



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



**DERİN ÖĞRENME İLE ÖZNİTELİK  
ÇIKARMA VE SINIFLANDIRMA  
UYGULAMASI**

**REŞİT MAMUR**

**YÜKSEK LİSANS TEZİ**

**KIRŞEHİR  
2025**



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



**DERİN ÖĞRENME İLE ÖZNİTELİK  
ÇIKARMA VE SINIFLANDIRMA  
UYGULAMASI**

**REŞİT MAMUR**

**YÜKSEK LİSANS TEZİ**

**DANIŞMAN**

**Dr. Öğr. Üyesi Memduh KÖSE**

**KIRŞEHİR**

**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.

03/09/2025

Reşit MAMUR

## 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>
<b>2. ÖNCEKİ ÇALIŞMALAR</b> .....	<b>5</b>
<b>3. MATERYAL VE METOT</b> .....	<b>9</b>
3.1. Veri Toplama .....	11
3.2. Önceden eğitilmiş derin sinir ağlarının kullanımı.....	15
3.3. ResNet-50 ve Yapısı .....	17
3.4. SqueezeNet ve Yapısı .....	20
3.5. Karışıklık Matrisleri .....	22
<b>4. BULGULAR VE TARTIŞMA</b> .....	<b>23</b>
<b>5. SONUÇ VE ÖNERİLER</b> .....	<b>29</b>
<b>KAYNAKLAR</b> .....	<b>31</b>
<b>EKLER</b> .....	<b>35</b>
Ek-1 Kongre Katılım Belgesi.....	35
<b>ÖZGEÇMİŞ</b> .....	<b>37</b>

## TEŐEKKÜR

Tez alıőmamın her aőamasında bilgi ve tecrübeleriyle bana yol gösteren, sabır ve desteęini hiçbir zaman esirgemeyen deęerli danıőmanım Dr. Öğr. Üyesi Memduh KÖSE'ye en içten teşekkürlerimi sunarım. Ayrıca katkı ve yönlendirmeleriyle sürece deęer katan çok kıymet verdięim Prof. Dr. Hakan SEPET'e de őükranlarımı sunarım.

Teze başlamam konusunda beni yüreklendiren ve zaman zaman bırakmak istesem de devam etmem için cesaretlendirerek bu süreci tamamlamamda büyük pay sahibi olan Bilgi İşlem Daire Başkanım Canfer MEMOĞLU'na özellikle teşekkür ederim.

Her zaman yanımda olan, sabrı, sevgisi ve anlayıőıyla en büyük desteęim olan sevgili eőim Merve MAMUR'a minnettarım. Onun desteęi olmasaydı bu yolculuęu tamamlamak çok daha zor olurdu.

Son olarak, koőulsuz sevgileri ve her zaman yanımda oldukları için aileme de en derin teşekkürlerimi sunarım.

Eylül, 2025

Reőit MAMUR

## ÖZET

### YÜKSEK LİSANS TEZİ

#### DERİN ÖĞRENME İLE ÖZİNİTELİK ÇIKARMA VE SINIFLANDIRMA UYGULAMASI

Reşit MAMUR

#### KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ FEN BİLİMLER ENSTİTÜSÜ İLERİ TEKNOLOJİLER ANABİLİM DALI

**Danışman:** Dr. Öğr. Üyesi Memduh KÖSE  
Yıl: 2025 Sayfa: 37  
**Jüri:** Dr. Öğr. Üyesi Memduh KÖSE  
Doç. Dr. H. Alparslan ILGIN  
Dr. Öğr. Üyesi Çağrı KILINÇ

Botanik ve tarımda, yaprakların sınıflandırılması biyoçeşitlilik, ekolojik çalışmalar ve bitki türlerinin tanımlanması üzerine yapılan çalışmalar için hayati bilgiler sağlayan kritik bir süreçtir. Hazır veri setleri, çeşitli bitki türlerinden kapsamlı bir yaprak görüntüsü koleksiyonu sunarak gelişmiş sınıflandırma algoritmalarının geliştirilmesini ve değerlendirilmesini sağlamaktadır. Bu çalışma, öznelik çıkarma ve sınıflandırma aşamalarından yaprak görüntülerini sınıflandırmak için sağlam bir metodoloji sunmaktadır. Oluşturulan veri seti her sınıftan 1000'er adet olmak üzere toplam 15000 görüntüye sahiptir. Öznelikler, önceden eğitilmiş sinir ağları ile çıkarılmaktadır. Ön işleme yöntemleri kullanılmamıştır. Bazı teknikleri sistematik olarak entegre ederek boyutluluğu azaltmayı, alakasız veya gereksiz öznelikleri ortadan kaldırmayı ve veri kalitesini iyileştirme amaçlanmaktadır. Öznelikle büyük veri kümeleri ve çok sayıda sınıf söz konusu olduğunda sınıflandırmada doğruluğu artırmak, veri ön işleme, model seçimi, düzenleme teknikleri ve ince ayarın bir kombinasyonunu içermek zorundadır. Düşük profilli veri seti olduğundan bu çalışmada buna gerek duyulmamıştır. Veri seti ileriki çalışmalarda daha büyük sıklıkla yükseltildiğinde özneliklerin daha sağlam olması açısından bazı ön işleme yöntemlerini kullanmak zorunlu olacaktır. Sonuçlar, 15 sınıflı veri seti için 2 modelin öznelik çıkarmada kullanıldığı çalışmada eğitim oranı %40'ın üzerine çıktığında her model için sınıflandırma başarımının %90'ın üzerine çıktığını göstermektedir.

**Anahtar Kelimeler:** Önceden eğitilmiş model, Sınıflandırma, Eğitim oranı

## ABSTRACT

### MASTER'S THESIS

## FEATURE EXTRACTION AND CLASSIFICATION APPLICATION WITH DEEP LEARNING

Reşit MAMUR

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

**Supervisor:** Assist. Prof. Dr. Memduh KÖSE  
Year: 2025 Pages: 37  
**Juries:** Assist. Prof. Dr. Memduh KÖSE  
Assos. Prof. Dr. H. Alparslan ILGIN  
Assist. Prof. Dr. Çağrı KILINÇ

In botany and agriculture, leaf classification is a critical process that provides vital information for studies on biodiversity, ecological research, and plant species identification. Pre-existing datasets facilitate the development and evaluation of advanced classification algorithms by offering a comprehensive collection of leaf images from various plant species. This study presents a robust methodology for classifying leaf images through feature extraction and classification stages. The created dataset contains a total of 15,000 images, with 1,000 images per class. Features are extracted using pre-trained neural networks. No preprocessing methods were used. The aim is to reduce dimensionality, eliminate irrelevant or unnecessary features, and improve data quality by systematically integrating certain techniques. When dealing with large feature sets and a large number of classes, improving classification accuracy requires a combination of data preprocessing, model selection, regularization techniques, and fine-tuning. Since the dataset was low-profile, this was not necessary in this study. When the dataset is scaled up in future studies, it will be necessary to use some preprocessing methods to ensure that the attributes are more robust. The results show that when the training rate exceeded 40% in the study where two models were used for feature extraction on a 15-class dataset, the classification performance exceeded 90% for each model.

**Key Words:** Pretrained model, Classification, Train ratio

## TABLULAR DİZİNİ

	Sayfa No
<b>Tablo 3.1.</b> Önceden eğitilmiş sinir ağları aşağıdaki görevlerde (Mathworks, 2023) kullanılabilir.....	15
<b>Tablo 3.2.</b> MATLAB ortamında gerçekleştirilebilecek önceden eğitilmiş ağlar ve özellikleri .....	16
<b>Tablo 3.3.</b> Karışıklık matrisi .....	22

## ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 3.1. Yaprak türlerinin sınıflandırması için ESA mimarisinin temel akışı .....	11
Şekil 3.2. 360° döndürülerek farklı açılardan fotoğraf çekimi .....	12
Şekil 3.3. Yaprak 1 verisine ait resimler .....	12
Şekil 3.4. Yaprak 2 verisine ait resimler .....	13
Şekil 3.5. Yaprak 3 verisine ait resimler .....	13
Şekil 3.6. Yaprak 4 verisine ait resimler .....	14
Şekil 3.7. Yaprak veri seti. ....	14
Şekil 3.8. Yaprak türlerinin sınıflandırması için ESA mimarisinin temel akışı .....	16
Şekil 3.9. ResNet mimarisindeki artık bağlantılara bir bakış. ....	19
Şekil 3.10. ResNet-50 yapısı. ....	20
Şekil 3.11. SqueezeNet katmanları. ....	21
Şekil 3.12. SqueezeNet yapısı. ....	21
Şekil 4.1. İki model için Sınıflandırma doğruluğu-Eğitim oranı grafiği .....	23
Şekil 4.2. İki model için Sınıflandırma doğruluğu-Eğitim oranı kutu çizimleri .....	24
Şekil 4.3. SqueezeNet model için %1 eğitim oranında sınıflandırma karışıklık matrisi	26
Şekil 4.4. ResNet-50 model için %1 eğitim oranında sınıflandırma karışıklık matrisi ..	26
Şekil 4.5. SqueezeNet model için %10 eğitim oranında sınıflandırma karışıklık matrisi .....	27
Şekil 4.6. ResNet-50 model için %10 eğitim oranında sınıflandırma karışıklık matrisi	27
Şekil 4.7. SqueezeNet model için %80 eğitim oranında sınıflandırma karışıklık matrisi .....	28
Şekil 4.8. ResNet-50 model için %80 eğitim oranında sınıflandırma karışıklık matrisi	28

## KISALTMALAR DİZİNİ

<b>Kısaltmalar</b>	<b>Açıklama</b>
DVM	: Destek Vektör Makinaları
EYK	: En Yakın Komşuluk
ESA	: Evrişimsel Sinir Ağları
GN	: Gerçek Negatif
GP	: Gerçek Pozitif
MÖ	: Makine Öğrenmesi
TPO	: Toplam Pozitif Oranı
YN	: Yanlış Negatif
YP	: Yanlış Pozitif

## 1. GİRİŞ

Yapraklar, bitkilerin temel bileşenleridir ve çeşitli ekolojik, tarımsal ve botanik çalışmalarda hayati bir rol oynarlar. Yaprakların tanımlanması ve sınıflandırılması, biyoçeşitliliğin korunması, bitki taksonomisi, ürün yönetimi ve çevresel izleme gibi alanlarda önemli kritik temel görevlerdir. Geleneksel yaprak sınıflandırma yöntemleri genellikle manuel gözlem ve uzman bilgisine dayanır; bu da zaman alıcı, öznel ve insan hatasına açık olabilmektedir. Bilgisayarlı görme ve makine öğrenmesi tekniklerinin ortaya çıkmasıyla birlikte, yaprak sınıflandırması için otomatik sistemler geliştirmeye olan ilgi artmıştır.

Son yıllarda, derin öğrenme, özellikle Evrişimli Sinir Ağları (ESA), görüntü sınıflandırma görevleri için güçlü bir yaklaşım olarak ortaya çıkmıştır. ESA, nesne tanıma, tıbbi görüntüleme ve doğal dil işleme dahil olmak üzere çeşitli alanlarda dikkate değer bir başarı göstermiştir. Ham verilerden hiyerarşik öznitelikleri otomatik olarak öğrenme yeteneklerinden yararlanan ESA, otomatik yaprak sınıflandırması için umut verici bir çözüm sunmaktadır. Etiketli yaprak görüntülerinden oluşan büyük veri kümeleri üzerinde eğitim alarak, ESA görsel desenlere ve özniteliklere dayanarak farklı türler ve çeşitler arasında ayırım yapmayı öğrenebilirler.

Bu çalışma, ESA kullanılarak otomatik yaprak sınıflandırması için yeni bir çerçeve olan bir program sunmaktadır. Bu program, yaprak tanımlama için ölçeklenebilir, doğru ve verimli bir çözüm sunarak geleneksel yöntemlerin sınırlamalarının üstesinden gelmeyi amaçlamaktadır. Önerilen çerçeve, güçlü bir sınıflandırma performansı elde etmek için ön işleme, veri artırma, model mimarisi tasarımı, eğitim ve değerlendirme dahil olmak üzere çeşitli aşamaları entegre eder. Derin öğrenmenin gücünden yararlanan program, çeşitli uygulamalarda yaprakların sınıflandırılma ve analiz edilme biçiminde devrim yaratma potansiyeline sahiptir.

Bitki yapraklarının sınıflandırılmasının otomasyonu, insan uzmanlığının ve manuel tanımlamanın sınırlarını aşmayı amaçlayan yeni bir girişimdir. Bu girişim, en erişilebilir ve bol bulunan bitki organı olan yaprakların, her türe özgü temel morfolojik özelliklere sahip olduğu öncülüne dayanmaktadır. Bu özellikler, dijital görüntülerde yakalandığında gelişmiş algoritmalar kullanılarak sistematik olarak analiz edilebilir ve sınıflandırılabilir. Temel amaç, verilerden öğrenebilen, böylece yaprakları verimli ve doğru bir şekilde tanımlayıp sınıflandırabilen bir sistem tasarlamaktır.

Bu teknolojik çözüm, birkaç kritik adımı içerir: yüksek kaliteli yaprak görüntüleri yakalamak, bunlardan anlamlı özellikleri çıkarmak ve ardından yaprakları kendi türlerine

göre sınıflandırmak için makine öğrenimi algoritmaları uygulamak. Otomatik sınıflandırma sistemlerinin başarısı, her adımın, özellikle özellik seçimi ve makine öğrenimi modellerinin seçiminin doğruluğuna ve sağlamlığına büyük ölçüde bağlıdır.

Bitki yaprağı sınıflandırmasında özellik seçimi, tüm sistemin başarısını belirleyen çok önemli bir süreçtir. Araştırmacılar yaprak görüntülerinden geniş ölçüde şekil, renk, doku ve damarlanma özelliklerine göre kategorize edilen çeşitli özellikler çıkarıyorlar. En boy oranı, dairesellik ve yaprak kenar yapısı gibi şekil özellikleri yaprağın geometrik özellikleri hakkında bilgi sağlar. Renk özellikleri belirli türlerin karakteristik özelliği olabilecek pigmentasyon desenlerini yakalarken, doku özellikleri yaprağın yüzey yapısı ve desenleriyle ilgilidir. Venasyon özellikleri veya bir yaprağın damarlarının oluşturduğu desenler, farklı türler arasında oldukça farklı olduklarından özellikle faydalıdır (Chougui ve ark., 2022; Shanker ve ark., 2022).

Son zamanlarda odak noktası, bireysel özellikleri ve sınıflandırmaya en iyi katkıda bulunan özelliklerin ilişkilerini ve kombinasyonlarını dikkate alan daha karmaşık özellik seçim yöntemlerine doğru kaymıştır. Özellik alanının boyutluluğunu azaltmak için Temel Bileşen Analizi (PCA) ve Doğrusal Ayırıcı Analiz (LDA) gibi teknikler kullanılmış ve sınıflandırma için yalnızca en ilgili özellikler seçilmiştir.

Makine öğrenimi yöntemleri, araştırmacıların bitki yaprağı sınıflandırmasına yaklaşımında devrim yarattı. Yaygın olarak benimsenen algoritmalar arasında Destek Vektör Makineleri (DVM), k-En Yakın Komşular (k-NN), Rastgele Ormanlar (RF) ve Evrişimli Sinir Ağları gibi artık yaygın olan Derin Öğrenme modelleri de dahil olmak üzere çeşitli Sinir Ağları (NN) biçimleri yer alır (ESA). Bu yöntemler karmaşıklık, yorumlanabilirlik ve hesaplama gereksinimleri açısından farklılık gösterir ve seçim genellikle eğitim ve doğrulama için mevcut veri kümesinin boyutuna ve niteliğine bağlıdır (Dudi ve Kumar, 2022).

Derin öğrenme, verilerden hiyerarşik özellik temsillerini öğrenme yeteneği nedeniyle bu alanda büyük umut vaat ediyor. Bu genellikle el yapımı özelliklere dayanan geleneksel makine öğrenimi yöntemlerinin performansını aşar. ESA'ları, ham görüntü verilerini doğrudan işleyebildikleri ve önemli bir insan müdahalesi olmadan ilgili özellikleri otomatik olarak çıkarabildikleri için özellikle etkili olmuştur.

Bu ilerlemelere rağmen, otomatik bitki yaprağı sınıflandırması çeşitli zorluklarla karşı karşıyadır. Ana sorunlardan biri, yaprak özelliklerinde bulunan yüksek sınıf içi değişkenlik ve sınıflar arası benzerliktir ve bu da sınıflandırma sürecini karmaşıktırabilir. Örneğin, farklı türlerin yaprakları çok benzer görünebilir veya tam

tersine, aynı türün yaprakları çevresel koşullar, yaş ve diğer faktörlerdeki farklılıklar nedeniyle farklı görünebilir (Hemanthkumar ve Bharathi, 2022).

Ek olarak, yeterince çeşitli ve yüksek doğrulukla etiketlenmiş yaprak görüntülerden oluşan geniş veri kümeleri elde etmek önemsiz olmayan bir iştir. Bu veri kümeleri, makine öğrenimi modellerinin eğitimi ve test edilmesi için çok önemlidir ancak derlenmesi önemli ölçüde zaman ve çaba gerektirir.

Diğer pratik zorluklar arasında aydınlatma, yönlendirme, tıkanma ve arka plan karmaşasındaki farklılıklar nedeniyle yaprak görüntülerinin değişen kalitesiyle başa çıkmak yer alır. Bu değişkenlik sisteme gürültü sokarak özellik çıkarma ve sınıflandırma doğruluğunu azaltabilir. Dahası, büyük görüntü veri kümelerinin gelişmiş makine öğrenimi yöntemleriyle işlenmesinin hesaplama karmaşıklığı engelleyici olabilir ve önemli hesaplama kaynakları gerektirebilir.

Ayrıca, otomatik bir sınıflandırma sisteminin nihai testi, ideal görüntü yakalamanın her zaman mümkün olmadığı gerçek dünya koşullarındaki performansı olduğundan, görünmeyen verilere iyi bir şekilde genelleme yapabilen modellere ihtiyaç vardır. Veri kalitesindeki değişikliklere dayanıklı ve çeşitli çevresel ve teknolojik bağlamlarda kullanılacak modeller geliştirmek önemli bir engel olmaya devam ediyor.

Bu giriş bölümünde, yaprak sınıflandırmasının önemi ve geleneksel yöntemlerle ilişkili zorluklar hakkında genel bir bakış sunulmuştur. Ayrıca, derin öğrenme tekniklerinin, özellikle ESA, bu zorlukların üstesinden gelme ve otomatik yaprak sınıflandırmasını ilerletmedeki potansiyelini vurgular. Çalışmanın geri kalanı şu şekilde düzenlenmiştir: Bölüm 2, yaprak sınıflandırması ve derin öğrenme alanındaki önceki ilgili çalışmaları incelemektedir. Bölüm 3, Materyal ve yöntem bölümüdür. Bölüm 4, deneysel sonuçları ve performans değerlendirmesini sunmaktadır. Son olarak, Bölüm 5, sonuçları sunmaktadır.



## 2. ÖNCEKİ ÇALIŞMALAR

Yaprak sınıflandırması, botanik, tarım ve çevre bilimi de dahil olmak üzere çeşitli bilimsel alanlarda ilgi odağı olmuştur. Derin öğrenme tekniklerindeki, özellikle de Evrişimli Sinir Ağları'ndaki (ESA) son gelişmeler, otomatik yaprak sınıflandırması için güçlü araçlar sunarak bu alanda devrim yaratmıştır. Birçok çalışma, yaprak sınıflandırması ve derin öğrenmenin kesişimini inceleyerek her iki metodolojideki ilerlemelere katkıda bulunmuştur.

Barbedo (2016), görünür alan görüntüleri kullanılarak otomatik bitki hastalığı teşhisindeki zorlukların kapsamlı bir incelemesini sunarak, bu alandaki gelecekteki araştırmalar için yön belirlemeye yardımcı olmuştur.

Dyrmann ve ark. (2016), derin evrişimli sinir ağları (ESA) kullanarak bitki türü sınıflandırmasını araştırmış ve tarımsal uygulamalarda tür tanımlama için önemli bir umut vaat etmiştir. Elde ettikleri sonuçlar, ESA bitki türlerini tanımlamada uyarlanabilirliğini ve doğruluğunu kanıtlamıştır.

Mohanty ve ark. (2016), görüntü tabanlı bitki hastalığı tespiti için derin öğrenmeyi uygulayarak, ESA'larının büyük görüntü veri kümeleri kullanarak bitki hastalığı teşhisini yüksek doğrulukla otomatikleştirme potansiyelinin altını çizmiştir.

Sladojevic ve ark. (2016), yaprak görüntülerini sınıflandırarak bitki hastalıklarını tanımak için derin sinir ağı tabanlı bir yaklaşım sunmuştur. Bulguları, bitki hastalığı semptomlarını sağlıklı yapraklardan ayırt etmede sinir ağlarının sağlamlığının erken bir göstergesi olmuştur.

Amara ve ark. (2017), muz yaprağı hastalıklarını sınıflandırmak için derin öğrenme tekniklerini uygulamış ve tarımda karmaşık hastalık sınıflandırma görevlerinin üstesinden gelmede ESA'larının faydasını gösteren, alana özgü bir vaka çalışması sunmuştur.

Liu ve ark. (2017), elma yaprağı hastalıklarının tespitinde ESA'larının uygulamasını göstererek, farklı ürünlerde hastalık teşhisi için derin öğrenmenin etkinliğini daha da doğrulamıştır.

Ramcharan ve arkadaşları (2017), görüntü tabanlı yöntemler kullanarak manyok hastalığı tespiti için derin öğrenmeyi uygulamış ve bu kritik üründeki hastalıkları tespit etmek için bir çerçeve sunarak, gelişmekte olan bölgelerdeki gıda güvenliği açısından çıkarımlarda bulunmuştur.

Singh ve Misra (2017), bitki yaprağı hastalığı tespiti için görüntü segmentasyonu ve yumuşak hesaplama tekniklerini kullanarak, hastalık sınıflandırmasında doğruluğu

artırmak için makine öğrenimi ve geleneksel görüntü işleme yöntemlerini birleştiren hibrit bir yaklaşım sunmuştur.

Ferentinos (2018), bitki hastalıklarının tespiti ve teşhisi için kullanılan çeşitli derin öğrenme modellerinin bir değerlendirmesini sunarak, gerçek zamanlı tarımsal izleme sistemlerinde performans için kıstaslar oluşturmuştur.

Ghosal ve ark. (2018), bitki stres fenotiplemesi için açıklanabilir bir derin makine görüşü çerçevesi önererek, gelişmiş görüntüleme teknikleri aracılığıyla bitki stres tepkilerinin anlaşılmasına katkıda bulunmuştur. Çalışmaları, karmaşık biyolojik süreçlerin açıklanmasında yorumlanabilir yapay zekânın önemini vurgulayarak, gelişmiş bitki stres yönetimi stratejilerinin önünü açmıştır.

Nagasubramanian ve ark. (2019), bitki hastalıklarını tanımlamak için hiperspektral görüntülerde açıklanabilir 3B derin öğrenme kullanan yeni bir yöntem sunmuş ve daha iyi hastalık yönetimi için yapay zekâ modellerinde yorumlanabilirliğin önemini vurgulamıştır.

Patel ve Jain (2019), derin öğrenme tekniklerini kullanarak yaprak hastalığı tespitine odaklanan kapsamlı bir inceleme gerçekleştirmiştir. Kapsamlı analizleri, bitki hastalığı yönetiminin zorluklarının ele alınmasında derin öğrenmenin önemini vurgulayarak, tarımsal araştırmanın bu kritik alanındaki en son metodolojiler ve gelişmeler hakkında fikir vermiştir.

Picon ve ark. (2019), gerçek dünya ortamlarında ürün hastalıklarının sınıflandırılması için derin evrişimli sinir ağlarının kullanımına odaklanmıştır. Çalışmaları, mobil yakalama cihazlarının bitki hastalıklarını yerinde teşhis etmedeki etkinliğini vurgulayarak pratik tarımsal uygulamaların kapsamını genişletmiştir.

Too ve ark. (2019), bitki hastalıklarının teşhisi için derin öğrenme modellerini ince ayar yapmak üzere karşılaştırmalı bir çalışma yürütmüş ve transfer öğrenmesinin, sınırlı veri kümeleriyle ürün hastalığı tespiti için çalışırken model performansını nasıl artırabileceğini göstermiştir.

Smith ve Jones (2020), otomatik bitki yaprak segmentasyonu ve sınıflandırması için derin öğrenmeyi kullanan öncü bir çerçeve olan DeepLeaf'i önermiştir. Çalışmaları, bitki yapraklarını doğru bir şekilde segmentlere ayırmak ve sınıflandırmak için evrişimli sinir ağları (ESA) kullanarak verimli yaprak analizine olan kritik ihtiyacı ele almış ve otomatik bitki fenotiplemesinde daha fazla ilerleme için sağlam bir temel oluşturmuştur.

Kumar ve ark. (2021), derin öğrenmeye dayalı otomatik bitki hastalığı tespitini ele alan kapsamlı bir inceleme sunmuştur. Mevcut literatürü sentezleyerek, bitki

patolojisinde derin öğrenme tekniklerinin evrimini açıklamış ve teknolojik müdahaleler yoluyla bitki hastalıklarıyla mücadele eden arařtırmacılar ve uygulayıcılar için deęerli bilgiler sunmuřtur.

Wang ve Li (2021), derin öğrenme tekniklerini kullanarak yaprak hastalığı tespitinin derinlemesine bir incelemesini sunarak, alandaki son gelişmeleri pekiřtirmiřtir. Çalışmaları, çeřitli kaynaklardan gelen bilgileri sentezleyerek, bu kritik alanda gelecekteki arařtırmalar için en son metodolojiler ve potansiyel yollar hakkında kapsamlı bir genel bakış sundu.

Choudhury ve ark. (2022), kapsamlı bir incelemeyle bitki hastalıkları tespiti için derin öğrenme tekniklerinin anlaşılmasına katkıda bulunmuřtur. Analizleri, çeřitli derin öğrenme mimarilerini ve metodolojilerini kapsayarak, bu tekniklerin etkili bitki hastalıkları yönetimi için kullanılmasındaki zorluklara ve fırsatlara ışık tutmuřtur.

Zhang ve ark. (2023), derin öğrenmeye dayalı yaprak hastalığı tespiti ve sınıflandırmasına odaklanan bir inceleme gerekleřtirmiřtir. Son gelişmeleri ve metodolojileri analiz ederek, bitkilerde otomatik hastalık teşhisinin zorluklarının üstesinden gelmek için derin öğrenmenin uygulanmasına ilişkin deęerli bilgiler sunmuř ve tarım teknolojisindeki ilerlemelere katkıda bulunmuřtur.



### 3. MATERYAL VE METOT

Bu bölümde, araştırmada kullanılan materyaller ve yöntemler açıklanmıştır. 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, özniteliklerin ham verilerden çıkarılması ve sınıflandırıcı modelinin çıkarılan özniteliklere göre otomatik olarak kendini eğitmesidir. Makine öğrenimi ve görüntü işleme yöntemleriyle sınıflandırma, ham görüntüleri işlemek için çeşitli ön işlem ve öznitelik çıkarma tekniklerini gerektirir.

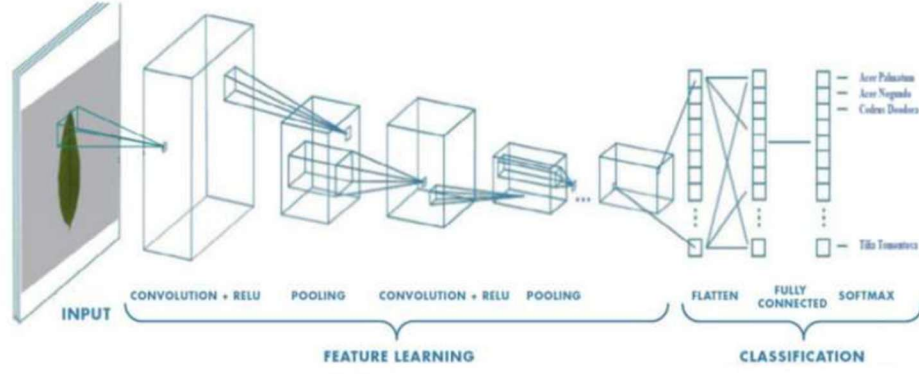
Bu çok zorlu ve deneyim gerektiren bir süreçtir. Bu nedenle, araştırmacılar manuel olarak öğrenmek yerine otomatik olarak öğrenme öznitelikleri üzerinde çalıştılar. Bu çalışmaların bir sonucu olarak, derin öğrenme popüler hale gelmiştir ve karmaşık matris operasyonlarına ve artan miktarda veriye izin veren paralel işleme GPU'larının geliştirilmesiyle birçok alanda yeteneklerini kanıtlamıştır (Zhang ve ark., 2018). Derin öğrenme sayesinde makineler, görüntülerden nesnelere tanıyabilir, ses ve metin gibi verileri diğer yöntemlerden çok daha düşük hata oranlarıyla sınıflandırabilir.

Derin öğrenme, yapay zeka çatısı altında makine öğreniminin önemli bir alt dalıdır. Sinir ağlarının gücünden yararlanarak, yüz tanıma gibi görevleri yerine getirmek için genişletilebilir ve dinamik öğrenme modelleri geliştirilebilir. Bu bölümde, evrimsel sinir ağları (ESA) tabanlı bir yaklaşım kullanarak yüz tanıma uygulamasının gerçekleştirilmesine odaklanılacaktır. ESA'ya geçmeden önce, derin öğrenme ve sinir ağlarının temel ilkelerini ve bunların bilgisayar görme teknolojisindeki uygulamalarını yeniden gözden geçirmek önemlidir. Genel olarak geleneksel öğrenmede, tahmin etmek veya elde etmek istediğimiz belirli bir sonuç parametresine katkıda bulunan bağımsız değişkenlerin (özniteliklerin) kombinasyonlarına odaklanılır (regresyon gibi yöntemler kullanarak). Bu, daha ilgili özniteliklerin kullanılması ideal olarak daha doğru bir model geliştirmeye yardımcı olur, ancak çıktı üretimi eğitim sırasında açıkça tanımlanmış özniteliklerle sınırlıdır. Öte yandan, derin öğrenmenin amacı, bizim için “gizli” gibi görünebilen, ancak sonuçları ara bir unsur olarak etkileyen, açıkça tanımlanmış öznitelikler arasındaki içsel korelasyonlardan ‘öğrenebilen’ bir model geliştirmektir. Bu, ilgili parametrelerin derin bir sinir ağını oluşturan daha fazla sayıda “düğüm” olacağı anlamına gelir. Bu düğümlerin düzenlemeleri, daha soyut ve karmaşık öznitelik temsillerine yol açan katmanlar oluşturur.

Konvolüsyon kavramı, bilgisayar görüşündeki uygulamalarıyla anlaşılabilir. Çekirdek konvolüsyonu, görüntüleri filtreler ve bulanıklıklar uygulamak için kullanılan bir tekniktir. Filtre, görüntü üzerinde elde etmek istediğimiz etkiye göre farklı sayı kombinasyonlarından oluşan küçük bir “ızgara”dır. Filtre, görüntünün üzerinden geçirilerek görüntüyü uygun şekilde dönüştürür. Daha iyi anlamak için  $3 \times 3$  ızgara çekirdeğini ele alalım. Bu çekirdek penceresi, görüntünün karşılık gelen  $3 \times 3$  bölgeleri boyunca kayar. Her durumda, karşılık gelen çekirdek ve görüntü piksel değerleri çarpılır. Bu, tanım gereği filtre değerleri ile giriş ızgarasının karşılık gelen değerleri arasında yapılan matematiksel bir işlem (genellikle çarpma) içeren konvolüsyon gösterir.

Bilgisayar görüşünde sinir ağlarının uygulanması açısından, yaygın bir varsayım, bir görüntünün her pikselinin sinir ağındaki bir giriş düğümüne atanabileceği yönündedir. Ancak, görüntüler genellikle milyonlarca pikselden oluştuğu için, bunu hesaplamak hesaplama açısından mümkün değildir. Bu, öznitelik temsilinin alternatif bir yolunun kullanılması gerektiği anlamına gelir. İşte burada konvolüsyon devreye girer. Konvolüsyonel sinir ağları, temel olarak her düğümü bir çekirdek konvolüsyon süreciyle değiştirmeyi içerir. Pratikte, bir görüntü ile başlar ve  $3 \times 3$  piksel gibi sabit bir pencere boyutu ile görüntü boyunca kaydırarak desenleri yakalar ve kenar/köşe desenleri ve diğer dokusal bilgileri içeren bir öznitelik haritası oluştururuz. Her yineleme, yeni bir öznitelik haritası oluşturan bir çekirdek konvolüsyon sürecini içerir ve bu şekilde konvolüsyonel sinir ağı, dokusal desenleri tanımlamada daha karmaşık ve doğru hale gelir. ESA'da üç tür katman vardır. İlk olarak, desenleri algılayan evrişimli katman. Ardından, evrişimli katmanlar tarafından algılanan desenleri basitleştiren havuzlama katmanı. Son olarak, bu basitleştirilmiş kalıpları anlamlı hale getiren ve öğrenilen temsili yorumlayan, dolayısıyla yüz tanıma çıktısını üreten tam bağlantılı katman.

Şekil 3.1'de ESA ağının temel akışında gösterildiği gibi, bu çalışmada ESA ile sıralı konvolüsyon ve havuzlama katmanları ile yaprak görüntülerinden öznitelikler çıkarılarak sınıflandırma ve yaprak tanıma yapılmıştır.



**Şekil 3.1.** Yaprak türlerinin sınıflandırması için ESA mimarisinin temel akışı

### 3.1. Veri Toplama


Bu çalışmada, Üniversite kampüsünden 15 farklı yaprak türünden veri seti toplanmıştır. Bu veri seti süs bitkisi yaprağı ağırlıklı olarak oluşturulmuştur. Yapraklar 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, POCO marka bir akıllı telefon kullanılmıştır. Bu cihaz; 5X hibrit optik zoom, 20X süper çözünürlüklü dijital zoom özneliklerine ve 64 megapiksel yüksek çözünürlüklü kameraya sahiptir. Bu öznelikler, 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 yaprak 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 3.7’de toplanan altı 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 yaprak 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. Yaprak 1 verisine ait resimler




Şekil 3.4. Yaprak 2 verisine ait resimler



Şekil 3.5. Yaprak 3 verisine ait resimler



Şekil 3.6. Yaprak 4 verisine ait resimler



Şekil 3.7. Yaprak veri seti

Şekil 3.7’de veri setinde yer alan yapraklardan birer adet gösterilmiştir. Toplam 15 farklı yaprak yer alan veri setinde şekil bakımından farklı yapraklar yer almaktadır. Karışıklık matrislerinde ilk yaprak 1 ve diğerleri sırasıyla Yaprak 1 ... Yaprak 15 olarak etiketlenmişlerdir.

### 3.2. Önceden eğitilmiş derin sinir ağlarının kullanımı

Doğal görüntülerden ayırt edici ve bilgilendirici öznitelikler 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. Tablo 3.1’de önceden eğitilmiş ağların kullanım amaçları açıklanmıştır (Ciaburro, 2024).

**Tablo 3.1** Önceden eğitilmiş sinir ağları aşağıdaki görevlerde (Mathworks, 2023) kullanılabilir.


Amaç	Açıklama
<i>Sınıflandırma</i>	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.
<i>Özellik Çıkartımı</i>	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 Feature Extraction (Öznitelik Çıkartımı) 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.
<i>Transfer Öğrenmesi</i>	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 Learning (Transfer Öğrenimi)” 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 3 farklı model bu şekilde oluşturulan yeni veri setinde kullanılmıştır.

Şekil 3.1’de yaprak türlerinin sınıflandırılmasında kullanılan önceden eğitilmiş modelin kullanıldığı yapı gösterilmiştir.

**Tablo 3.2.** MATLAB ortamında gerçekleştirilebilecek önceden eğitilmiş ağlar ve özellikleri

Model Adı/ Sinir Ağı Adı	Derinlik	Parametre Belleği	Parametreler (Milyon)	Görüntü Giriş Boyutu	Giriş Aralığı	Değer
squeezenet	18	4.7 MB	1,24	227x227	0,255	
googlenet	22	27 MB	7,0	224x224	0,255	
googlenet-places365	48	91 MB	23,9	299x299	0,255	
densenet201	201	77 MB	20,0	224x224	0,255	
mobilenetv2	53	14 MB	3,5	224x224	0,255	
resnet18	18	45 MB	11,7	224x224	0,255	
resnet50	50	98 MB	25,6	224x224	0,255	
resnet101	101	171 MB	44,6	224x224	0,255	
xception	71	88 MB	22,9	299x299	0,255	
inceptionresnetv2	164	213 MB	55,9	299x299	0,255	
shufflenet	50	5.5 MB	1,4	224x224	0,255	
nasnetmobile	*	20 MB	5,3	224x224	0,255	
nasnetlarge	*	340 MB	88,9	331x331	0,255	
darknet19	19	80 MB	20,8	256x256	0,255	
darknet53	53	159 MB	41,6	256x256	0,255	
efficientnetb0	82	20 MB	5,3	224x224	0,255	
alexnet	8	233 MB	61,0	227x227	0,255	
vgg16	16	528 MB	138	224x224	0,255	
vgg19	19	548 MB	144	224x224	0,255	

MATLAB ortamında gerçekleştirilebilecek önceden eğitilmiş ağlar Tablo 3.2. de verilmiştir. Bu tez kapsamında kullanılan önceden eğitilmiş modeller tabloda renklendirilmiştir



**Şekil 3.8.** Yaprak türlerinin sınıflandırması için ESA mimarisinin temel akışı

Son zamanlarda, derin öğrenmeye dayalı birkaç bitki yaprağı tanıma yöntemi önerilmiştir (Lee ve ark., 2015; Liu ve ark., 2015; Grinblat ve ark., 2016; Lee ve ark., 2017; Hu ve ark., 2018). Liu ve ark. (2015), öznelikleri çıkarmak için geleneksel bir ESA kullanır ve ardından yaprak görüntülerini sınıflandırmak için bir DVM kullanır.

Grinblat ve ark. (2016), önce damar ikili bölümlenmiş görüntüler oluşturmak için UHMT kullanarak damar desenini bölümlendirdi, ardından bir ESA eğitmek için orijinal giriş görüntülerini bu ikili bölümlenmiş görüntülerle değiştirdiler. Lee ve ark. (2015), bitki yaprak görüntülerini tanımak için DeepPlant ağını önerdi. Ayrıca, ESA modelinin seçilen özneliklerine ilişkin fikir edinmek için dekonvolüsyon ağını (Shellhamer ve ark. 2016) kullandılar. Lee ve ark. (2017), önceki çalışmalarına devam ederek, iki akışlı bir evrişimli sinir ağı (TwoCNN) önerdi. TwoCNN, sırasıyla görüntülerin tamamı ve bir parçası üzerinde eğitilen iki akışlı bir öznelik öğrenmesidir. TwoCNN, çeşitli ölçeklerde (hem görüntünün tamamı hem de parçaları) ayırt edici bilgi alabilmesine rağmen, eğitim süreci daha karmaşık bir örneklem kümesi gerektirir. Çünkü bu ağ için hem tüm görüntüleri hem de segmentlere ayrılmış görüntüleri sağlamanız gerekir. Hu ve ark. (2018), bitki yapraklarını birden çok ölçekte sınıflandırmak için MSF-CNN adı verilen bir evrişim sinir ağı ile çok ölçekli özneliklerin bir kombinasyonunu kullanmayı denediler. Bu şekilde, MSF-CNN tarafından eğitilen çok ölçekli öznelikler adım adım birleştirilir ve birden fazla öğrenme dalı gerektirmez. Ancak, derin öğrenme yöntemlerinin de bazı sınırlamaları vardır. Mevcut görüntü sayısı, GoogleNet ağı gibi son teknoloji tabanlı modeller için gereken görüntü sayısından azsa, ağı eğitmek konusunda zorlanacağız. Yukarıda belirtildiği gibi, Transfer Öğrenmesi bu durumda yararlı bir tekniktir. Göreviniz, ağın daha önce eğitildiği bir probleme benziyorsa, etiketli görüntülerin küçük bir kümesiyle probleminizde kullanmak üzere ağı değiştirmek için transfer öğrenmesini kullanabilirsiniz. Aslında, transfer öğrenme yönteminde, küçük veri kümeleri üzerinde hedef modelleri eğitmek için kaynak mimarisi olarak önceden eğitilmiş ağların kullanımıyla veri sınırlama sorunu çözülebilir (Zeiler ve Fergus, 2014). Neyse ki, AlexNet, GoogleNet, ResNet, Xception, VGG16, VGG19, ResNet50, InceptionV3, InceptionResNetV2 ve MobileNet gibi ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesi'nin (ILSVRC) kazanan modelleri, önceden eğitilmiş ağlar olarak kamuya açıktır. Bu ağlar transfer öğrenmesi için kullanılabilir. Bu makalede, bitki sınıflandırma görevi için transfer öğrenmeye dayalı bir yöntem olarak bu ağlardan birkaçı kullanılmıştır.

### **3.3. ResNet-50 ve Yapısı**

Otomatik görüntü analizi, hız yapan araçları tespit etmek veya tıbbi görüntüleri analiz etmek gibi uygulamalarda giderek daha yaygın hale gelmiştir. Bu yenilikleri destekleyen teknoloji, bilgisayar görüşü veya Görsel Yapay Zeka'dır. Bu, makinelerin

tıpkı insanlar gibi görüntüleri ve videoları yorumlayıp anlamasını sağlayan yapay zeka (AI) dalıdır.

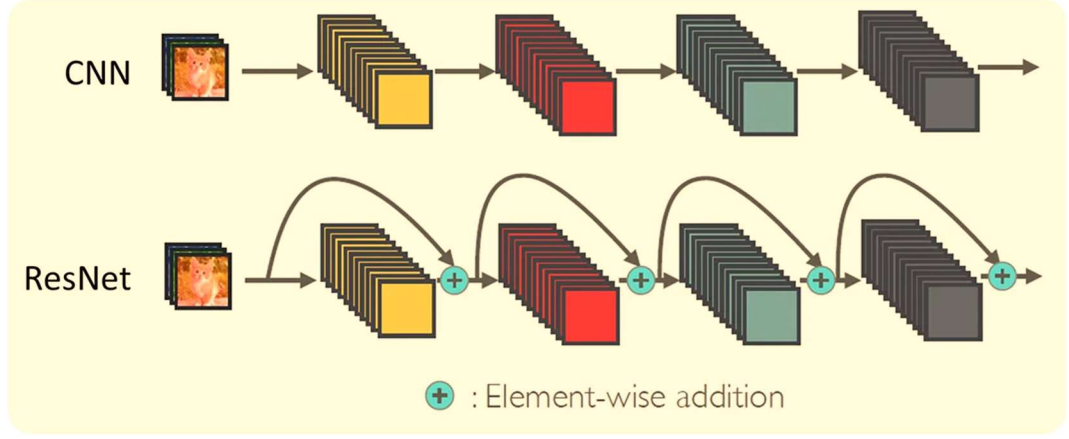
Bu tür bilgisayar görme çözümlerini oluşturmak için geliştiriciler, büyük miktarda görsel veriden öğrenebilen Görsel Yapay Zeka modellerine güvenmektedir. Yıllar boyunca araştırmacılar, görüntü sınıflandırma (görüntülere etiket atama), nesne algılama (görüntülerdeki nesnelere bulma ve tanımlama) ve örnek segmentasyonu (nesnelere algılama ve tam şekillerini belirleme) gibi Görsel Yapay Zeka görevlerinde etkileyici performans gösteren daha yeni ve daha gelişmiş modeller geliştirmiştir.

Ancak, geriye dönüp önceki modelleri anlamak, günümüzün bilgisayar görme sistemlerinin nasıl çalıştığını anlamaya yardımcı olabilir. Örneğin, önemli bir örnek, modelin daha hızlı ve daha doğru öğrenmesine yardımcı olan basit yollar olan kısayol bağlantıları fikrini ortaya atan etkili bir model olan ResNet-50'dir.

Bu yenilik, çok daha derin sinir ağlarının etkili bir şekilde eğitilmesini mümkün kılmış, görüntü sınıflandırmasında önemli gelişmelere yol açmış ve sonraki birçok modelin tasarımını şekillendirmiştir.

ResNet-50, ESA adı verilen bir tür sinir ağına dayanan bir bilgisayar görme modelidir. ESA, bilgisayarların kenarlar, renkler veya şekiller gibi görüntülerdeki kalıpları öğrenerek ve bu kalıpları nesnelere tanımak ve sınıflandırmak için kullanarak görsel bilgileri anlamalarına yardımcı olmak için tasarlanmıştır.

2015 yılında Microsoft Research araştırmacıları tarafından tanıtılan ResNet-50, büyük ölçekli görüntü tanıma görevlerinde gösterdiği doğruluk ve verimlilik sayesinde kısa sürede bu alandaki en etkili modellerden biri haline gelmiştir. ResNet-50'nin temel özelliklerinden biri, kısayol bağlantıları olarak da bilinen kalıntı bağlantılarının kullanılmasıdır. Bunlar, modelin öğrenme sürecindeki bazı adımları atlamasına olanak tanıyan basit yollardır. Diğer bir deyişle, modeli her bir katmandan bilgi geçmeye zorlamak yerine, bu kısayollar önemli ayrıntıları daha doğrudan iletmesine olanak tanır. Bu da öğrenmeyi daha hızlı ve daha güvenilir hale getirir.



**Şekil 3.9.** ResNet mimarisindeki artık bağlantılara bir bakış

Şekil 3.9’da verilen tasarım, derin öğrenmede yaygın olarak görülen bir sorun olan kaybolan gradyan sorununu çözmeye yardımcı olur. Çok derin modellerde, önemli bilgiler birçok katmandan geçerken kaybolabilir ve bu da modelin öğrenmesini zorlaştırır. Kalan bağlantılar, bilginin baştan sona net bir şekilde akmasını sağlayarak bunu önlemeye yardımcı olur. Bu nedenle modele ResNet-50 adı verilmiştir: ResNet, Kalan Ağ anlamına gelir ve “50” ise bir görüntüyü işlemek için kullandığı katman sayısını ifade eder.

ResNet-50, modelin önemli bilgileri kaybetmeden derinlemesine çalışmasını sağlayan iyi organize edilmiş bir yapıya sahiptir. Verimliliği korurken aynı zamanda güçlü performans sağlayan basit ve tekrarlanabilir bir model izler. ResNet-50 mimarisinin çalışması beş ana başlıkta açıklanabilir ve Şekil 3.10’da gösterilmiştir.

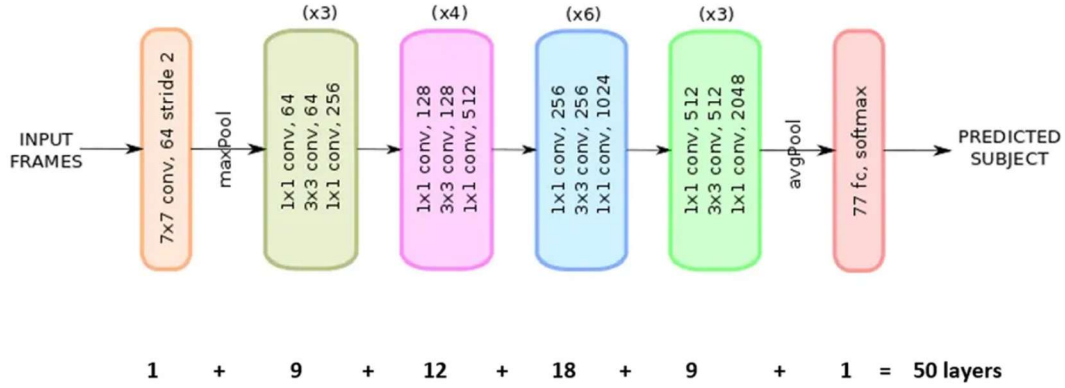
**Temel özellik çıkarma:** Model, konvolüsyon adı verilen bir matematiksel işlem uygulayarak başlar. Bu işlem, görüntü üzerinde küçük filtreler (çekirdekler olarak adlandırılır) kaydırarak özellik haritaları oluşturmayı içerir. Bu haritalar, kenarlar veya dokular gibi temel desenleri vurgulayan görüntünün yeni versiyonlarıdır. Model, bu şekilde yararlı görsel bilgileri almaya başlar.

**Karmaşık özellikleri öğrenme:** Veriler ağda ilerledikçe, özellik haritalarının boyutu küçülür. Bu, havuzlama veya daha büyük adımlara sahip filtreler (adımlar olarak adlandırılır) kullanma gibi tekniklerle yapılır. Aynı zamanda, ağ daha fazla özellik haritası oluşturarak şekiller, nesnelerin parçaları veya dokular gibi giderek daha karmaşık desenleri yakalamasına yardımcı olur.

**Verileri sıkıştırma ve genişletme:** Her aşama verileri sıkıştırır, işler ve ardından tekrar genişletir. Bu, modelin bellek tasarrufu yaparken öğrenmesine yardımcı olur.

Kısayol bağlantıları: Bunlar, bilginin her katmanı geçmek yerine atlamasına izin veren basit yollardır. Öğrenmeyi daha istikrarlı ve verimli hale getirirler.

Tahmin yapma: Ağın sonunda, öğrenilen tüm bilgiler birleştirilir ve bir softmax fonksiyonundan geçirilir. Bu, olası sınıflar üzerinde bir olasılık dağılımı çıkarır ve modelin her bir tahminine olan güvenini gösterir. Örneğin, %90 kedi, %9 köpek, %1 araba gibi sonuç verir.



Şekil 3.10. ResNet-50 yapısı

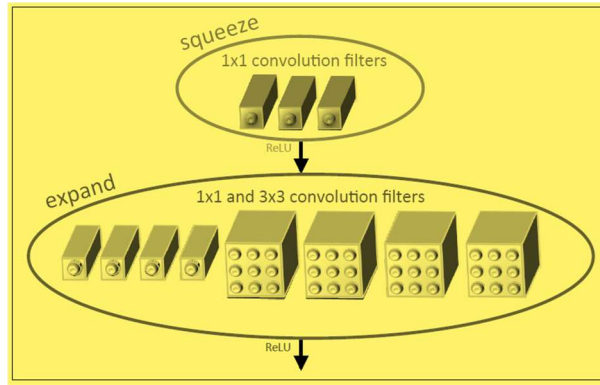
ResNet-50, başlangıçta görüntü sınıflandırması için tasarlanmış olsa da, esnek tasarımı sayesinde bilgisayar görme alanının birçok alanında kullanışlı hale gelmiştir. ResNet-50'yi öne çıkaran en önemli özelliği görüntü sınıflandırmadır. Görüntü sınıflandırması için ResNet-50 kullanımı, ResNet-50, öncelikle bir görüntüye tek bir etiket atamak amacıyla görüntü sınıflandırması için kullanılır. Örneğin, bir fotoğraf verildiğinde, model gördüğü ana nesneye göre onu köpek, kedi veya uçak olarak etiketleyebilir. Güvenilir tasarımı ve PyTorch ve TensorFlow gibi yaygın olarak kullanılan derin öğrenme kütüphanelerinde bulunması, ResNet-50'yi büyük görüntü veri kümelerinde eğitim için popüler bir ilk tercih haline getirmiştir. En iyi bilinen örneklerden biri, bilgisayar görme modellerini değerlendirmek ve karşılaştırmak için kullanılan etiketli görüntülerin büyük bir koleksiyonu olan ImageNet'tir. YOLO11 gibi daha yeni modeller onu geride bıraksa da, ResNet-50 doğruluk, hız ve basitlik arasındaki sağlam dengesi sayesinde hala yaygın olarak bir referans noktası olarak kullanılmaktadır.

### 3.4. SqueezeNet ve Yapısı

SqueezeNet, diğer ESA'larına göre daha az parametreye sahip küçük bir ESA mimarisidir. Yine de AlexNet gibi mimarilerle aynı sonuçları (doğruluğu) elde

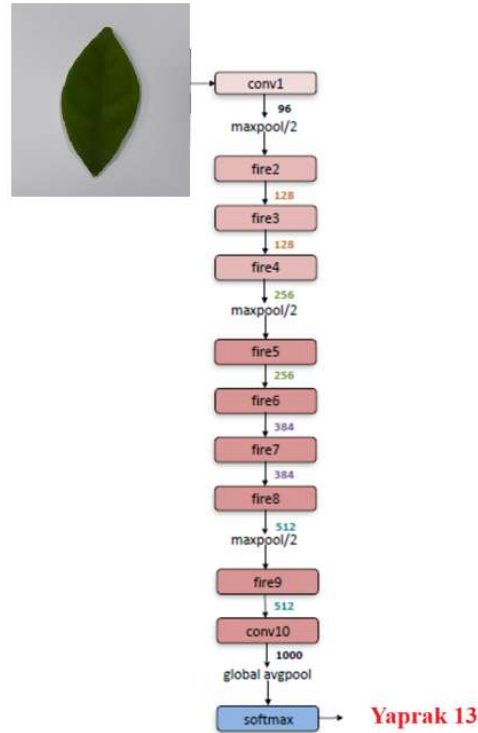
eder.SqueezeNet'in bu küçük mimarisi çeşitli avantajlar sunar (Iandola ve ark. ): dağıtılmış eğitim sırasında sunucular arasında daha az iletişim, örneğin buluttan arabaya aktarmak için daha az bantwith'e ihtiyaç duyan hafif model, sınırlı belleğe sahip donanımlarda dağıtım yapılabilir.

SqueezeNet, yangın modülleri adı verilen birkaç yapı taşına sahiptir. Bu yangın modülü, yalnızca 1x1 filtrelere sahip bir sıkıştırma evrişim katmanı içerir ve bu katman, 1x1 ve 3x3 evrişim filtrelerinin bir karışımına sahip bir genişletme katmanına beslenir (Şekil 3.11).



Şekil 3.11. SqueezeNet katmanları

SqueezeNet yapısı ve ayrıntılı katmanları Şekil 3.12'de verilmiştir.



Şekil 3.12. SqueezeNet yapısı

### 3.5. Karışıklık Matrisleri

Karışıklık matrisi, bir sınıflandırma algoritmasının başarımını sınıf bazında detaylı bir şekilde değerlendirmeye olanak tanımaktadır (Bishop, 2006; Bonaccorso, 2017; Kim, 2017; Al-Malah, 2023). Genellikle  $N \times N$  boyutunda kare bir yapıdan oluşmakta olup, burada  $N$ , sınıflandırma problemindeki toplam sınıf sayısını ifade etmektedir. Matrisin her bir satırı, modelin tahmin ettiği sınıfları; her bir sütunu ise gerçek sınıfları temsil etmektedir. Bu yapı sayesinde modelin hangi sınıflarda başarılı tahminler gerçekleştirdiği ve hangi sınıflarda hata yapma eğiliminde olduğu ayrıntılı olarak ortaya konulmaktadır.

Karışıklık matrisi yalnızca genel başarı oranını değil; doğruluk (accuracy), hassasiyet (precision), geri çağırma (recall), özgüllük (specificity) ve F1 skoru gibi çeşitli performans metriklerinin de elde edilmesine imkân tanımaktadır (Al-Malah, 2023). Bu metrikler, modelin hangi tür hatalara daha yatkın olduğunu belirlemede ve performans artırımı için uygun stratejilerin geliştirilmesinde kritik rol oynamaktadır.

Karışıklık matrisleri, özellikle etiketli veri kümeleri üzerinde çalışan denetimli öğrenme (supervised learning) yöntemlerinde kullanılmaktadır. Çünkü bu algoritalarda model çıktılarının doğruluğu, önceden bilinen gerçek etiketlerle doğrudan karşılaştırılabilmektedir.

Sınıflandırma problemleri ikili (binary) veya çok sınıflı (multiclass) yapıda olabilmektedir. Örneğin, bir tıbbi tanı sistemi bir bireyi “hastalık mevcut” ya da “hastalık yok” şeklinde sınıflandırdığında, sonuçlar pozitif ve negatif olarak değerlendirilmektedir. Bu tür durumlarda karışıklık matrisinde yer alan gerçek pozitif (GP), gerçek negatif (GN), yanlış pozitif (YP) ve yanlış negatif (YN) değerleri, modelin tanı yeteneğini ortaya koymaktadır (Tablo 3.3).


Sonuç olarak, karışıklık matrisi, sınıflandırma algoritmalarının hem doğruluk düzeylerini nicel olarak değerlendirmekte hem de hangi sınıflar arasında karışıklık yaşandığını nitel olarak göstermektedir. Bu tez kapsamında geliştirilen modellerin başarımları analizleri de karışıklık matrisinden elde edilen metrikler aracılığıyla gerçekleştirilmekte; böylece sınıf içi ve sınıflar arası ayırım gücü bilimsel olarak ortaya konulmaktadır (Gupta ve Nandyala, 2023; Ciaburro, 2024).

**Tablo 3.3.** Karışıklık matrisi

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

#### 4. BULGULAR VE TARTIŞMA

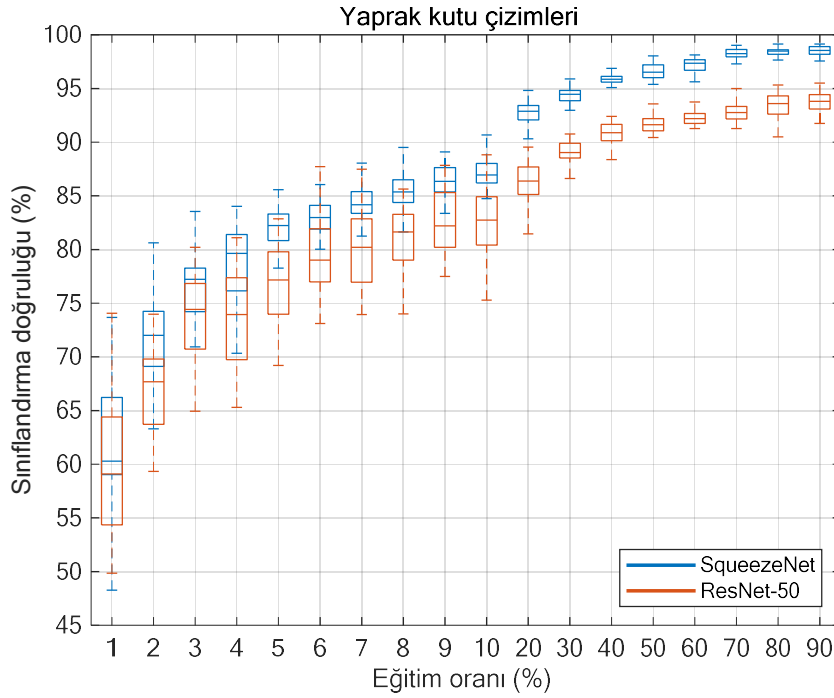
Bu bölümde yaprak verileri kullanılarak önceden eğitilmiş ağlarla elde edilen görüntülerin sınıflandırıldığı çalışmanın sonuçları grafiklerle sunulmuştur. Önceden eğitilmiş ağ olarak ResNet50 ve SqueezeNet ağları kullanılmıştır. Otuz deneme sonuçları verilmiştir. Eğitim oranı %1'den %90'a kadar değiştirilerek ve her değişimde 50 farklı deneme yapılarak elde edilen başarıım grafiği Şekil 4.1'de verilmiştir. Her denemede yanlılığı önlemek amacıyla rasgele örnekler seçilmiş, otuz denemenin ortalama başarıım grafikte verilmiştir. Eğitim oranı %40 civarında iken üç modelin sınıflandırma başarıım doğruluğu %90'ın üzerine çıkmıştır. Aynı başarıım oranına SqueezeNet %15 eğitim oranından sonra ulaşmıştır. Tatmin edici bir başarıım tercih edilecek olursa iki modelin başarıım oranları %40 eğitim oranından sonra %90'ın üzerinde sınıflandırma doğruluğuna ulaşmaktadırlar ve daha sonra fazla bir değişim ile karşılaşılmamaktadır. Makine öğreniminde %50 eğitim oranının kabul sınırı kabul edildiği göz önünde bulundurulduğunda %40 yeterli olmaktadır.



Şekil 4.1. İki model için Sınıflandırma doğruluğu-Eğitim oranı grafiği

Şekil 4.2'de iki 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 başarıım oranı bir kutuyu temsil etmektedir. Kutunun ortası başarıım 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.** İki model için Sınıflandırma doğruluğu-Eğitim oranı kutu çizimleri

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 hakkındada bilgilere ulaşılır. Mavi renk her sınıfın ne kadar doğru sınıflandırıldığını diğer renk ise diğer sınıflara ne kadar karıştırıldığını göstermektedir. Karıştırılma 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 4.3-4.8 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 %80 için karışıklık matrisleri Şekil 4.3-Şekil 4.8' te verilmiştir. Şekil 4.3-Şekil 4.4 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 1 verilerinde yapılmıştır. En çok karıştırma ise 11 verisi 394 ile 14 verisine karıştırılmıştır. Daha sonraki en büyük hata ise yine 1 verisi 348 ile 13 verisine karıştırılmıştır. İki model sınıflandırıcıdan en iyi durumda olan SqueezeNet model olmasına rağmen bu eğitim oranında bunda da hata oranı yüksek çıkmıştır. SqueezeNet model %1 eğitim oranında %63 civarı sınıflandırma başarımına sahiptir. Şekil 4.4'da verilen ResNet-50 model sınıflandırıcı karışıklık matrisi bu eğitim oranının en kötü modeli durumdadır ve bu matrisin renk sıkalasından bellidir. Eğitim oranı %10 ve %80 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 4.5'te eğitim oranı %10 için sınıflandırma karışıklık matrisi görülmektedir. Matrise bakıldığında mavi kutuların değerleri yükselmiş, beyaz kutuların sayısı (hatasız sınıflandırma) artmış, diğer renkteki kutuların değerleride azalmıştır. Bu bize başarımın arttığı hakkında bilgi vermektedir. Eğitim oranı arttıkça sınıflandırma başarım oranı artmaktadır sonucu çıkarılır.

Yaprak1	198		75	14	348	296	25	3		3	8		9	10	
Yaprak10	2	464	4	140	1	54	16		91	55	28	5	3	109	18
Yaprak11	64		194	68	185	394	18	13	3	8	6		34	4	
Yaprak12	13	182	36	459	33	55	11		17	95	16	3		69	
Yaprak13					990										
Yaprak14			34			956									
Yaprak15	31		29	7	89	38	585	40			3	24	134	10	
Yaprak2	37		31	40	171	100	97	329	11	7	47	1	73	45	
Yaprak3		21		12				3	836	24	14	3		77	
Yaprak4	7	7	4	44		9	6		110	724	8	1	50	19	
Yaprak5				12				1			457		280	15	224
Yaprak6	1	5	7	41	104	9	28	1	62	41	40	403	174	74	
Yaprak7											75		915		
Yaprak8		11		45	1	21	10		12	67	55	16		736	14
Yaprak9		4									29				957

Öngörülen Sınıf

Şekil 4.3. SqueezeNet model için %1 eğitim oranında sınıflandırma karışıklık matrisi

Yaprak1	474	20	198	15	4	70	41	25		6	36	40	20	24	17
Yaprak10	34	367	30	203	16	81	15	5	62	5	20	20	22	45	66
Yaprak11	77	115	589	66		69	11		8	6	9	18	10	4	7
Yaprak12	62	120	31	389	33	126	69	17	11	21	3	55	14	14	26
Yaprak13	31			9	724	108			103			5		9	
Yaprak14	1	77	5	56	59	624	115		1			8	6	5	33
Yaprak15	4					15	905	40			23	2			
Yaprak2	95		31	13	12	89	284	317		5	49	38	21	36	
Yaprak3	9	14		81	103	55	158	25	317	18	34	60	9	4	104
Yaprak4	30	13	11	23	60	31	93	10	68	230	38	92	153	21	116
Yaprak5											852				137
Yaprak6	67	10	28	59	42	35	19	45	22	115	74	291	154	5	24
Yaprak7													990		
Yaprak8	12	1		4	1	35		1			2	4	16	763	150
Yaprak9											1				989

Öngörülen Sınıf

Şekil 4.4. ResNet-50 model için %1 eğitim oranında sınıflandırma karışıklık matrisi

Yaprak1	588		29	22	179	61	18	3											
Yaprak10		828		38					15	16		1							
Yaprak11	2		408		74	383	2	2							29				
Yaprak12		37	8	820					1	32		1			1				
Yaprak13					900														
Yaprak14						900													
Yaprak15							879								21				
Yaprak2	43		32		119	1	26	658		2	13			5					
Yaprak3		1							888	5								7	
Yaprak4			2	1					48	847									
Yaprak5											605			190					105
Yaprak6					20				3			802	75						
Yaprak7											38		862						
Yaprak8										29						871			
Yaprak9																			900
	Yaprak1	Yaprak10	Yaprak11	Yaprak12	Yaprak13	Yaprak14	Yaprak15	Yaprak2	Yaprak3	Yaprak4	Yaprak5	Yaprak6	Yaprak7	Yaprak8	Yaprak9				

Şekil 4.5. SqueezeNet model için %10 eğitim oranında sınıflandırma karışıklık matrisi

Yaprak1	717	2	59	13	5	50	37					2	9	5	1				
Yaprak10	4	659		79		13	16	2	45			19	7	4	47	4			
Yaprak11	12	11	824	19		15	15					1		2					
Yaprak12	16	132		575	18	31	52	4	21	6		29	5	8	2				
Yaprak13					834	31				35									
Yaprak14					19	765	109												8
Yaprak15						1	899												
Yaprak2	2					8	268	602				15		1	5				
Yaprak3	3	14		2	23	45	135	43	463	74		54	4	2	37				
Yaprak4		18			14	11	70	1	54	521	15	27	88	68	12				
Yaprak5											900								
Yaprak6	5	10	3	8	6		6	19		84	7	675	75	2					
Yaprak7														900					
Yaprak8															895	5			
Yaprak9																			900
	Yaprak1	Yaprak10	Yaprak11	Yaprak12	Yaprak13	Yaprak14	Yaprak15	Yaprak2	Yaprak3	Yaprak4	Yaprak5	Yaprak6	Yaprak7	Yaprak8	Yaprak9				

Şekil 4.6. ResNet-50 model için %10 eğitim oranında sınıflandırma karışıklık matrisi

Yaprak1	188		1	2	10														
Yaprak10		200																	
Yaprak11			187	1		11													
Yaprak12		1		199															
Yaprak13					200														
Yaprak14						200													
Yaprak15							200												
Yaprak2	6		1		9			184											
Yaprak3									200										
Yaprak4										200									
Yaprak5											198			2					
Yaprak6												200							
Yaprak7													1		199				
Yaprak8														3				197	
Yaprak9																			200
	Yaprak1	Yaprak10	Yaprak11	Yaprak12	Yaprak13	Yaprak14	Yaprak15	Yaprak2	Yaprak3	Yaprak4	Yaprak5	Yaprak6	Yaprak7	Yaprak8	Yaprak9				

Öngörülen Sınıf

Şekil 4.7. SqueezeNet model için %80 eğitim oranında sınıflandırma karışıklık matrisi

Yaprak1	190		2			3	4												
Yaprak10		183		16		1													
Yaprak11	4		194				1												
Yaprak12	3	19		166	3	4			1			2			1				
Yaprak13					200														
Yaprak14						200													
Yaprak15							200												
Yaprak2							51	149											
Yaprak3						4	11	6	139	14		22						3	
Yaprak4						2	2		6	187		2			1				
Yaprak5											200								
Yaprak6								3		1		196							
Yaprak7													200						
Yaprak8														200					
Yaprak9																			200
	Yaprak1	Yaprak10	Yaprak11	Yaprak12	Yaprak13	Yaprak14	Yaprak15	Yaprak2	Yaprak3	Yaprak4	Yaprak5	Yaprak6	Yaprak7	Yaprak8	Yaprak9				

Öngörülen Sınıf

Şekil 4.8. ResNet-50 model için %80 eğitim oranında sınıflandırma karışıklık matrisi

## 5. SONUÇ VE ÖNERİLER

Yaprak sınıflandırma, biyoloji ve kimya alanlarında önemli bir görev olarak karşımıza çıkmakta ve bilimsel gelişmelere önemli katkı sağlamaktadır. Bu alana yönelik kapsamlı araştırmalar, konunun kritik önemini yansıtmaktadır. Bu çalışmada amacımız, 15 farklı bitki yaprağı türünü doğru bir şekilde tanıyıp sınıflandırabilen bir derin öğrenme programı geliştirmektir. Bunu yaparken herkesin başka uygulamalara kolayca uygulayabileceği bir yöntemi kullanmaktır. Bu amaçla önceden eğitilmiş sinir ağları kullanılmıştır. İki farklı ağ veri seti ile eğitilmiş ağın çıkardığı öznitelikler sınıflandırmada kullanılmıştır. Matlab ortamında gerçekleştirilen bu işlemde bu ortamın örneklerinden faydalanılmıştır. Veri seti az sıklıkta veri seti gibi görülmeye yeterli sınıflandırma başarımını göstermiştir.

Performans değerlendirmesi, dikkate değer tanıma oranları ortaya koymuştur. Eğitim seti artırıldıkça başarımlarında ciddi artışlar gözlemlenmiştir. Görüntü ön işleme teknikleri kullanılmamış, sinir ağının hem performansını hem de doğruluğunu artırmada ve eğitim süresini önemli ölçüde azaltmada etkili olacağını düşündüğümüz bu teknikleri ileri çalışmalarda kullanacağımızı belirtiriz.

Bulgularımız, ESA görüntü sınıflandırma alanındaki üstünlüğünü vurgulayarak, teknoloji için dönüştürücü bir potansiyele işaret etmektedir. Sinir ağlarının gücünden yararlanarak, yaprak sınıflandırmasında ve ötesinde önemli ilerlemeler kaydederek teknolojik inovasyonun yeni zirvelere taşınacağını öngörmekteyiz. Biyoloji, kimya alanlarında ciddi ilerlemelerle sağlık alanındanda önemli gelişmelere yol açacaktır.

İleri çalışmalarda veri setinin büyütülmesi ve testleri gerçekçi ortamlarda ele alınması planlanmaktadır. Zor koşul testleri, ışık, gürültü gibi şartlarda geliştirilen uygulamanın ne kadar başarılı olacağı hakkında veriler içerecektir. Veri setinin ve bu testlerin başarıya ulaşması durumunda uygulama ve veri setleri akademik ortamlarda diğer akademisyenlerle paylaşılacaktır.



## KAYNAKLAR

- Al-Malah, K.I.M. (2023). Machine and Deep Learning Using MATLAB: Algorithms and Tools for Scientists and Engineers, John Wiley & Sons, Inc.
- Abade, A., Ferreira, P. A., & Barata, C. (2021). Plant leaf identification using deep learning models. *Computers in Biology and Medicine*, 133, 104403.
- Amara, J., Bouaziz, B., & Algergawy, A. (2017). A deep learningbased Approach for Banana leaf Diseases classification. In BTW (79-88).
- Barbedo, J. G. A. (2016). A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems Engineering*, 144, 52-60.
- Bishop, C.M. (2006). Pattern Recognition and Machine Learning, Springer.
- Bonaccorso, G. (2017). Machine Learning Algorithms, Reference guide for popular algorithms for data science and machine learning. Packt Publishing.
- Choudhury, S., Samanta, S., & Sil, J. (2022). A comprehensive review on deep learning techniques for plant disease detection. *Journal of Ambient Intelligence and Humanized Computing*, 1-18.
- Chougui, A., Moussaoui, A., Moussaoui, A. (2022). CNN, CBAM ve Görme Trafosu kullanılarak Bitki Yaprağı Hastalıkları Sınıflandırması. 5. Uluslararası Bilişim ve Uygulamaları Sempozyumu (ISIA) Bildirilerinde, M'sila, Cezayir, 29–30 Kasım , 1–6.
- Ciaburro, G. (2024). MATLAB for Machine Learning, 2nd Edition, Packt Publishing.
- Dudi, VR. & Kumar, GP. (2022). Çift Yönlü Uzun Kısa Süreli Bellek ile Derin Özellik Füzyonu Yoluyla Bitki Yaprağı Sınıflandırması. Sürdürülebilir Kalkınma için Bilim ve Teknolojide Yenilikler Uluslararası Konferansı (ICISTSD) Bildirilerinde, Kollam, Hindistan, 25–26 Ağustos, 68–73.
- Dyrmann, M., Karstoft, H., & Midtiby, H. S. (2016). Plant species classification using deep convolutional neural networks. *Biosystems Engineering*, 151, 72-80.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318.
- Ghosal, S., Blystone, D., Singh, A. K., Ganapathysubramanian, B., Singh, A., & Sarkar, S. (2018). An explainable deep machine vision framework for plant stress phenotyping. *Proceedings of the NationalAcademy of Sciences*, 115(18), 4613-4618.
- Gonzalez, R.C., Woods, R.E. & Eddins, S.L. (2020). Digital Image Processing Using MATLAB, 3rd Edition, Gatesmark Publishing.

- Gupta, A.K. & Nandyala, S.P. (2023). Deep Learning on Microcontrollers: Learn how to develop embedded AI applications using TinyML, BPB Publications.
- He, K., Zhang, X., Ren, S. & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 770-778, doi: 10.1109/CVPR.2016.90.
- Hemanthkumar, KA. & Bharathi, PS. (2022). K-En Yakın Komşular Üzerinden Rastgele Orman Sınıflandırıcısı Kullanılarak Bitki Yaprağı Sınıflandırmasının Geliştirilmiş Doğruluğu. Yenilikçi Bilgi İşlem, Akıllı İletişim ve Akıllı Elektrik Sistemleri (ICES) Uluslararası Konferansı Bildirilerinde, Chennai, Hindistan, 15–16.
- Hu, J., Chen, Z., Yang, M., Zhang, R. & Cui, Y. (2018). A Multiscale Fusion Convolutional Neural Network for Plant Leaf Recognition, *IEEE Signal Processing Letters*, 25(6), 853-857.
- Iandola, F.N., Han, S. Moskewicz, M.W., Ashraf, K., Dally, W.J., Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *3th International Conference on Learning Representations*. Toulon: ICLR, 1-13.
- Kim, P. (2017). MATLAB Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence, Apress.
- Kumar, A., Jatav, N. K., & Singh, R. (2021). Deep learning-based automatic plant disease detection: A review. *Archives of Computational Methods in Engineering*, 1-21.
- Lee, S. H., Chan, C. S., Wilkin, P. & Remagnino, P. (2015). Deep-plant: Plant identification with convolutional neural networks, Image Processing (ICIP), *IEEE International Conference*, 452-456.
- Lee, S. H., Chan, C. S., Mayo, S. J. & Remagnino, P. (2017). How deep learning extracts and learns leaf features for plant classification, *Pattern Recognition*, (71), 1-13.
- Liu, Z., Zhu, L., Zhang, X., Shang, L., Huang, Z. & Gan, Y. (2015). Hybrid Deep Learning for Plant Leaves Classification, *International Conference on Intelligent Computing*, 115-123.
- Grinblat, G. L., Uzal, L. C., Larese, M. G. and Granitto, P. M. (2016). Deep learning for plant identification using vein morphological patterns, *Computers and Electronics in Agriculture*, (127), 418-424.
- Liu, B., Zhang, Y., He, D., & Li, Y. (2017). Identification of apple leaf diseases based on deep convolutional neural networks. *Symmetry*, 9(8), 10.

- Mathworks. (2023). Pretrained Deep Neural Networks. Retrieved from <https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419.
- Nagasubramanian, K., Jones, S., Sarkar, S., Singh, A. K., Singh, A., & Ganapathysubramanian, B. (2019). Plant disease identification using explainable 3D deep learning on hyperspectral images. *Plant Methods*, 15, 98.
- Paluszek, M. (2024). MATLAB Machine Learning Recipes: A Problem-Solution Approach, 3rd Edition, Apress.
- Patel, R., & Jain, D. (2019). Leaf disease detection using deep learning techniques: A review. In 2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT) (1-6). IEEE.
- Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., & Johannes, A. (2019). Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild. *Computers and Electronics in Agriculture*, 161, 280-290.
- Ramcharan, A., Baranowski, K., McCloskey, P., Ahmed, B., Legg, J., & Hughes, D. P. (2017). Deep learning for image-based cassava disease detection. *Frontiers in Plant Science*, 8, 1852.
- Shanker, R., Sharma, D., Bhattacharya, M. (2022). Evrişimli Sinir Ağı Kullanılarak Bitki Yaprağı Hastalığı Sınıflandırma Modelinin Geliştirilmesi. IEEE 4. Uluslararası Siberetik, Biliş ve Makine Öğrenimi Uygulamaları Konferansı (ICCCMLA) Bildirilerinde, Goa, Hindistan, 434–438.
- Shelhamer, E., Long, J. & Darrell, T. (2016). Fully convolutional networks for semantic segmentation, arXiv preprint arXiv:1605.06211.
- Singh, V., & Misra, A. K. (2017). Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information Processing in Agriculture*, 4(1), 41-49.
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 1-11.

- Smith, A. B., & Jones, C. D. (2020). DeepLeaf: A deep learning-based framework for automated plant leaf segmentation and classification. *Computers and Electronics in Agriculture*, 176, 105684.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S. & Anguelov, D. (2015). Going deeper with convolutions. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 1-9, doi: 10.1109/CVPR.2015.7298594.
- Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272-279.
- Wang, Y., & Li, W. (2021). A comprehensive review on leaf disease detection using deep learning techniques. *Computers and Electronics in Agriculture*, 192, 105627.
- Yavuzer, E. & Köse, M. (2022). Prediction of fish quality level with machine learning. *International Journal of Food Science & Technology*, 57(8), 5250-5255.
- Yavuzer, E. (2020). Determination of rainbow trout quality parameters with Arduino microcontroller. *Journal of Food Safety*, 40(6), e12857.
- Zeiler M. D. & Fergus, R. (2014). Visualizing and understanding convolutional networks, in European conference on computer vision, 818-833.
- Zhang, Y., Li, X., & Hu, X. (2023). Deep learning-based leaf disease detection and classification: A review. In 2023 4th International Conference on Automation, Control and Robotics Engineering (CACRE) (1-6). IEEE.

## EKLER

### Ek-1 Kongre Katılım Belgesi





## ÖZGEÇMİŞ

<b>KİŞİSEL BİLGİLER</b>	
<b>Adı Soyadı</b>	Reşit MAMUR
<b>Uyruğu</b>	T.C.
<b>Orcid Numarası</b>	0009-0000-8099-3978

<b>EĞİTİM BİLGİLERİ</b>	
<b>Lisans</b>	
<b>Üniversite</b>	Sakarya Üniversitesi
<b>Fakülte</b>	Mühendislik Fakültesi
<b>Bölümü</b>	Bilgisayar Mühendisliği
<b>Mezuniyet Yılı</b>	2011
<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., Mamur, R. (2024) "Leaf classification with pre-trained neural networks", 6th International Conference on Applied Engineering and Natural Sciences ICAENS 2024 , (pp. 158), Konya, Türkiye, (Eylül 2024)