde edilirken, fc8 katmanından 1000 özellik vektörü elde edilmiştir. Şekil 6.3'de, bu yaklaşımın genel akış şeması sunulmuştur.



Şekil 6.3. AlexNet, VGG16 and VGG19 modellerinin genel akış şeması.

6.1.1.3. Önerilen Yaklaşımların İşlem Adımları

Aşağıdaki verilen işlem adımları, derin özellik çıkarıma yaklaşımını özetlemektedir:

- Adım 1:** Bitki hastalık görüntüsü elde et.
- Adım 2:** Bitki hastalık görüntüsünü bilinear interpolation kullanılarak derin ağların yapısına göre yeniden boyutlandır. Örneğin, 224 x 224 ve 227 x 227 boyutlarına sahip renkli görüntüler sırasıyla ResNet50 ve AlexNet modelleri için kullanılmıştır.
- Adım 3:** Derin öğrenme mimarilerinin tam bağlı katmanları kullanılarak derin özellikler elde edilir.
- Adım 4:** DVM, AÖM ve k-EYK yöntemleri kullanılarak elde edilen derin özelliklerin sınıflandırma işlemi gerçekleştirilir.

Aşağıdaki verilen işlem adımları, transfer öğrenme yaklaşımını özetlemektedir:

- Adım 1:** Bitki hastalık görüntüsü elde et.
- Adım 2:** Bitki hastalık görüntüsünü bilinear interpolation kullanılarak derin ağların yapısına göre yeniden boyutlandır. Örneğin, 224 x 224 ve 227 x 227 boyutlarına sahip renkli görüntüler sırasıyla ResNet50 ve AlexNet modelleri için kullanılmıştır.
- Adım 3:** Önceden eğitilmiş ESA mimarilerinin son üç katmanı çıkartılır ve yerini bir probleme adapte etmek için bu çıkartılan katmanların yerine tam bağlı bir katman, softmax katmanı ve bir sınıflandırma çıkış katmanı eklenir.
- Adım 4:** Yeni oluşturulan derin model kullanılarak sınıflandırma işlemi gerçekleştirilir.

6.1.2. Deneysel Çalışmalar

Bu bölümde, bitki hastalıklarının tespiti için Evrişimsel Sinir Ağlarına dayalı geliştirilen derin mimarilerden: AlexNet, VGG16, VGG19, GoogleNet, ResNet50, ResNet101, InceptionV3, InceptionResNetV2 ve SqueezeNet modellerinin performansları değerlendirilmiştir. Buna ek olarak, bitki hastalıklarının tespit sistemleri için yaygın olarak kullanılan Renk özellikleri ile YİÖ, GSEM ve YGH gibi geleneksel yöntemlerin de performansları incelenmiştir.

Bu çalışmada, derin mimarilerden elde edilen derin özellikleri sınıflandırmak ve test etmek için DVM, AÖM ve k-EYK yöntemleri kullanılmıştır. Deneysel çalışmalarda kullanılan bu yöntemlerin parametreleri şunlardır:

- *DVM yöntemi:* bire karşı hepsi yaklaşımı ile sınıflandırıcı türü olarak ise Kübik DVM yöntemi kullanılmıştır. Buna ek olarak, DVM parametresi olan C değişkeni için $[10^{-4} - 10^3]$ aralığındaki değerler araştırılmıştır.

- *AÖM yöntemi*: aktivasyon fonksiyonu sigmoid ile gizli katman nöron sayısı ise 10000 olarak belirlenmiştir.
- *k-EYK yöntemi*: uzaklık fonksiyonu olarak Oklid ile k değeri olarak ise 1 ve 3 değerleri kullanılarak deneysel çalışmalar yapılmıştır.

Farklı yaklaşımlar kullanılarak bu derin mimarilerin performanslarını test etmek için bitki hastalıkları ve zararlıları için inşa ettiğimiz veri seti kullanılmıştır. Bu veri seti, sekiz farklı bitki hastalık ve zararlıları içeren toplam 1965 görüntüden oluşmaktadır. Bu veri seti hakkında detaylı bilgiler Bölüm 4’de verilmiştir. Veri seti 10 kat çapraz doğrulama işlemine göre önceden bölümlere ayrılmıştır. Her bitki türü için eğitim ve test sayıları Çizelge 6.2’de verilmiştir.

Çizelge 6.2. Deneysel çalışmalar için eğitim ve test sayıları.

Bitki hastalık ve zararlıları	Eğitim	Test	Toplam
Kayısı çil	545	61	606
Kayısı monilya	76	9	85
Ceviz gal akarı	62	7	69
Şeftali koşnil	310	35	345
Şeftali monilya	278	31	309
Kiraz yaprak biti	175	19	194
Ceviz bakteriyel yanıklık	129	14	143
Armut ateş yanıklığı	193	21	214
Toplam	1768	197	1965

Deneysel sonuçlar ve performans karşılaştırmaları aşağıdaki alt başlıklar altında detaylandırılmıştır.

6.1.2.1. AlexNet, VGG16 ve VGG19 Modelleri kullanılarak derin özellik çıkarmaya dayalı performans sonuçları

Bu bölümde, önceden eğitilmiş ESA mimarilerinden AlexNet, VGG16 ve VGG19 modellerinin üç farklı tam bağlı katmanları (fc6,fc7,fc8) kullanılarak özellikler çıkartılmıştır. Daha sonra, elde edilen bu derin özellikler DVM, AÖM ve k-EYK yöntemleri kullanılarak sınıflandırma performansları hesaplanmıştır. Bu deneysel çalışmaların doğruluk skorları Çizelge 6.3’de verilmiş ve bu doğruluk skorları katlar (10 kat) arasında hesaplanılan ortalama doğruluk skoru ve onların standart sapmalarına göre belirlenmiştir.

Çizelge 6.3. Derin özelliklere dayalı doğruluk skorları (%)

Sınıflandırıcı Yöntemleri	AlexNet			VGG16			VGG19		
	fc6	fc7	fc8	fc6	fc7	fc8	fc6	fc7	fc8
DVM	95.5±1.2	94.1±0.65	92.2±0.92	95.00±1.4	93.7±1.21	92.5±0.7	94.45±0.8	93.99±0.74	91.76±1.26
AÖM	93.41±0.72	92.29±0.5	91.53±0.96	94.84±1.12	93.57±0.62	92.11±0.8	94.74±1.14	94.38±0.81	93.01±0.54
k-EYK	89.41±1.8	89.01±1.41	84.5±1.02	88.55±1.49	87.00±1.11	84.7±0.82	89.01±1.52	87.94±1.38	85.5±0.98

Çizelge 6.3’de, AlexNet, VGG16 ve VGG19 modellerinin her biri için fc6, fc7 ve fc8 katmanlarından elde edilen derin özellikler DVM, AÖM ve k-EYK sınıflandırıcıları kullanılarak performans sonuçları verilmiştir. Elde edilen doğruluk skorlarına göre, fc6 katmanının bu modeller için en iyi derin özelliklere sahip olduğu tespit edilmiştir. AlexNet modeli için en yüksek doğruluk skoru %95.5 olarak DVM sınıflandırıcısı kullanılarak hesaplanmıştır. Bunun yanı sıra, VGG16 modeli için en yüksek doğruluk skoru DVM sınıflandırıcısı kullanılarak %95 elde edilirken, VGG19 modeli için en yüksek doğruluk skoru ise AÖM sınıflandırıcısı ile %94.74 olarak elde edilmiştir. Ayrıca bu deneysel çalışmalarla ilgili duyarlılık, özgüllük ve F1-skor gibi performans ölçütleri Çizelge 6.4’de verilmiştir.

Çizelge 6.4. Derin özelliklere dayalı performans ölçütleri (%).

Sınıflandırıcı Yöntemleri	Performans Ölçütleri	AlexNet			VGG16			VGG19		
		fc6	fc7	fc8	fc6	fc7	fc8	fc6	fc7	fc8
DVM	Duyarlılık	94.34	93.03	89.61	93.02	91.91	89.96	92.22	92.41	89.34
	Özgüllük	99.35	99.22	98.78	99.31	99.12	98.88	99.19	99.13	98.79
	F1- skor	94.58	93.49	90.02	93.19	91.69	89.87	92.47	92.44	89.10
AÖM	Duyarlılık	90.75	89.44	88.20	92.12	91.51	89.85	92.67	91.87	89.98
	Özgüllük	99.00	98.86	98.70	99.22	99.08	98.87	99.23	99.12	98.97
	F1- skor	91.29	90.23	89.30	92.46	91.99	90.36	93.06	91.93	90.65
k-EYK	Duyarlılık	87.94	87.07	76.31	86.56	83.87	82.61	87.28	85.43	82.88
	Özgüllük	98.38	98.35	97.38	98.35	98.01	97.75	98.40	98.23	97.85
	F1- skor	87.35	86.33	78.03	85.46	82.69	80.94	86.33	84.87	82.03

AlexNet, VGG16 ve VGG19 modellerinin tam bağlı katmanlarının her birinin gerçekleştirme süreleri Çizelge 6.5’de verilmiştir.

Çizelge 6.5. Derin özelliklere dayalı gerçekleştirme süreleri.

AlexNet			VGG16			VGG19		
fc6	fc7	fc8	fc6	fc7	fc8	fc6	fc7	fc8
31 sn	32 sn	34 sn	1 dak 6 sec	1 dak 7 sn	1 dak 9 sn	1 dak 15 sn	1 dak 16 sn	1 dak 19 sn

Çizelge 6.5'den anlaşılacağı üzere, fc6, fc7 ve fc8 özellik çıkarıcı katmanları için AlexNet, üç model arasında en düşük gerçekleştirme süresine sahipken, VGG16 ve VGG19 için gerçekleştirme süreleri yaklaşık olarak eşittir.

6.1.2.2. Diğer derin öğrenme mimarileri kullanılarak derin özellik çıkarmaya dayalı performans sonuçları

Bu bölümde, önceden eğitilmiş ESA mimarilerinden GoogleNet, ResNet50, ResNet101, InceptionV3, InceptionResNetV2 ve SqueezeNet modellerinin tam bağlı katmanları kullanılarak derin özellikler çıkartılmıştır. Bu modellerin her biri için, Çizelge 2'de verilen tam bağlı katmanlar kullanılmıştır. Daha sonra, elde edilen bu derin özellikler DVM, AÖM ve k-EYK yöntemleri kullanılarak sınıflandırma performansları hesaplanmıştır. Bu deneysel çalışmaların doğruluk skorları Çizelge 6.6'da verilmiş ve bu doğruluk skorları katlar (10 kat) arasında hesaplanan ortalama doğruluk skoru ve onların standart sapmalarına göre belirlenmiştir.

Çizelge 6.6. Derin özelliklere dayalı derin mimarilerinin doğruluk skorları (%)

Sınıflandırıcı Yöntemleri	GoogleNet	ResNet50	ResNet101	Inceptionv3	InceptionResNetv2	SqueezeNet
DVM	95.22±1.24	97.86±1.56	96.74±0.64	94.96±1.22	94.76±1.04	95.62±1.08
AÖM	94.18±0.96	97.65±1.34	97.45±0.78	94.54±0.87	95.20±1.16	95.10±0.94
k-EYK	89.16±2.06	90.48±2.24	91.20±1.41	88.65±1.52	88.80±2.2	87.02±3.82

Çizelge 6.6'da, GoogleNet, ResNet50, ResNet101, InceptionV3, InceptionResNetV2 ve SqueezeNet modellerinin belirli katmanlarından elde edilen derin özellikler DVM, AÖM ve k-EYK yöntemleri kullanılarak performans sonuçları verilmiştir. ResNet50 modeli ve DVM sınıflandırıcısı, diğer derin mimariler arasında %97.86 olarak en yüksek doğruluğa sahiptir. Bu derin öğrenme mimarileri arasında DVM yöntemi kullanılarak en yüksek doğruluk skorları GoogleNet modeli için %95.22, InceptionV3 modeli için %94.96 ve SqueezeNet modeli için %95.62 elde edilmiştir. AÖM sınıflandırıcısını kullanarak en yüksek doğruluk skorları ise ResNet101 modeli için %97.34 ve InceptionResNetV2 modeli için %95.35 elde edilmiştir. Ek olarak, bu deneysel çalışmalarla ilgili duyarlılık, özgüllük ve F1-skor gibi performans ölçütleri Çizelge 6.7'de verilmiştir.

Çizelge 6.7. Derin özelliklere dayalı derin mimarilerinin performans ölçütleri (%)

Sınıflandırıcı Yöntemleri	Performans Ölçütleri	GoogleNet	ResNet50	ResNet101	Inceptionv3	InceptionResNetv2	SqueezeNet
DVM	Duyarlılık	94.21	97.35	95.02	92.66	91.94	93.91
	Özgüllük	99.30	99.69	99.53	99.25	99.24	99.36
	F1- skor	94.13	97.14	94.92	93.20	92.13	93.83
AÖM	Duyarlılık	92.09	96.60	96.21	91.39	92.54	93.12
	Özgüllük	99.14	99.66	99.63	99.18	99.28	99.26
	F1- skor	92.57	96.70	96.26	92.31	93.17	93.51
k-EYK	Duyarlılık	86.12	88.80	89.34	84.84	84.52	83.78
	Özgüllük	98.40	98.59	98.71	98.25	98.33	98.10
	F1- skor	86.02	88.01	88.40	85.65	84.39	83.19

Bu derin mimarilerin her biri için gerçekleştirme süreleri Çizelge 6.8'de verilmiştir.

Çizelge 6.8. Derin özelliklere dayalı derin mimarilerinin gerçekleştirme süreleri

GoogleNet	ResNet50	ResNet101	Inceptionv3	InceptionResNetv2	SqueezeNet
1 dak 41 sn	2 dak 21 sn	4 dak 11 sn	9 dak 29 sn	28 dak 13 sn	1 dak 3 sn

Çizelge 6.8'den anlaşılacağı üzere, SqueezeNet (1 dk, 3 sn) diğer modeller arasında en düşük gerçekleştirme süresine sahip iken, InceptionResNetV2 (28 dk, 13 sn) en yüksek gerçekleştirme süresine sahiptir. Derçekleştirme sürelerine dayalı diğer sonuçlara göre; GoogleNet modeli (1 dak, 41 sn.) SqueezeNet modelinden (1 dak, 3 sn) daha yavaştır, ResNet101 modeli (4 dak, 11 sn) ResNet50 modelinin (2 dak, 21 sn) yaklaşık olarak iki katı kadar daha hızlıdır ve InceptionV3 modeli (9 dakika, 29 saniye) ResNet50 modelinden (2 dakika, 21 saniye) dört kat daha yavaştır.


Çizelge 6.9'da, en iyi doğruluk modeli (ResNet50 modeli ve DVM sınıflandırıcısı) için karışıklık matrisi verilmiştir.

Çizelge 6.9. En iyi doğruluk modelinin karışıklık matrisi (gri gölgeleme doğru sınıflandırmayı gösterir)

	1	2	3	4	5	6	7	8
1	204	1			2	1		6
2		138	4			1		
3		1	68					
4				83			1	1
5					606			
6	1	3				186		4
7			1				343	1
8	2	1	1	2	1	2	5	295

Not: 1. Armut ateş yanıklığı; 2. Ceviz bakteriyel yanıklık; 3. Ceviz gal akarı; 4. Kayısı monilya; 5. Kayısı çil; 6. Kiraz yaprak biti; 7. Şeftali koşnil; 8. Şeftali monilya.

Bu çalışmada kullanılan veri setindeki sınıfların içerdikleri görüntü sayıları heterojendir. Bu sebeple, her sınıf için Doğruluk, Duyarlılık, Özgüllük ve F1-skor gibi performans ölçütlerin hesaplanmıştır ve ResNet50 modeli ile DVM sınıflandırıcısı kullanılarak elde edilen sonuçlar Şekil 6.4’de gösterilmiştir.



Şekil 6.4. ResNet50 modeli ile DVM sınıflandırılmasına dayalı her bir sınıf için performans ölçütleri

6.1.2.3. Derin öğrenme modelleri kullanılarak transfer öğrenme yaklaşımına dayalı performans sonuçları

Bu bölümde, AlexNet, GoogleNet, VGG16, VGG19, ResNet50, ResNet101, InceptionV3, InceptionResNetV2 ve SqueezeNet gibi önceden eğitilmiş ESA mimarileri kullanılarak transfer öğrenmeye dayalı ince ayar işlemi gerçekleştirilmiştir. Transfer öğrenme parametreleri için batch boyutu 10, epoch sayısı 7 ve başlangıç öğrenme hızı ise 0,0004 olarak belirlenmiştir. Bunlara ek olarak, SDAM (Stokastik Dereceli Alçalma ile Momentum) optimizasyon yöntemi kullanılarak derin ağın eğitimi gerçekleştirilmiştir. Eğitim işlemi 1250 iterasyondan sonra sona ermiştir. Bu deneysel çalışmaların doğruluk skorları Çizelge 6.10’da verilmiştir ve bu doğruluk skorları katlar (10 kat) arasında hesaplanan ortalama doğruluk skoru ve onların standart sapmalarına göre belirlenmiştir.

Çizelge 6.10. Transfer öğrenmeye dayalı derin mimariler için doğruluk skorları.

AlexNet	VGG16	VGG19	GoogleNet	ResNet50	ResNet101	Inceptionv3	InceptionResNetv2	SqueezeNet
93.33±2.41	96.92±1.26	94.87±1.3	95.38±1.02	95.38±0.9	96.41±0.86	92.31±2.12	89.23±3.46	91.28±1.96


Çizelge 6.10’da, dokuz derin sinir ağ mimarisinin transfer öğrenme yaklaşımına dayalı doğruluk skorları gösterilmiştir. Bu sonuçlara göre, VGG16 modeli diğer derin modeller arasında %96.92 olarak en iyi doğruluk skoruna sahip iken, InceptionResNetV2

modeli ise %89.23 olarak en düşük doğruluğa sahiptir. Buna ek olarak, ResNet101 modeli kullanılarak ikinci en iyi doğruluk skoru (%96.41) elde edilirken, GoogleNet ve ResNet50 modelleri kullanılarak en iyi üçüncü doğruluk skoru (%95.38) elde edilmiştir. Ayrıca, bu deneysel çalışmalarla ilgili duyarlılık, özgülük ve F1-skor gibi performans ölçütleri Çizelge 6.11'de verilmiştir.

Çizelge 6.11. Transfer öğrenmeye dayalı derin mimariler için performans ölçütleri.

Performans Ölçütleri	AlexNet	VGG16	VGG19	GoogleNet	ResNet50	ResNet101	Inceptionv3	InceptionResNetv2	SqueezeNet
Duyarlılık	88.02	96.64	92.24	92.29	94.91	95.81	87.05	85.09	89.22
Özgülük	99.00	99.54	99.14	95.75	99.36	99.43	98.90	98.48	98.70
F1-skor	88.30	96.38	93.87	93.53	93.28	95.94	88.76	85.15	88.33

Transfer öğrenme yaklaşımına dayalı olarak bu çalışmada kullanılan derin mimarilerden en iyi doğruluğa sahip VGG16 modelinin iterasyonlara karşı eğitim doğruluğu ve eğitim kaybının değişimi Şekil 6.5’de gösterilmiştir.



Şekil 6.5. Artan iterasyon sayısının etkileri

Şekil 6.5'de anlaşılacağı üzere, eğitim doğruluğu ilk iterasyonlarda hızlı bir şekilde artmasına rağmen daha sonra çok yavaş bir şekilde artmaya devam etmiştir. Buna benzer şekilde, eğitim kaybındaki değişim ilk iterasyonlarda hızlı şekilde azalmasına rağmen daha sonra çok yavaş bir şekilde azalmaya devam etmiştir. Bu bağlamda, ilk iterasyonlar modeli ezberlemek yerine hedeflenen işlevi iteratif olarak optimum değere doğru ilerlemiş ve kayıp fonksiyonunu en aza indirmiştir.

Çizelge 6.12. Transfer öğrenmeye dayalı mimarilerin gerçekleştirme süreleri

AlexNet	VGG16	VGG19	GoogleNet	ResNet50	ResNet101	Inceptionv3	InceptionResNetv2	SqueezeNet
5 dak 48 sn	15 dak 26 sn	42 dak 53 sn	11 dak 30 sn	20 dak 49 sn	31 dak 30 sn	40 dak 39 sn	111 dak 21 sn	8 dak 33 sn

Çizelge 6.12'de, kullanılan derin modellerin gerçekleştirme süreleri gösterilmektedir. Bu sonuçlara göre, AlexNet modeli diğer mimariler arasında en hızlı gerçekleştirme süresine (5 dak, 48 sn) sahipken, InceptionResNetV2 modeli ise en yavaş

gerçekleştirme süresine (1 saat, 51 dak, 21 saniye) sahiptir. Bunun yanı sıra, SqueezeNet modeli(8 dakika, 33 saniye), GoogleNet (11 dakika, 30 saniye) ve VGG16 (15 dakika, 26 saniye) modellerinden daha hızlı bir gerçekleştirme süresine sahiptir. Ayrıca, ResNet50 modeli (20 dakika, 49 saniye) VGG19 modelinin (42 dakika, 53 saniye) gerçekleştirme süresinin yaklaşık olarak iki katı ve ResNet101 modelinden (31 dakika, 30 saniye) üçte iki oranında daha hızlıdır.

6.1.2.4. Geleneksel yöntemlere dayalı performans sonuçları

Bu bölümde, bitki hastalıklarının sınıflandırılmasına dayalı geliştirilen sistemlerde yaygın olarak kullanılan geleneksel renk özellikleri ile YİÖ, YGH ve GSEM yöntemleri uygulanmıştır. Bu yöntemlerden elde edilen özellikler DVM, AÖM ve k-EYK yöntemleri kullanılarak doğruluk skorları hesaplanmıştır ve bu sonuçlar Çizelge 6.13'de gösterilmiştir.


Çizelge 6.13. Geleneksel yöntemler için doğruluk skorları (%)

Sınıflandırıcı Yöntemleri	YİÖ	YGH	Renk Özellikleri	GSEM
DVM	70.9	56.8	45.3	45.2
AÖM	68.26	53.36	43.57	42.85
k-EYK	61.4	46.5	35.9	38.5

Çizelge 6.13'de, renk özellikleri ile YİÖ, YGH ve GSEM yöntemlerinden elde edilen özellikler DVM, AÖM ve k-EYK sınıflandırıcıları kullanılarak doğruluk skorları gösterilmiştir. Çizelge 14'den anlaşılacağı üzere, geleneksel tanımlayıcıların için en iyi performans DVM sınıflandırıcısı kullanılarak elde edilmiştir. Bu sonuçlara göre, DVM sınıflandırıcı kullanılarak elde edilen en iyi performanslar YİÖ yöntemi için %70.9, YGH metodu için %56.8, Renk Özellikleri için %45.3 ve GSEM metodu için ise %45.2 olarak hesaplanmıştır.

6.1.2.5. Benzetim sonuçlarının karşılaştırılması

Bu çalışma, en iyi performansa sahip bitki hastalığı tespit sistemini tanımlamak için önceden eğitilmiş dokuz güçlü derin öğrenme modelini kullanılmıştır. Bu derin öğrenme modellerinin performansları transfer öğrenme ve derin özellik çıkarımına dayalı yaklaşımlar kullanılarak hesaplanmıştır. Bunun yanı sıra, bitki hastalığı tespit sistemlerinde yaygın olarak kullanılan geleneksel yöntemler uygulanmıştır. Derin mimarilere dayalı yaklaşımlar (transfer öğrenme ve derin özellik çıkarımı) ile geleneksel yöntemlerin doğruluk skorları genel olarak karşılaştırılmış ve Şekil 6.6'da gösterilmiştir.



Şekil 6.6. Kullanılan yöntem ve modellerin doğruluk skorlarının karşılaştırılması

Şekil 6.6'dan anlaşılacağı üzere, en yüksek doğruluk skoru %97.86 olarak ResNet50+DVM modeli kullanılarak elde edilirken, ResNet101+DVM modeli kullanılarak ikinci en iyi doğruluk skoru %97.45 olarak elde edilmiştir. Transfer öğrenme yaklaşımına dayalı en iyi doğruluk skoru ise VGG16 modeli kullanılarak %96.92 hesaplanmıştır. Şekil 10'da, geleneksel yöntemlerin derin öğrenme modellerine kıyasla çok düşük performansa sahip olduğu gözlenmiştir. Bunun yanı sıra, geleneksel yöntemler arasında en yüksek doğruluk YİÖ-DVM modeli ile %70.9 olarak hesaplanmıştır.

Derin mimarilerin her bir modeli için derin özellik çıkarımı ve transfer öğrenme yaklaşımlarının doğruluk skorlarına dayalı karşılaştırmalar aşağıda maddeler halinde verilmiştir:

- ResNet50 modeline dayalı derin özellikler ile DVM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan ResNet50 modeline göre daha başarılıdır.
- ResNet101 modeline dayalı derin özellikler ile AÖM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan ResNet101 modeline göre daha başarılıdır.
- SqueezeNet modeline dayalı derin özellikler ile DVM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan SqueezeNet modeline göre daha başarılıdır.

- AlexNet modeline dayalı derin özellikler ile DVM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan AlexNet modeline göre daha başarılıdır.
- InceptionResNetV2 modeline dayalı derin özellikler ile AÖM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan InceptionResNetV2 modeline göre daha başarılıdır.
- InceptionV3 modeline dayalı derin özellikler ile DVM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan InceptionV3 modeline göre daha başarılıdır.
- VGG16 modeline dayalı derin özellikler ile DVM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan VGG16 modeline göre başarımı daha düşüktür.
- GoogleNet modeline dayalı derin özellikler ile DVM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan GoogleNet modeline göre başarımı daha düşüktür.
- VGG19 modeline dayalı derin özellikler ile DVM sınıflandırıcısı, transfer öğrenme yaklaşımına dayalı ince ayar işlemi uygulanan VGG19 modeline göre başarımı daha düşüktür.

Gerçekleştirilen deneysel sonuçlara göre, önceden eğitilmiş ESA mimarilere dayalı derin özellik çıkarma yaklaşımı ile DVM-AÖM sınıflandırıcılarının, transfer öğrenme yaklaşımına göre daha yüksek performans sağladığı gözlenmiştir. Buna ek olarak, kullanılan derin mimarilerin her biri katman sayısı, bağlantı sayısı ve filtre türleri gibi benzersiz özelliklere sahiplerdir. Ayrıca, bu çalışmada kullanılan derin mimarilerin katman veya bağlantı sayılarının sınıflandırma performansları ile doğru orantılı olmadığı gözlenmiştir. Örneğin, ResNet mimarisinin InceptionResNetV2 mimarisinden daha az katman ve bağlantı sayısı olmasına rağmen performansı daha yüksektir.

Bu çalışmada, Çizelge 6.8 ve 6.12'de gösterildiği üzere, derin öğrenme modellerine dayalı derin özellik çıkarımı ve transfer öğrenme yaklaşımları için gerçekleştirme süreleri hesaplanmıştır. Bu sonuçlara göre, derin özellik çıkarımı yaklaşımı transfer öğrenmeye kıyasla çok daha düşük bir gerçekleştirme süresine sahiptir. Örneğin, AlexNet modeline dayalı derin özellik çıkarımı, ince ayarlı işlemi uygulanan

AlexNet modeline göre gerçekleştirme süresi yaklaşık olarak on kat daha düşüktür. Sonuç olarak, derin özellik çıkarımına dayalı önerilen mimari, transfer öğrenme yaklaşımından daha düşük gerçekleştirme süresiyle sonuçlanmasına ve daha yüksek doğruluk skoruna sahiptir.

Bitki hastalıkları ve zararlıları tespiti için önerilen yaklaşımların genel olarak literatüre katkıları ve avantajları şunlardır;

- Gerçek zamanlı görüntüler kullanılarak bitki hastalık ve zararlıların sınıflandırması, makine öğrenmesi için zor bir problemdir. Bu problemin çözümü için literatürde yapılan çalışmalarda çeşitli yöntemler geliştirilmiştir. Günümüzde derin öğrenme yöntemleri, makine öğrenmesi olgusudur ve denetimli öğrenim için evrimsel sinir ağlarına dayalı çok sayıda derin mimariler geliştirilmiştir. Bu çalışmada kullanılan dokuz güçlü derin ağ mimarilerine dayalı (AlexNet, GoogleNet, VGG16, VGG19, ResNet50, ResNet101, InceptionV3, Inception ResNetV2 ve SqueezeNet) transfer öğrenimi ve derin özellik çıkarımı yaklaşımları kullanılarak bitki hastalıkları ve zararlıları tespiti için değerlendirilmiş ve performans sonuçları kapsamlı bir şekilde tartışılmıştır.
- Bu çalışmada, önceden eğitilmiş derin öğrenme ağları ile geleneksel sınıflandırıcılar kullanılarak yeni bir sınıflandırma mimarisi önerilmiştir. Bitki hastalık ve zararlı tespiti için önceden eğitilmiş mimarilerin ağırlıkları kullanılarak derin özellikler çıkartılmıştır. Elde edilen bu özellikler DVM, AÖM ve k-EYK gibi geleneksel sınıflandırıcı yöntemleri kullanarak performansları hesaplanmıştır. Gerçekleştirilen deneysel sonuçlara göre, önerilen sınıflandırma mimarisinin transfer öğrenme yaklaşımından daha yüksek sınıflandırma doğruluğuna sahip olduğu tespit edilmiştir.
- Önerilen mimari, transfer öğrenmeye dayalı modellerden daha düşük hesaplama karmaşıklığına sahiptir. Bu durum gerçekleştirme süresi hesaplaması kullanılarak kanıtlanmıştır.
- Literatürde, genel olarak sentetik bitki hastalık ve zararlı görüntüler kullanılarak çalışmalar yapılmıştır. Bu çalışmada, sekiz sınıflı olamk üzere toplam 1965 gerçek bitki hastalık ve zararlı görüntülerinden oluşan veri seti inşa edilmiştir. Derin mimarilere dayalı farklı yaklaşımlar bu veri seti üzerinde test edilmiştir ve

elde edilen sonuçlara göre önerilen yaklaşımların gerçek dünya uygulamalarında kullanılabileceği kanıtlanmıştır.

6.2. Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması


Bu bölümde, kayısı hastalıklarının tespiti için DESA dayalı bir model geliştirilmiştir. Önerilen model, Evrişim, Relu, Normalizasyon, Havuzlama ve tam bağlı katmanlardan oluşmaktadır. Buna ek olarak, bu çalışmada evrişim katmanlarında kullanılan filtrelerin pencere boyutu 3×3 , 5×5 , 7×7 , 9×9 ve 11×11 olmak üzere beş farklı filtre çeşitleri kullanılmıştır. Bu bağlamda, önerilen model kullanılarak farklı evrişim filtrelerinin performansları değerlendirilmiştir. Bu çalışmada, Bingöl ve İnönü Üniversitelerinin Ziraat Fakültelerinin çalışma alanları kullanılarak kayısı hastalık görüntülerinden oluşan bir veri tabanı elde edilmiştir. Geliştirilen model, gerçek zamanlı elde edilen bu veri seti kullanılarak test edilmiştir. Yapılan deneysel çalışmalarda, kayısı hastalık tespiti için önerilen derin ağ modeli, önceden eğitilmiş derin mimariler ve geleneksel görüntü tanımlayıcılarına göre daha yüksek doğruluk skoru elde edildiği tespit edilmiştir.

6.2.1. Önerilen Derin Model

Bu bölümde, kayısı hastalıklarının tespiti için Evrişimsel Sinir Ağlarına dayalı önerilen model detaylandırılmıştır. Önerilen modeli oluşturan katmanlar sırasıyla aşağıda verilmiştir:

- İlk katman ham görüntünün verildiği giriş katmanıdır.
- İkinci, altıncı ve dokuzuncu katmanlar evrişim katmanlarıdır. Bu katmanlar sırasıyla 32, 64 ve 128 adet evrişim filtreleri içermektedir.
- Üçüncü, yedinci ve onuncu katmanlar aktivasyon fonksiyonu olan Relu katmanlarıdır. Dördüncü, sekizinci, on birinci ve on dördüncü katmanlar normalizasyon katmanlarıdır. Beşinci ve on ikinci katmanlar maksimum havuzlama katmanıdır. Bu katmanlarda 3×3 'lük pencere boyutu kullanılmıştır.
- On üçüncü katman 64 nöronlu tam bağlı katmandır.
- Son katmanlar ise bir tam bağlı katmanı, bir softmax kaybı katmanı ve sınıflandırma katmanlarıdır.

Önerilen modelin genel akış adımları Şekil 6.7’de gösterilmiştir.



Şekil 6.7. Önerilen derin model

Evrişim katmanlarında, 3×3 , 5×5 , 7×7 , 9×9 ve 11×11 pencere boyutlarına sahip beş farklı filtre çeşidi kullanılmıştır. Önerilen model kullanılarak her bir filtre türü için ayrı ayrı deneysel çalışmalar yapılmıştır.

6.2.2. Deneysel Çalışmalar

Önerilen evrişimsel sinir ağlarına dayalı derin modelin performansını test etmek için inşa ettiğimiz kayısı hastalık görüntülerini içeren veri seti kullanılmıştır. Bu veri seti, dört farklı kayısı hastalık türlerini içeren toplam 886 görüntüden oluşmaktadır. Bu veri seti hakkında detaylı bilgiler Bölüm 4’de verilmiştir. Deneysel çalışmalarda, iki veri seti için eğitim - test kümeleri sırasıyla %70 ile %30 olarak rastgele bir şekilde ayrılmış ve bu işlem sadece bir defa yapılmıştır. Rastgele ayrılan verilerin performansa etkilerini en aza indirmek için tüm uygulamalarda aynı eğitim ve test kümesi kullanılmıştır. Her kayısı hastalık türü için eğitim ve test sayıları Çizelge 6.14’de verilmiştir.

Çizelge 6.14. Deneysel çalışmalar için eğitim ve test sayıları.

Kayısı hastalıkları	Eğitim	Test	Toplam
Çil	350	117	467
Monilya	64	21	85
Kanser Belirtisi	104	35	139
Kuruma Belirtisi	146	49	195
Toplam	664	222	886

Önerilen modelin performansı beş farklı evrişim filtresi kullanılarak ayrı ayrı hesaplanmıştır. Bu model için kullanılan ağ parametreleri Çizelge 6.15’de verilmiştir.

Çizelge 6.15. Deneysel çalışmalar için kullanılan ağ parametreleri.

Epoch sayısı :	10
Batch boyutu :	7
Öğrenme katsayısı (learning rate) :	0.0001
Optimizasyon yöntemi :	SDAM

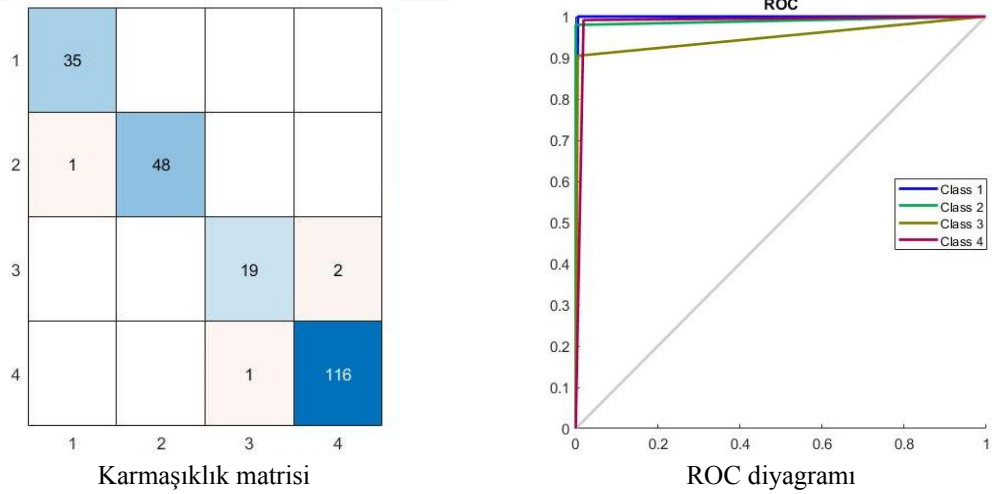
Önerilen modelin; doğruluk, duyarlılık ve özgüllük, kesinlik ve F1-skor değerleri gibi performans ölçütleri Çizelge 6.16’da verilmiştir.

Çizelge 6.16. Önerilen derin modelin performans sonuçları

Performans ölçütleri	Evrışim filtreleri				
	3×3	5×5	7×7	9×9	11×11
Doğruluk	97.30	96.40	96.85	98.20	95.50
Duyarlılık	94.81	92.59	92.35	96.90	88.57
Özgüllük	98.79	98.48	98.44	99.27	97.73
Kesinlik	97.08	96.95	98.09	97.63	96.29
F1-skor	94.80	94.48	94.60	97.24	91.36

Çizelge 6.16’da, önerilen modelin evrişim katmanlarında kullanılan 3×3, 5×5, 7×7, 9×9 ve 11×11 pencere boyutlarına sahip evrişim filtrelerinin ayrı ayrı performansları verilmiştir. Önerilen modelde 9×9 evrişim filtresi kullanılarak %98.20 oranında en yüksek doğruluk skoru elde edilirken, en düşük doğruluk 11×11 evrişim filtresi kullanılarak elde edilmiştir. Bu deneysel sonuçlara göre, evrişim katmanında farklı boyutlarda filtreler kullanıldığında doğruluk skorları arasında önemli farklılıklar olduğu gözlenmiştir.

Önerilen modelde 9×9 evrişim filtresi kullanılarak elde edilen en yüksek performansın karmaşıklık matrisi ve AİK diyagramı Şekil 6.8’de verilmiştir.



Şekil 6.8. Önerilen modelin performans gösterimleri

Şekil 6.8’de, sınıf 1, 2, 3 ve 4 olarak gösterilen değerler sırasıyla kanser belirtisi, kuruma belirtisi, monilya hastalığı ve çil hastalığını temsil etmektedir. Buna ek olarak, Şekil 6.8’den anlaşılacağı üzere, önerilen model kullanılarak kayısı hastalık türlerinden kanser belirtisini tanıma başarımı %100 olarak elde edilmiştir. Bunun yanı sıra, diğer

kayıslı hastalık türleri için kuruma belirtisinde 1, monilya hastalığında 2 ve çil hastalığında 1 olarak yanlış hastalık tespiti yapılmıştır.

ESA'ya dayalı geliştirilen ve birbirinden farklı özelliklere sahip çok sayıda derin mimari mevcuttur. Bu çalışmada, AlexNet, SqueezeNet, Inceptionv3, InceptionResNetv2 ve GoogleNet gibi nesne tanıma alanında kullanılan modeller, kayıslı hastalık tespiti için uygulanmıştır. Bu modelleri, kayıslı hastalık tespit problemine uyarlamak için transfer öğrenme yaklaşımı benimsenmiştir. Transfer öğrenme yaklaşımı, önceden eğitilmiş derin mimarilerin son üç katmanının yerine bir tam bağlı katman, bir softmax katmanı ve çıkış katmanı eklenir ve yeni problem için bu derin mimari adapte edilmiş olunur. bu mimarilerin performans sonuçları Çizelge 6.17'de verilmiştir. Önerilen model ile bu mimarilerin performans sonuçlarının karşılaştırılabilmesi için: ağ parametreleri (Çizelge 6.14) ile eğitim ve test verileri (Çizelge 6.15) aynı olarak ayarlanmıştır.

Çizelge 6.17. Önceden eğitilmiş derin mimarilerin sınıflandırma sonuçları (%)

AlexNet	SqueezeNet	Inceptionv3	InceptionResNetv2	GoogleNet
97.75	73.87	97.30	90.99	98.87

Çizelge 6.17'den anlaşılacağı üzere, önceden eğitilmiş derin mimarilerden en yüksek performans GoogleNet modeli ile %98.87 olarak elde edilmiştir. İkinci en yüksek performans AlexNet mimarisi ile %97.75 doğruluk elde edilirken en kötü performans %73.87 olarak SqueezeNet mimarisi ile elde edilmiştir.


Bu çalışmada, evrimsel sinir ağları dışında hastalık tespiti için geleneksel görüntü tanımlayıcıları ve makine öğrenmesi sınıflandırıcıları kullanılarak performansları değerlendirilmiştir. Geleneksel görüntü tanımlayıcılarından literatürde yapılan çalışmalarda yaygın olarak kullanılan ve performansları yüksek olan Renk Özellikleri ile YİÖ, YGH ve GSEM yöntemleri kullanılmıştır. Bu yöntemlerden elde edilen özellik vektörleri DVM sınıflandırıcısı kullanılarak performansları hesaplanmıştır. Sınıflandırıcı olarak kullanılan DVM yönteminde, bire karşı hepsi yaklaşımı ve kübik çekirdek fonksiyonu gibi parametreler kullanılmıştır. Kayıslı hastalık tespiti için geleneksel görüntü tanımlayıcılarının bireysel performans sonuçları Çizelge 6.18'de gösterilmiştir.

Çizelge 6.18. Geleneksel yöntemlerin sınıflandırma sonuçları (%)

YİÖ	YGH	Renk istatistikleri	GSEM
89.64	86.94	76.58	81.98

Çizelge 6.18'den anlaşılacağı üzere, geleneksel görüntü tanımlayıcıları arasında en yüksek doğruluk %89.64 oranında YİÖ yöntemi ile elde edilirken, en kötü performans ise %81.98 olarak GSEM yöntemi ile elde edilmiştir.

Bu çalışmada, önerilen model ile birlikte önceden eğitilmiş derin mimariler ve geleneksel yöntemlerin tüm performans sonuçları Şekil 6.9'da verilmiştir.



Şekil 6.9. Doğruluk skorlarının karşılaştırılması

Şekil 6.9'da anlaşılacağı üzere, önerilen model kullanılarak geleneksel yöntemlere göre üstün performans sağlamıştır. GoogleNet mimarisi kullanılarak %98.87 olarak en yüksek doğruluk skoru elde edilmiş ve önerilen model ile performansları yaklaşık olarak eşittir. Diğer önceden eğitilmiş derin mimarilere göre önerilen model daha yüksek performans sağlamıştır. Bu derin mimariler, 1000 sınıflı büyük veri setleri ile eğitilmesine rağmen transfer öğrenme yaklaşımına dayalı olarak kullanıldığında önerilen modelden daha düşük performans elde edilmiştir.

Genel olarak, önerilen modelin literatüre katkıları ve avantajları şunlardır:

- Bu çalışmada, Malatya ve Bingöl illerindeki kayısı ağaçlarından insansız hava aracı (İHA) ve fotoğraf makinesi ile hastalıklı kayısı görüntüleri kaydedilmiş ve kapsamlı bir kayısı hastalıkları veri tabanı elde edilmiştir.
- Kayısı hastalıklarının sınıflandırılması için Evrişimsel Sinir Ağlarına dayalı bir derin model önerilmiştir. Geliştirilen model için farklı evrişim filtreleri kullanılmış ve en iyi performans gösteren evrişim filtresi belirlenmiştir.
- Bitki hastalık tespiti için Literatürde yapılan çalışmalarda genel olarak sentetik bitki hastalık görüntüleri kullanılmıştır. Bu çalışmada ise gerçek kayısı hastalık görüntülerini içeren bir veri seti inşa edilmiş ve önerilen model bu veri seti

kullanılarak test edilmiştir. Deneysel çalışmalarda elde edilen üstün performans sonuçlarına dayalı olarak, geliştirilen model gerçek dünya problemlerinde kullanılabileceği kanıtlanmıştır.

6.3. Elma Hastalık Tespiti İçin Derin Mimariler Kullanılarak Transfer Öğrenmeye Dayalı Optimum Ağ Parametreleri

Bu bölümde, elma hastalık ve zararlı tespiti için DESA ve ağ parametrelerinin sınıflandırma performansına etkileri değerlendirilmiştir. Önceden eğitilmiş derin mimarilerin performansları, transfer yaklaşımına dayalı olarak hesaplanmıştır. Bu yaklaşım, bir problemin çözümünde geliştirilen bir modelden elde edilen ağırlıklar farklı bir problemin çözümü için bir başlangıç noktası olarak kullanılmasına dayalıdır. Buna ek olarak, bu derin mimariler kullanılarak momentum, adam ve rmsprop gibi SDA (Stokastik dereceli alçalma) optimizasyon yöntemleri ile epoch ve batch değişkenlerinin performansa olan etkileri incelenmiştir. Sonuç olarak, önceden eğitilmiş derin mimarilerin, değişken olan ağ parametrelerine karşı performansları karşılaştırılmış ve her bir model için en uygun parametreler tespit edilmiştir.

6.3.1. Önerilen Yaklaşım

Bu çalışmada, elma hastalık ve zararlı tespiti için Evrişimsel Sinir Ağlarına dayalı önceden geliştirilmiş VGG19, SqueezeNet ve Inceptionv3 mimarileri kullanılmıştır. Birbirinden farklı yapılarda olan bu mimarilerin performansları transfer öğrenme yaklaşımı kullanılarak elde edilmiştir. Transfer öğrenme yaklaşımı, önceden eğitilmiş derin mimarilerin son üç katmanı yerine tam bağlı katman, softmax katmanı ve çıkış katmanı eklenmesine dayalıdır. Bu yaklaşım ile ilgili detaylı bilgiler Bölüm 6.2’de verilmiştir. Buna ek olarak, bu derin mimariler kullanılarak momentum, adam ve rmsprop gibi SDA optimizasyon yöntemleri ile epoch ve batch değişkenlerinin performansa olan etkileri incelenmiştir.

6.3.2. Deneysel Çalışmalar

Bu çalışmada, gerçek zamanlı olarak elde edilen elma hastalık ve zararlı görüntüleri kullanılarak önceden eğitilmiş derin mimarilerin ağ parametrelerine göre performansları değerlendirilmiştir. Önceden eğitilmiş mimarilerden birbirleri arasında benzersiz yapılara sahip olan VGG16, SqueezeNet ve Inceptionv3 modelleri

kullanılmıştır. Önerilen çalışmada, transfer öğrenme yaklaşımı kullanılarak bu mimariler, bitki hastalık sınıflandırma problemi için adapte edilmiştir.

Farklı ağ parametrelerine dayalı önceden eğitilmiş derin mimarilerin performanslarını test etmek için bitki hastalık ve zararlı görüntülerden elde edilen veri seti kullanılmıştır. Bu veri seti ile ilgili bilgiler Çizelge 6.19’da detaylandırılmıştır. Deneysel çalışmalarda, iki veri seti için eğitim - test kümeleri sırasıyla %70 ile %30 olarak rastgele bir şekilde ayrılmış ve bu işlem sadece bir defa yapılmıştır. Rastgele ayrılan verilerin performansa etkilerini en aza indirmek için tüm uygulamalarda aynı eğitim ve test kümesi kullanılmıştır.

Çizelge 6.19. Deneysel çalışmalar için eğitim ve test sayıları.

Elma hastalıkları ve zararlıları	Eğitim	Test	Toplam
Karaleke	295	127	422
Monilya	179	76	255
Pamuk Biti	251	108	359
Yaprak Biti	109	47	156
Toplam	834	358	1192

Çizelge 6.19’den anlaşılacağı üzere, veri seti dört farklı elma hastalık türü olmak üzere toplam 1192 görüntüden oluşmaktadır. Bu veri seti hakkında detaylı bilgiler Bölüm 4’de verilmiştir.

Derin ağ parametrelerine dayalı SDA optimizasyon yöntemlerinden momentum, adam ve rmsprop kullanılmıştır. Buna ek olarak, epoch ve batch değerleri [10-100] aralığında ardışık 10 adım olarak değerlendirilmiştir. Gerçekleştirilen deneysel çalışmalarda kullanılan VGG19, SqueezeNet ve Inceptionv3 mimarilerinin her biri için, optimizasyon yöntemleri ayrı ayrı uygulanmış ve epoch ile batch değerlerinin her bir optimizasyon yöntemi için ayrı ayrı hesaplanmıştır. Elde edilen sonuçlar Çizelge 6.20’de verilmiştir.

Çizelge 6.20. Derin mimarilerin sınıflandırma sonuçları (%).

Derin mimariler	Optimizasyon Yöntemleri		
	Momentum	Adam	Rmsprop
VGG19	96.37	92.18	84.08
SqueezeNet	71.23	94.97	93.02
Inceptionv3	90.50	96.93	96.65

Çizelge 6.20’den anlaşılacağı üzere, VGG16 modeli için en yüksek doğruluk momentum yöntemi kullanılarak elde edilirken, SqueezeNet ve Inceptionv3 modelleri için en yüksek doğruluk adam yöntemiyle elde edilmiştir. Buna ek olarak, elma hastalık

tespiti için en yüksek doğruluk skoru %96.93 olarak Inceptionv3 mimarisi ile elde edilmiştir. Çizelge 6.20’de verilen sonuçlara göre:

- VGG19 modeli için elde edilen en iyi performans; momentum yöntemi, epoch sayısı (40) ve batch değeri (10) kombinasyonu kullanılarak %96.37 hesaplanmıştır. Rmsprop yöntemi kullanılarak en yüksek doğruluk (%84.08) epoch sayısı (40) ve batch değeri (10) ile elde edilirken, adam yöntemi için ise epoch sayısı (30) ve batch değeri (30) kullanılarak en yüksek doğruluk (%92.18) elde edilmiştir. Ayrıca, adam yöntemi momentum yöntemine göre daha düşük ve rmsprop yöntemine göre ise daha yüksek doğruluk elde edilmiştir.
- SqueezeNet modeli için elde edilen en iyi performans; adam yöntemi, epoch sayısı (20) ve batch değeri (10) kombinasyonu kullanılarak (%94.97) hesaplanmıştır. Rmsprop yöntemi kullanılarak en yüksek doğruluk (%93.02) epoch sayısı (50) ve batch değeri (10) ile elde edilirken, momentum yöntemi için ise epoch sayısı (30) ve batch değeri (10) kullanılarak en yüksek doğruluk (%71.23) elde edilmiştir. Ayrıca, momentum yöntemi kullanılarak diğer iki yönteme göre çok düşük doğruluk elde edilmiştir.
- Inceptionv3 modeli için elde edilen en iyi performans; adam yöntemi, epoch sayısı (50) ve batch değeri (30) kombinasyonu kullanılarak (%96.93) hesaplanmıştır. Rmsprop yöntemi kullanılarak en yüksek doğruluk (%96.65) epoch sayısı (40) ve batch değeri (60) ile elde edilirken, momentum yöntemi için ise epoch sayısı (50) ve batch değeri (10) kullanılarak en yüksek doğruluk (%90.50) elde edilmiştir. Ayrıca, adam yöntemi ile rmsprop yöntemleri kullanılarak elde edilen doğruluklar yaklaşık olarak eşittir.

Çizelge 6.20’de görüldüğü üzere, farklı optimizasyon yöntemleri kullanılarak derin mimarilerin performansları önemli ölçüde değişmektedir. Bunun yanı sıra, epoch ve batch değerlerindeki değişimler de derin mimarilerinin performanslarını etkilemektedir. Bu bağlamda, Inceptionv3 modeli için momentum yöntemi kullanılarak epoch ve batch değerlerindeki değişimlerin sınıflandırma performansına etkileri Çizelge 6.21’de gösterilmiştir.

Çizelge 6.21. Epoch ve batch değerlerindeki değişimlerin performansa etkileri.

	Batch Sayısı					
	10	20	30	40	50	
Epoch Sayısı	10	89.11	88.55	85.47	86.31	85.75
	20	90.22	89.66	88.83	88.27	87.43
	30	89.94	88.83	88.27	87.99	87.71
	40	90.22	88.83	89.66	87.43	87.43
	50	90.50	88.22	88.83	87.71	86.39

Çizelge 6.21’de, Inceptionv3 modeli için momentum yöntemi kullanılarak 10 ile 50 arasında ardışık 10 adım olarak epoch ve batch değerlerinin performans sonuçları verilmiştir. Bu sonuçlara göre, en iyi performans %90.50 olarak epoch ve batch için sırasıyla 50 ve 10 değerlerinde elde edilirken, en düşük performans %85.47 olarak epoch ve batch için sırasıyla 10 ve 30 değerleri kullanılarak elde edilmiştir. Buna ek olarak, epoch değerlerinin hepsi için batch 10 değerinde genel olarak en yüksek doğruluk skorları elde edilmiştir.

Gerçekleştirilen deneysel çalışmaların sonuçlarına göre bu çalışmanın literatüre katkıları ve avantajları aşağıda verilmiştir:

- Çok sınıflı büyük veri setleri kullanılarak önceden eğitilmiş farklı karakteristiklere sahip derin mimariler için transfer öğrenme yaklaşımı kullanılarak elma hastalık tespiti için adapte edilmiş ve performans sonuçları kapsamlı bir şekilde tartışılmıştır.
- ESA’ya dayalı geliştirilen modeller için SDA optimizasyon yöntemlerinin önemi kanıtlanmıştır.
- Derin mimariler için epoch ve batch değerlerindeki değişimlerin önemli ölçüde performansı etkilediği gözlenmiştir.
- Literatürde, genel olarak sentetik bitki hastalık ve zararlı görüntüler kullanılarak çalışmalar yapılmıştır. Bu çalışmada, dört sınıflı olmak üzere toplam 1192 gerçek elam hastalık ve zararlı görüntülerinden oluşan veri seti inşa edilmiştir. Deneysel çalışmalar bu veri seti kullanılarak test edilmiştir.


6.4. Derin Öğrenme Tabanlı Bitki Hastalıkları ve Zararlıları Tespit Sistemi

Bu bölümde, bitki hastalık ve zararlıların tespiti için Çoklu-ESA PlantDiseaseNet olarak adlandırılan bir model önerilmiştir. Geliştirilen bu modelde, son teknolojiye sahip derin evrişimsel sinir ağlarına dayalı geliştirilen altı güçlü mimari kullanılmıştır. Bu derin

mimarilerden elde edilen performans sonuçları değerlendirilmiştir. Bunun yanı sıra, farklı yapılara sahip derin mimarilerin eğitilmiş ağırlıkları birleştirilmiş ve performansları hesaplanmıştır. Son olarak, farklı ESA modellerinden gelen tahmin sonuçlarını çoğunluk oylayıcısı yöntemiyle birleştirerek Çoklu-ESA PlantDiseaseNet modelinin performansı hesaplanmıştır. Gerçekleştirilen deneysel çalışmaların geçerliğini doğrulamak için gerçek zamanlı hastalık ve zararlı bitki görüntülerinden inşa edilen veri seti kullanılmış ve elde edilen tüm sonuçları karşılaştırılmıştır.

6.4.1. Önerilen Çoklu-ESA PlantDiseaseNet Modeli

Bu çalışmada, önceden eğitilmiş derin mimarilere dayalı derin özellik çıkarım yaklaşımı kullanılarak Çoklu-ESA PlantDiseaseNet modeli geliştirilmiştir. Önerilen derin tabanlı sistemin genel akış diyagramı Şekil 6.10'da verilmiştir.



Şekil 6.10. Çoklu-ESA PlantDiseaseNet sisteminin genel akış şeması

Bitki hastalık ve zararlı tespiti için önceden eğitilmiş farklı derin mimarilerinin sınıf tahminlerine dayalı bir sistem geliştirilmiştir. Şekil 6.10'da verilen Çoklu-ESA PlantDiseaseNet modelinin genel akış şeması için uygulama adımları aşağıda detaylandırılmıştır:

- Adım 1:** Bitki hastalık ve zararlı görüntüsü elde et.
- Adım 2:** Bitki görüntüsünü bilinear interpolation kullanılarak derin ağların yapısına göre yeniden boyutlandır.
- Adım 3:** Hastalık ve zararlı bitki görüntüleri, birden fazla derin mimarilere giriş görüntüsü olarak ver.
- Adım 4:** Önceden eğitilmiş ESA mimarileri kullanılarak derin özellikler çıkart.
- Adım 5:** DVM yöntemi kullanılarak elde edilen derin özellikleri sınıflandır ve sınıf tahmin sonucunu belirle.

Adım 6: Her bir derin mimarilerden elde edilen tahmin sonuçları kullanılarak çoğunluk oylayıcısı yöntemini uygula.

Adım 7: Bitki hastalık ve zararlı tespiti için sınıf etiketi elde edilir.

Önerilen Çoklu-ESA PlantDiseaseNet modeli kullanılarak sınıf etiketi belirlemek için AlexNet, GoogleNet, ResNet18, ResNet50, ResNet10 ve DenseNet201 mimarilerinin farklı kombinasyonlarına dayalı yaklaşımlar kullanılmıştır. Derin özellik çıkarma yaklaşımına dayalı bu mimarilerin tam bağlı katmanlarından özellikler elde edilmiştir. Her bir mimari için sınıf etiketleri elde edilir. Son olarak, tüm sınıf etiketleri için çoğunluk oylaması yöntemi kullanılarak en çok tahmin edilen sınıf etiketinin sistemin genel kararı olarak belirlenir.

6.4.2. Deneysel Çalışmalar

Önerilen Çoklu-ESA PlantDiseaseNet modeli test etmek için doğal ortamdan elde ettiğimiz hastalık ve zararlı görüntülerinden içeren veri seti kullanılmıştır. Bu veri seti, 15 sınıflı olmak üzere toplam 4447 görüntüden oluşmaktadır. Bu veri seti hakkında detaylı bilgiler Bölüm 4’de verilmiştir. Bu çalışmada, bitki hastalık ve zararlı veri seti 10 kat çapraz doğrulama işlemine göre önceden bölümlere ayrılmıştır. Her sınıf için eğitim ve test sayıları Çizelge 6.22’de verilmiştir.

Çizelge 6.22. Deneysel çalışmalar için eğitim ve test sayıları.

Bitki hastalık ve zararlıları	Eğitim	Test	Toplam
Armut Ateş Yanıklığı	194	21	215
Ceviz Antraknozu	162	18	180
Ceviz Gal Akarı	62	7	69
Kiraz Yaprak Biti	320	36	356
Şeftali Koşnil	384	43	427
Şeftali Monilya	283	31	314
Elma Karaleke	570	63	633
Elma Pamuklu Bit	329	37	366
Elma Yaprak Biti	146	16	162
Elma Monilya	230	25	255
Erik Yaprak Biti	63	7	70
Kayısı Çil	1000	110	1100
Kayısı Monilya	76	9	85
Kanser Belirtisi	68	8	76
Kuruma belirtisi	125	14	139
Toplam	4002	445	4447

Bitki hastalık ve zararlı görüntülerini içeren veri seti kullanılarak farklı derin mimarilere dayalı kapsamlı deneysel çalışmalar yapılmıştır. Bu bağlamda, önceden

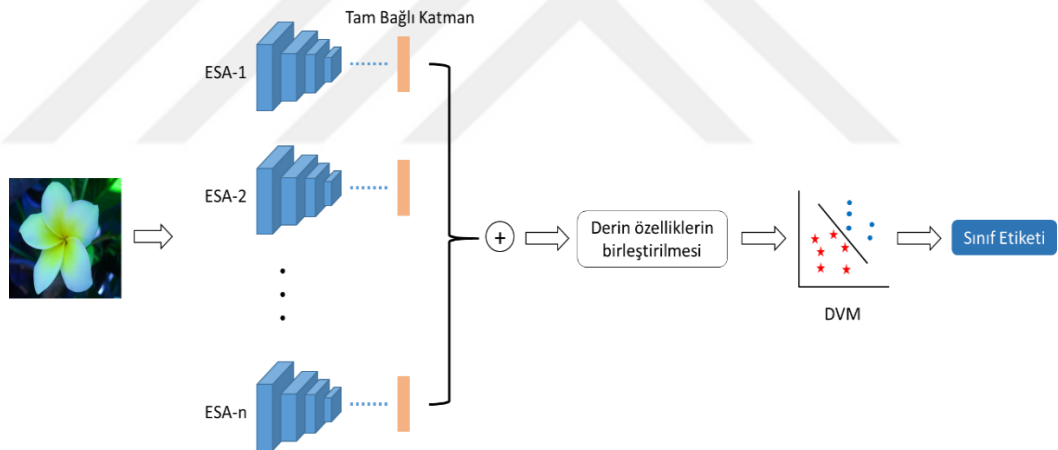
eđitilmiş ESA mimarilerinden elde edilen derin özellikler kullanılarak DVM yöntemi ile bireysel performansları hesaplanmıştır. Bu sonuçlar Çizelge 6.23’de verilmiştir.

Çizelge 6.23. Derin mimarilerin doğruluk skorları (%).

AlexNet	GoogleNet	ResNet18	ResNet50	ResNet101	DenseNet201
90.42	90.89	91.84	94	94.63	94.85

Çizelge 6.23’den anlaşılacağı üzere, bitki hastalık ve zararlı tespiti için en yüksek doğruluk DenseNet201 mimarisi kullanılarak %94.85 elde edilmiştir. İkinci en yüksek performans ResNet101 mimarisi ile %94.63 doğruluk elde edilirken en kötü performans %90.42 olarak AlexNet mimarisi ile elde edilmiştir. Diğer derin mimariler arasından GoogleNet modeli için %90.89 ve ResNet50 modeli için %94.63 doğruluk skorları hesaplanmıştır.

Derin mimarilerden elde edilen özelliklerin farklı kombinasyonları birleştirme işlemi kullanılarak dayalı bir çalışma yapılmıştır. Bu çalışmanın genel akış şeması Şekil 6.11’da verilmiştir.



Şekil 6.11. Birleştirilmiş Çoklu-ESA sisteminin genel akış şeması

Şekil 6.11’den anlaşılacağı üzere, birden fazla derin mimarilerden elde edilen özellikler için birleştirme işlemi uygulanmış ve DVM yöntemi kullanılarak sınıflandırılmıştır. Deneysel çalışmalarda, altı farklı derin mimarilerin farklı kombinasyonları kullanılmış ve elde edilen sonuçlar Çizelge 6.24’de verilmiştir.

Çizelge 6.24. Birleştirme işlemi kullanılarak farklı kombinasyonlar için doğruluk skorları
(Not: A: Alexnet, B: GoogleNet, C: DenseNet201, D: ResNet18, E: Resnet50, F: ResNet101)

Birleştirme İşlemi	Doğruluk Skoru (%)
D+E+F	95.73
A+B+C+F	96.33
C+E+F	96.47
B+C+E+F	96.51
C+D+E+F	96.54
A+B+C+E	96.56
A+C+E+F	96.63
A+C+D+E+F	96.65
A+B+C+D+E+F	96.72
A+B+C+E+F	96.83

Çizelge 6.24’de, bitki hastalık ve zararlı tespiti için en yüksek doğruluk skorlarının elde edildiği derin mimari tabanlı kombinasyonlar verilmiştir. Elde edilen sonuçlara göre, en yüksek doğruluk skoru Alexnet, GoogleNet, DenseNet201, Resnet50 ve ResNet101 mimarilerinin kombinasyonu kullanılarak %96.83 elde edilmiştir.

Önerilen Çoklu-ESA PlantDiseaseNet modeli (Şekil 6.10) kullanılarak sekiz derin mimarisinin farklı kombinasyonları test edilmiş ve elde edilen sonuçlar Çizelge 6.25’de verilmiştir.

Çizelge 6.25. Çoklu-ESA PlantDiseaseNet modeline dayalı farklı kombinasyonlar için doğruluk skorları.

(Not: A: Alexnet, B: GoogleNet, C: DenseNet201, D: ResNet18, E: Resnet50, F: ResNet101)

Çoklu-ESA PlantDiseaseNet modeli	Doğruluk Skoru (%)
C+E+F	96.31
A+B+E+F	96.42
A+B+C+F	96.58
A+B+C+E	96.58
B+C+D+E+F	96.92
A+C+D+E+F	96.94
A+ B+C+D+E+F	97.26
A+ B+C+E+F	97.56

Çizelge 6.25’de, bitki hastalık ve zararlı tespiti için Çoklu-ESA PlantDiseaseNet modeli kullanılarak en yüksek doğruluk skorlarının elde edildiği derin mimari tabanlı kombinasyonlar verilmiştir. Elde edilen sonuçlara göre, en yüksek doğruluk skoru AlexNet, GoogleNet, DenseNet201, Resnet50 ve ResNet101 mimarilerinin kombinasyonuna dayalı Çoklu-ESA PlantDiseaseNet modeli kullanılarak %97.56 elde edilmiştir.

DeneySEL çalışmalarından elde edilen tüm sonuçlara göre, önerilen Çoklu-ESA PlantDiseaseNet modeli kullanılarak bitki hastalık ve zararlı tespiti için en yüksek

doğruluk skoru elde edilmiştir. Alexnet, GoogleNet, DenseNet201, Resnet18, Resnet50 ve ResNet101 mimarilerinin bireysel performansları, birleştirme işlemleri ve önerilen yaklaşımın performanslarından daha düşük bir doğruluk elde edildiği tespit edilmiştir.

Bitki hastalıkları ve zararlıları tespiti için önerilen Çoklu-ESA PlantDiseaseNet modelinin literatüre katkıları ve avantajları şunlardır;


- Bitki hastalık ve zararlı tespiti için doğal ortamdaki elde edilmiş 15 sınıflı olmak üzere toplam 4447 hastalık ve zararlı görüntülerinden oluşan veri seti inşa edilmiştir. Bu veri seti, ülkemizde yaygın olarak görülen bitki hastalıklarını içermektedir. Deneysel çalışmalar bu veri seti üzerinde test edilmiştir ve elde edilen sonuçlara göre önerilen modelin gerçek dünya uygulamalarında kullanılabileceği kanıtlanmıştır.
- Bitki hastalık ve zararlı tespiti için Çoklu-ESA PlantDiseaseNet modeline dayalı altı derin mimarilerin farklı kombinasyonları kullanılmıştır ve elde edilen sonuçlara göre, önerilen model kullanılarak derin mimarilerin bireysel performanslarına göre daha başarılı olduğu gözlenmiştir.
- Farklı derin mimarilerin kombinasyonlarına dayalı önerilen Çoklu-ESA PlantDiseaseNet modeli ile diğer birleştirme teknikleri karşılaştırılmış ve önerilen modelin daha başarılı olduğu gözlenmiştir. Bu sonuçlara göre, bitki hastalıklarının sınıflandırma performansının yükseltilmesi için ESA'ya dayalı geliştirilen mimarilerin katman sayılarını artırmak yada farklı özellikler eklemek yerine alternatif bir yaklaşım olarak önerilen modelin kullanılabileceği tespit edilmiştir.

7. BİTKİ HASTALIKLARININ SINIFLANDIRILMASI İÇİN GELİŞTİRİLEN GERÇEK ZAMANLI YAZILIM UYGULAMASI

MATLAB, ileri düzey hesaplamalarda kullanılan yüksek performansa sahip bir dildir. Matlab yazılım dili kullanılarak matematiksel hesaplama, algoritma geliştirme, modelleme, simülasyon ve prototip kurma, veri analizi, görselleştirme, grafikler ve uygulama geliştirme gibi birçok işlem yapılabilmektedir [127]. Matlab yazılım dilinin kullanıldığı en temel uygulama alanları şunlardır:

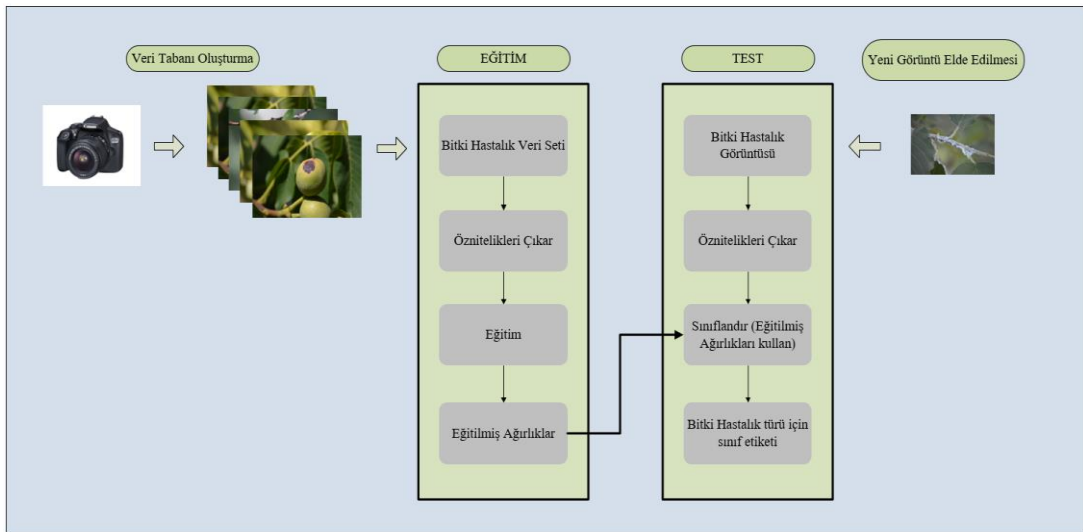
- Teknik ve karmaşık matematiksel hesaplama işlemleri,
- Kontrol sistemlerinin model tabanlı tasarımı,
- Görüntü işleme,
- Sinyal işleme ve analiz,
- Test ve ölçüm,
- Veri analizi ve görselleştirme,
- Bilimsel ve mühendislik grafiklerin çizimi,
- Finansal modellemeler ve analizler.

MATLAB yukarıda belirtilen uygulama alanlarının yanı sıra görsel ara yüz geliştirme aracına sahiptir. Guide denilen araç MATLAB ortamında görsel tasarım yapma imkânı sağlamaktadır (Şekil 7.1). GKA (Grafiksel Kullanıcı Ara Yüzü); butonlar, metin kutuları, radyo düğmeleri, onay kutuları, kaydırma çubukları ve grafikler gibi nesnelere içermektedir. Bu nesnelere arka planında .m uzantılı kod dosyaları saklanmaktadır [233].



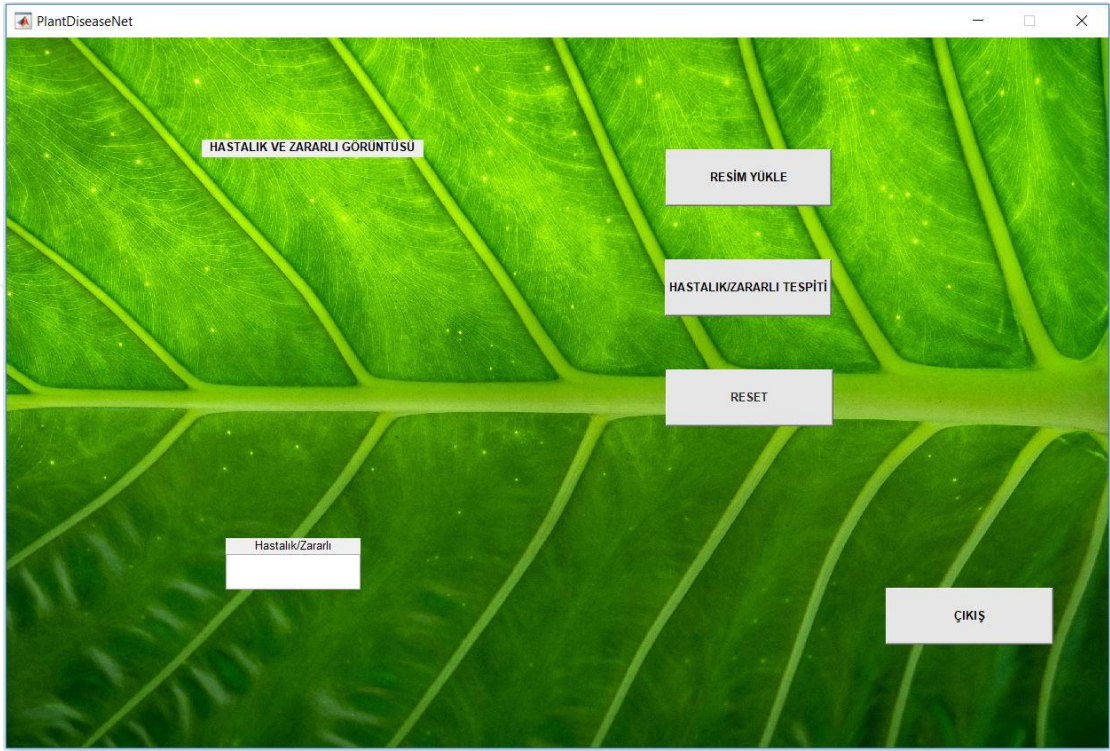
Şekil 7.1. Matlab ara yüz program görüntüsü

Bu tez çalışmasında, gerçek zamanlı olarak bitki hastalık tespitine yönelik Bitki Hastalık Tespit Yazılımı geliştirilmiştir. Bu amaç doğrultusunda, doğal ortamdan elde edilen bitki hastalık ve zararlı görüntülerini içeren bir veri seti inşa edilmiştir. Bu veri seti 15 sınıflı toplam 4400 hastalık ve zararlı görüntülerden oluşmaktadır. Bu veri seti ile ilgili bilgiler Bölüm 4’de detaylandırılmıştır. Bitki Hastalık Tespit Yazılımının genel aşamaları Şekil 7.2’de verilmiştir.



Şekil 7.2. Önerilen bitki hastalık sınıflandırma sisteminin genel aşamaları

Şekil 7.2’de, önerilen sistemin çalışma prensibi gösterilmiştir. Bu sistemin özellik çıkarım ve sınıflandırma işlemleri için Bölüm 6.4’de önerilen yüksek performanslı Çoklu-ESA PlantDiseaseNet modeli kullanılmıştır. Önerilen modelden elde edilen eğitilmiş ağırlıklar kullanılarak yeni gelen görüntüden elde edilen öznelikler test edilir ve sınıf etiketi belirlenir. Bu sistem, MATLAB GUI platformu kullanılarak tasarlanmıştır. Bitki Hastalık Tespit Yazılımı için tasarlanan arayüz programı Şekil 7.3’de gösterilmiştir.

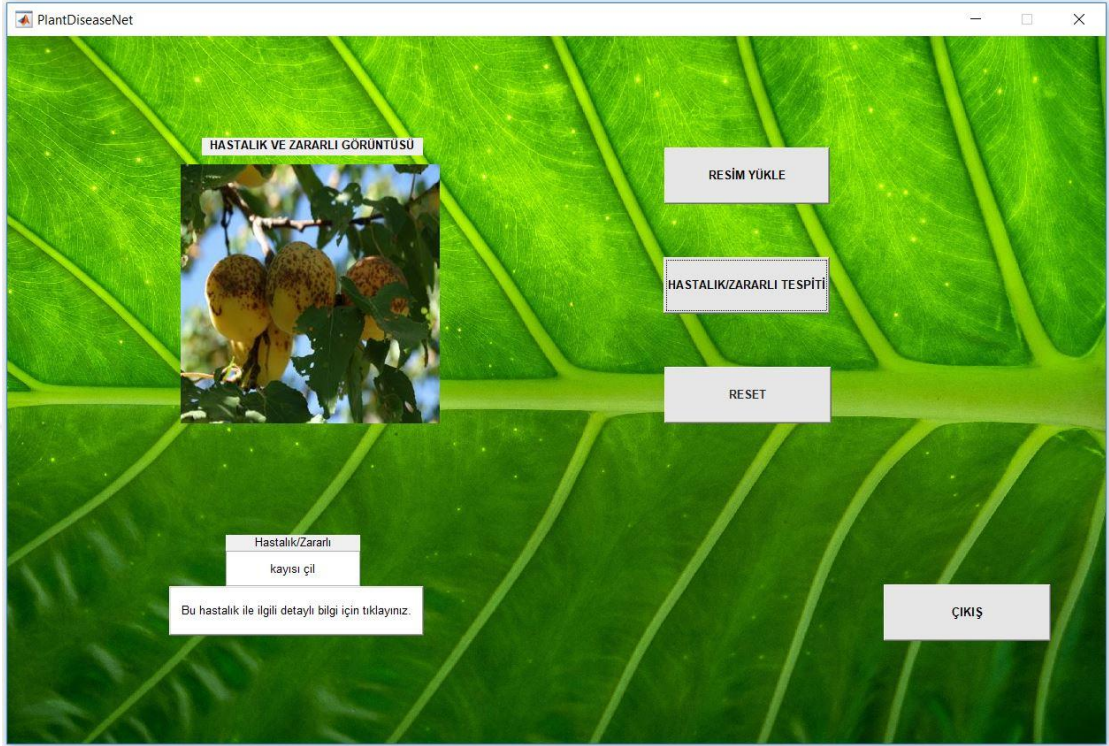


Şekil 7.3. Geliştirilen Matlab arayüz program görüntüsü

Şekil 7.3’de görüleceği gibi, önerilen sistem için kolay kullanıma sahip basit bir arayüz tasarlanmıştır. Bu arayüz de, resim yükle, hastalık tespiti, reset ve çıkış gibi dört buton bulunmaktadır. Bu butonların görevleri şunlardır:

- *Resim yükle*; bitki hastalık ve zararlı görüntüsünü sisteme yüklemek için kullanılan bir butondur.
- *Hastalık-Zararlı Tespiti*; resim yükle butonu kullanılarak eklenen görüntü için hastalık/zararlı tespiti butonu aktif hale getirildiğinde saniyeler içinde sınıf etiketi belirlenir ve ekrana yazılır. Buna ek olarak, ‘bu hastalık ile ilgili detaylı bilgi için tıklayınız’ butonu görünür hale gelir. Bu butona tıklayınca tespit edilen hastalık ile ilgili pdf dökümanı açılır. Şekil 7.4’de, Hastalık/Zararlı Tespiti butonu aktif iken arayüz programının görüntüsü verilmiştir.

- *Reset*; arayüz yazılım sistemini bir defa çalıştırdıktan sonra yeniden başka bir hastalık/zararlı görüntüsü tespiti için sistemi sıfırlayan bir butondur.
- *Çıkış*; arayüz yazılım sistemini kapatmak için kullanılan bir butondur.



Şekil 7.4. Hastalık-Zararlı Tespiti butonu aktif iken arayüz programı

Bu tez çalışmasında, doğal ortamdan elde edilen bitki hastalık görüntüleri kullanılarak gerçek zamanlı otomatik Bitki Hastalık Tespit Yazılımı geliştirilmiştir. Bu sistem, MATLAB GUI platformu kullanılarak tasarlanmış ve masaüstü uygulaması olarak herkes tarafından kolaylıkla kullanılabilme imkânı sağlanmıştır. Bu yazılım, uzman kişilere destek olacak, kolay ve kısa sürede bitki hastalıklarının erken tespit edilmesine olanak sağlayacak, yeni enfeksiyonların oluşması ve hastalıkların neden olduğu verim kaybını önleyecektir.

8. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, tarımsal alandaki bitki türlerinin tanınması ve bitki hastalıklarının tespiti ile ilgili iki büyük problem için yeni yaklaşımlar geliştirilmiştir. Tezin hedefleri doğrultusunda önerilen bu yaklaşımlar:

- Kenar Adım Yöntemi,
- Bölme yaklaşımına dayalı geliştirilen algoritmalar,
- Bölgesel ve Genel ortalamaya dayalı geliştirilmiş YİÖ yöntemi,
- Derin-dokusal tabanlı özellik çıkarıcı bir model,
- Çok-Bölmeli Derin Evrişimsel Sinir Ağı (ÇB-DESA) modeli,
- Derin sinir ağları ile geleneksel sınıflandırıcılara dayalı yeni bir sınıflandırma mimarisi,
- Evrişimsel Sinir Ağlarına (ESA) dayalı farklı evrişim filtrelerini içeren derin bir model,
- Derin Öğrenme Tabanlı Gerçek zamanlı Bitki Hastalık ve Zararlı Tespit Sistemi (Çoklu-ESA PlantDiseaseNet).

Bitki türlerinin sınıflandırılmasına yönelik geliştirilen algoritmalar ve sitemler test etmek için kamuya açık olan 8 farklı veri seti kullanılarak deneysel çalışmalar yapılmıştır. Bitki hastalık tespiti için ise literatürde doğal ortamlardan elde edilmiş görüntülere ait bir veri seti bulunmamaktadır. Bu nedenden dolayı, bölgemizde yaygın olarak görülen bitki hastalıkları incelenmiş ve farklı bitki türlerine ait 15 farklı hastalık tespit edilmiştir. Yapılan araştırmalar sonucunda doğal ortamlardan elde edilen 3000 hastalık görüntüsünden oluşan bir veri seti inşa edilmiştir. Gerçek zamanlı hastalık tespiti için geliştirilen algoritmalar ve sitemler bu veri seti kullanılarak test edilmiştir.

Bitki türleri ve hastalıkların sınıflandırılması için yapılan deneysel çalışmalarda elde edilen sonuçların değerlendirilmesi bölümünde yapılmış ve aşağıda verilmiştir.

8.1. Sonuçların değerlendirilmesi

Beşinci bölümde, bitki türlerinin tanınması ve sınıflandırılması ile ilgili önerilen yaklaşımlar sunulmuştur. Bu çalışmalardan elde edilen sonuçların değerlendirilmesi maddeler halinde aşağıda verilmiştir:

- 5.1. Bölümde, bitki türlerinin sınıflandırılması için MKU yönteminden esinlenerek yaprağın geometrik özelliklerine dayalı KA olarak adlandırılan yeni

bir yöntem önerilmiştir. KA yönteminin etkinliğini göstermek amacıyla yaprak görüntülerinden oluşan 4 farklı veri seti kullanılmıştır. Gerçekleştirilen deneysel çalışmalarda, KA yönteminin MKU yöntemine göre, Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla yaklaşık olarak %8, %16, %12 ve %10 daha yüksek doğruluk elde edilmiştir. Buna ek olarak, KA yöntemi önceki çalışmalarda geliştirilen şekil tabanlı yöntemlere göre üstün performans sağlamıştır. Elde edilen bu sonuçlara göre, KA yöntemi MKU yöntemine göre bir görüntüye ait daha az sayıda öznitelik elde etmekle beraber daha yüksek performansa sahip olduğu tespit edilmiştir. Ayrıca, KA yöntemine ek olarak doku tanımada iyi hassasiyet gösteren ve yön bağımsızlığına sahip olan Shearlet Dönüşüm yöntemi ile bitki yapraklarındaki farklı dokuları ortaya çıkarmak için kullanılan GSEM yöntemi ve istatistiksel momentlere dayalı renk özellikleri de kullanılmıştır. Bu yöntemlerden elde edilen öznitelik vektörleri birleştirilmiş ve AÖM sınıflandırıcısı kullanılarak test edilmiştir. Bu sonuçlara göre, Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla %98.31, %99.46, %93.71 ve %96.62 doğruluk skorları elde edilmiştir. Sonuç olarak, önerilen sistemin etkili, uygulaması kolay ve daha az sayıda öznitelik kullanılarak önceki çalışmalara kıyasla daha yüksek performansa sahip olduğu gözlenmiştir.

- 5.2. Bölümde, yaprak tabanlı bitki görüntüleri kullanılarak bölme yaklaşımına dayalı şekil, renk ve doku tabanlı hibrit bir sistem geliştirilmiştir. Önerilen bu sistem, özellik çıkarıcı olarak Renk özellikleri, Damar özellikleri, Fourier tanımlayıcıları ve GSEM yöntemi ile beraber AÖM sınıflandırıcısının kullanılmasına dayalıdır. Bu tez çalışmasında, tüm bir yaprak görüntüsü yerine yaprağın ağırlık merkezine dayalı 2 ve 4 parçaya bölme işlemi gerçekleştirilmiş ve her bir parça için öznitelik çıkarım yöntemleri uygulanmıştır. Daha sonra her bir parça için elde edilen parametreler birleştirilerek tüm bir yaprak görüntüsünü oluşturan öznitelik vektörü elde edilir. Geliştirilen bölme yaklaşımına dayalı hibrit sistemin performansını test etmek için AÖM sınıflandırıcısı kullanılmıştır. Flavia veri setine dayalı gerçekleştirilen deneysel çalışmalarda, orijinal görüntü, ikiye ve dörde bölme yaklaşımları kullanılarak sırasıyla %97.68, %99.10 ve %98.36 doğruluk skorları elde edilmiştir. Bu sonuçlara göre, ikiye bölme yaklaşımı kullanılarak en yüksek performans elde edilmiştir. Buna ek olarak, dörde bölme yaklaşımı kullanılarak özellik çıkarım yöntemlerinin bireysel

performanslarında %5-15 oranlarında önemli bir başarıml artışı olduđu gözlenmiştir.

- 5.3. Bölümde, bitki yaprakların doku özellikleri çıkarmak için kullanılan YİÖ yönteminin geliştirilmiş versiyonu olarak BOG-YİÖ yaklaşımı önerilmiştir. BOG-YİÖ yönteminin çalışma prensibi: renkli yaprak görüntülerinin R ve G kanallarına dayalı 3x3 lük blokların ortalaması ile görüntünün genel ortalaması dikkate alınarak gerçekleştirilir. AÖM sınıflandırıcı kullanılarak önerilen yaklaşımın performansı hesaplanmıştır. Önerilen BOG-YİÖ yöntemini test etmek için yaprak görüntülerinden oluşan 4 farklı veri seti kullanılarak kapsamlı deneysel çalışmalar yapılmıştır. Bu sonuçlara göre, Flavia, Swedish, ICL ve Foliage veri setleri için sırasıyla %98.31, %99.46, %93.71 ve %96.62 doğruluk skorları elde edilmiştir. Bu deneysel çalışmaların yanı sıra, çeşitli gürültü yöntemleri kullanılarak önerilen yöntemin etkinliği ve sağlamlığı da değerlendirilmiştir. Sonuç olarak, önerilen yöntem orijinal YİÖ, geliştirilmiş YİÖ yöntemleri ve diğer görüntü tanımlayıcılarla karşılaştırıldığında hem gürültülü hem de gürültüsüz görüntüler için daha başarılı olduđu gözlenmiştir.
- 5.4. Bölümde, bitki tanıma problemi için derin ve yerel özelliklerin kombinasyonuna dayalı bir sistem önerilmiştir. ESA'ya dayalı geliştirilen AlexNet modelinin fc6 tam bağı katmanı kullanılarak yaprak görüntülerinden derin özellikler çıkartılmıştır. Daha sonra, yaprak görüntülerinin R, G ve B kanalları için YİÖ yöntemi kullanılarak tüm görüntü için özellikler elde edilmiştir. Son olarak, derin ve yerel özellikler birleştirilerek DVM yöntemi ile sınıflandırılmıştır. Deneysel çalışmalarda elde edilen sonuçlara göre, ICL ve Folio veri seti için sırasıyla %98.50 ve %99.48 doğruluk skorları elde edilmiştir. Bu sonuçlara göre, bitki sınıflandırmak için geliştirilen derin-dokusal tabanlı yaklaşım sınıflandırma performansını olumlu yönde etkilemiştir. Buna ek olarak, önerilen Renkli-YİÖ yöntemi, orijinal YİÖ yönteminden daha başarılı olduđu gözlenmiştir.
- 5.5. Bölümde, bitki türlerinin sınıflandırılması için nxn boyutunda bölme yaklaşımına dayalı Çok-Bölmeli Derin Evrişimsel Sinir Ağı (ÇB-DESA) modeli geliştirilmiştir. Önerilen model, 2x2, 3x3, 4x4 ve 5x5 pencere boyutları kullanılarak bitki görüntüleri parçalara bölünür ve daha sonra her bir parça için derin özellikler çıkartılmıştır. TBA yöntemi kullanılarak her bir parça için elde

edilen derin özelliklerden etkili parametreler seçilmiştir. Son olarak, bölünmüş parçalardan elde edilen seçkin özellikler birleştirilmiş ve DVM yöntemi ile sınıflandırma performansı hesaplanmıştır. Önerilen ÇB-DESA modelinin sağlamlığını ve performansını test etmek için 8 farklı bitki veri seti kullanılmıştır. Deneysel çalışmalarda elde edilen sonuçlara göre, Flavia, Swedish ve Folio veri setleri için %100 doğruluk elde edilirken, ICL, Foliage, Flower17, Flower102 ve LeafSnap veri setleri için sırasıyla %99.77, %99.93, %97.87, %98.03 ve %97.8 doğruluk skorları elde edilmiştir. ÇB-DESA modeli, en son teknolojiye sahip yapılan çalışmalarla karşılaştırılmış ve tüm veri setlerinde daha üstün performans sağladığı gözlenmiştir. Elde edilen üstün performans sonuçlarına dayalı olarak, geliştirilen ÇB-DESA modelinin gerçek dünya problemlerinde kullanılabileceği kanıtlanmıştır.

Altıncı bölümde, bitki hastalıklarının tespiti ile ilgili önerilen yaklaşımlar sunulmuştur. Bu çalışmalardan elde edilen sonuçların değerlendirilmesi maddeler halinde aşağıda verilmiştir:

- 6.1. Bölümde, bitki hastalıkları ve zararlıları tespiti için Derin ESA kullanılarak geliştirilen dokuz güçlü derin ağ mimarilerine dayalı (AlexNet, GoogleNet, VGG16, VGG19, ResNet50, ResNet101, InceptionV3, Inception ResNetV2 ve SqueezeNet) transfer öğrenimi ve derin özellik çıkarımı yaklaşımları değerlendirilmiş ve performans sonuçları kapsamlı bir şekilde tartışılmıştır. Bu tez çalışmasında, önceden eğitilmiş derin öğrenme ağları ile geleneksel sınıflandırıcılar kullanılarak yeni bir sınıflandırma mimarisi önerilmiştir. Bitki hastalık ve zararlı tespiti için önceden eğitilmiş mimarilerin ağırlıkları kullanılarak derin özellikler çıkartılmıştır. Elde edilen bu özellikler DVM, AÖM ve k-EYK gibi geleneksel sınıflandırıcı yöntemleri kullanarak performansları hesaplanmıştır. Bu deneysel çalışmalar, bizim oluşturduğumuz sekiz sınıflı olmak üzere toplam 1965 gerçek bitki hastalık ve zararlı görüntülerini içeren veri seti kullanılarak gerçekleştirilmiştir. Bu sonuçlara göre, önerilen sınıflandırma mimarisinin transfer öğrenme yaklaşımından daha yüksek doğruluk skoruna sahip olduğu gözlenmiştir. Deneysel çalışmalarda elde edilen sonuçlara göre önerilen yaklaşımların gerçek dünya uygulamalarında kullanılabileceği kanıtlanmıştır.
- 6.2. Bölümde, kayısı hastalıklarının tespiti için Derin Evrişimsel Sinir Ağlarına (DESA) dayalı bir model önerilmiştir. Geliştirilen bu model, Evrişim, Relu,

Normalizasyon, Havuzlama ve tam bağı katmanları olmak üzere 17 katmandan oluşmaktadır. Buna ek olarak, bu tez çalışmasında farklı evrişim filtreleri (3×3, 5×5, 7×7, 9×9 ve 11×11) kullanılarak sınıflandırma performansına etkileri incelenmiştir. Deneysel çalışmalar için doğal ortamdan elde edilmiş kayısı hastalık görüntülerini içeren bir veri seti inşa edilmiş ve önerilen model bu veri seti kullanılarak test edilmiştir. Bu sonuçlara göre, önerilen model geleneksel yöntemler ile önceden eğitilmiş derin mimarilerden daha başarılı olduğu tespit edilmiştir. Deneysel çalışmalarda elde edilen üstün performans sonuçlarına dayalı olarak, geliştirilen model gerçek dünya problemlerinde kullanılabileceği kanıtlanmıştır.

- 6.3. Bölümde, çok sınıflı büyük veri setleri kullanılarak önceden eğitilmiş farklı karakteristiklere sahip derin mimariler için transfer öğrenme yaklaşımı kullanılarak elma hastalık tespiti için adapte edilmiş ve sınıflandırma performansları hesaplanmıştır. Bunun yanı sıra, momentum, adam ve rmsprop gibi SDA optimizasyon yöntemleri ile epoch ve batch değişkenlerinin bu derin mimarilerinin performansına olan etkileri incelenmiştir. Bu tez çalışmada, dört sınıflı olmak üzere toplam 1192 doğal ortamdan elde edilen elma hastalık ve zararlı görüntülerinden oluşan veri seti inşa edilmiştir. Deneysel çalışmalar bu veri seti kullanılarak test edilmiştir. ESA'ya dayalı geliştirilen modeller için optimizasyon yöntemlerinin önemi kanıtlanmıştır. Buna ek olarak, epoch ve batch değerlerindeki değişimlerin derin mimarilerin sınıflandırma performansını önemli ölçüde etkilediği gözlenmiştir.
- 6.4. Bölümde, bitki hastalık ve zararlıların tespiti için önceden eğitilmiş derin mimarilerin kombinasyonlarına dayalı Çoklu-ESA PlantDiseaseNet olarak adlandırılan bir model önerilmiştir. Bu model, farklı derin mimarilerden gelen tahmin sonuçlarını çoğunluk oylama yöntemi ile birleştirilmesine ve nihai sınıf etiketinin belirlenmesine dayalıdır. Çoklu-ESA PlantDiseaseNet modelini test etmek için inşa ettiğimiz 15 sınıflı 4447 hastalık ve zararlı görüntülerinden oluşan veri seti kullanılmıştır. Yapılan kapsamlı deneysel çalışmalarda, Çoklu-ESA PlantDiseaseNet modeli kullanılarak derin mimarilerin bireysel performanslarından daha yüksek doğruluk elde edilmiştir. Ayrıca, Çoklu-ESA PlantDiseaseNet modeli ile diğer birleştirme teknikleri karşılaştırılmış ve önerilen modelin daha başarılı olduğu gözlenmiştir. Bu sonuçlara göre, bitki hastalıklarının

sınıflandırma performansının yükseltilmesi için ESA'ya dayalı geliştirilen mimarilerin katman sayılarını artırmak veya farklı özellikler eklemek yerine alternatif bir yaklaşım olarak önerilen modelin kullanılabilceği kanıtlanmıştır.

Yedinci bölümde, MATLAB GUI platformu kullanılarak gerçek zamanlı otomatik Bitki Hastalık Tespit Yazılımı geliştirilmiştir. Bu çalışma için doğal ortamdan elde edilen 15 sınıflı toplam 4400 hastalık ve zararlı görüntülerini içeren bir veri seti inşa edilmiş ve bu veri seti kullanılarak geliştirilen sistem eğitilmiş ve test edilmiştir. Bu sistemin özellik çıkarım ve sınıflandırma işlemleri için Bölüm 6.4'de önerilen yüksek performanslı Çoklu-ESA PlantDiseaseNet modeli kullanılmıştır. Önerilen modelden elde edilen eğitilmiş ağırlıklar kullanılarak yeni gelen görüntüden elde edilen öznitelikler test edilir ve sınıf etiketi belirlenir. Sonuç olarak, gerçek zamanlı Bitki Hastalık Tespit Yazılım sisteminin avantajları şunlardır:

- Uzman kişilere yardımcı olması,
- Kolay, yüksek doğruluklu ve kısa sürede bitki hastalıklarının erken tespit edilmesine olanak sağlaması,
- Yeni enfeksiyonların oluşmasına ve hastalığın yayılmasını engellemesi,
- Hastalıkların neden olduğu verim kaybının önlenmesi.

Bu tez çalışmasında, doğal ortamdan elde edilen bitki hastalık görüntüleri kullanılarak gerçek zamanlı otomatik Bitki Hastalık Tespit Yazılımı geliştirilmiştir. Bu sistem, MATLAB GUI platformu kullanılarak tasarlanmış ve masaüstü uygulaması olarak herkes tarafından kolaylıkla kullanılabilme imkânı sağlanmıştır. Bu yazılım, uzman kişilere destek olacak, kolay ve kısa sürede bitki hastalıklarının erken tespit edilmesine olanak sağlayacak, yeni enfeksiyonların oluşması ve hastalıkların neden olduğu verim kaybını önleyecektir.

8.2. Öneriler

Tez çalışması süresince yapılan çalışmalar ve elde edilen bulgulara dayalı olarak ileri zamanlarda yapılması düşünülen çalışmalar şunlardır:

- Bitki hastalık ve zararlı veri setinin görüntü ve sınıf sayısı artırılarak, geniş çaplı bir hastalık ve zarar tespit sistemi geliştirilebilir.

- Online öğrenebilen sistemler geliştirilerek sürekli güncel kalacak programlar geliştirilecektir.
- Mobil tabanlı yazılımlar geliştirilerek kullanıcılara donanımdan ve ortamdaki bağımsız bir platform sağlanabilir. Bu sayede veri tabanlarının sayısı ve içerikleri zenginleşebilecektir.



9. KAYNAKLAR

- [1] M. Turkoglu and D. Hanbay, Classification of the grape varieties based on leaf recognition by using SVM classifier, 23 th In Signal Processing and Communications Applications Conference (SIU), Inonu University, Malatya, Türkiye, (2015), pp. 2674-2677.
- [2] Z. Wang, X. Sun, Y. Ma, H. Zhang, Y. Ma, W. Xie and Y. Zhang, Plant recognition based on intersecting cortical model, In Neural Networks (IJCNN), International Joint Conference on. IEEE, Beijing, China, (2014), pp. 975-980.
- [3] P. Nijalingappa and V.J. Madhumathi, Plant identification system using its leaf features, In Applied and Theoretical Computing and Communication Technology (iCATccT), 2015 International Conference on. IEEE, Davangere, India, (2015), pp. 338-343.
- [4] M. Shabanzade, M. Zahedi and S.A. Aghvami, *Combination of local descriptors and global features for leaf recognition*, **Signal & Image Processing**, 2:3 (2011) 23.
- [5] M. Turkoglu, O.F. Alcin, M. Ustundag, D. Hanbay, Leaf recognition and classification based on geometric and statistical features, International Conference on Natural Science and Engineering (ICNASE'16), Kilis, Türkiye, (2016), pp. 1-4.
- [6] Merve Güzel. *“The importance of good agricultural practices (gap) in the context of quality practices in agriculture and a sample application”* Master’s Thesis, Dokuz Eylul University Turkey, 2012.
- [7] B.M. Asma and O. Birhanlı, *Mişmiş*, Malatya: Evin Ofset, Türkiye, 2004.
- [8] M. Turkoglu and D. Hanbay, Apricot Disease Identification based on attributes obtained from Deep Learning Algorithms, In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), Inonu University, Malatya, Turkey, (2018), pp. 1-4.
- [9] M. Turkoglu and D. Hanbay, *Plant disease and pest detection using deep learning-based features*, **Turkish Journal of Electrical Engineering & Computer Sciences**, 27:3 (2019) 1636-1651.
- [10] M. Turkoglu and D. Hanbay, *Shearlet dönüşüm ve yeni geometrik özellikler kullanılarak aşırı öğrenme makinesine dayalı bitki tanıma sistemi*, **Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi**, 34:4 (2019) 2097-2112.
- [11] S.G. Wu, F.S. Bao, E.Y. Xu, Y.X. Wang, Y.F. Chang and Q.L. Xiang, A leaf recognition algorithm for plant classification using probabilistic neural network, 2007 IEEE International Symposium Signal Processing and Information Technology, Giza, Egypt, (2007), pp. 11-16.
- [12] Oskar Söderkvist. *“Computer vision classification of leaves from swedish trees”* Master Thesis, Linköping University Sweden, 2011.

- [13] P.F. Silva, A.R. Marcal and R.M.A. da Silva, Evaluation of features for leaf discrimination, International Conference Image Analysis and Recognition. Springer, Berlin, Heidelberg, (2013).
- [14] A. Kadir, L.E. Nugroho, A. Susanto and P.I. Santosa, *Neural network application on foliage plant identification*. **International Journal of Computer Applications**, 29:9 (2013).
- [15] T. Munisami, M. Ramsurn, S. Kishnah, and S. Pudaruth, Plant leaf recognition using shape features and colour histogram with K-nearest neighbour classifiers, Computer Vision and the Internet (VisionNet'15), Second International Symposium on, Procedia Computer Science, (2015), pp.740-747.
- [16] N. Kumar, P.N. Belhumeur, A. Biswas, D.W. Jacobs, W.J. Kress, I.C. Lopez, and J.V. Soares, Leafsnap: A computer vision system for automatic plant species identification, In European Conference on Computer Vision. Springer, Berlin, Heidelberg, (2012), pp.502-516.
- [17] M.E. Nilsback and A. Zisserman, A visual vocabulary for flower classification, In 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06), (2006), pp.1447-1454.
- [18] M.E. Nilsback and A. Zisserman, *Delving into the whorl of flower segmentation*, **In BMVC**, (2007) 1-10.
- [19] M.E. Nilsback and A. Zisserman, Automated flower classification over a large number of classes In 2008 Sixth Indian Conference on Computer Vision, Graphics & Image Processing IEEE, Bhubaneswar, India. (2008), pp.722-729.
- [20] J.X. Du, X.F. Wang and G.J. Zhang, *Leaf shape based plant species recognition*, **Applied mathematics and computation**, 185:2 (2007) 883-893.
- [21] K. Mahdikhanlou, and H. Ebrahimnezhad, Plant leaf classification using centroid distance and axis of least inertia method, In Electrical Engineering (ICEE), 2014 22nd Iranian Conference on. IEEE, Tehran, Iran, (2004), pp.1690-1694.
- [22] K.B. Lee and K.S. Hong, *An implementation of leaf recognition system using leaf vein and shape*, **International Journal of Bio-Science and Bio-Technology**, 5:2 (2013) 57-66.
- [23] A. Kadir, L.E. Nugroho, A. Susanto and P.I. Santosa, *Experiments of Zernike moments for leaf identification*, **Journal of Theoretical and Applied Information Technology (JATIT)**, 41:1 (2012) 82-93.
- [24] C. Sari, C.B. Akgul and B. Sankur, Combination of gross shape features, fourier descriptors and multiscale distance matrix for leaf recognition, In AÖMAR, 2013 55th International Symposium. IEEE, Zadar, Croatia, (2013), pp.23-26.
- [25] Y.G. Naresh and H.S. Nagendraswamy, *Classification of medicinal plants: an approach using modified LBP with symbolic representation*, **Neurocomputing**, 173 (2016) 1789-1797.

- [26] E. Elhariri, N. El-Bendary and A.E. Hassanien, Plant classification system based on leaf features, In 2014 9th International Conference on Computer Engineering & Systems (ICCES) IEEE, Cairo, Egypt, (2014), pp.271-276.
- [27] D.G. Tsolakidis, D.I. Kosmopoulos and G. Papadourakis, Plant leaf recognition using Zernike moments and histogram of oriented gradients, Hellenic Conference on Artificial Intelligence. Springer, Cham, (2014), pp.406-417.
- [28] A. Kadir, L.E. Nugroho, A. Susanto and P.I. Santosa, *Performance improvement of leaf identification system using principal component analysis*, **International Journal of Advanced Science and Technology**, 44 (2012) 113-124.
- [29] X. Wang, J. Liang and F. Guo, *Feature extraction algorithm based on dual-scale decomposition and local binary descriptors for plant leaf recognition*, **Digital Signal Processing**, 34 (2014) 101-107.
- [30] Y. Herdiyeni and M.M. Santoni, Combination of morphological, local binary pattern variance and color moments features for indonesian medicinal plants identification, In 2012 International Conference on Advanced Computer Science and Information Systems (ICACSIS), Epok, Indonesia, (2012), pp.255-259.
- [31] V.N.T. Le, B. Apopei and K. Alameh, *Effective plant discrimination based on the combination of local binary pattern operators and multiclass support vector machine methods*, **Information processing in agriculture**, 6:1 (2019) 116-131.
- [32] Saleem, G., Akhtar, M., Ahmed, N., Qureshi, W.S. Automated analysis of visual leaf shape features for plant classification. **Computers and Electronics in Agriculture**, 157 (2019) 270-280.
- [33] A. Aakif and M.F. Khan, *Automatic classification of plants based on their leaves*, **Biosystems Engineering**, 139 (2015) 66-75.
- [34] T. Munisami, M. Ramsurn, S. Kishnah and S. Pudaruth, *Plant leaf recognition using shape features and colour histogram with K-nearest neighbour classifiers*, **Procedia Computer Science**, 58 (2015) 740-747.
- [35] J. Chaki, R. Parekh and S. Bhattacharya, *Plant leaf recognition using texture and shape features with neural classifiers*, **Pattern Recognition Letters**, 58 (2015) 61-68.
- [36] R. Hu, W. Jia, H. Ling and D. Huang, *Multiscale distance matrix for fast plant leaf recognition*, **IEEE transactions on image processing**, 21:11 (2012) 4667-4672.
- [37] A. Yasar, I. Saritas, M.A. Sahman and A.O. Dundar, *Classification of Leaf Type Using Artificial Neural Networks*, **International Journal of Intelligent Systems and Applications in Engineering**, 3:4 (2015) 136-139.
- [38] A. Kadir, L.E. Nugroho, A. Susanto and P.I. Santosa, *Foliage plant retrieval using polar fourier Transform, color moments and vein features*, **Signal & Image Processing: An International Journal (SIPIJ)**, 2:3 (2011).

- [39] C.A. Priya, T. Balasaravanan and A.S. Thanamani, An efficient leaf recognition algorithm for plant classification using support vector machine, In International conference on pattern recognition, informatics and medical engineering (PRIME-2012), Salem, Tamilnadu, India, (2012), pp.428-432.
- [40] M.A.J. Ghasab, S. Khamis, F. Mohammad and H.J. Fariman, *Feature decision-making ant colony optimization system for an automated recognition of plant species*, **Expert Systems with Applications**, 42:5 (2015) 2361-2370.
- [41] J.K. Hsiao, L.W. Kang, C.L. Chang and C.Y. Lin, Comparative study of leaf image recognition with a novel learning-based approach, In 2014 Science and Information Conference IEEE, London, UK, (2014), pp.389-393.
- [42] X.M. Ren, X.F. Wang and Y. Zhao, An efficient multi-scale overlapped block LBP approach for leaf image recognition, In: Proceedings of the 8th international conference on intelligent computing theories and applications (ICIC'12), Springer, Berlin, (2012), pp.237-243.
- [43] M. Sulc and J. Matas, Texture-based leaf identification, In European Conference on Computer Vision, Springer, Cham, (2014), pp.185-200
- [44] X. Qi, R. Xiao, C.G. Li, Y. Qiao, J. Guo and X. Tang, *Pairwise rotation invariant co-occurrence local binary pattern*, **IEEE transactions on pattern analysis and machine intelligence**, 36:11 (2014) 2199-2213.
- [45] H. Laga, S. Kurttek, A. Srivastava and S.J. Miklavcic, *Landmark-free statistical analysis of the shape of plant leaves*, **Journal of theoretical biology**, 363 (2014) 41-52.
- [46] B. Wang, D. Brown, Y. Gao and J. La Salle, *MARCH: Multiscale-arch-height description for mobile retrieval of leaf images*, **Information Sciences**, 302 (2015) 132-148.
- [47] S. Prasad, S. Peddoju and D. Ghosh, Mobile plant species classification: a low computational approach, In: 2013 IEEE second international conference on image information processing (ICIIP), Shimla, India, (2013), pp.405-409.
- [48] C. Hewitt and M. Mahmoud, *Shape-only Features for Plant Leaf Identification*, **Computer Vision and Pattern Recognition**, (2018).
- [49] F.S. Khan, J. Weijer, A.D. Bagdanov and M. Vanrell, *Portmanteau vocabularies for multi-cue image representation*, In **Advances in neural information processing systems (In NIPS)**, (2011) 1323-1331.
- [50] J. Zhu, J. Yu, C. Li and F.Z. Wang, *Object recognition via contextual color attention*, **Journal of Visual Communication and Image Representation**, 27 (2015) 44-56.
- [51] H.A. Elnemr, Feature selection for texture-based plant leaves classification, In 2017 Intl Conf on Advanced Control Circuits Systems (ACCS) Systems & 2017 Intl Conf on New Paradigms in Electronics & Information Technology (PEIT), Alexandria, Egypt, (2007), pp.91-97.

- [52] A. Beikmohammadi and K. Faez, Leaf Classification for Plant Recognition with Deep Transfer Learning, In 2018 4th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS), Tehran, Iran, (2018), pp.21-26.
- [53] Grinblat, G.L., Uzal, L.C., Larese, M.G., Granitto, P.M. *Deep learning for plant identification using vein morphological patterns*, **Computers and Electronics in Agriculture**, 127 (2016) 418-424.
- [54] M.M. Ghazi, B. Yanikoglu and E. Aptoula, *Plant identification using deep neural networks via optimization of transfer learning parameters*, **Neurocomputing**, 235 (2017) 228-235.
- [55] S. Prasad and P.P. Singh, Medicinal plant leaf information extraction using deep features, In TENCON 2017 IEEE Region 10 Conference, Penang, Malaysia, (2017), pp.2722-2726.
- [56] Y. Sun, Y. Liu, G. Wang and H. Zhang, *Deep learning for plant identification in natural environment*, **Computational intelligence and neuroscience**, (2017) 1-6.
- [57] S.H. Lee, C.S. Chan, P. Wilkin and P. Remagnino, Deep-plant: Plant identification with convolutional neural networks, In 2015 IEEE International Conference on Image Processing (ICIP), Quebec City, Canada, (2015), pp.452-456.
- [58] A. He and X. Tian, Multi-organ plant identification with multi-column deep convolutional neural networks, In 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Budapest, Hungary, (2016), pp.2020-2025.
- [59] M. Cibuk, U. Budak, Y. Guo, M.C. Ince and A. Sengur, *Efficient deep features selections and classification for flower species recognition*, **Measurement**, 137 (2019) 7-13.
- [60] T.T.N. Nguyen, T.L.L. Van Tuan, H. Vu, N. Pantuwong and Y. Yagi, Flower species identification using deep convolutional neural networks, In AUN/SEED-Net Regional Conference for Computer and Information Engineering, (2016).
- [61] P. Pawara, E. Okafor, L. Schomaker and M. Wiering, Data augmentation for plant classification, In International Conference on Advanced Concepts for Intelligent Vision Systems. Springer, Cham, (2017), pp.615-626.
- [62] M. Dyrmann, H. Karstoft and H.S. Midtiby, *Plant species classification using deep convolutional neural network*, **Biosystems Engineering**, 151 (2016) 72-80.
- [63] C. Zhang, P. Zhou, C. Li and L. Liu, A convolutional neural network for leaves recognition using data augmentation, In 2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing, Liverpool, UK, (2015), pp.2143-2150.
- [64] H. Zhu, Q. Liu, Y. Qi, X. Huang, F. Jiang and S. Zhang, *Plant identification based on very deep convolutional neural networks*, **Multimedia Tools and Applications**, 77:22 (2018) 29779-29797.

- [65] Z. Liu, L. Zhu, X.P. Zhang, X. Zhou, L. Shang, Z. K. Huang and Y. Gan, Hybrid Deep Learning for Plant Leaves Classification, In International Conference on Intelligent Computing, Springer, Cham, (2015), pp.115-123.
- [66] C. Wick and F. Puppe, *Leaf identification using a deep convolutional neural network*, **Computer Vision and Pattern Recognition**, (2017).
- [67] W.S. Jeon and S.Y. Rhee, *Plant leaf recognition using a convolution neural network*, **International Journal of Fuzzy Logic and Intelligent Systems**, 17:1 (2017) 26-34.
- [68] H. Yalcin and S. Razavi, Plant classification using convolutional neural networks, In 2016 Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics), Tianjin, China, (2016), pp.1-5.
- [69] P. Barré, B.C. Stöver, K.F. Müller and V. Steinhage, *LeafNet: A computer vision system for automatic plant species identification*, **Ecological Informatics**, 40 (2017) 50-56.
- [70] S.H. Lee, C.S. Chan, S.J. Mayo, P. Remagnino, *How deep learning extracts and learns leaf features for plant classification*, **Pattern Recognition**, 71 (2017) 1-13.
- [71] M. Šulc and J. Matas, *Fine-grained recognition of plants from images*, **Plant methods**, 13:1 (2017) 115.
- [72] S. Fiel and R. Sablatnig, Automated identification of tree species from images of the bark, leaves and needles, In: Proceedings of 16th computer vision winter workshop, Mitterberg, Austria, (2011), pp.1-6.
- [73] P. Novotný and T. Suk, *Leaf recognition of woody species in Central Europe*, **Biosyst Eng.** 115:4 (2013) 444-52.
- [74] A. Kaya, A.S. Keceli, C. Catal, H.Y. Yalic, H. Temucin and B. Tekinerdogan, *Analysis of transfer learning for deep neural network based plant classification models*, **Computers and electronics in agriculture**, 158 (2019) 20-29.
- [75] H. Wang, G. Li, Z. Ma and X. Li, Image recognition of plant diseases based on backpropagation networks, In 2012 5th International Congress on Image and Signal Processing, IEEE, Chongqing, China, (2012), pp.894-900.
- [76] S. Arivazhagan, R.N. Shebiah, S. Ananthi and S.V. Varthini, *Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features*, **Agricultural Engineering International: CIGR Journal**, 15:1 (2013) 211-217.
- [77] A.H. Kulkarni and A. Patil, *Applying image processing technique to detect plant disease*, **International Journal of Modern Engineering Research**, 2:5 (2012) 3661-3664.
- [78] S. Bashir and N. Sharma, *Remote area plant disease detection using image processing*, **IOSR J Electron Commun Eng.**, 2:6 (2012) 31-4.

- [79] K. Prashar, Robust Automatic Cotton Crop Disease Recognition (ACDR) Method using the Hybrid Feature Descriptor with SVM. 4th 2016 International Conference on Computing on sustainable Global Development, (2016).
- [80] G. Athanikar and P. Badar, *Potato Leaf Diseases Detection and Classification System*, **International Journal of Computer Science and Mobile Computing**, 5:2 (2016) 76-88.
- [81] H. Waghmare, R. Kokare and Y. Dandawate, Detection and classification of diseases of Grape plant using opposite colour Local Binary Pattern feature and machine learning for automated Decision Support System, In 2016 3rd international conference on signal processing and integrated networks (SPIN), Noida, India, (2016), pp.513-518.
- [82] S.R. Dubey and A.S. Jalal, *Apple disease classification using color, texture and shape features from images*, **Signal, Image and Video Processing**, 10:5 (2016) 819-826.
- [83] K.J. Mohan, M. Balasubramanian and S. Palanivel, *Detection and recognition of diseases from paddy plant leaf images*, **Int J Comput Appl.**, 144:12 (2016) 34-41.
- [84] P.B. Padol and A.A. Yadav, SVM classifier based grape leaf disease detection, In 2016 Conference on advances in signal processing (CASP), Pune, India, (2016), pp.175-179.
- [85] S. Tippannavar and S. Soma, *A machine learning system for recognition of vegetable plant and classification of abnormality using leaf texture analysis*, **Int. J. Sci. Eng. Res.** 8:6 (2017) 1558-1563.
- [86] H. Sabrol and K. Satish, Tomato plant disease classification in digital images using classification tree, In 2016 International Conference on Communication and Signal Processing (ICCSP), Melmaruvathur, India, (2016), pp.1242-1246.
- [87] M. Thilagavathi and S. Abirami, *Application of image processing in diagnosing guava leaf diseases*, **International Journal of Scientific Research and Management (IJSRM)**, 5:7 (2017).
- [88] L.T. Ayesha and G.J. Devang, *Disease detection in leaves using image processing techniques*, **International Research Journal of Engineering and Technology (IRJET)**, 4:4 (2017).
- [89] J.D. Pujari, R. Yakkundimath and A.S. Byadgi, *Classification of fungal disease symptoms affected on cereals using color texture features*, **International Journal of Signal Processing, Image Processing and Pattern Recognition**, 6:6 (2013) 321-330.
- [90] V. Singh and A.K. Misra, *Detection of plant leaf diseases using image segmentation and soft computing techniques*, **Information processing in Agriculture**, 4:1 (2017) 41-49.
- [91] N.N. Kurniawati, S.N.H.S. Abdullah, S. Abdullah and S. Abdullah, Investigation on image processing techniques for diagnosing paddy diseases, In 2009

- international conference of soft computing and pattern recognition, Malacca, Malaysia, (2009), pp.272-277.
- [92] S. Biswas, B. Jagyasi, B.P. Singh and M. Lal, Severity identification of Potato Late Blight disease from crop images captured under uncontrolled environment, In 2014 IEEE Canada International Humanitarian Technology Conference-(IHTC), Montreal, QC, Canada, (2014), pp:1-5.
- [93] Y. Dandawate and R. Kokare, An automated approach for classification of plant diseases towards development of futuristic Decision Support System in Indian perspective, In: IEEE international conference on advances in computing, communications and informatics (ICACCI), Kochi, India, (2015), pp.794–799.
- [94] S. Yun, W. Xianfeng, Z. Shanwen and Z. Chuanlei, *PNN based crop disease recognition with leaf image features and meteorological data*, **International Journal of Agricultural and Biological Engineering**, 8:4 (2015) 60-68.
- [95] M. Ramakrishnan, Groundnut leaf disease detection and classification by using back propagation algorithm, In: IEEE international conference on communications and signal processing (ICCSP), Melmaruvathur, India, (2015), pp.964-968.
- [96] P.R. Rothe and R.V. Kshirsagar, Cotton leaf disease identification using pattern recognition techniques, In: IEEE international conference on pervasive computing (ICPC), Pune, India, (2015), pp.1-6.
- [97] S. Kaur, S. Pandey and S. Goel, *Semi-automatic leaf disease detection and classification system for soybean culture*, **IET Image Processing**, 12:6 (2018) 1038-1048.
- [98] M.S. Hossain, R.M. Mou, M.M. Hasan, S. Chakraborty and M.A. Razzak, Recognition and detection of tea leaf's diseases using support vector machine, In 2018 IEEE 14th International Colloquium on Signal Processing & Its Applications (CSPA) IEEE, Batu Feringghi, Malaysia, (2018), pp.150-154.
- [99] S. Walleign, M. Polceanu and C. Buche, Soybean Plant Disease Identification Using Convolutional Neural Network, In The Thirty-First International Flairs Conference, Florida, (2018), pp.1-6.
- [100] B. Liu, Y. Zhang, D. He and Y. Li, *Identification of apple leaf diseases based on deep convolutional neural networks*, **Symmetry**, 10:1 (2017) 11.
- [101] J. Amara, B. Bouaziz, A. Algergawy, *A Deep Learning-based Approach for Banana Leaf Diseases Classification*, **In BTW (Workshops)**, (2017) 79-88.
- [102] A.T. Sapkal and U.V. Kulkarni, *Comparative study of leaf disease diagnosis system using texture features and deep learning features*, **International Journal of Applied Engineering Research**, 13:19 (2018) 14334-14340.
- [103] A. Ramcharan, K. Baranowski, P. McCloskey, B. Ahmed, J. Legg and D.P. Hughes, *Deep learning for image-based cassava disease detection*, **Frontiers in plant science**, 8 (2017) 1852.

- [104] G. Wang, Y. Sun and J. Wang, *Automatic image-based plant disease severity estimation using deep learning*, **Computational intelligence and neuroscience**, 1-8 (2017).
- [105] K.P. Ferentinos, *Deep learning models for plant disease detection and diagnosis*, **Computers and Electronics in Agriculture**, 145 (2018) 311-318.
- [106] M. Brahim, K. Boukhalfa and A. Moussaoui, *Deep learning for tomato diseases: classification and symptoms visualization*, **Applied Artificial Intelligence**, 31:4 (2017) 299-315.
- [107] Y. Lu, S. Yi, N. Zeng, Y. Liu and Y. Zhang, *Identification of rice diseases using deep convolutional neural networks*, **Neurocomputing**, 267 (2017) 378-384.
- [108] S.P. Mohanty, D.P. Hughes and M. Salathé, *Using deep learning for image-based plant disease detection*, **Frontiers in plant science**, 7 (2016) 1419.
- [109] E. Fujita, Y. Kawasaki, H. Uga, S. Kagiwada and H. Iyatomi, *Basic investigation on a robust and practical plant diagnostic system*, In 2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA), Anaheim, CA, USA, (2016), pp.989-992.
- [110] S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk and D. Stefanovic, *Deep neural networks based recognition of plant diseases by leaf image classification*, **Computational intelligence and neuroscience**, (2016) 1-11.
- [111] A. Picon, A. Alvarez-Gila, M. Seitz, A. Ortiz-Barredo, J. Echazarra and A. Johannes, *Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild*, **Computers and Electronics in Agriculture**, 161 (2019) 280-290.
- [112] J.G. Barbedo, *Factors influencing the use of deep learning for plant disease recognition*, **Biosystems engineering**, 172 (2018) 84-91.
- [113] J.G.A. Barbedo, *Plant disease identification from individual lesions and spots using deep learning*, **Biosystems Engineering**, 180 (2019) 96-107.
- [114] Y. Altuntaş, Z. Cömert and A.F. Kocamaz, *Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach*, **Computers and Electronics in Agriculture**, 163 (2019) 104874.
- [115] M.M. Ozguven and K. Adem, *Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms*, **Physica A: Statistical Mechanics and its Applications**, 535 (2019) 122537.
- [116] G. Geetharamani and A. Pandian, *Identification of plant leaf diseases using a nine-layer deep convolutional neural network*, **Computers & Electrical Engineering**, 76 (2019) 323-338.
- [117] E.C. Too, L. Yujian, S. Njuki and L. Yingchun, *A comparative study of fine-tuning deep learning models for plant disease identification*, **Computers and Electronics in Agriculture**, 161 (2019) 272-279.

- [118] G. Hu, H. Wu, Y. Zhang and M. Wan, *A low shot learning method for tea leaf's disease identification*, **Computers and Electronics in Agriculture**, 163 (2019) 104852.
- [119] S. Zhang, W. Huang and C. Zhang, *Three-channel convolutional neural networks for vegetable leaf disease recognition*, **Cognitive Systems Research**, 53 (2019) 31-41.
- [120] M. Arsenovic, M. Karanovic, S. Sladojevic, A. Anderla and D. Stefanovic, *Solving Current Limitations of Deep Learning Based Approaches for Plant Disease Detection*, **Symmetry**, 11:7 (2019) 939.
- [121] M. Turkoglu and D. Hanbay, *Recognition of plant leaves: An approach with hybrid features produced by dividing leaf images into two and four parts*, **Applied Mathematics and Computation**, 352 (2019) 1-14.
- [122] M. Turkoglu and D. Hanbay, *Leaf-based plant species recognition based on improved local binary pattern and extreme learning machine*, **Physica A: Statistical Mechanics and its Applications**, 527 (2019) 121297.
- [123] M. Turkoglu and D. Hanbay, *Leaf recognition system based on geometric features*, **Tr. J. Nature Sci.** 5:2 (2016) 26.
- [124] M. Turkoglu and D. Hanbay, *Combination of Deep Features and KNN Algorithm for Classification of Leaf-Based Plant Species*, In 2019 International Conference on Artificial Intelligence and Data Processing (IDAP), Inonu University, Malatya, (2019), pp.1-4.
- [125] M. Turkoglu and D. Hanbay, *Plant Recognition System based on Deep Features and Color-LBP method*, In 2019 27th Signal Processing and Communications Applications Conference (SIU), Cumhuriyet University, Sivas, (2019), pp.1-4.
- [126] M. Turkoglu and D. Hanbay, *Destek Vektör Makinaları Kullanılarak Renk ve Morfolojik Özelliklere Dayalı Yaprak Tanıma Sistemi*, International Engineering, Science and Education Conference, Dicle Üniversitesi, Diyarbakır, (2016), pp.1-4.
- [127] Muammer Türkoglu. *“Otomatik Kan Hücrelerinin Tanınması Ve Sınıflandırılmasında Değişmez Momentlere Dayalı Görüntü İşleme Yöntemlerinin Kullanılması”* Yüksek Lisans Tezi, Fırat Üniversitesi, Elazığ, 2013.
- [128] Ramazan Polat. *“Biyomedikal Görüntü Bölütleme”* Yüksek Lisans Tezi, Fırat Üniversitesi, Elazığ, 2007.
- [129] M. Sezgin and B. Sankur, *Thresholding by dynamic variance function and foreground attributes*, **Pattern Recognition Letters**, (2001).
- [130] Y. Solihin and C.G. Leedham, *The multi-stage approach to grey-scale image thresholding for specific applications*, Nanyang Technological University, School of Computer Engineering, Nanyang Avenue, Republic of Singapore, (2000), pp.1-27.

- [131] Güzide Miray Perihanoğlu. “*Dijital Görüntü İşleme Teknikleri Kullanılarak Görüntülerden Detay Çıkarımı*” Doktora Tezi, İstanbul Teknik Üniversitesi, İstanbul, 2015.
- [132] Aydın Kızılkaya, Görüntü Bölütleme, Elektrik-Elektronik Mühendisliği Bölümü, Pamukkale Üniversitesi, Denizli, (2008).
- [133] N. Otsu, *A threshold selection method from gray-level histograms*, **Automatica**, 11:285-296 (1975). 23-27.
- [134] B.K. Savaş, S. İlkin, S. Hangisi and S. Şahin, *Gölge Tespitinde Kullanılan Bayes Sınıflandırma, Otsu Bölütleme ve Histogram Dağılımı Yöntemlerinin Karşılaştırılması*, **Düzce Üniversitesi Bilim ve Teknoloji Dergisi**, 5:2 (2017) 345-355.
- [135] Anonim. (2013). <http://www.cescript.com/2012/07/otsu-metodu-ile-adaptif-esikleme.html> (on-line access on 20 Feb, 2018).
- [136] Nabiyev, V., Bahçekapılı, S. (2007). Diabetik Retinopatinin Otomatik Algılanması Amacıyla Göz Görüntüsünden Kan Damarlarının Eşiklenmesi. Ulusal Kongresi ve Fuarı Bildirileri, 14-18.
- [137] M. Karhan, M.O. Oktay, Z. Karhan and H. Demir, Morfolojik görüntü işleme yöntemleri ile kayıslarda yaprak delen (çil) hastalığı sonucu oluşan lekelerin tespiti, In 6 th International Advanced Technologies Symposium (IATS’11), Fırat Üniversitesi, Elazığ, (2011), pp.172-176.
- [138] Ali Arı. “*Beyin Mr Görüntülerinden Tümörlerin Tespit Edilerek Sınıflandırılması*” Doktora Tezi, İnönü Üniversitesi, Malatya, 2019.
- [139] Osman Seçkin Şimşek. “*Gömülü grafik işlemcileri için opencl tabanlı görüntü işleme kütüphanesi ve insan yüzü tespit etme uygulaması*” Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi, Ankara, 2014.
- [140] Suat Toraman. “*Kızılötesi Spektroskopisi Kullanılarak Kan Örneklerinden Kolon Kanserine Yönelik Özellik Çıkarımı*” Doktora Tezi, Fırat Üniversitesi, Elazığ, 2016.
- [141] J. Wäldchen and P. Mäder, *Plant species identification using computer vision techniques: A systematic literature review*, **Archives of Computational Methods in Engineering**, 25:2 (2018) 507-543.
- [142] Z. Wang, H. Li, Y. Zhu and T. Xu, *Review of plant identification based on image processing*, **Archives of Computational Methods in Engineering**, 24:3 (2017) 637-654.
- [143] F.T.S. Yu and Y. Li, *Application of Moment Invariant to Neural computing for Pattern Recognition*, **Hybrid Image and signal Processing II. Proc. SPIE**, (1990) 1297-1307.
- [144] M.K. Hu, *Visual Pattern Recognition by Moment Invariants*, **IRE Trans., Inf., Theor., IT-8**, (1962), 179.

- [145] F.W. Smith and M.H. Wright, *Automatic Ship Photo Interpretation by the Method of Moments*, **IEEE Trans. Comput.**, 20:9 (1971) 1089-1095.
- [146] İlhan Uğur Ünal. “*Fourier Tanımlayıcıları ve Moment Değişmezleri ile 2D Nesne Tanımlama*” Yüksek Lisans Tezi, Marmara Üniversitesi, İstanbul, 2006.
- [147] D. Avcı and A. Varol, *An expert diagnosis system for classification of human parasite eggs based on multi-class SVM*, **Expert Systems with Applications**, 36:1 (2009) 43-48.
- [148] A.A.S. Costa, *Leaf Shape Recognition Using Fourier Descriptors and Hough Transform and Classification Using Probabilistic Neural Network*, Science Thesis Report in Computer Engineering, Mapua Institute of Technology, (2015).
- [149] A. Kadir, *Leaf identification using Fourier descriptors and other shape features*, **Gate to Computer Vision and Pattern Recognition**, 1:1 (2015) 3-7.
- [150] G. Easley, D. Labate and W.Q. Lim, *Sparse directional image representations using the discrete shearlet transform*, **Applied and Computational Harmonic Analysis**, 25:1 (2008) 25-46.
- [151] K. Guo and D. Labate, *Optimally sparse multidimensional representation using shearlets*, **SIAM journal on mathematical analysis**, 39:1 (2007) 298-318.
- [152] H. Yaşar, and M. Ceylan, *Investigation of image representation and denoising performances of real and complex valued fast finite shearlet transform*, Signal Processing and Communications Applications Conference (SIU), (2015).
- [153] Kazım Hanbay, “*Yuvarlak örgü makineleri için görüntü işleme tabanlı kumaş hatası tespit sistemi*” Doktora Tezi, İnönü Üniversitesi, Malatya, 2016.
- [154] K. Guo, K. Gitta and L. Demetrio, *Sparse multidimensional representations using anisotropic dilation and shear operators*, International Conference on the Interaction between Wavelets and Splines, (2005), pp.189-201.
- [155] Anonymous. (2015). *Fast finite shearlet transform: a tutorial*, preprint, Access: <http://arxiv.org/pdf/1202.1773.pdf>.
- [156] A. Çalışkan, E. Acar and Y. Kaya, *GSEM Tabanlı KNN Sınıflandırıcı Modeli İle Avuç İçi Tanıma Sistemi*, **Batman University-Journal of Life Sciences**, 1:2 (2012).
- [157] R. Hudec and M. Benco, *Novel method for color textures features extraction based on GSEM*, **Radioengineering**, 16:4 (2007) 64-67.
- [158] X. Wang and N.D. Georganas, *GLCM texture based fractal method for evaluating fabric surface roughness*, Canadian Conference on Electrical and Computer Engineering, St. John's, NL, Canada, (2009).
- [159] R.M. Haralick and K. Shanmugam, *Textural features for image classification*, **IEEE Transactions on systems, man, and cybernetics**, 6 (1973) 610-621.

- [160] A. Demirhan and İ. Güler, *Özörgütlemeli Harita Ağları ve Gri Düzey Eş Oluşum Matrisleri ile Görüntü Bölütleme*, **Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi**, 25:2 (2010).
- [161] A. Shashua, Y. Gdalyahu and G. Hayon, Pedestrian detection for driving assistance systems: Single-frame classification and system level performance, In Proceedings of IEEE Intelligent Vehicles Symposium, Parma, Italy, (2004).
- [162] N. Dalaland and B. Triggs, Histograms of oriented gradients for human detection, In 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, United States, (2005), pp.886-893.
- [163] N. Alpaslan, M.F. Talu, M. Gül and B. Yiğitcan, *HOG tabanlı YSA kullanılarak yağlı karaciğer tedavisindeki ilaç etkinliklerinin hesaplanması*, **Sakarya University Journal of Science**, 16:2 (2000) 106-112.
- [164] A. Emrullah and M.S. Özerdem, *Tarımsal İmge Dokularından HOG Algoritması ile Öznitelik Çıkarımı ve Öznitelik Tabanlı Toprak Neminin Tahmini*, **Anatolian Science-Bilgisayar Bilimleri Dergisi**, 1:1 (2016) 1-7.
- [165] F. Karakaya, H. Altun and M.A. Çavuşlu, Gerçek zamanlı nesne tanıma uygulamaları için HOG algoritmasının FPGA tabanlı gömülü sistem uyarlaması. In IEEE 17th Signal Processing and Communications Applications Conference (SIU), Antalya, Turkey, (2009).
- [166] A. Saygili and S. Albayrak, Meniscustear classification using histogram of oriented gradients in knee MR images, In 26th Signal Processing and Communications Applications Conference (SIU), Izmir, Turkey, (2018), pp.1-4.
- [167] N. Dalal and B. Triggs, *Histograms of oriented gradients for human detection*, In **2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**, 1:1 (2005) 886-893.
- [168] D.C. He and L. Wang, *Texture unit, texture spectrum, and texture analysis*, **IEEE transactions on Geoscience and Remote Sensing**, 28:4 (1990) 509-512.
- [169] J. Machicao, L.C. Ribas, L.F. Scabini and O.M. Bruno, *Cellular automata rule characterization and classification using texture descriptors*, **Physica A: Statistical Mechanics and its Applications**, 497 (2018) 109-117.
- [170] A. Şeker, B. Diri and H.H. Balık, *Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme*, **Gazi Mühendislik Bilimleri Dergisi (GMBD)**, 3:3 (2017) 47-64.
- [171] K. Kayaalp and A.A. Süzen, *Derin Öğrenme ve Türkiye'deki Uygulamaları. Institution of Economic Development and Social Researches Publications*, Türkiye, 2018, p. 1-93.
- [172] M.A. Kızrak and B. Bolat *Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma*, **Bilişim Teknolojileri Dergisi**, 11:3 (2018) 263-286.

- [173] E. Ülker, *Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri*, **Gaziosmanpaşa Bilimsel Araştırma Dergisi**, 6:3 (2017) 85-104.
- [174] F. Doğan and İ. Türkoğlu, *Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması*, **Sakarya University Journal of Computer and Information Sciences**, 1:1 (2018) 10-21.
- [175] A. Krizhevsky, I. Sutskever and G.E. Hinton, *Imagenet classification with deep convolutional neural networks*, **In Advances in neural information processing systems**, (2012) 1097-1105.
- [176] K. Simonyan and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*, **In ICLR**, (2014).
- [177] F.N. Landola, S. Han, M.W. Moskewicz, K. Ashraf, W.J. Dally and K. Keutzer, *Squeezenet: Alexnet-level accuracy with 50x fewer parameters and 0.5 mb model size*, **In ICLR**, (2016).
- [178] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, et al., Going deeper with convolutions, In: Proceedings of the IEEE conference on computer vision and pattern recognition, Boston, MA, USA, (2015), pp.1-9.
- [179] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens and Z. Wojna, Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, (2016), pp.2818-2826.
- [180] C. Szegedy, S. Ioffe, V. Vanhoucke and A.A. Alemi, *Inception-v4, inception-resnet and the impact of residual connections on learning*, **In AAAI**, (2017) 4278-4284.
- [181] K. He, X. Zhang, S. Ren and J. Sun, Deep residual learning for image recognition, In: Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), Las Vegas, USA, (2016), pp.770-778.
- [182] G. Huang, Z. Liu, L. Van Der Maaten and K.Q. Weinberger, Densely Connected Convolutional Networks. **In CVPR**, 1:2 (2017) 3.
- [183] Y. LeCun, Y. Bengio and G. Hinton, *Deep learning*, **Nature**, 521(7553) (2015) 436.
- [184] M. Luo and Zhang, K. (2014). *A hybrid approach combining extreme learning machine and sparse representation for image classification*, **Engineering Applications of Artificial Intelligence**, 27 (2014) 228-235.
- [185] F. Doğan, and İ. Türkoğlu, *Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme*, **DÜMF Mühendislik Dergisi**, 10:2 (2019) 409-445.
- [186] L.D. Nguyen, D. Lin, Z. Lin and J. Cao, Deep CNNs for microscopic image classification by exploiting transfer learning and feature concatenation, In 2018 IEEE International Symposium on Circuits and Systems (ISCAS), (2018), pp.1-5.

- [187] X. Chen, Y. Zhu, H. Zhou, L. Diao and D. Wang, *ChineseFoodNet: A large-scale image dataset for Chinese food recognition*, **Computer Vision and Pattern Recognition**, (2017).
- [188] U. Kamal, A.M. Rafi, R. Hoque, S. Das, A. Abrar and M. Hasan, *Application of DenseNet in Camera Model Identification and Post-processing Detection*, **arXiv preprint arXiv:1809.00576**, 2018.
- [189] S. Liang, R. Zhang, D. Liang, T. Song, T. Ai, C. Xia and Y. Wang, *Multimodal 3D DenseNet for IDH genotype prediction in gliomas*, **Genes**, 9:8 (2018) 382.
- [190] Anonymous. (2018). <https://towardsdatascience.com/review-densenet-image-classification-b6631a8ef803> (on-line access on 20 Feb, 2018).
- [191] C. Cortes and V. Vapnik, *Support-vector networks*, **Machine Learning**, 20:3 (1995) 273.
- [192] V. Vapnik, *The Nature of Statistical Learning Theory*, **Springer-Verlag**, (1995).
- [193] V. Vapnik, *The nature of statistical learning theory*, **Springer science & business media**, (2013).
- [194] O.G. Sezer, A. Erçil and M. Keskinöz, *Destek Vektör Makinesi Kullanarak Bağımsız Bileşen Tabanlı 3B Nesne Tanıma* (in Turkish), SIU 2005, (2005).
- [195] İ. Yabanova and M. Yumurtacı, *Classification of dynamic egg weight using support vector machine*, **Journal of the Faculty of Engineering and Architecture of Gazi University**, 33:2 (2018) 393-402.
- [196] T. Kavzoğlu and İ. Çölkesen, *Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi*, **Harita Dergisi**, 144:7 (2010) 73-82.
- [197] D. Avcı and A. Varol, *An expert diagnosis system for classification of human parasite eggs based on multi-class SVM*, **Expert Systems with Applications**, 36:1 (2009) 43-48.
- [198] Öykü Eren. “*Alerjen Proteinlerin Otomatik Sınıflandırılması*” Yüksek Lisans Tezi, Başkent Üniversitesi, Ankara, (2008).
- [199] Z.G. Jiang, H.G. Fu and L.J. Li, *Support vector machine for mechanical faults classification*, **Journal of Zhejiang University Science**, 6:5 (2005) 433-439.
- [200] J.A. Suykens and J. Vandewalle, *Least squares support vector machine classifiers*, **Neural processing letters**, 9:3 (1999) 293-300.
- [201] Osman Eray. “*Destek Vektör Makineleri ile Ses Tanıma Uygulaması*” Yüksek Lisans Tezi, Pamukkale Üniversitesi, Denizli, (2008).
- [202] M.S. Özerdem and E. Acar, *Zambak Yaprağı İmgelerinde Pas Hastalıklarının GLCM Tabanlı Sınıflandırma Yöntemleri ile Tespiti*, **Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi**, 2:2 (2011) 95-105.

- [203] N. Ceryan, U. Okkan, P. Samui and S. Ceryan, *Modeling of tensile strength of rocks materials based on support vector machines approaches*, **International Journal for Numerical and Analytical Methods in Geomechanics**, 37:16 (2013) 2655-2670.
- [204] G.B. Huang, Q.Y. Zhu and C.K. Siew, *Extreme learning machine: theory and applications*, **Neurocomputing**, 70:1 (2006) 489-501.
- [205] Ö.F. Alçın, A. Şengür and M.C. İnce, *İleri-geri takip algoritması tabanlı seyrek aşırı öğrenme makinesi*, **Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi**, 30:1 (2015).
- [206] G.B. Huang, Q.Y. Zhu and C.K. Siew, *Extreme learning machine: a new learning scheme of feedforward neural networks*, **Neural Networks**, 2 (2004) 985-990.
- [207] M. Luo and K. Zhang, *A hybrid approach combining extreme learning machine and sparse representation for image classification*, **Engineering Applications of Artificial Intelligence**, 27 (2014) 228-235.
- [208] O.F. Alcin, A. Sengur, J. Qian and M.C. Ince, *OMP-AÖM: orthogonal matching pursuit-based extreme learning machine for regression*, **Journal of Intelligent Systems**, 24:1 (2015) 135-143.
- [209] A. Şengür, B.N. Akılotu, S.A. Tuncer, Z. Kadiroğlu, S. Yavuzkılıç, Ü. Budak and E. Deniz, *Optic disc determination in retinal images with deep features*. In 2018 26th Signal Processing and Communications Applications Conference (SIU), Izmir, Turkey, (2018).
- [210] İ. Çölkesena, T. Kavzoğlua and T. Yomralıoğlu, *Uzaktan Algılanmış Görüntülerde Optimum Bantların Seçiminde Destek Vektör Makinelerinin Kullanımı*, TUFUAB VIII. Teknik Sempozyumu, Konya, (2015).
- [211] H. Budak, *Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım*, **Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, 22 (2018) 21-31.
- [212] E. Yildiz and Y. Sevim, *Comparison of linear dimensionality reduction methods on classification methods*, In 2016 National conference on electrical, electronics and biomedical engineering (ELECO), Bursa, Turkey, (2016), pp.161-164.
- [213] M. Karabatak, M.C. Ince and E. Avci, *An expert system for diagnosis breast cancer based on Principal Component Analysis method*, In 2008 IEEE 16th Signal Processing, Communication and Applications Conference, Aydin, Turkey, (2008), pp.1-4.
- [214] A. Jain, K. Nandakumar and A. Ross, *Score normalization in multimodal biometric systems*, **Pattern recognition**, 38:12 (2005) 2270-2285.
- [215] D.T. Larose and C.D. Larose, *Discovering knowledge in data: an introduction to data mining*, John Wiley & Sons, (2014).

- [216] S. Yavuz and M. Deveci, *İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi*, **Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 40 (2012) 167-187.
- [217] Mete Aydemir. “*Zirai Mücadele Teknik Talimatları*” Gıda Tarım ve Hayvancılık Bakanlığı Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü Bitki Sağlığı Araştırmaları Daire Başkanlığı, Ankara, (2008).
- [218] C. Yang, H. Wei and Q. Yu, *Multiscale Triangular Centroid Distance for Shape-Based Plant Leaf Recognition*, **ECAI**, (2016).
- [219] S. Mouine, I. Yahiaoui and A. Verroust-Blondet, A shape-based approach for leaf classification using multiscale triangular representation, In Proceedings of the 3rd ACM conference on International conference on multimedia retrieval ACM. (2013), pp.127-134.
- [220] C. Huang, T.X. Han and Z. He, *Multi-scale embedded descriptor for shape classification*, **Journal of Visual Communication and Image Representation**, 25:7 (2014) 1640-1646.
- [221] A. Kadir, L.E. Nugroho, A. Susanto and P.I. Santosa, *Leaf classification using shape, color, and texture features*, **International Journal of Engineering Trends and Technology**, 2:1 (2013) 225-230.
- [222] A.H. Kulkarni, H.M. Rai, K.A. Jahagirdar and P.S. Upparamani, *A leaf recognition technique for plant classification using RBPNN and Zernike moments*, **International Journal of Advanced Research in Computer and Communication Engineering**, 2:1 (2013) 984-988.
- [223] K. Singh, I. Gupta and S. Gupta, *Svm-bdt pnn and fourier moment technique for classification of leaf shape*, **International Journal of Signal Processing, Image Processing and Pattern Recognition**, 3:49 (2010) 67-78.
- [224] C. Uluturk and A. Ugur, Recognition of leaves based on morphological features derived from two half-regions, In Innovations in intelligent systems and applications (INISTA), (2012), pp.1-4.
- [225] H. Zhang and X. Tao, *Leaf image recognition based on wavelet and fractal dimension*, **Journal of Computational System**, 11:1 (2015) 141-148.
- [226] A. Muthevi and R.B. Uppu, Leaf classification using completed local binary pattern of textures, In 2017 IEEE 7th International Advance Computing Conference (IACC), (2017), pp.870-874.
- [227] M. Lukic, E. Tuba and M. Tuba, Leaf recognition algorithm using support vector machine with Hu moments and local binary patterns, In 2017 IEEE 15th International Symposium on Applied Machine Intelligence and Informatics (SAMI). (2017), pp.485-490.
- [228] S. Chakraborty, S.K. Singh and P. Chakraborty, *Local quadruple pattern: a novel descriptor for facial image recognition and retrieval*, **Computers & Electrical Engineering**, 62 (2017) 92-104.

- [229] E.E. Abusham and H.K. Bashir, Face recognition using local graph structure (LGS) In International Conference on Human-Computer Interaction Springer, Berlin, Heidelberg. (2011), pp.169-175.
- [230] M.F.A. Abdullah, M.S. Sayeed, K.S. Muthu, H.K. Bashier, A. Azman and S.Z. Ibrahim, Face recognition with symmetric local graph structure (SLGS), Expert Systems with Applications, 41:14 (2014) 6131-6137.
- [231] R.D. Rakshit, S.C. Nath and D.R. Kisku, *Face identification using some novel local descriptors under the influence of facial complexities*, **Expert Systems with Applications**, 92 (2018) 82-94.
- [232] P. Pawara, E. Okafor, O. Surinta, L. Schomaker and M. Wiering, *Comparing Local Descriptors and Bags of Visual Words to Deep Convolutional Neural Networks for Plant Recognition*, **In: ICPRAM**, (2017) 479-486.
- [233] Samet Kaya. “İki seviyeli inverter anahtarlama teknikleri için MATLAB/GUI tabanlı interaktif benzetim ortamı” Yüksek Lisans Tezi, Fırat Üniversitesi, Elazığ, (2017).

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	Muammer TÜRKOĞLU
Doğum Yeri- Tarihi	Elazığ-1990
Adres	Bingöl Üniversitesi Mühendislik-Mimarlık Fakültesi / Bingöl
E-posta	mturkoglu@bingol.edu.tr

EĞİTİM BİLGİLERİ

Doktora	İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı (2015-2019)
Yüksek Lisans	Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Eğitimi Anabilim Dalı (2011-2013)
Lisans	Fırat Üniversitesi, Teknik Eğitim Fakültesi, Elektronik ve Bilgisayar Öğretmenliği (2007-2011)
Lise	Elazığ Fatih Lisesi (2004-2007)

MESLEKİ DENEYİMLER

Üniversite	Bingöl Üniversitesi, Bilgisayar Mühendisliği, Araştırma Görevlisi, 2013-Devam ediyor
------------	--

Tezden Türetilen Yayınlar

1- Uluslararası hakemli dergilerde yayınlanan makaleler (SCI & SSCI)

A1. M. Turkoglu and D. Hanbay, Recognition of plant leaves: An approach with hybrid features produced by dividing leaf images into two and four parts, Applied Mathematics and Computation, 352 (2019) 1-14.

A2. M. Turkoglu and D. Hanbay, Leaf-based plant species recognition based on improved local binary pattern and extreme learning machine, Physica A: Statistical Mechanics and its Applications, 527 (2019) 121297.

A3. M. Turkoglu and D. Hanbay, Shearlet dönüşüm ve yeni geometrik özellikler kullanılarak aşırı öğrenme makinesine dayalı bitki tanıma sistemi, Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 34:4 (2019) 2097-2112.

A4. M. Turkoglu and D. Hanbay, Plant disease and pest detection using deep learning-based features, Turkish Journal of Electrical Engineering & Computer Sciences, 27:3 (2019) 1636-1651.

2- Ulusal ulakbimde ve dergi parkta taranan dergilerde yapılan çalışmalar

B1. M. Turkoglu and D. Hanbay, Leaf recognition system based on geometric features, Tr. J. Nature Sci. 5:2 (2016) 26.

3- Uluslararası Bilimsel Toplantılarda Sunulan ve Bildiri Kitabında Basılan Bildiriler

C1. M. Turkoglu and D. Hanbay, Combination of Deep Features and KNN Algorithm for Classification of Leaf-Based Plant Species, In 2019 International Conference on Artificial Intelligence and Data Processing (IDAP), Inonu University, Malatya, (2019), pp.1-4.

C2. M. Turkoglu and D. Hanbay, Plant Recognition System based on Deep Features and Color-LBP method, In 2019 27th Signal Processing and Communications Applications Conference (SIU), Cumhuriyet University, Sivas, (2019), pp.1-4.

C3. M. Turkoglu and D. Hanbay, Apricot Disease Identification based on attributes obtained from Deep Learning Algorithms, In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), Inonu University, Malatya, Turkey, (2018), pp. 1-4.

C4. M. Turkoglu, O.F. Alcin, M. Ustundag, D. Hanbay, Leaf recognition and classification based on geometric and statistical features, International Conference on Natural Science and Engineering (ICNASE'16), Kilis, Turkiye, (2016), pp. 1-4.

C5. M. Turkoglu and D. Hanbay, Destek Vektör Makinaları Kullanılarak Renk ve Morfolojik Özelliklere Dayalı Yaprak Tanıma Sistemi, International Engineering, Science and Education Conference, Dicle Üniversitesi, Diyarbakır, (2016), pp.1-4.

C6. M. Turkoglu and D. Hanbay, Classification of the grape varieties based on leaf recognition by using SVM classifier, 23 th In Signal Processing and Communications Applications Conference (SIU), Inonu University, Malatya, Türkiye, (2015), pp. 2674-2677.

4- Tez ile ilgili Projeler:

D1. Bingöl Üniversitesi Bilimsel Araştırma Projeleri programı (Proje Numarası: BAP-MMF.2018.00.004).