



T.C.  
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
İLERİ TEKNOLOJİLER ANABİLİM DALI



**DERİN ÖĞRENME İLE ÖZNİTELİK  
ÇIKARMANIN ÇİÇEK  
SINIFLANDIRMADA KULLANIMI**

**ASLAN İÇEL**

**YÜKSEK LİSANS TEZİ**

**KIRŞEHİR**

**2025**



T.C.  
KIRSEHİR AHİ EVRAN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
İLERİ TEKNOLOJİLER ANABİLİM DALI



**DERİN ÖĞRENME İLE ÖZNİTELİK  
ÇIKARMANIN ÇİÇEK  
SINIFLANDIRMADA KULLANIMI**

**ASLAN İÇEL**

**YÜKSEK LİSANS TEZİ**

**DANIŞMAN**

**Dr. Öğr. Üyesi Memduh KÖSE**

**KIRSEHİR**

**2025**

**KIRŐEHİR AHİ EVRAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ**  
**YÜKSEK LİSANS TEZ ÇALIŐMASI**  
**ETİK BEYANI**

Kırőehir Ahi Evran Üniversitesi Bilimsel Araőtırma ve Yayın Etięi Yönergesini okuduęumu ve anladığımı ve Kırőehir Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduęum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettięimi,
- Tüm bilgi, belge, deęerlendirme ve sonuçları bilimsel etik kurallarına uygun olarak sunduęumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir deęişiklik yapmadığımı,
- Tez olarak sunduęum bu çalışmanın özgün olduęunu,

bildirir, aksi bir durumda bu konuda hakkımda yapılacak tüm yasal işlemleri ve aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

27/08/2025

Aslan İÇEL

## İÇİNDEKİLER DİZİNİ

Sayfa No

<b>TEŞEKKÜR</b> .....	<b>II</b>
<b>ÖZET</b> .....	<b>III</b>
<b>ABSTRACT</b> .....	<b>IV</b>
<b>TABLolar DİZİNİ</b> .....	<b>V</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>VI</b>
<b>KISALTMALAR DİZİNİ</b> .....	<b>VII</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Manuel Özelliklere Dayalı Çiçek Tanıma Yöntemleri .....	3
1.2. Derin Öğrenme Tabanlı Çiçek Tanıma Yöntemleri.....	4
<b>2. ÖNCEKİ ÇALIŞMALAR</b> .....	<b>9</b>
<b>3. MATERYAL VE METOD</b> .....	<b>13</b>
3.1. Evrişimsel Sinir Ağı.....	14
3.2. Veri Toplama .....	16
3.3. Önceden Eğitilmiş Derin Sinir Ağları.....	20
3.4. Uygulamada Kullanılan Önceden Eğitilmiş Sinir Ağı Mimarileri .....	21
<b>4. BULGULAR VE TARTIŞMA</b> .....	<b>23</b>
<b>5. SONUÇ VE ÖNERİLER</b> .....	<b>33</b>
<b>KAYNAKLAR</b> .....	<b>35</b>
<b>EKLER</b> .....	<b>43</b>
EK-1 Kongre Katılım Belgesi.....	43
<b>ÖZGEÇMİŞ</b> .....	<b>45</b>

## TEŐEKKÜR

Yüksek Lisansa başlamamda ve yüksek lisans ders sürecinde kendisini tanıdığım günden bu yana gösterdiği sakin ve sabırlı hali ile her zaman bana örnek olmasının yanı sıra bir bilim insanının nasıl çalışması gerektiğini kendisinden öğrendiğim değerli danışmanım Dr. Öğr. Üyesi Memduh KÖSE'ye büyük bir içtenlikle teşekkür ederim.

Bu tez çalışmam süresince bana her zaman destek olan, sevgisiyle güç veren değerli eşim 'e, hayatımın neşesi ve ilham kaynağı sevgili kızım ve oğlum 'a sonsuz teşekkürler ederim. Varlığınız, bu yolculukta en büyük dayanağım oldu.

Ağustos, 2025

Aslan İÇEL

## ÖZET

### YÜKSEK LİSANS TEZİ

#### DERİN ÖĞRENME İLE ÖZİNİTELİK ÇIKARMANIN ÇİÇEK SINIFLANDIRMADA KULLANIMI

Aslan İÇEL

KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ  
FEN BİLİMLER ENSTİTÜSÜ  
İLERİ TEKNOLOJİLER ANABİLİM DALI

Danışman: Dr. Öğr. Üyesi Memduh KÖSE  
Yıl: 2025, Sayfa: 45  
Jüri: Dr. Öğr. Üyesi Memduh KÖSE  
Doç. Dr. H. Alparslan ILGIN  
Dr. Öğr. Üyesi Çağrı KILINÇ

Derin öğrenme teknikleri, görüntü tanıma ve sınıflandırma problemleri için yaygın olarak kullanılmaktadır. Derin öğrenme mimarileri, giderek daha fazla katman içerecek ve sınıflandırma problemleri için daha sağlam modeller haline gelecek şekilde değişime uğramıştır. Bu çalışmada, derin öğrenme modellerinden 4 tanesi çiçekleri 20 kategoriye sınıflandırmak için ince ayarlanmıştır. 20 farklı çiçek kategorisinden rasgele eğitilen derin ağların çıkardığı öz nitelikler destek vektör makinaları kullanılarak sınıflandırılmıştır. Kullanılan veri seti özgün olarak kampüste bulunan bitki familyasından oluşturulmuştur. Derin öğrenme yöntemleri Matlab ortamında gerçekleştirilmiştir. Her sınıftan 1000 görüntü olmak üzere veri setinde toplam 20000 görüntü vardır. Modelin eğitimi yanlılığı önlemek amacıyla rasgele seçilen görüntüler kullanılarak yapılmıştır. Geri kalan görüntüler test aşamasında kullanılmıştır. Eğitim oranı parametresine göre veri setinden elemanlar seçilmiştir. Eğitim oranı %10'un üzerine iken ShuffleNet, SqueezeNet ve ResNet-50 modellerin sınıflandırma doğrulukları %95'in üzerine çıkmaktadır. GoogleNet'in ise %25 eğitim oranından sonra sınıflandırma doğruluğu %95'in üzerine çıkmaktadır. Sınıflandırmada kullanılan karşılaştırma metriklerinden karışıklık matrisi metrikleri de dört model için eğitim oranının artmasına göre değerlendirilmiştir.

**Anahtar Kelimeler:** Öz nitelik çıkarma, Sınıflandırma, Evrişimli sinir ağı, Transfer öğrenmesi, Derin öğrenme.

## ABSTRACT

### MASTER'S THESIS

## USING FEATURE EXTRACTION WITH DEEP LEARNING IN FLOWER CLASSIFICATION

Aslan İÇEL

KIRŞEHİR AHI EVRAN UNIVERSITY  
INSTITUTE OF NATURAL AND APPLIED SCIENCES  
DEPARTMENT OF ADVANCED TECHNOLOGIES

**Supervisor:** Assist. Prof. Dr. Memduh KÖSE  
Year: 2025, Pages: 45  
**Juries:** Assist. Prof. Dr. Memduh KÖSE  
Assos. Prof. Dr. H. Alparslan ILGIN  
Assist. Prof. Dr. Çağrı KILINÇ

Deep learning techniques are widely used for image recognition and classification problems. Deep learning architectures have evolved to include more layers and become more robust models for classification problems. In this study, four deep learning models were fine-tuned to classify flowers into 20 categories. Features extracted by deep networks randomly trained from 20 different flower categories were classified using support vector machines. The dataset used was originally composed of plant families found on campus. Deep learning methods were implemented in Matlab. The dataset contained 20,000 images in total, 1,000 from each class. The model was trained using randomly selected images to prevent bias. The remaining images were used in the testing phase. Elements were selected from the dataset according to the training rate parameter. When the training rate exceeds 10%, the classification accuracies of ShuffleNet, SqueezeNet, and ResNet-50 models exceed 95%. However, GoogleNet's classification accuracy exceeds 95% after a 25% training rate. Confusion matrix metrics, one of the comparison metrics used in classification, were also evaluated according to the increase in training rate for four models.

**Key Words:** Feature extraction, Classification, Convolution neural network, Transfer learning, Deep learning.

## TABLolar DİZİNİ

Sayfa No

<b>Tablo 3.1.</b> Uygulamada kullanılan önceden eğitilmiş ağlar ve özellikleri.....	<b>21</b>
<b>Tablo 4.1.</b> Karışıklık matrisi .....	<b>24</b>

## ŞEKİLLER DİZİNİ

Sayfa No

Şekil 3.1. Çiçek türlerinin sınıflandırması için ESA mimarisinin temel akışı.....	13
Şekil 3.2. 360° döndürülerek farklı açılardan fotoğraf çekimi .....	18
Şekil 3.3. Çiçek 1 verisine ait resimler .....	18
Şekil 3.4. Çiçek 2 verisine ait resimler .....	19
Şekil 3.5. Çiçek 3 verisine ait resimler .....	19
Şekil 3.6. Çiçek 3 verisine ait resimler .....	19
Şekil 3.7. SqueezeNet mimarisi .....	21
Şekil 3.8. ResNet-50 mimarisi .....	21
Şekil 3.9. GoogleNet mimarisi.....	22
Şekil 3.10. ShuffleNet mimarisi.....	22
Şekil 4.1. Dört Model (ShuffleNet, ResNet-50, GoogleNet, SqueezeNet) için Sınıflandırma Doğruluğu-Eğitim Oranı Grafiği.....	23
Şekil 4.2. Dört Model (ShuffleNet, ResNet-50, GoogleNet, SqueezeNet) için Sınıflandırma Doğruluğu-Eğitim Oranı Kutu Çizimleri.....	24
Şekil 4.3. SqueezeNet model için %1 eğitim oranında sınıflandırma karışıklık matrisi	26
Şekil 4.4. ShuffleNet model için %1 eğitim oranında sınıflandırma karışıklık matrisi..	26
Şekil 4.5. ResNet-50 model için %1 eğitim oranında sınıflandırma karışıklık matrisi ..	27
Şekil 4.6. GoogleNet model için %1 eğitim oranında sınıflandırma karışıklık matrisi..	27
Şekil 4.7. GoogleNet model için %10 eğitim oranında sınıflandırma karışıklık matrisi	28
Şekil 4.8. ResNet-50 model için %10 eğitim oranında sınıflandırma karışıklık matrisi	28
Şekil 4.9. ShuffleNet model için %10 eğitim oranında sınıflandırma karışıklık matrisi	29
Şekil 4.10. SqueezeNet model için %10 eğitim oranında sınıflandırma karışıklık matrisi .....	29
Şekil 4.11. GoogleNet model için %50 eğitim oranında sınıflandırma karışıklık matrisi .....	30
Şekil 4.12. ResNet-50 model için %50 eğitim oranında sınıflandırma karışıklık matrisi .....	30
Şekil 4.13. ShuffleNet model için %50 eğitim oranında sınıflandırma karışıklık matrisi .....	31
Şekil 4.14. SqueezeNet model için %50 eğitim oranında sınıflandırma karışıklık matrisi .....	31

## KISALTMALAR DİZİNİ

<b>Kısaltmalar</b>	<b>Açıklama</b>
DVM	: Destek Vektör Makinaları
ESA	: Evrişimsel Sinir Ağı
EYK	: En Yakın Komşuluk

## 1. GİRİŞ

Çiçekler doğada etrafımızda her yerde bulunurlar. Böcekleri, kuşları, hayvanları ve insanları besleyebilirler. Ayrıca insanlar ve bazı hayvanlar için ilaç olarak da kullanılırlar. Yeni veya nadir türlerle karşılaşıldığında onları tespit etmek için çiçekler hakkında iyi bir anlayış şarttır. Bu, ilaç endüstrisinin gelişmesine yardımcı olacaktır. Çalışmada önerilen sistem, botanikçiler, kampçılar ve doktorlar tarafından kullanılabilir. Bu, konu hakkında daha fazla bilgi edinmek ve en iyi eşleşen sonuçları bulmak için metin yerine fotoğrafın girdi olarak alınabileceği bir görüntü arama çözümü olarak genişletilebilir. Otomatik çiçek tanıma yöntemi oluşturmanın önemi, hasat robotları için hızlı tanıma sağlamak gibi birçok avantajıyla öne çıkmaktadır. Otomatik çiçek tanıma, çiçek türleri konusunda sınırlı deneyime sahip kişilere, bir türü tanıma olanağı sağlar.

Yüzyıllardır çiçekler, güzellikleri ve çeşitlilikleriyle insanoğlunun ilgisini çekmiştir. Çiçekler, yol kenarlarından bahçelere, parklardan dağ patikalarına ve vahşi alanlara kadar günlük manzaralarımızı süsler. Çiçekler, çok yönlü rolleri ve çeşitli alanlardaki etkileri nedeniyle büyük bir öneme sahiptir ve Botanik Araştırma ve Koruma, Tarım ve Bahçecilik, Ekolojik Çalışmalar, Eğitimsel ve Bilimsel Amaçlar, Ticari Uygulamalar, Tıbbi ve Farmakolojik Araştırmalar, Çevresel Etki ve Estetik Değerlendirme vb. gibi çok sayıda fayda ve uygulama sunar. Çiçekler sadece güzel semboller olmaktan çok daha fazlasını temsil eder; ekosistemlerin, kültürel sembolizmin, bilimsel keşiflerin ve ekonomik sektörlerin karmaşık dengesinde vazgeçilmez bir rol oynarlar. Önemleri çeşitli alanlara yayılır, ekolojik sistemleri, insan geleneklerini ve bilimsel araştırmaları etkilerken aynı zamanda ekonomik faaliyetlere de önemli ölçüde katkıda bulunurlar. Dolayısıyla, çiçeklerin kesin bir şekilde sınıflandırılması yalnızca bilimsel bir çaba değildir; Pratik uygulamalar ve araştırma alanları boyunca kapsamlı çıkarımlar taşır ve doğal dünyaya dair anlayışımızı ve hayranlığımızı derinden zenginleştirir.

Çiçek sınıflandırması hem geçmiş hem de günümüz senaryolarında dikkate değer bir evrim geçirmiştir. Tarihsel olarak, çiçek sınıflandırması büyük ölçüde manuel gözlem ve taksonomik uzmanlığa dayanıyordu. Geçmişte, bu süreç botanik uzmanlarının çiçeklerin taç yaprağı dizilimi, renk, şekil ve diğer fiziksel özellikler gibi morfolojik özelliklerini titizlikle incelemesini içeriyordu. Bu gözlemler, botanik metinlerinde ve saha rehberlerinde kataloglayarak çiçek taksonomisinin temelini oluşturuyordu. Ancak, günümüz senaryosu, özellikle Yapay Zeka (YZ), Makine Öğrenimi (ML) ve bilgisayarlı görme alanlarındaki teknolojik gelişmelerle önemli ölçüde dönüştürülmüştür. Görüntü

işleme ve makine öğrenimi tekniklerinin kullanımı, çiçek sınıflandırmasında devrim yaratmıştır. Günümüzde, otomatik çiçek tanımlama ve sınıflandırma için bilgisayar tabanlı sistemler ve algoritmalar kullanılmaktadır. Modern teknikler, çiçek görüntülerinden taç yaprağı şekli, renk dağılımı, dokular ve yapısal detaylar gibi özellikleri çıkarabilen bilgisayarlı görme algoritmalarını içermektedir. Bu özellikler daha sonra çeşitli sınıflandırma algoritmaları ve derin öğrenme modelleri kullanılarak analiz edilir ve işlenir. Bu tür modeller, öğrenilen desen ve özelliklere göre çiçekleri tanımlayıp kategorilere ayırabilen Evrimsel Sinir Ağları'nı (ESA: CNN) içerebilir. ESA gıda, ziraat, savunma v.b. alanlarda uygulama alanları olan güncel ve popüler bir uygulamadır. (Yavuzer, 2018; Yavuzer, 2020; Yavuzer ve Köse, 2022).

Nilsback ve Zisserman (2008), 103 sınıf içeren bir veri kümesi üzerinde bir Çiçek Sınıflandırması gerçekleştirmiştir. Yöntem, yerel şekil/doku, sınır şekli, taç yapraklarının mekânsal dağılımı ve renkten hesaplanan özellikleri kullanır. Yazar, çoklu çekirdekli bir çerçeveye sahip DVM (Destek Vektör Makinası) sınıflandırıcısı kullanarak bir çalışma yürütmüş ve %55,1 (tek özellik) ve %72,8 (tüm özellikler) oranında sınıflandırma doğruluğu elde etmiştir. Xia ve ark., (2017), transfer öğrenme konseptiyle Inception-v3 kullanarak Çiçek Sınıflandırması için bir yöntem önermiştir. Yazarlar, Oxford-I7 ve Oxford-I02 çiçek veri setlerini kullanmışlardır. Son katmanı eğitmek için geri yayımlı sinir ağı (BPNN) kullanılmıştır. Sınıflandırma doğruluğu, Oxford-I7 çiçek veri setinde %95, Oxford-102 çiçek veri setinde ise %94'tür. Zawbaa ve ark., (2014), Ölçek Değişmez Özellik Dönüşümü (SIFT) ve Segmentasyon Tabanlı Fraktal Doku Analizi (SFTA) tabanlı özellikler kullanılarak eğitilen DVM ve Rastgele Orman (RF) sınıflandırıcılarını kullanarak çiçek sınıflandırması (sekiz kategori) için bir yöntem önermiştir. Eldem ve ark., (2018), farklı aktivasyon fonksiyonlarına sahip Derin Sinir Ağı kullanarak İris Sınıflandırması için bir yöntem önermiştir. Relu, sigmoid ve Tanh fonksiyonları, epoklu (100 ila 400) gizli katmanlarda kullanılmıştır. Wu ve ark. (2018), Oxford-17 ve Oxford-102 çiçek veri setlerini kullanarak bir çalışma yürütmüştür. Konvolüsyon sinir ağı modelleri VGG-16, VGG-19, Inception-v3 ve ResNet50 modelleri, transfer öğrenmesiyle kullanılmıştır. Xie (2011), LandUse-21 veri seti, Indoor-67 veri seti ve SUN-397 veri seti ile görüntü sınıflandırma ve erişim algoritmaları önermiştir. Yazarlar, hem görüntü sınıflandırma hem de erişim için birleşik bir algoritma olan Çevrimiçi En Yakın Komşu Tahmini'ni önermiştir. Guru ve ark. (2010), EYK sınıflandırıcısı kullanarak çiçek sınıflandırması için bir model önermiştir. Yazarlar, zamandan ve emekten tasarruf sağlayan 25 çiçek türünden oluşan kendi veri setlerini oluşturmuştur. Ayrıca, son

zamanlarda çiçek yetiştiriciliğine olan talep artmış ve bu da onu tarımda önemli bir ticari meslek haline getirmiştir. Bu sistem, çiçekçilik alanında ticari bir şekilde yardımcı olabilmektedir. Çeşitli nedenlerden dolayı farklı çiçek türlerini kategorize etmek çok zordur. Bir çiçek sınıfı içinde çok fazla renk çeşitliliği ve çeşitli sınıflar arasında çok fazla benzerlik vardır. Uzman botanikçiler ve bahçıvanlar bile bazılarını doğru bir şekilde tanımlayamamaktadır. Ayrıca çiçekler katı nesnelere değildir; görünüşleri sıcaklık, güneş ışığı, beslenme ve nem gibi birçok dış faktörden etkilenebilir. Çiçek türlerini tanımlamak ve tanımak için yetkin bir otomatik sisteme ihtiyaç vardır. Segmentasyon, eşik tabanlı yöntem kullanılarak gerçekleştirilir ve ardından GLCM tabanlı özellik çıkarımı ve Gabor filtre tepkisi kullanılabilir. Nilsback ve Zisserman (2008), çoklu çekirdekli DVM sınıflandırıcısı kullanarak çiçek sınıflandırması için yerel şekil/doku, sınır şekli, renk ve taç yapraklarının renginin mekânsal dağılımı dahil olmak üzere görüntü özelliklerine dayalı bir yöntem önermiştir. Deshpande ve ark., (2019), hastalık tespiti için Haar dalgacık özellikleri üzerine bir metodoloji önermiştir. Giraddi ve ark., (2020) derin öğrenme modelleri kullanarak mısır yapraklarında mantar hastalığı tespiti üzerine bir çalışma yürütmüştür.

### **1.1. Manuel Özelliklere Dayalı Çiçek Tanıma Yöntemleri**

Bu yaklaşım, sınıflandırma ve tanıma için görüntü verilerinden belirli özellikleri çıkarmak üzere yapay olarak tasarlanmış özellik operatörleri kullanır. Genellikle renk, doku, şekil veya bunların bir kombinasyonuna dayanan bu özellikler, çiçeklerin ayırt edici özelliklerini yakalamak için özenle seçilir. Manuel özelliklerin çıkarılma süreci, görüntü sınıflandırmasında çok önemlidir ve hem konunun alanında (örneğin botanik) hem de görüntü işleme tekniklerinde kapsamlı profesyonel bilgi gerektirir. Çıkarılan özelliklerin kalitesi, sınıflandırma ve tanıma sonuçlarının doğruluğunu doğrudan etkiler.

Çiçek tanıma bağlamında, DVM ve EYK gibi geleneksel makine öğrenmesi yöntemleri yaygın olarak kullanılır. DVM, farklı sınıflar için en uygun ayırıcı hiper düzlemi etkili bir şekilde bulurken, basit ancak güçlü bir algoritma olan EYK, nesnelere komşularının çoğunluk oyuna göre sınıflandırır.

Das ve ark. (1999) araştırmalarında renk özelliklerini ve uzamsal alanları kullanarak çiçek görüntüsü sınıflandırması uygulamışlardır. Bu özellikleri kullanarak, çiçeklerin benzersiz renk desenlerini ve uzamsal düzenlemelerini yakalayıp sınıflandırma modellerinin doğruluğunu artırmışlardır. Nilsback ve Zisserman (2008), çiçek sınıflandırması için görsel bir sözlük önermiş ve optimize edilmiş bir en yakın

komşu sınıflandırıcısı geliştirmiştir. Yöntemleri, 17 çiçek türü için %71,76'lık bir doğruluk elde ederek, yaklaşımlarının farklı türler arasında ayırım yapmadaki etkinliğini göstermiştir. Nilsback ve Zisserman (2008) tarafından geliştirilen Oxford-17 ve Oxford-102 Çiçek veri kümeleri, çiçek görüntüsü tanıma araştırmalarında yaygın olarak kullanılan kıstaslar haline gelmiştir. Bu veri kümeleri, araştırmacıların çeşitli tanıma yöntemlerinin performansını değerlendirmelerine ve karşılaştırmalarına olanak tanıyan çeşitli bir çiçek görüntüsü koleksiyonu sunar. Yakın tarihli bir çalışmada, Ke ve ark. (2010), HSV renk modelinden türetilen morfolojik ve doku özelliklerini birleştiren yeni bir çiçek tanıma yöntemi sunmuştur. Bu yaklaşım, çiçeklerin hem şekil hem de doku özelliklerini yakalamayı ve böylece tanıma sisteminin ayırt etme gücünü artırmayı amaçlamaktadır.

## **1.2. Derin Öğrenme Tabanlı Çiçek Tanıma Yöntemleri**

Donanım performansındaki, özellikle GPU'lardaki (Grafik İşleme Birimleri) hızlı iyileşme, derin öğrenmenin çeşitli alanlarda yaygın olarak uygulanmasına önemli ölçüde katkıda bulunmuştur. Bu gelişmeler, büyük veri hacimlerinin benzeri görülmemiş hızlarda işlenmesini ve analiz edilmesini sağlayarak daha karmaşık ve gelişmiş sinir ağı mimarilerinin geliştirilmesini kolaylaştırmıştır. Son zamanlarda, çok sayıda bilim insanı derin öğrenme teknolojisinin çiçek tanıma alanında uygulanmasına yönelik araştırmalar başlatmıştır (Liu ve ark. 2020). Derin öğrenme yaklaşımlarına doğru bu geçiş, çiçek türlerinin daha doğru ve verimli bir şekilde tanımlanması için yeni olanakların kilidini açmıştır. AlexNet, VGGNet, GoogleNet ve ResNet gibi derin öğrenme modelleri, çiçek tanıma görevleri de dahil olmak üzere görüntü tanıma zorluklarında dikkate değer başarılar göstermiştir. Bu modeller, doğruluk için yeni ölçütler oluşturmuş ve bilgisayarlı görme alanında temel mimariler haline gelmiştir (Liu ve Zheng, 2017). Çiçek tanıma bağlamında, Liu ve Gao (2018), ince taneli görüntü sınıflandırması için derin model transfer öğrenmesini kullanan bir yöntem önermiştir. Bu yaklaşım, önceden eğitilmiş modellerden elde edilen bilgiden yararlanarak ince farklılıklara sahip çiçek türlerinin daha hassas bir şekilde sınıflandırılmasını sağlar (Lv ve ark. 2021). Wang (2018), ImageNet veri kümesi üzerinde eğitilen AlexNet ağından çiçek özelliklerini çıkarmak için transfer öğrenmesini kullandı. Önceden eğitilmiş modeli çiçek tanıma gibi belirli bir göreve uyarlayarak, bu yöntem sıfırdan kapsamlı bir eğitim gerektirmeden verimli bir özellik çıkarımı sağlar (Samragh ve ark. 2023).

Qin Min (2020), dikkat mekanizmalarını ESA'lerle birleřtirdi ve LD Kaybına dayalı bir sınıflandırma modeli oluşturmak için Doğrusal Ayırt Edici Analizi (LDA) geliřtirdi. Bu model, ilgili özelliklere odaklanarak ve sınıf içi deęişkenlięi azaltarak aęın ayırt edici gücünü artırmayı amaçlamaktadır.

Çiçek tanıma için derin öğrenmedeki geliřmelere raęmen, hedef tespiti ve çiçek tanıma konusundaki arařtırmalarda önemli bir boşluk bulunmaktadır. Bu alan nispeten keřfedilmemiş olup, daha fazla arařtırma ve geliřtirme fırsatı sunmaktadır. Xie ve Hu (2022), çoklu hedef çiçek tanıma için YOLOv4 mimarisini kullanan bir sistem önermiştir. Bu sistem, bir görüntüdeki birden fazla çiçeęi aynı anda tespit edip sınıflandırmak üzere tasarlanmıştır ve doğal ortamlarda karmařık tanıma görevleri için derin öğrenmenin potansiyelini ortaya koymaktadır.

2020 yılında, Google'dan bir ekip, Transformer mimarisini görüntü sınıflandırma görevlerine uygulayan Vision Transformer (ViT) modelini tanıttı. Bu çığır açan çalıřma, Transformer mimarisini (Vaswani ve ark. 2017; Zhang ve ark. 2022) bilgisayarlı görüř alanına ilk kez soktu. Bir dizi deney yoluyla yazarlar, ViT modelinin büyük veri kümeleri üzerinde eęitimden sonra görüntü sınıflandırmasında mevcut en iyi ESA mimarilerinden daha yüksek doğruluk elde ettięini göstermiştir (Dosovitskiy ve ark. 2020). ESA'lerin aksine, ViT modeli sığ ve derin katmanlarda elde edilen temsiller arasında daha fazla benzerlik saęlayarak, küresel ölçekte daha derin özellik bilgileri öğrenmek için Transformer mimarisinin avantajlarından yararlanmasını saęlar.

ViT modelinin tanıtımı, evriřimsel katmanlar olmadan yalnızca Transformer mimarisini kullanan ESA'lerinkine benzer, hatta onları aşan bilgisayarlı görüř başarılarına olanak saęlamıştır. Küçük veri kümeleriyle bile, ViT modeli, önceden eęitilmiş aęırlıkları yükleyerek veya ResNet ve ViT'yi birleřtiren bir hibrit aę yapısı kullanarak güçlü deneysel sonuçlar üretebilir. Bu çok yönlülük, ViT modelinin eęitim sürecinde daha az bilgi iřlem kaynaęı gerektirirken, en iyi performans gösteren ESA'lerle karřılařtırılabilir bir performans seviyesine ulařabileceęini göstermektedir. Basitlięi, etkinlięi ve saęlam ölçeklenebilirlięi nedeniyle ViT modeli, bilgisayarlı görme alanında bir dönüm noktası olarak kabul edilmektedir. Yaygın ilgi görmüř ve birçok sonraki çalıřmaya ilham kaynaęı olmuřtur. Örneęin, Beal ve ark., (2020) özellik çıkarma için omurga aęı olarak ViT ve Faster RCNN modellerini birleřtirerek, hedeflenen bölgeler için sınıflandırma ve yerleřtirme görevlerinde etkileyici sonuçlar elde etmişlerdir (Beal ve ark., 2020). Bu başarılar arasında, Dosovitskiy ve ark. (2020), da bulunmaktadır. Dosovitskiy ve ark. (2020), ViT-LargeI21k modelinin Oxford-102 Flowers veri setinde

%99,60'lık bir sınıflandırma doğruluğuna ulaştığını deneysel olarak doğruladı ve bu da modelin yüksek doğruluklu görüntü sınıflandırma görevleri için potansiyelini vurguladı.

Bitki organlarından biri olan çiçekler, ekolojik düzenin vazgeçilmez bir unsurudur. Çiçekler insanlara faydalı olan birçok alanda kullanılmıştır (Roddy ve ark., 2019). Çiçekler, ilaç endüstrisi, gıda ve kozmetik endüstrisi, peyzaj alanları ve özel günler için sürekli talep görmektedir (Madoui ve ark., 2019). Çiçeklerin şekli ve renginin benzerliği nedeniyle onları ayırt etmek zor bir iştir. Çiçek sınıflandırması, yüksek şekil çeşitliliği, renk dağılımı, aydınlatma koşulları ve pozlama deformasyonu nedeniyle zor bir sorundur. Çiçekler sert olmayan bedenlerdir ve görüntüden görüntüye farklı şekillerde deforme olabilir. Daha genel olarak, taksonomi ilginç bir görüntü sınıflandırma problemidir. İnsanların belirli türleri doğru bir şekilde ayırt etmesi için önemli bir eğitim gerektirir ve genellikle çok spesifik morfolojik özellikler, yakından ilişkili türleri ayırt eden tek şeydir (Bayram ve Nabiyeve, 2021). Dahası, bu özel özellikler belirli bir bitki türünden diğerine tamamen farklı olabilir (örneğin, gövde uzunluğu - yaprak şekli). Bugün yaklaşık dört yüz bin çiçek çeşidi vardır (Christenhusz ve ark., 2016). Bazı görüntüler için insan gözü ile renk ve şekil bakımından birbirine benzer çiçekleri ayırt etmek zorlaşır (Seeland ve ark., 2019). Çiçeklerin iyi anlaşılması, karşılaşıldığında yeni veya nadir türlerin tanımlanmasına yardımcı olmak için gereklidir. Bu sınıflandırma, ilaç endüstrisinin geliştirilmesine yardımcı olacaktır. Bu bilimsel çalışmalar bilişimin yanı sıra botanikçiler, kampçılar ve doktorlar tarafından da kullanılabilir (Sangale ve ark., 2020). Çiçek türlerinin sınıflandırılması önemli bir görev olduğundan, yaygın olarak incelenmiştir ve araştırmacılar tarafından birçok farklı yaklaşım geliştirilmiştir. Daha önce yönlendirilmiş gradyanların histogramı, deforme edilebilir parça modelleri ve ölçekli değişken özellik dönüşümü, özellik çıkarma, doğrusal olmayan sınıflandırıcılar gibi yöntemler kullanılmıştır. Daha sonra çalışma, el işi özellik mühendisliği kullanarak segmentasyon ve sınıflandırmaya odaklanmıştır (Seeland ve ark., 2017). Ancak bugün, CNN'lerle en iyi performanslar elde edildi. ESA, sağlamlık ihtiyacını ortadan kaldırır ve manuel özelliklere olan ihtiyacı ortadan kaldırır. ESA'ler sinir ağlarına benzer, ancak özellik mühendisliği gerektirmez (Narvekar ve Rao, 2020).

ESA modeli yakın zamanda araştırmacılar tarafından hastalık teşhisi, yüz tanıma ve nesne tanıma gibi birçok sınıflandırma probleminde kullanılmıştır (Voulodimos ve ark., 2018). Literatürde çiçek görüntülerini sınıflandırma sürecinde birçok teknik ve yöntem sunulmuştur. Guo ve ark. (2019), çiçekleri sınıflandırmak için lenet modeli ile genetik algoritma (GA) kullanmıştır. Kısa sürede etkili özellikler elde etmek için Tabu

arama algoritması ve GA'yı birlikte kullandılar. Hiper parametre üzerindeki optimizasyon metodolojileri, öğrenme algoritmalarının hiper parametreleri için etkili arama sağladı. Bu modelle çiçek sınıflandırmasında% 78,46 doğruluk elde ettiler. Luus ve ark. (2019,) çiçek sınıflandırmasında SSL yöntemini ve TSNE boyutsallığı azaltma kullanmayı önermişlerdir. VGG-16 modeliyle% 77,32 doğruluk elde ettiler. En iyi başarıyı elde etmek için başlangıç ve resnet mimarilerini birleştirdiler. Veri kümelerini etiketlemek için yarı denetimli öğrenme (SSL) yöntemini kullandılar. ESA, T-SNE boyutsallığı azaltma ve SSL'yi birleştirerek% 79.33 doğruluk elde ettiler. Chen ve ark. (2019) çiçek türlerini sınıflandırmak için makine öğrenimi (rastgele orman, DVM) ve derin öğrenme modelleri (ESA, Densenet, VGG16 ve ResNet) kullandı. VGGNet modeli ile en iyi başarı oranını %90 elde ettiler. Toğaçar ve ark. (2019) özellik çıkarma için ESA'yi kullanmıştır. Çalışmalarında VGG-16, Alexnet ve VGG-19'u kullandılar. ESA mimarilerini ve özellik seçim yöntemlerini (Ridge regresyonu, maksimum bilgi katsayısı ve öz yinelenmeli özelliklerin eliminasyonu) kullanmayı önerdiler. ESA modellerinde özellik seçim yöntemleri kullanarak% 91.10 doğruluk elde ettiler. Mitrović ve Milošević (2019) önceden tanımlanmış modelleri Alexnet ve Lenet olarak kullandı. Sigmoid fonksiyonu olan Lenet ESA ile en yüksek doğruluk (%73.41) elde ettiler. Fatihahsahidan ve ark. (2019) ESA kullanılarak çiçek tanıma çalışmıştır. Katman sayısının doğruluk performansı üzerindeki etkilerini incelemek için farklı katman yığınlarını araştırdılar. Dört yığın katmanla en yüksek doğruluğu (%74) elde ettiler. Arinda ve ark. (2018) DVM'nı HSV ve DOG ile kullanmayı önerdi. HSV yöntemi ile renk segmentasyonu gerçekleştirdiler. Her görüntünün bölgesel histogramlarını elde etmek için domuz yöntemini kullandılar. Sonra gri tonlamalı görüntüleri DVM ile sınıflandırdılar. Çalışmalarında sınıflandırma doğruluğu oranı %87 idi. Gadkari ve ark. (2019) transfer öğrenme yöntemlerini (VGG-16, VGG-19 ve IncepceV3) incelemiş ve çiçek veri kümelerinde tanımak için çiçeklerin çeşitli özelliklerini incelemişlerdir. VGGNet modeli ile % 91,73'lük en iyi doğrulama doğruluğunu elde ettiler. Gurnani ve ark. (2017) farklı çiçeklerin sınıflandırılması için derin bir öğrenme (DL) ağı desteklediler. Oxford Üniversitesi'nden görsel geometri grubundan 102 çiçek kategorisinde 8189 çiçek verisi kullandılar. Yazarların yöntemleri temel olarak iki bölüme ayrılmıştır; Segmentasyon ve sınıflandırma. Sınıflandırma için Alexnet ve GoogleNet olan iki farklı ESA mimarisini karşılaştırdılar. Ghazi ve ark. (2017), çalışmalarında bitki türlerinin sınıflandırılması için önceden eğitilmiş (transfer öğrenimi) ESA modellerini kullanmıştır. Sağlam sınıflandırma için yeni bir görüntü kümesi elde etmek için veri kümesine görüntü büyütme tekniği uyguladılar. En iyi ortak

sistemleriyle %80 doğruluk oranına ulaşmışlardır. Lv ve ark. (2021), modeli çiçek sınıflandırması için optimize etmek için stokastik gradyan iniş algoritması ve bırakma ile VGG-16 Derin Nöral Ağ Modeli önerdi. Oxford Flower-102 veri setinde deneyler için %91.9 sınıflandırma doğruluğu elde ettiler. Yıldırım ve ark. (2014) yoğun SIFT özellikleri, görsel kelime torbası ve SVM sınıflandırması kullanmayı önermişlerdir. Çalışmalarında, görüntüdeki bitki yoğun hal ve görsel kelime çantası yaklaşımı ile tanımlanır ve DVM tarafından sınıflandırılır. Sınıflandırma doğruluğu ImageClef'2013 çiçek veri seti için %42.68 olarak elde edilir. Türkoglu ve Hanbay (2019), bitki türlerinin tanınması için ESA ve renk-yerel ikili desen yöntemi ile hibrit bir model kullanmayı önerdiler. LBP yöntemi her renk görüntüsünün kanalına işlenir. Daha sonra, özellikleri SVM ile sınıflandırmak için derin ve LBP özelliklerini birleştirdiler. Seeland ve ark. (2017) çiçekleri sınıflandırmak için klasik makine öğrenme yöntemleri kullandı. Yerel şekil ve renk tanımlayıcı yöntemlerinin ve özellik seçim dedektörlerinin bir kombinasyonunu kullandılar. SVM sınıflandırıcısı ile % 94 başarı oranı elde ettiler. Bu çalışmada, çiçek türlerinin tanınması için ESA tabanlı transfer öğrenme yöntemleri incelenmiştir. Çiçek türlerinin sınıflandırılması için VGG16, VGG19, SqueezeNet, Densenet-121, Densenet-2011 ve InceptionResNetV2 olan popüler önceden eğitilmiş öğrenme teknikleri gerçekleştirilir. Sınıflandırma performansları deneysel sonuçlarda aynı çiçek veri kümesinde karşılaştırılır. İşin geri kalanı aşağıdaki gibi düzenlenmiştir. Bölüm III'de malzeme ve yöntem sunulmaktadır. Bu bölümde, deneysel çalışma ve yöntemde kullanılan veri kümesi ayrıntılı olarak açıklanmaktadır. Deneysel sonuçlar Bölüm IV verilmiştir ve çalışmanın tartışma ve sonuçlar kısmı Bölüm V'te verilmiştir.

## 2. ÖNCEKİ ÇALIŞMALAR

Bu bölümde, çiçek sınıflandırma alanını kapsayan önceki akademik araştırmaları derinlemesine inceleyen kapsamlı ve detaylı bir literatür taraması sunulmaktadır. Bu inceleme, önceki çalışmaların bulgularını ve sonuçlarını titizlikle inceleyerek, yalnızca sonuçlarının doğruluğunu değil, aynı zamanda araştırma çalışmalarında kullanılan çeşitli algoritmaları da titizlikle değerlendirmektedir. Bu derinlemesine inceleme, akademisyenlerin çiçekleri doğru bir şekilde sınıflandırma çabalarında benimsedikleri metodolojileri titizlikle incelemektedir. Ayrıca, uygulanan çeşitli algoritmaların etkinliğini eleştirel bir şekilde analiz ederek, güçlü yönlerine, sınırlamalarına ve çiçek sınıflandırma sistemlerinin hassasiyetine ışık tutmaktadır.

Nauck ve Kruse (1996), geri yayılım algoritmasını kullanarak bulanık bir Sinir Ağı yaklaşımı sundular. Üç gizli katmanla daha iyi sonuçlar elde edilebileceğini buldular. Saitoh ve ark. (2003), alt bölge çıkarımına dayalı olarak çiçek açan çiçekleri tanımak için otomatik bir teknik tanımladılar. Saitoh ve ark. (2003), tanıma için parça parça doğrusal bir ayırıcı analiz kullandılar. Yoshioka ve ark. (2004), taç yapraklardaki ilk beş temel bileşeni dikkate alarak temel bileşen analizi kullanarak yaprak rengi ölçümü gerçekleştirdikleri bulundu. Wang ve ark. (2005), bitki sınıflandırması için "hareketli medyan merkezi" olarak adlandırılan bir teknik uyguladılar; ancak bu teknik, özellikle Yapay Sinir Ağları'ndan (YSA) yararlanan yöntemlerle karşılaştırıldığında daha yavaş bir işlem hızı gösterdi. Diğer metodolojiler, bitki türlerini belirlemek için bitki özelliklerinin benzerliğini incelemiştir; ancak kullanımdan önce bazı manuel müdahaleler gerektirmiştir.

Du ve ark. (2007) tarafından yürütülen ayrı bir çalışmada, bir bitki şekli tanıma yöntemi geliştirmişlerdir. Yaklaşımları, "Ortogonal En Küçük Kareler Algoritması" (OLSA) da dahil olmak üzere matematiksel algoritmalar kullanarak bir hesaplamalı modelin eğitilmesini içermiştir ve bu algoritma "özyinelemeli OLSA" ile daha da geliştirilmiştir. Bu teknik, bitkileri yaprak şekillerine göre tanımlamayı amaçlamış, ancak yapraklar belirsiz veya hasarlı olduğunda sınırlamalarla karşılaşmıştır. "Dinamik programlama" kullanan önceki yöntemleri, yaprak şekli eşleştirmeye odaklanmıştır. Nilsback ve Zisserman (2008) tarafından 103 sınıf içeren bir veri kümesi üzerinde bir Çiçek Sınıflandırma çalışması gerçekleştirilmiştir. Çeşitli özellikler kullanmışlar ve bir DVM sınıflandırıcısı kullanarak tek bir özellikte %55,1, tüm özelliklerle ise %72,8 doğruluk elde etmişlerdir. Huang ve ark. (2009), Fark Görüntü Entropisi (DIE) yöntemini kullanarak çiçek tanımayla odaklanmış ve %95 ortalama tanıma oranı elde etmişlerdir.

DIE tabanlı işleme, tanıma sonuçlarını üretmek için orijinal çiçek görüntüsünü kullanmıştır. Siraj ve ark. (2010), Malezya'da çiçek açan çiçekler için, çiçek görüntüsü analizi için sinir ağları ve görüntü işlemeyi kullanan bir sınıflandırma sistemi sunmuş ve %26,8'lik bir tahmin doğruluğu elde etmişlerdir. Rashad ve ark. (2011), dokusal özelliklerin analizine vurgu yaparak bitki görüntüsü sınıflandırmasına odaklanmışlardır. Yenilikçi yaklaşımları, sınıflandırma doğruluğunu artırmak için çeşitli yöntemleri bir araya getirerek LVQ + RBF sınıflandırıcısını sunmuşlardır. Doğruluğu optimize etmek için dönem sayısını ve öğrenme oranlarını ayarlayarak bu modeli hassas bir şekilde ayarlamışlardır. LVQ + RBF sistemi, sahadaki diğer sistemleri geride bırakarak etkileyici bir %98,7 doğruluk oranına ulaşmıştır. Bu sistemin şekil veya renkten ziyade yaprak dokusuna dayanması, onu hasarlı bitkilerin tanımlanmasında değerli kılmaktadır. Öncelikle bitki yaprak sınıflandırmasını ele alan bu araştırma, doku ve özellik çıkarımını güçlü bir algoritmayla vurgulayarak çiçek sınıflandırması için içgörüler sunmaktadır. Bu bulgulardan yararlanmak, çiçek sınıflandırma doğruluğunu potansiyel olarak artırabilir. Xie ve ark. (2017), farklı veri kümeleri için görüntü sınıflandırma ve alma algoritmaları sunmuştur. Nilsback ve Zisserman (2008), çoklu çekirdekli DVM sınıflandırıcıları kullanan bir çiçek sınıflandırma yöntemi önermiştir. Mishra ve ark. (2012), renk, şekil, hacim ve hücre özellikleri gibi özelliklerle çoklu sınıflandırma kullanan, yaprak ve çiçek görüntülerini kullanan yarı otomatik bir bitki tanımlama yöntemi sunmuştur. Metodoloji üç adımdan oluşmaktadır: RGB özellik karşılaştırması, şekil özelliği kullanımı (Alan Dışbükeyliği, Çevre Dışbükeyliği, Küresellik ve Dairesellik) ve hücre ve hacim kesri özelliklerinin analizi. 1000 örnek üzerinde yapılan deneyler %85 tanıma oranına ulaşmıştır. Hesaplama kısıtlamaları nedeniyle, tüm özelliklerin eş zamanlı olarak değerlendirilmesi mümkün olmamıştır. Bu da, uzun işlem süreleri ve sonuçların depolanması için birden fazla tablonun kullanımıyla çok aşamalı bir karşılaştırma yaklaşımına yol açmıştır. Sistem, denetimli yöntemlere kıyasla daha düşük doğruluk oranına sahip denetimsiz bir öğrenme algoritması kullanmıştır. Mukane ve ark. (2013), yapay sinir ağları (YSA) kullanarak bir Çiçek Sınıflandırma yöntemi geliştirmiştir. Yaklaşımları, gri seviye eş-oluşum matrisi ve ayrık dalgacık dönüşümü (DWT) gibi dokusal özelliklere dayanmaktadır. Zawbaa ve ark. (2014), SIFT ve SFTA özellikleri üzerinde eğitilmiş DVM ve RF sınıflandırıcıları ile bir çiçek sınıflandırma yöntemi önermiştir. Ayrıca Tiay ve ark. (2014), yaklaşık %80 doğrulukla KNN tabanlı çiçek sınıflandırması için kenar ve renk özelliklerini kullanan görüntü işleme tabanlı bir çiçek tanıma sistemi araştırmış ve önermiştir. Başka bir araştırmacı olan Xia ve ark. (2017),

Inception-v3 modelini kullanarak bir Çiçek Sınıflandırma yöntemi sunmuş ve transfer öğrenmesi ile Oxford-I7'de %95, Oxford102 çiçek veri kümelerinde ise %94 doğruluk elde etmiştir. Eldem ve ark. (2018), farklı aktivasyon fonksiyonlarına sahip bir Derin Sinir Ağı kullanarak bir İris Sınıflandırma yöntemi geliştirmiştir. Wu ve ark., (2018), Oxford17 ve Oxford-102 çiçek veri kümelerinde transfer öğrenmesi ile çeşitli ESA modelleri kullanmışlardır. Ursani ve Corne (2018), doğrusal olmayan ayırıcı sınıflandırma için bir evrimsel algoritma önermişlerdir. Bireysel özelliklerin toplu olarak sınıf üyeliği kararlarını etkilediği İris Çiçeği de dahil olmak üzere veri kümeleri üzerinde bunu test etmişlerdir. Patel ve Patel (2019), çoklu etiket sınıflandırması ile MKL-SVM kullanan hibrit bir çiçek sınıflandırma metodolojisi önermiştir. Yaklaşımları, görüntü ön işleme, Otsu yöntemi kullanılarak segmentasyon ve özellik çıkarımını içermektedir. Renk (HSV ve Lab renk uzayları kullanılarak), boyut (ağırlık merkezi ve sınır kutusu yöntemleri), doku (Gri Seviye Eş Oluşum Matrisi) ve ek morfolojik özellikler (Disk Çiçek, Korona, Taçyaprak Türü, Taçyaprak Sayısı, Yaz Sonu ve Çiçek Sınıfı) dahil olmak üzere çeşitli çiçek özelliklerini dahil etmişlerdir. Bu yaklaşım, bireysel makine öğrenmesi tekniklerini geride bırakarak %78,3'lük etkileyici bir doğruluk elde etmiştir. Önemli doğruluk iyileştirmeleri göstermesine rağmen, çalışma daha hassas modellerin araştırılmasını atlamış ve gelişmiş çiçek sınıflandırması için derin öğrenme tekniklerinin potansiyel entegrasyonunu göz ardı etmiştir. Veri derinliği ve eğitim zorluklarını ele almak için Feng ve ark. (2019), çiçek tanıma için Transfer Öğrenme ve Adam Derin Öğrenme optimizasyon algoritmalarını değerlendirmiştir. Toplu model eğitimi, parametre güncellemelerini iyileştirerek optimum sonuçlar vermiştir. Araştırmalarında, Zhenjiang ve ark. (2006) çok sayıda özelliğin kapsamlı bir analizini gerçekleştirerek çeşitli gül türlerini kategorize etmek için geliştirdikleri bir yöntemi incelediler. Ancak, bu yöntemin kapsamı sınırlıydı ve içsel bir kusur nedeniyle yalnızca belirli gül çeşitlerine etkili bir şekilde uygulanabiliyordu. Giraddi ve ark. (2020), derin öğrenme modelleri kullanarak mısır yapraklarında mantar hastalığı tespiti üzerine bir çalışma yürüttüler. Giraddi ve ark. (2020), ESA ve VGG16 ile transfer öğrenmesi kullanan bir çiçek sınıflandırma sistemi geliştirdiler. Veri setini segmentlere ayırdılar, görüntü ön işleme için Keras uyguladılar ve veri artırma kullandılar. Önceden eğitilmiş modelin en üst katmanı değiştirildi ve Stokastik Gradyan İnişi (SGD) ile ince ayar yapıldı. İnce Ayarlı VGG16, %95 ile en yüksek doğruluğu elde ederek Temel VGG16 ve ESA modellerini geride bıraktı. Farklı ESA yapılandırmaları ve hiperparametre ayarlamaları sonuçları daha da iyileştirebilir. Shukla ve ark. (2020), İris çiçeklerini alt kategorilere ayırmak için

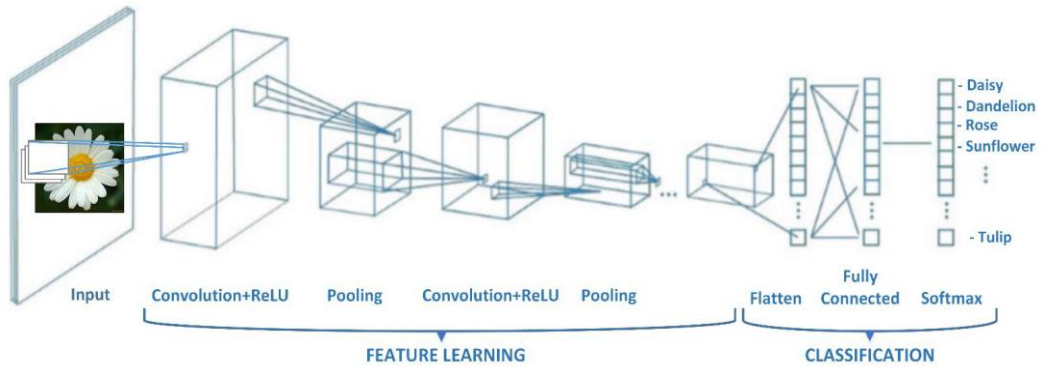
Sinir Ađı, Lojistik Regresyon, Destek Vektör Makinesi (SVM) ve k-En Yakın Komşular dahil olmak üzere bir dizi makine öğrenimi algoritması kullandı. Fisher'ın İris veri setini kullandılar ve görüntü segmentasyonu, özellik çıkarma (Çanak Yaprak Uzunluğu, Çanak Yaprak Genişliği, Taç Yaprak Uzunluğu ve Taç Yaprak Genişliği gibi öznitelikler dahil) ve scikit-learn kullanan makine öğrenimi modellerini içeren bir metodoloji geliştirdiler. DVM, özellikle Temel Bileşen Analizi (PCA) ve ölçekleyiciler gibi boyut azaltma tekniklerini içeriyordu. Sonuçlar, Sinir Ađı ve Lojistik Regresyon'un %96,667, Doğrusal DVM'nin eğitim setinde %97 ve test setinde %100 ve Doğrusal Olmayan DVM 'nin eğitim setinde %99,17 ve test setinde %100'e ulaşmasıyla yüksek doğruluk ortaya koymuştur. Bu çalışma, çeşitli makine öğrenmesi tekniklerinin etkinliğini vurgulayarak, Süsen çiçekleri için sağlam sınıflandırma modellerini sergilemektedir. Gupta ve ark. (2022), çanak yaprađı genişliği, çanak yaprađı uzunluğu, taç yaprađı genişliği ve taç yaprađı uzunluğu gibi özelliklere dayanarak Süsen çiçeđi türlerini tahmin etmek için üç sınıflandırma modeli içeren bir makale sunmuştur: Lojistik Regresyon, DVM ve K-En Yakın Komşular (KNN). Keşifsel Veri Analizi (EDA) sonrasında, modeller sırasıyla %96,43, %98,21 ve %94,64 gibi yüksek doğruluk oranlarına ulaşmıştır. Çalışma, bu denetlenen makine öğrenimi modellerinin süsen çiçeklerini doğru bir şekilde kategorize etmedeki etkinliğini göstermektedir. Anand ve ark. (2023), çiçek sınıflandırması için bir ADET-CNN üreten optimum desen çıkarımı için CLAHE, filtreleme ve IRSO'yu entegre etmiştir. Deneysel sonuçlar dikkate değer bir verimlilik göstermiştir.

### 3. MATERYAL VE METOD

Bu bölümde, araştırmada kullanılan materyaller ve yöntemler açıklanmıştır. Çiçek sınıflandırması, temel olarak iki temel gruba ayrılan bir sınıflandırma algoritmaları yelpazesi kullanır: gözetimli öğrenme ve gözetimsiz öğrenme. Gözetimli öğrenme, tahminlerde bulunmak için etiketli verilere dayanır ve algoritmaların doğru sınıflandırmalar için sağlanan veri kümelerinden öğrenmesini sağlar. Buna karşılık, gözetimsiz öğrenme, etiketsiz veriler üzerinde çalışır ve veri kümesinin içindeki gizli örüntüleri ve içsel ilişkileri ortaya çıkararak önceden tanımlanmış etiketler olmadan içgörüler sunar. Gözetimli bir öğrenme yöntemi olarak derin öğrenme, çok sayıda veri ve değişken içeren ancak mevcut bir formül veya denklemi olmayan karmaşık problemlerde birçok gizli katmandan oluşan yapay bir sinir ağı modelini eğitmek ve öğrenmek için gerekli katmanları kullanma çalışması olarak tanımlanabilir. Bu işlemin ana avantajı, özelliklerin ham verilerden çıkarılması ve sınıflandırıcı modelinin çıkarılan özelliklere göre otomatik olarak kendini eğitmesidir. Makine öğrenimi ve görüntü işleme yöntemleriyle sınıflandırma, ham görüntüleri işlemek için çeşitli ön işlem ve özellik çıkarma tekniklerini gerektirir (Al-Malah, 2023).

Bu çok zorlu ve deneyim gerektiren bir süreçtir. Bu nedenle, araştırmacılar manuel olarak öğrenmek yerine otomatik olarak öğrenme özellikleri üzerinde çalıştılar. Bu çalışmaların bir sonucu olarak, derin öğrenme popüler hale gelmiştir ve karmaşık matris operasyonlarına ve artan miktarda veriye izin veren paralel işleme GPU'larının geliştirilmesiyle birçok alanda yeteneklerini kanıtlamıştır (Zhang ve ark., 2022). Derin öğrenme sayesinde makineler, görüntülerden nesnelere tanıyabilir, ses ve metin gibi verileri diğer yöntemlerden çok daha düşük hata oranlarıyla sınıflandırabilir.

Şekil 3.1'de ESA ağının temel akışında gösterildiği gibi, ESA'de sıralı konvolüsyon ve havuzlama katmanları ile çiçek görüntülerinden özellikler çıkarıldı ve bu çalışmada sınıflandırma ve çiçek tanıma yapılabilir.



Şekil 3.1. Çiçek türlerinin sınıflandırması için ESA mimarisinin temel akışı

### 3.1. Evrişimsel Sinir Ağı

Evrişimsel sinir ağı, gelen verileri nöral ağı aracılığıyla, katmanlardaki filtrelerle alınan verilerdeki farklılıklardan elde ettiği ağırlık değerlerine göre sınıflandırır. ESA, görüntü işleme problemlerinin çözümü için önerilen ve görüntülere çok iyi uyum sağlayabilen derin bir öğrenme mimarisidir. Ağ, evrişim işlemleri yaparak adını karmaşık işlemler yapmaktan alır. Bir görüntü klasik yöntemlerde vektörlere dönüştürülür, pikseller sadece belirli mahalle değerlerine göre incelenir veya pikseller birbirinden bağımsız olarak incelenir. Bu durumda, görüntüdeki nesnelere hakkında birçok bilgi kaybolur. ESA yapısı, kullandığı filtrelerle bu sorunu ortadan kaldırır. ESA önceden tanımlanmış özellikleri kullanmaz, bunun yerine dataspesifik temsil eden yerel olarak bağlı nöronları öğrenir özellikler. ESA'da filtreler tüm görüntüye tekrar tekrar uygulanır. ESA, özellikleri otomatik olarak görüntüden öğrenebilir (Li ve ark., 2016).

Derin öğrenmenin en temel mimarisi olarak kabul edilen ESA, bir veya daha fazla evrişim katmanından ve havuzlama katmanlarından, daha sonra tamamen bağlı bir katmandan ve son olarak Şekil 3.1'de gösterildiği gibi bir sınıflandırma katmanı, sonucu etkileyen çeşitli özellikler, son sınıflandırma katmanından ilk giriş katmanına elde edilir ve sınıflandırma işlemi son katmanla gerçekleştirilir. Bu özellikler sayesinde, veri kümesinde atanması gereken belirlenen sınıf ile sınıf arasındaki fark kadar bir hata olduğu anlamına gelir. Geri yayılma algoritması ile, bu hata payı, her aşamadaki ağırlıkların değerleri güncellenerek en aza indirilir. Bu şekilde, özellik çıkarma işlemi geliştirildi ve test verilerindeki doğruluk arttı.

ESA, giriş katmanı, konvolüsyon katmanı (CONV), havuz katmanı, tamamen bağlı katman (FCL) ve bırakma katmanı gibi katmanlardan oluşur. Havuzlama katmanı, ortalama veya maksimize ederek alt bölgeleri özetleyerek özellik haritalarının boyutunu azaltan önemli bir yapı taşıdır. Tamamen bağlı katman, sınıflandırma performansını artırmak için bir görüntüden elde edilen özelliklerin evrişim katmanları tarafından kullanılır. Bırakma katmanı, ağıdaki bazı bağlantıları eğitmekten, ağ aşırı takılmasını önlemek ve eğitim performansını iyileştirmek için hariç tutar (Krizhevsky ve ark., 2017).

Evrişim katmanı, konvolüsyonel sinir ağının en önemli katmanıdır, bu katmanda, özellik haritaları giriş verilerine çok boyutlu filtreler uygulanarak oluşturulur. Genel olarak, birden fazla evrişim katmanına sahip modeller, farklı özelliklerin ortaya çıkmasını sağlarken, aynı zamanda filtre boyutuna bağlı olarak alınan verileri daraltır. Bu katmanda, tüm görüntüye 2x2, 3x3 ve 5x5 gibi küçük filtreler uygulanır. Bu nedenle, görüntüdeki daha karakteristik özellikleri kaldırarak yeni bir görüntü elde edilir. Evrişim operasyonu

için kullanılan filtre matrisinin ağırlıkları, evrişimsel sinir ağının öğrenme aşamasında belirlenir. Filtre matrisi belirtilen adım ile değiştirilir ve evrişim işlemi gerçekleştirilir. Eşitlik 3.1'de olduğu gibi, filtre katsayıları (F), görüntüdeki eşit boyutta (W) pencerelerin çarpılmasıyla ve bunları toplanarak hesaplanır. Sonuç olarak, farklı üst düzey özelliklere dayanan yeni bir görüntü oluşturulur. Burada elde edilen sonuç, bir sonraki katman için girdi olarak verilmiştir. Özellik öğrenimi bu katmandaki filtrelerle yapılır. Kullanılan filtrelerin sayısı, boyutu ve türü gibi farklı parametreler de sınıflandırmada elde edilecek performansı etkiler (Kim, 2017).

$$w(x, y) * f(x, y) = \sum_{i=-a}^a \sum_{j=-b}^b w(i, j) f(x+1, y+j) \quad (3.1)$$

Havuzlama katmanı genellikle bir veya daha fazla evrişim katmanı arasındadır, bir evrişim katmanı gibi bir filtre uygular. Havuzlama katmanı, evrişim katmanı gibi oluşturulan modellerde birçok kez kullanılabilir. Havuzlama katmanı, ağ içindeki parametreleri azaltır, hesaplama yükünü azaltmak için kullanılır. Maksimum havuzlama için filtre penceresindeki piksel değerlerinin en yüksek olması maksimum olarak tutulur, ortalama havuzlama için filtre penceresindeki tüm piksel değerlerinin ortalaması çıkış pikselinde tek bir değer olarak tutulur. Böylece, havuzlama işleminin sonunda görüntünün en boy oranı azalır. Bu işlemde piksel değerleri kaybolur, ancak bu kayıplar bir sonraki katmanlar için daha az hesaplama yükü oluşturur.

Yukarıda belirtilen evrişim ve havuz katmanları ardışık olarak birden çok kez uygulanabilir. Bu işlemlerden sonra elde edilen matris, tamamen bağlı katmanda kullanılacak düzleştirme tabakasında düzleştirilmelidir. Bu katmanın görevi, gelen verileri düzleştirmek ve aktarmaktır. Birçok evrişim ve havuz katmanından oluşan bir yapıyı sınıflandırma katmanına bağlarken, gelen çok boyutlu matrisi tek boyutlu bir matrise dönüştürür. Böylece, bu tercüme edilen matris, ağın sınıflarının sayısı için uygundur.

Tamamen bağlı katmanlar, bir final sınıf etiketi elde etmek için özellik bilgilerini kullanır. Tamamen bağlı katmanların düğümleri, önceki katmanın her çıkışına bağlanır ve çıkışları bir sonraki katmanın her düğümüne bağlanır. Son katmanda n düğümler vardır (n sınıf sayısına eşittir). Tamamen bağlı katmanların son katmanındaki düğümlerin genellikle özel bir aktivasyon işlevi vardır (Erdem ve Aydın, 2021). Bu işlev, her etiket için olasılıksal bir sonuç oluşturacaktır. Bu aktivasyon işlevi genellikle bir softmax işlevi veya ikili sınıflandırma durumunda bir sigmoid fonksiyonudur ve Eşitlik 3.2 ile verilir,

$$\text{soft max}(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}; \quad j = 1, \dots, K \quad (3.2)$$

Sınıflandırma işlemi, ESA modelinin sınıflandırma katmanında yapılır. Bu katmanın çıktı değerleri, tanınacak nesnelerin sayısına bağlıdır ve sınıf sayısına eşittir. Ağ değişkenleri arasındaki karmaşık ve sürekli ilişki aktivasyon fonksiyonları tarafından öğrenilir. Örneğin, ağdaki doğrusallığı önlemek için relu aktivasyon fonksiyonu kullanılır. Çiçek sınıflandırması için ESA mimarisinde tamamen bağlı katmanda (FCL) çok sınıflı sınıflandırma gerekli olduğundan, denklem (2) 'de verildiği gibi bir softmax fonksiyonu kullanılır. Bu sınıflandırıcı, her sınıf için 0-1 arasında olasılıksal değerler üretir. Sonuç olarak, en yüksek olasılık değeri, modelin öngördüğü sınıfı verir (Kim, 2017).

ESA mimari yapısı incelendiğinde, birçok parametre içerdiği görülmektedir. Bununla birlikte, bu durum ağın eğitim verileriyle aşırı uymasına neden olabilir ve doğrulama ve test verilerinde veya aşırı öğrenmede düşük doğruluğa neden olabilir. Özellikler katmanlar arasında aktarılabilir. Özellikleri aktarma işlemi, bir matrisin, görüntünün özellik matrislerini görüntünün üzerindeki evrim katmanındaki kaydırarak tüm görüntüyü işlediği anlamına gelir. Böylece, her matris görüntüyü etkiler. Bu özellik ile, ağ para metre olması gerekenden çok daha az olur. Düşük eğitim parametresi hem eğitim sürecini hızlandırır hem de aşırı uydurma sorunu ortadan kaldırır. Ağ derinleştikçe, başka bir deyişle, gizli katmanların sayısı artar, görüntülerin boyutu ve ağdaki öğrenilen özellikler azalır. Bu indirgeme işleminde, görüntüdeki en yüksek temsil yeteneğine sahip pikseller kullanılır. Nesnenin görüntüdeki yeri de önemsizdir, bu sorun filtrelerin kaydırılmasıyla aşılmıştır (Krizhevsky ve ark., 2017).


### 3.2. Veri Toplama

Bu çalışmada, Üniversite kampüsünden 20 farklı çiçek türünden veri seti toplanmıştır. Bu veri seti süs bitkisi çiçeği ağırlıklı olarak oluşturulmuştur. Çiçekler çalışma ortamında kayda alınmıştır. Veri toplama süreci, standartlaştırılmış bir ortam oluşturularak gerçekleştirilmiştir. Çekimlerin yapılacağı ortamda, dış etkilerden arındırılmış ve doğal ışık kaynaklarıyla desteklenmiş uygun bir aydınlatma düzeni kurulmuştur (Şekil 3.2). Fotoğrafların yüksek kaliteli ve detaylı biçimde alınabilmesi için beyaz zemine sahip bir masa kullanılmıştır. Bu masa, yansımaları en aza indirecek şekilde temizlenmiş ve düzgün bir yüzey elde edilmiştir.


Görüntü verilerinin elde edilmesinde, Samsung marka bir akıllı telefon kullanılmıştır. Bu cihaz; 10X hibrit optik zoom, 30X süper çözünürlüklü dijital zoom özelliklerine ve 64 megapiksel yüksek çözünürlüklü kameraya sahiptir. Bu özellikler, detaylı görüntü yakalama ve analiz açısından tercih sebebi olmuştur. Çekim esnasında kamera ile masa yüzeyi arasında yaklaşık 40–50 cm’lik sabit bir mesafe korunmuş ve bu mesafe her çekim için standardize edilmiştir. Her bir çiçek türü, masanın üzerine yerleştirildikten sonra, cihaz sabit tutulmak kaydıyla masa etrafında 360° döndürülerek her 90 derecede 250 görüntü olmak üzere her türden en az 1000 görüntü alınmıştır (Şekil 3.2). Her tür için 1000 adet yüksek çözünürlüklü fotoğraf çekilmiştir. Böylece toplamda 20000 adetten fazla görüntü verisi elde edilmiştir. Şekil 3.3-Şekil 3.6’de toplanan 4 çiçek türe ait örnek veriler gösterilmiştir.

Veri aktarımı için kullanılan cihaz, USB bağlantı kablosu aracılığıyla bir kişisel bilgisayara bağlanmış ve tüm fotoğraflar düzenli şekilde dijital klasörlere ayrılarak dosyalama işlemi gerçekleştirilmiştir. Bu süreçte her çiçek türüne ait fotoğraflar ayrı klasörlerde ve sıralı numaralandırmayla saklanmıştır. Görüntülerin bütünlüğü, netliği ve ışık dengesi kontrol edildikten sonra analiz süreci için hazır hale getirilmiştir.


Araştırma, sabit çevresel koşullar altında gerçekleştirilmiş olup, verilerin güvenilirliğini artırmak amacıyla tüm çekim ve aktarım işlemleri kayıt alındığı gün içerisinde tamamlanmıştır. Elde edilen görüntü verileri, daha sonraki analiz aşamalarında görüntü işleme, sınıflandırma veya ölçümleme tekniklerinde kullanılmak üzere arşivlenmiştir.



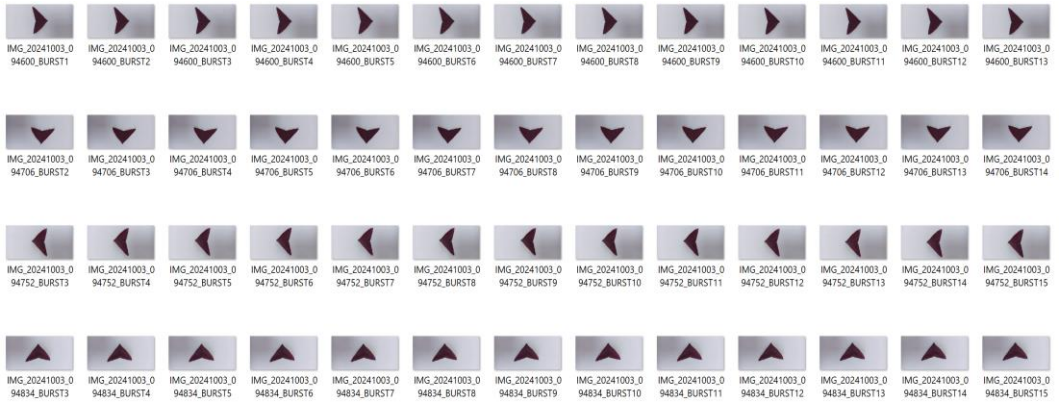
**Şekil 3.2.** 360° döndürülerek farklı açılardan fotoğraf çekimi




**Şekil 3.3.** Çiçek 1 verisine ait resimler



Şekil 3.4. Çiçek 2 verisine ait resimler



Şekil 3.5. Çiçek 3 verisine ait resimler



Şekil 3.6. Çiçek 4 verisine ait resimler

### 3.3. Önceden Eğitilmiş Derin Sinir Ağları

Doğal görüntülerden ayırt edici ve bilgilendirici özellikler çıkarma konusunda önceden eğitim almış bir görüntü sınıflandırma sinir ağı, yeni görevlerin öğrenilmesinde başlangıç modeli olarak kullanılmıştır. Bu tür ağların çoğu, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) kapsamında kullanılan ImageNet veri tabanının sınırlı bir alt kümesi üzerinde eğitilmiştir (Mathworks, 2023). Bu sinir ağları, bir milyondan fazla görüntü üzerinde eğitilmiş olup; klavye, kahve fincanı, kurşun kalem ve çeşitli hayvanlar gibi 1000 nesne kategorisini sınıflandırma yeteneğine sahiptir. Transfer öğrenmesiyle birlikte önceden eğitilmiş bir sinir ağı kullanmak, genellikle sıfırdan bir sinir ağı eğitmekten çok daha hızlı ve kolaydır. Önceden eğitilmiş ağların kullanım amaçları açıklanmıştır. (Ciaburro, 2024).

Önceden eğitilmiş sinir ağları aşağıdaki görevlerde (Mathworks, 2023) kullanılabilir: Sınıflandırma, özellik çıkarma ve transfer öğrenmesi.

Sınıflandırma problemlerinde önceden eğitilmiş sinir ağlarını doğrudan kullanmak mümkündür. Yeni görüntülerin sınıflandırılmasında MATLAB ortamında `minibatchpredict` fonksiyonunu tercih edilir. Tahmin edilen skorların etiketlere dönüştürülmesi için `scores2label` fonksiyonu kullanılır. Önceden eğitilmiş bir ağ ile sınıflandırma işlemine örnek bir uygulama için MATLAB ortamında “Classify Image Using GoogLeNet” başlıklı örneğe başvurulabilir.

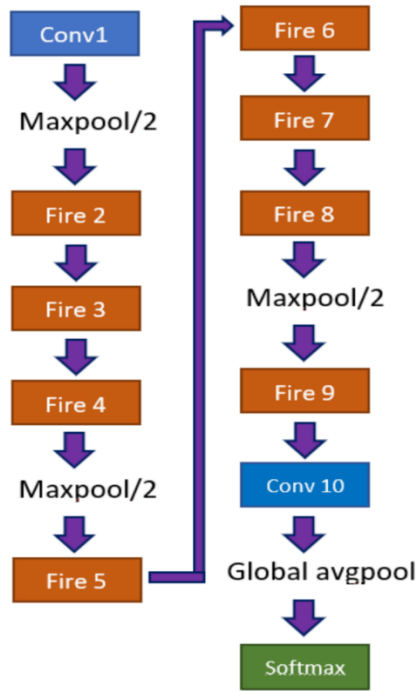
Katman aktivasyonlarını özellik seti olarak kullanarak, önceden eğitilmiş sinir ağını bir özellik çıkarıcı olarak değerlendirilir ve kullanılabilir. Bu özellikler, destek vektör makineleri (DVM) gibi farklı makine öğrenmesi modellerinin eğitimi için girdi olarak kullanılabilir. Detaylı açıklamalar için MATLAB ortamında öznetelik çıkarımı bölümü incelenebilir, uygulamalı örnek olarak MATLAB ortamında “Extract Image Features Using Pretrained Network” başlıklı örneğe başvurulabilir. Bu tez kapsamında bu örneklerden faydalanılarak kod çalışmaları gerçekleştirilmiştir.

Geniş ölçekli bir veri setinde eğitilmiş sinir ağı katmanlarını alıp, yeni veri üzerinde ince ayar (fine-tuning) yapılabilir, bu süreçle ilgili detaylı bilgi MATLAB ortamında “Transfer Öğrenimi (Transfer Learning)” bölümüne bakılabilir. Ayrıca bu konu ile ilgili basit bir örnek için MATLAB ortamındaki “Get Started with Transfer Learning” başlığı incelenebilir, farklı önceden eğitilmiş modellerinin denenmesi için “Retrain Neural Network to Classify New Images” bölümü gözden geçirilebilir. Bu çalışmada 4 farklı model bu şekilde oluşturulan yeni veri setinde kullanılmıştır.


**Tablo 3.1** Uygulamada kullanılan önceden eğitilmiş ağlar ve özellikleri

Model Adı/ Ağı Adı	Sinir Derinlik	Parametre Belleği	Parametreler (Milyon)	Görüntü Giriş Boyutu	Giriş Değer Aralığı
squeezenet	18	4.7 MB	1,24	227x227	0,255
googlenet	22	27 MB	7,0	224x224	0,255
resnet50	50	98 MB	25,6	224x224	0,255
shufflenet	50	5.5 MB	1,4	224x224	0,255


### 3.4. Uygulamada Kullanılan Önceden Eğitilmiş Sinir Ağı Mimarileri



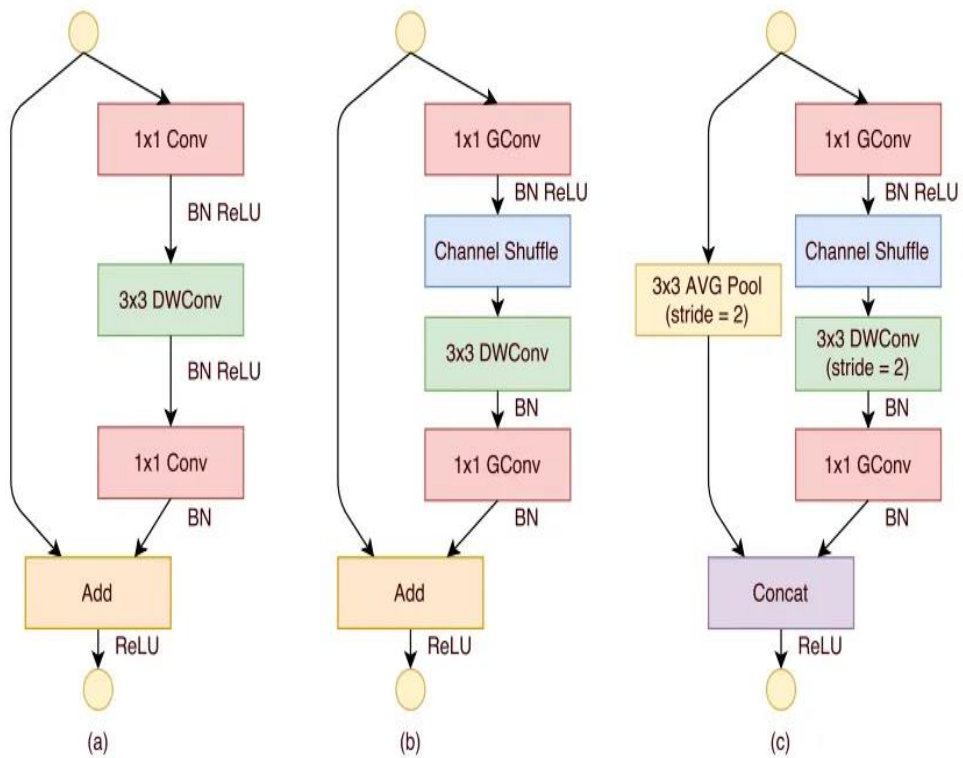
Şekil 3.7. SqueezeNet mimarisi



Şekil 3.8. ResNet-50 mimarisi



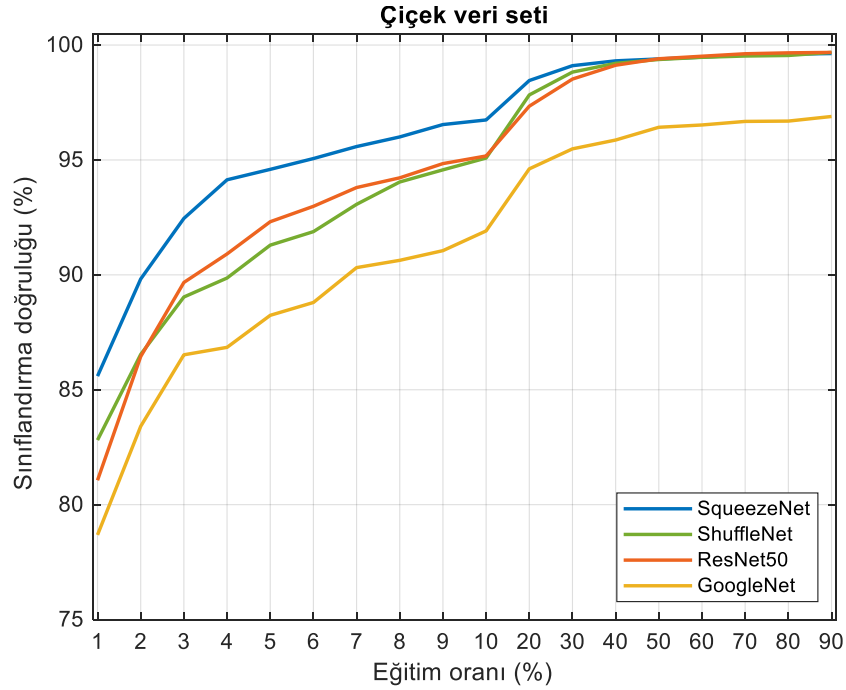
Şekil 3.9. GoogleNet mimarisi



Şekil 3.10. ShuffleNet mimarisi

#### 4. BULGULAR VE TARTIŞMA

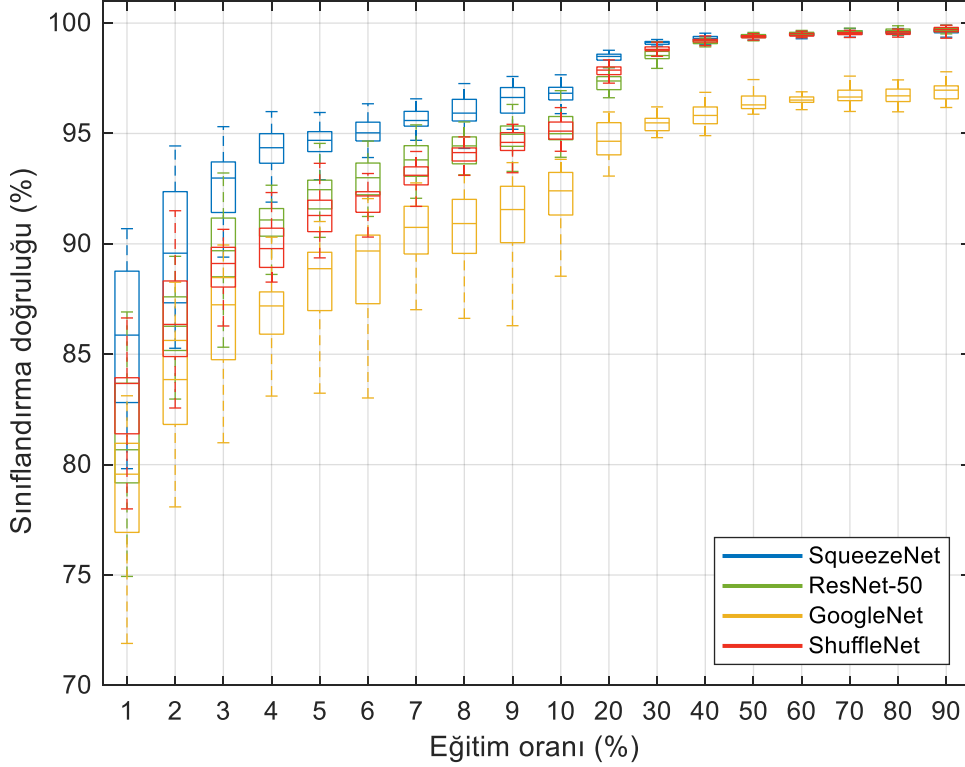
Bu bölümde çiçek verileri kullanılarak önceden eğitilmiş ağlarla elde edilen görüntülerin sınıflandırıldığı çalışmanın sonuçları grafiklerle sunulmuştur. Önceden eğitilmiş ağ olarak ShuffleNet, ResNet50, GoogleNet ve SqueezeNet ağları kullanılmıştır. Otuz deneme sonuçları verilmiştir. Eğitim oranı %1'den %90'a kadar değiştirilerek ve her değişimde 50 farklı deneme yapılarak elde edilen başarımların grafiği Şekil 4.1'de verilmiştir. Her denemede yanlılığı önlemek amacıyla rasgele örnekler seçilmiş, otuz denemenin ortalama başarımları grafikte verilmiştir. Eğitim oranı %10 civarında iken üç modelin sınıflandırma başarımları doğruluğu %95'in üzerine çıkmıştır. Aynı başarımlara GoogleNet %25 eğitim oranından sonra ulaşmıştır. Tatmin edici bir başarımlar tercih edilecek olursa dört modelin başarımları oranları %40 eğitim oranından sonra %95'in üzerinde sınıflandırma doğruluğuna ulaşmaktadırlar ve daha sonra fazla bir değişim ile karşılaşmamaktadır. Makine öğreniminde %50 eğitim oranının kabul sınırı kabul edildiği göz önünde bulundurulduğunda %40 yeterli olmaktadır.



**Şekil 4.1.** Dört Model (ShuffleNet, ResNet-50, GoogleNet, SqueezeNet) için Sınıflandırma Doğruluğu-Eğitim Oranı Grafiği

Şekil 4.2'de dört modelin eğitim oranı kutu çizimleri grafiği verilmiştir. Başarımlara kutu çizimleri açısından bakılırsa düşük eğitim oranlarında çok fazla dağılıma sahip olmalarıyla birlikte eğitim oranı arttıkça kutuların dağılımları küçülmektedir. Grafikte her başarımlar oranı bir kutuyu temsil etmektedir. Kutunun ortası başarımlar ortalamasını, kenarları çeyreklikleri göstermektedir. Uçlarında en düşük ve en

büyük başarımları gösterir. %30 eğitim oranına kadar kutular büyük iken daha sonra kutuların küçülmesi başarımların her denemede daha yakın olarak ortaya çıktığını göstermektedir. Başka bir açıdan bakılırsa başarımların en büyük değeri ile en küçük değeri açısından fazla fark yoktur, başarımlar her denemede yakın seyretmektedir.



Şekil 4.2. Dört Model (ShuffleNet, ResNet-50, GoogleNet, SqueezeNet) için Sınıflandırma Doğruluğu-Eğitim Oranı Kutu Çizimleri

Tablo 4.1. Karışıklık matrisi

		Gerçek Değerler	
		Pozitif	Negatif
Tahmin Edilen Değerler	Pozitif	Gerçek, Pozitif	Yanlış, Pozitif
	Negatif	Yanlış, Negatif	Gerçek, Negatif

Karışıklık matrisleri sınıflandırıcının ve özniteliklerin karşılaştırılmasında kullanılan yöntemlerdir. Sınıflandırma işleminin ne kadar doğru, tutarlı, vb. olduğu hakkında bilgiler içerirler. Şekil 4.3'te verilen karışıklık matrisinde SqueezeNet model kullanıldığında sınıflandırma başarımı, F1 skoru, vb. bilgilerin yanında her sınıfın hangi sınıfa karıştırıldığı hakkında da bilgilere ulaşılır. Mavi renk her sınıfın ne kadar doğru sınıflandırıldığını diğer renk ise diğer sınıflara ne kadar karıştırıldığını göstermektedir. Karıştırılmak miktarı arttıkça renk koyu renge dönmektedir. Her satırın içindeki elemanların toplamı sınıfın o denemede ne kadar eleman içerdiğini göstermektedir.

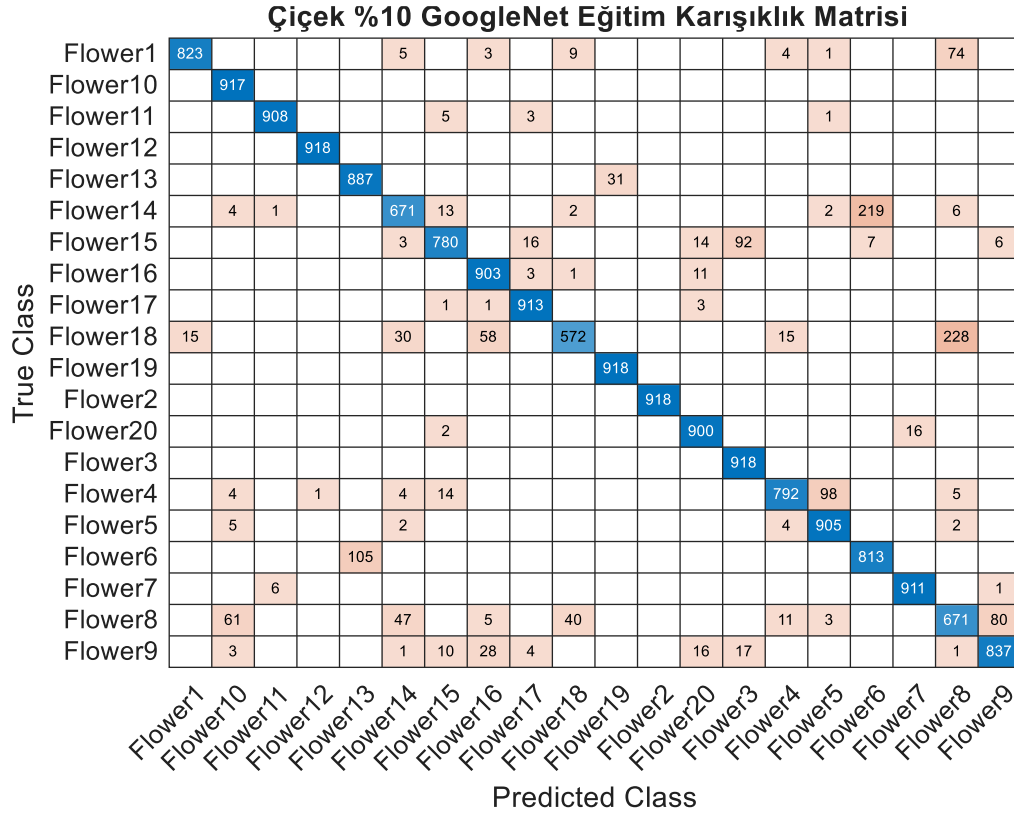
Köşegen matrisinin elemanlarının ortalaması sınıflandırma doğruluğuna karşılık gelmektedir. Karışıklık matrisi yüzde ya da eleman sayısı olarak verilebilir. Yüzde verilmesi durumunda denemelerdeki eleman sayıları hakkında bilgiler içermez. Bu değerleri dönüşüm formülü kullanılarak ulaşılabilir. Eleman sayısı verilmesi durumunda ise yüzde oranları formül kullanılarak hesaplanabilir. Bu Matlab ortamında confusionmat ve confusionchart komutları kullanılarak gerçekleştirilebilir. Şekil 4.3-4.14 için Matlab ortamında confusionchart komutu kullanılmıştır. Karışıklık matrisleri test aşaması için verilmiştir. Bu yüzden her satırdaki toplam eleman sayısı o sınıf için o denemede kullanılan test eleman sayısını vermektedir. Örneğin toplam her sınıftan 1000 eleman olduğundan her satır %10 eğitim oranı için karışıklık matrisinde toplam 900 eleman görünmektedir.

Eğitim oranları %1, %10 ve %50 için karışıklık matrisleri Şekil 4.3-Şekil 4.14' te verilmiştir. Şekil 4.3-Şekil 4.6 Eğitim oranının düşük olduğu %1 için verilmiştir. Köşegen mavi renklerdeki sayılar düşüktür. Bu sınıflandırmada çok hata olduğunu göstermektedir. Diğer beyaza doğru olan değerler hata değerlerini göstermektedir. En çok hata 11 ve 4 verilerinde yapılmıştır. En çok karıştırma ise 11 verisi 275 ile 10 verisine karıştırılmıştır. Daha sonraki en büyük hata ise yine 11 verisi 255 ile 13 verisine karıştırılmıştır. Dört model sınıflandırıcıdan en iyi durumda olan SqueezeNet model olmasına rağmen bu eğitim oranında bunda da hata oranı yüksek çıkmıştır. SqueezeNet model %1 eğitim oranında %86 civarı sınıflandırma başarımına sahiptir. Şekil 4.6'da verilen GoogleNet model sınıflandırıcı karışıklık matrisi bu eğitim oranının en kötü modeli durumdadır ve bu matrisin renk skalasından bellidir. Eğitim oranı %10 ve %50 değerlerine yükseldiğinde köşegen mavi kutu değerleri büyümekte diğer hata değerleri olan turuncu değerler beyaz çok olmakla birlikte azalmaktadır. Buda eğitim oranı ile sınıflandırma başarımının arttığını hatalı sınıflandırmaların azaldığını göstermektedir.


Şekil 4.7'te eğitim oranı %10 için sınıflandırma karışıklık matrisi görülmektedir. Matrise bakıldığında mavi kutuların değerleri yükselmiş, beyaz kutuların sayısı (hatasız sınıflandırma) artmış, diğer renkteki kutuların değerleri de azalmıştır. Bu bize başarımın arttığı hakkında bilgi vermektedir. Eğitim oranı arttıkça sınıflandırma başarım oranı artmaktadır sonucu çıkarılır.



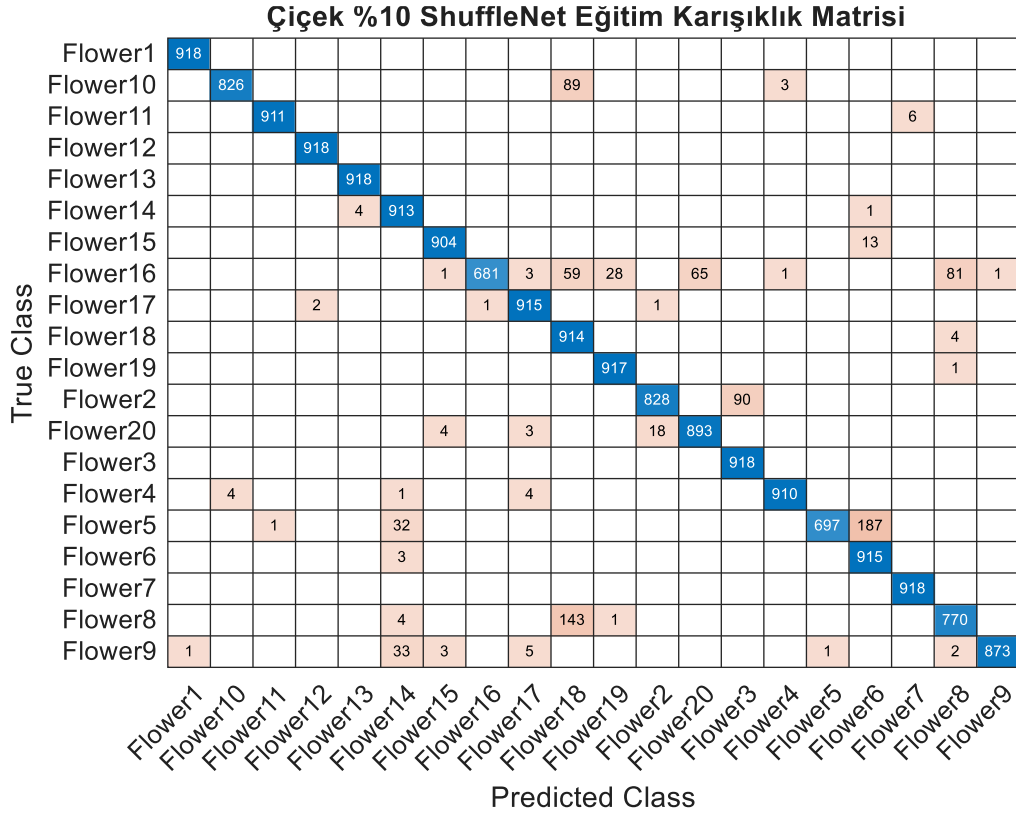





Şekil 4.7. GoogleNet model için %10 eğitim oranında sınıflandırma karışıklık matrisi



Şekil 4.8. ResNet-50 model için %10 eğitim oranında sınıflandırma karışıklık matrisi




Şekil 4.9. ShuffleNet model için %10 eğitim oranında sınıflandırma karışıklık matrisi




Şekil 4.10. SqueezeNet model için %10 eğitim oranında sınıflandırma karışıklık matrisi





Şekil 4.13. ShuffleNet model için %50 eğitim oranında sınıflandırma karışıklık matrisi



Şekil 4.14. SqueezeNet model için %50 eğitim oranında sınıflandırma karışıklık matrisi



## 5. SONUÇ VE ÖNERİLER

Bitkilerin izlenmesi, kontrol edilmesi, büyümesi, sağlık durumları hakkında bilgilerin toplanmasında çiçeklerin önemi büyüktür. Çiçekler her ne kadar bitkileri tanımlasa da uygulamada yaşanan zorluklar makine öğrenmesinin kullanımını zorunlu kılabilmektedir. Bunun sebebi ise birbirlerine çok benzer çeşitlerin olması ve çeşitliliğin çok büyük olamasın dan kaynaklanmaktadır. Genellikle gıda, sağlık, ilaç ve sanayi sektörü buna daha çok ihtiyaç duymaktadır. İlaç ve parfüm sektörü çiçekleri daha çok kullandığından hata payı daha düşüktür. Bu sebeple çiçek sınıflandırması çalışmaları akademik çalışmalarda sıklıkla karşımıza çıkmaktadır.

Bu çalışmada, tarafımızdan toplanan özel bir veri seti kullanılarak 20 farklı çiçek türü sınıflandırılmıştır. Sınıflandırma sürecinde, derin öğrenme tabanlı dört farklı model (GoogLeNet, SqueezeNet, ShuffleNet ve ResNet50) ile öznetelik çıkarımı gerçekleştirilmiş ve bu öznetelikler doğrultusunda sınıflandırma işlemleri gerçekleştirilmiştir. Elde edilen deneysel sonuçlara göre, kullanılan modeller yüksek bir başarı oranı sergilemiş ve genel doğruluk oranı yaklaşık %95 civarında olmuştur. Bu da derin öğrenme tabanlı öznetelik çıkarım yöntemlerinin çiçek sınıflandırma problemlerinde etkili bir şekilde kullanılabileceğini göstermektedir. Kullanılan modellemelerin derinlik, parametre belleği, parametreleri, görüntü giriş boyutu gibi değerleri, doğruluk oranlarında belirli şekilde etkileyici olmamıştır. Bu da modellemenin değil kullanılan veri setinin etkili olduğunu göstermiştir. Çalışma hem özel veri setlerinin değerlendirilmesi hem de farklı mimarilerin karşılaştırılması açısından önemli katkılar sunmaktadır. Gelecek çalışmalarda, veri setinin genişletilmesi ve farklı derin öğrenme modellerinin entegrasyonu ile sınıflandırma performansının daha da artırılması hedeflenmektedir.

Bu çalışmada özgün veri seti oluşturulmuştur. Veri seti farklı modeller kullanılarak sınıflandırılmıştır. İleride amaç bu veri setini büyütme ve Kırşehir ya da Üniversite kampüsü özelinde oluşturmak ve açık veri setleri arasında yerini almasını sağlamaktır.

Yapılan çalışma daha sonra mobil uygulama şekline dönüştürülerek kullanıcıların yararına sunulacaktır. Mobil uygulamalar herkesin ulaşabileceği uygulamalardır. Sistem devamlı kendini geliştirmesi esasına dayalı olduğundan veri setinin genişlemesi sistemin güncel halde kalmasına yol açacaktır. Ayrıca farklı uygulama alanları içinde entegre edilerek farklı alanlarda uygulama alanları bulacaktır.



## KAYNAKLAR

Al-Malah, K. I. (2023). *Machine and deep learning using MATLAB: Algorithms and tools for scientists and engineers*. John Wiley & Sons.

Anand, M. S., Swaroopa, K., Nainwal, M., & Therasa, M. (2024). An intelligent flower classification framework: Optimal hybrid flower pattern extractor with adaptive dynamic ensemble transfer learning-based convolutional neural network. *IMAGING SCIENCE JOURNAL*, 72(1), 52-75.

Arinda, Y. K., Rahman, M. A., & Alamsyah, D. (2018). Klasifikasi Jenis Bunga menggunakan SVM dengan Fitur HSV dan HOG. *Ijccs*, no. x, 1-12.

Bayram, E., & Nabiyeu, V. (2021, June). Classification of camouflage images using Local Binary Patterns (LBP). In *2021 29th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.

Beal, J., Kim, E., Tzeng, E., Park, D. H., Zhai, A., & Kislyuk, D. (2020). Toward transformer-based object detection. *arXiv preprint arXiv:2012.09958*.

Chen, B., Liu, J., Sun, J., & Liu, J. (2019). Flowers classification via deep learning models. [http://noiselab.ucsd.edu/ECE228\\_2019/Reports/Report40.pdf](http://noiselab.ucsd.edu/ECE228_2019/Reports/Report40.pdf) (accessed November 10, 2021).

Christenhusz, M. J., & Byng, J. (2016). The number of known plants species in the world and its annual increase. *Phytotaxa*, 261(3), 201-217.

Das, M., Manmatha, R., & Riseman, E. M. (1999). Indexing flower patent images using domain knowledge. *IEEE Intelligent Systems and their Applications*, 14(5), 24-33.

Deshapande, A. S., Giraddi, S. G., Karibasappa, K. G., & Desai, S. D. (2018). Fungal disease detection in maize leaves using haar wavelet features. In *Information and Communication Technology for Intelligent Systems: Proceedings of ICTIS 2018, Volume 1* (pp. 275-286). Singapore: Springer Singapore.

Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Houlsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.

Du, J. X., Huang, D. S., Wang, X. F., & Gu, X. (2007). Shape recognition based on neural networks trained by differential evolution algorithm. *Neurocomputing*, 70(4-6), 896-903.

Du, J. X., Wang, X. F., & Zhang, G. J. (2007). Leaf shape based plant species recognition. *Applied mathematics and computation*, 185(2), 883-893.

Eldem, A., Eldem, H., & Üstün, D. (2018, September). A model of deep neural network for iris classification with different activation functions. In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP) (pp. 1-4). IEEE.

Erdem, E., & Aydin, T. (2021). A CNN-based hybrid model to detect Coronavirus disease. *Avrupa Bilim ve Teknoloji Dergisi*, (27), 66-73.

FatihahSahidan, N., Juha, A. K., Mohammad, N., & Ibrahim, Z. (2019). Flower and leaf recognition for plant identification using convolutional neural network. *Indonesian Journal of Electrical Engineering and Computer Science*, 16(2), 737-743.

Feng, J., Wang, Z., Zha, M., & Cao, X. (2019, September). Flower recognition based on transfer learning and Adam deep learning optimization algorithm. In Proceedings of the 2019 international conference on robotics, intelligent control and artificial intelligence (pp. 598-604).

Gadkari, S., Mathias, J., & Pansare, A. (2019). Analysis of pre-trained convolutional neural networks to build a flower classification system. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 2321-9653.

Ghazi, M. M., Yanikoglu, B., & Aptoula, E. (2017). Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing*, 235, 228-235.

Ciaburro, G. (2024). *MATLAB for Machine Learning: Unlock the power of deep learning for swift and enhanced results*. Packt Publishing Ltd.

Giraddi, S., Desai, S., & Deshpande, A. (2020, May). Deep learning for agricultural plant disease detection. In *ICDSMLA 2019: Proceedings of the 1st International Conference on Data Science, Machine Learning and Applications* (pp. 864-871). Singapore: Springer Singapore.

Giraddi, S., Seeri, S., Hiremath, P. S., & GN, J. (2020, October). Flower classification using deep learning models. In 2020 International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE) (pp. 130-133). IEEE.

Guo, B., Hu, J., Wu, W., Peng, Q., & Wu, F. (2019). The Tabu\_Genetic algorithm: A novel method for hyper-parameter optimization of learning algorithms. *Electronics*, 8(5), 579.

Gupta, T., Arora, P., Rani, R., Jaiswal, G., Bansal, P., & Dev, A. (2022, December). Classification of flower dataset using machine learning models. In 2022 4th

International conference on artificial intelligence and speech technology (AIST) (pp. 1-6). IEEE.

Gurnani, A., Mavani, V., Gajjar, V., & Khandhediya, Y. (2017). Flower categorization using deep convolutional neural networks. arXiv. arXiv preprint arXiv:1708.03763.

Guru, D. S., Sharath, Y. H., & Manjunath, S. (2010). Texture features and KNN in classification of flower images. IJCA, Special Issue on RTIPPR (1), 21-29.

Ke, X., Chen, X. F., & Li, S. Z. (2010). Flower image retrieval based on multi-feature fusion. Comput. Sci, 11, 282-286.

Kim, P. (2017). Convolutional neural network. In MATLAB deep learning: with machine learning, neural networks and artificial intelligence (pp. 121-147). Berkeley, CA: Apress.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 84-90.

Yandong, L., Zongbo, H., & Hang, L. (2016). Survey of convolutional neural network. Journal of Computer Applications, 36(9), 2508-2515.

Li, Y., Hao, Z. B., & Lei, H. (2016). Survey of convolutional neural network. Journal of Computer Applications, 36(9), 2508-2515.

Liu, B., Ding, Z., Zhang, Y., He, D., & He, J. (2020, July). Kiwifruit leaf disease identification using improved deep convolutional neural networks. In 2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC) (pp. 1267-1272). IEEE.

Liu, Y., & Zheng, F. B. (2017). Object-oriented and multi-scale target classification and recognition based on hierarchical ensemble learning. Computers & Electrical Engineering, 62, 538-554.

Liu, S., Gao, X. (2018). Fine-grained image classification method based on deep model transfer. J. Comput. Appl., 38, 2198–2204.

Luus, F., Khan, N., & Akhalwaya, I. (2019). Active learning with tensorboard projector. arXiv preprint arXiv:1901.00675.

Lv, R., Li, Z., Zuo, J., & Liu, J. (2021, January). Flower classification and recognition based on significance test and transfer learning. In 2021 IEEE International Conference on Consumer Electronics and Computer Engineering (ICCECE) (pp. 649-652). IEEE.

Madoui, S., Charef, N., Arrar, L., Baghianni, A., & Khenouf, S. (2019). In vitro antioxidant activities of various extracts from flowers-leaves mixture of Algerian *Cytisus triflorus*.

Mathworks. (2023). Pretrained Deep Neural Networks. Retrieved from <https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>

Mishra, P. K., Maurya, S. K., Singh, R. K., & Misra, A. K. (2012, March). A semi automatic plant identification based on digital leaf and flower images. In IEEE-International Conference On Advances In Engineering, Science And Management (ICAESM-2012) (pp. 68-73). IEEE.

Mitrović, K., & Milošević, D. (2019, October). Flower classification with convolutional neural networks. In 2019 23rd International Conference on System Theory, Control and Computing (ICSTCC) (pp. 845-850). IEEE.

Mukane S.M. and Kendule, J.A. (2013). Flower Classification Using Neural Network Based Image Processing. IOSR Journal of Electronics and Communication Engineering (IOSR-JECE) Volume 7, Issue 3, Sep.Oct.

Narvekar, C., & Rao, M. (2020, December). Flower classification using CNN and transfer learning in CNN-Agriculture Perspective. In 2020 3rd international conference on intelligent sustainable systems (ICISS) (pp. 660-664). IEEE.

Nauck, D., & Kruse, R. (1996). Designing neuro-fuzzy systems through backpropagation. In Fuzzy Modelling: Paradigms and Practice (pp. 203-228). Boston, MA: Springer US.

Nilsback, M. E., & Zisserman, A. (2008, December). Automated flower classification over a large number of classes. In 2008 Sixth Indian conference on computer vision, graphics & image processing (pp. 722-729). IEEE.

Patel, I., & Patel, S. (2019). Flower identification and classification using computer vision and machine learning techniques. International Journal of Engineering and Advanced Technology (IJEAT), 8(6), 277-285.

Qin, M. (2020). Research on Flower Image Classification and Recognition Model Based on Deep Learning. Master's Thesis, Guangxi Normal University, Guilin, China.

Rashad, M. Z., El-Desouky, B. S., & Khawasik, M. S. (2011). Plants images classification based on textural features using combined classifier. International Journal of Computer Science and Information Technology, 3(4), 93-100.

Roddy, A. B., Jiang, G. F., Cao, K., Simonin, K. A., & Brodersen, C. R. (2019). Hydraulic traits are more diverse in flowers than in leaves. *New Phytologist*, 223(1), 193-203.

Huang, R. G., Jin, S. H., Kim, J. H., & Hong, K. S. (2009, December). Flower image recognition using difference image entropy. In *Proceedings of the 7th International Conference on Advances in Mobile Computing and Multimedia* (pp. 618-621).

Saitoh, T., & Kaneko, T. (2003). Automatic recognition of wild flowers. *Systems and Computers in Japan*, 34(10), 90-101.

Samragh, M., Farajtabar, M., Mehta, S., Vemulapalli, R., Faghri, F., Naik, D., ... & Rastegari, M. (2023). Weight subcloning: direct initialization of transformers using larger pretrained ones. *arXiv preprint arXiv:2312.09299*.

Sangale, R., Jangada, R., De, A., Sanga, N., & Deokar, S. (2020). Flower recognition using deep learning. *International Journal of Research Publication and Reviews*, 1(8), 20-23.

Seeland, M., Rzanny, M., Alaqraa, N., Wäldchen, J., & Mäder, P. (2017). Plant species classification using flower images—A comparative study of local feature representations. *PloS one*, 12(2), e0170629.

Seeland, M., Rzanny, M., Boho, D., Wäldchen, J., & Mäder, P. (2019). Image-based classification of plant genus and family for trained and untrained plant species. *BMC bioinformatics*, 20(1), 4.

Shantala, S.T. (2020). Study on fungal disease detection in maize leaves using deep learning models.

Siraj, F., Salahuddin, M. A., & Yusof, S. A. M. (2010, September). Digital image classification for Malaysian blooming flower. In *2010 second international conference on computational intelligence, modelling and simulation* (pp. 33-38). IEEE.

Shukla, A., Agarwal, A., Pant, H., & Mishra, P. (2020). Flower classification using supervised learning. *Int. J. Eng. Res*, 9(05), 757-762.

Tiay, T., Benyaphaichit, P., & Riyamongkol, P. (2014, March). Flower recognition system based on image processing. In *2014 Third ICT International Student Project Conference (ICT-ISPC)* (pp. 99-102). IEEE.

Toğaçar, M., Ergen, B., & Özyurt, F. (2020). Evrişimsel sinir ağı modellerinde özellik seçim yöntemlerini kullanarak çiçek görüntülerinin sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(1), 47-56.

Turkoglu, M., & Hanbay, D. (2019, April). Plant recognition system based on deep features and color-LBP method. In 2019 27th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

Ursani, Z., & Corne, D. W. (2018, April). A hierarchical nonlinear discriminant classifier trained through an evolutionary algorithm. In International Conference on Big Data, Cloud and Applications (pp. 273-288). Cham: Springer International Publishing.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.

Wang, S. (2018). Research and Implementation of Flower Recognition Algorithm Based on Machine Learning. Master's Thesis, University of Electronic Science and Technology of China, Chengdu, China, 2018.

Wang, X. F., Du, J. X., & Zhang, G. J. (2005, August). Recognition of leaf images based on shape features using a hypersphere classifier. In International Conference on Intelligent Computing (pp. 87-96). Berlin, Heidelberg: Springer Berlin Heidelberg.

Voulodimos, A., Doulamis, N., Doulamis, A., & Protopapadakis, E. (2018). Deep learning for computer vision: A brief review. *Computational intelligence and neuroscience*, 2018(1), 7068349.

Xia, X., Xu, C., & Nan, B. (2017, June). Inception-v3 for flower classification. In 2017 2nd international conference on image, vision and computing (ICIVC) (pp. 783-787). IEEE.

Xie, L. (2011). Image classification and retrieval algorithms with LandUse-21 dataset, Indoor-67 dataset and SUN-397 dataset.

Xie, L., Wang, J., Lin, W., Zhang, B., & Tian, Q. (2017). Towards reversal-invariant image representation. *International Journal of Computer Vision*, 123(2), 226-250.

Xie, Z., & Hu, Y. (2022). Multi-target recognition system of flowers based on YOLOv4. *J. Nanjing Agric. Univ*, 45, 818-827.

Yavuzer, E. (2018). Development of defective fish egg sorting machine with colour sensor for trout facilities. *Aquaculture Research*, 49(11), 3634-3637.

Yavuzer, E., & Köse, M. (2022). Prediction of fish quality level with machine learning. *International Journal of Food Science and Technology*, 57(8), 5250-5255.

Yavuzer, E. (2020). Determination of rainbow trout quality parameters with Arduino microcontroller. *Journal of Food Safety*, 40(6), e12857.

Yıldıran, S. T., Yamkoğlu, B., & Abdullah, E. (2014, April). Plant identification using local invariants. In 2014 22nd Signal Processing and Communications Applications Conference (SIU) (pp. 2094-2097). IEEE.

Yoshioka, Y., Iwata, H., Ohsawa, R., & Ninomiya, S. (2004). Quantitative evaluation of flower colour pattern by image analysis and principal component analysis of *Primula sieboldii* E. Morren. *Euphytica*, 139(3), 179-186.

Wu, Y., Qin, X., Pan, Y., & Yuan, C. (2018, July). Convolution neural network based transfer learning for classification of flowers. In 2018 IEEE 3rd international conference on signal and image processing (ICSIP) (pp. 562-566). IEEE.

Zhang, C., Huang, W., Liang, X., He, X., Tian, X., Chen, L., & Wang, Q. (2022). Slight crack identification of cottonseed using air-coupled ultrasound with sound to image encoding. *Frontiers in Plant Science*, 13, 956636.

Zawbaa, H. M., Abbass, M., Basha, S. H., Hazman, M., & Hassenian, A. E. (2014, September). An automatic flower classification approach using machine learning algorithms. In 2014 International conference on advances in computing, communications and informatics (ICACCI) (pp. 895-901). IEEE.

Zhenjiang, M., Gandelin, M. H., & Baozong, Y. (2006). An OOPR-based rose variety recognition system. *Engineering Applications of Artificial Intelligence*, 19(1), 79-101.



## EKLER

### EK-1 Kongre Katılım Belgesi





## ÖZGEÇMİŞ

<b>KİŞİSEL BİLGİLER</b>	
<b>Adı Soyadı</b>	Aslan İÇEL
<b>Uyruğu</b>	T.C.
<b>Orcid Numarası</b>	0009-0007-7341-7682

<b>EĞİTİM BİLGİLERİ</b>	
<b>Lisans</b>	
<b>Üniversite</b>	Mersin Üniversitesi
<b>Fakülte</b>	Mühendislik Fakültesi
<b>Bölümü</b>	Bilgisayar Mühendisliği Bölümü
<b>Mezuniyet Yılı</b>	2005
<b>Yüksek Lisans</b>	
<b>Üniversite</b>	Kırşehir Ahi Evran Üniversitesi
<b>Enstitü</b>	Fen Bilimleri Enstitüsü
<b>Anabilim Dalı</b>	İleri Teknolojiler
<b>Mezuniyet Yılı</b>	2025

<b>Tezden Üretilen Makaleler ve Bildiriler</b>
<b>Uluslararası Konferans ve Sempozyumlarda Sunulan Bildiriler</b> Köse, M., İçel, A. (2024) "Classification application with small scale flower dataset", 5th International Conference on Innovative Academic Studies ICIAS 2024 , (pp. 133), Konya, Türkiye, (Kasım 2024)