



**T.C.
HARRAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**İNSANSIZ HAVA ARACI GÖRÜNTÜLERİ VE DİNOV2 DERİN ÖĞRENME
MİMARİSİ KULLANILARAK TURP BİTKİSİNDE HASTALIK ŞİDDETİNİN
TESPİTİ**

**Emin BAKIRCI
BİLGİSAYAR MÜHENDİSLİĞİ**

**ŞANLIURFA
2026**



**T.C.
HARRAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**İNSANSIZ HAVA ARACI GÖRÜNTÜLERİ VE DİNOV2 DERİN ÖĞRENME
MİMARİSİ KULLANILARAK TURP BİTKİSİNDE HASTALIK ŞİDDETİNİN
TESPİTİ**

**Emin BAKIRCI
BİLGİSAYAR MÜHENDİSLİĞİ**

DANIŞMAN: Doç. Dr. Mehmet Emin TENKEKİ

**ŞANLIURFA
2026**

TEŞEKKÜR

Tez çalışmamın başından sonuna kadar bilgi, birikim ve tecrübeleriyle bana rehberlik eden, desteklerini esirgemeyen değerli hocam Doç. Dr. Mehmet Emin Tenekeci'ye derin şükranlarımı sunarım.

Eğitim hayatım boyunca maddi ve manevi her türlü desteği sağlayarak yanımda olan, inançları ve sevgileriyle bana güç veren sevgili aileme sonsuz teşekkür ederim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
ÇİZELGELER DİZİNİ	iii
ŞEKİLLER DİZİNİ	iv
KISALTMALAR	v
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR	5
2.1. Hassas Tarımda İHA Kullanımı	5
2.2. Bitki Hastalıklarının Tespitinde Görüntü İşleme	8
2.3. Tarımda Derin Öğrenme Uygulamaları	9
2.3.1. CNN Tabanlı Çalışmalar	10
2.3.2. Transformer ve Özdenetimli Öğrenme Çalışmaları	12
3. GEREÇ ve YÖNTEM	15
3.1. Materyal	15
3.1.1. Çalışma Alanı ve Çevresel Koşullar	15
3.1.2. Veri Toplama Aracı ve Görüntüleme Sistemi	16
3.1.3. Veri Setinin Yapısı ve Organizasyonu	17
3.2. Yöntem (Önerilen Mimari)	18
3.2.1. Görüntü Ön İşleme ve Hibrit Segmentasyon Mimarisi	20
3.2.1.1. Çok Modlu Öznitelik Çıkarımı	21
3.2.1.2. Çok Boyutlu Öznitelik Dengeleme ve Yıgınlı Oto-kodlayıcı (SAE) ile Optimizasyon	24
3.2.1.3. K-means Kümeleme ve Olasılıksal Bitki Maskeleme	26
3.2.1.4. Kayan Pencere Algoritması ile Yama Üretimi	26
3.2.2. Çıkarılan Yamaların Objektif Etiketlenmesi ve Veri Artırımı	28
3.2.2.1. Renk Tabanlı Hastalık Kategorizasyonu	28
3.2.2.2. Veri Artırma Stratejileri	30
3.2.3. DINOv2 Tabanlı Sınıflandırma Modeli	31
3.2.3.1. Vision Transformer (ViT) Teorisi ve DINOv2 Mimarisi	32
3.2.3.2. DINOv2'nin Özdenetimli Öğrenme ve Öğrenci-Öğretmen Mimarisi	33
3.2.3.3. Transfer Öğrenme ve İnce Ayar (Fine-Tuning) Stratejisi	34
3.2.4. Eğitim Parametreleri, Donanım ve Performans Metrikleri	36
3.2.4.1. Hiperparametre Optimizasyonu ve Eğitim Konfigürasyonu	37
3.2.4.2. Performans Değerlendirme Metrikleri	39
4. BULGULAR	41
4.1. Turp Bölgesi Sınıflandırma Sonuçları ve Değerlendirmesi	41
4.2. DINOv2 Sınıflandırma Performans Bulguları ve Karşılaştırmalı Analiz	42
4.2.1. Transfer Öğrenme Modellerinin İstatistiksel Anlamlılık ve Kararlılık Analizi	43
4.3. Doğrusal Sınıflandırma (Linear Probing) Bulgularının Yapısal Analizi	45
4.4. Tam İnce Ayar (Full Fine-Tuning) ve Sınıf Sınırı Bulgularının Değerlendirilmesi	46
4.5. Literatür Karşılaştırması ve Benchmarking Tartışması	47
5. TARTIŞMA	49
5.1. Model Performansının Biyolojik ve İstatistiksel Değerlendirilmesi	49
5.2. Mimari Üstünlük Tartışması: Konvolüsyonel Ağlar (CNN) ve Vision Transformer	

(ViT).....	50
5.3. Öğretme Stratejisinin Yakınsama ve Kararlılık Üzerindeki Etkisi.....	51
5.4. Veri Stratejisinin Etkisi: Dengesizlik, Varyasyon ve Ezber Yönetimi.....	52
6. SONUÇLAR	53
7. ÖNERİLER	56
KAYNAKLAR.....	59
ÖZ GEÇMİŞ	62

ÖZET

YÜKSEK LİSANS TEZİ

İNSANSIZ HAVA ARACI GÖRÜNTÜLERİ VE DİNOV2 DERİN ÖĞRENME MİMARİSİ KULLANILARAK TURP BİTKİSİNDE HASTALIK ŞİDDETİNİN TESPİTİ

Emin BAKIRCI

HARRAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ

Tez Danışmanı: Doç. Dr. Mehmet Emin TENKECE

Yıl: 2026, Sayfa: 62

Tarımsal üretimde verim kayıplarını minimize etmek ve sürdürülebilirliği sağlamak amacıyla bitki hastalıklarının erken ve doğru tespiti büyük önem taşımaktadır. Özellikle geniş tarım arazilerinde geleneksel gözleme dayalı yöntemlerin zaman alıcı, maliyetli ve öznel olması, otomatik ve yüksek doğruluklu izleme sistemlerine olan ihtiyacı artırmıştır. Bu tez çalışmasında, İnsansız Hava Aracı (İHA) ile elde edilen yüksek çözünürlüklü görüntüler kullanılarak, turp bitkisindeki solgunluk (wilt) hastalığının şiddet seviyelerinin (Sağlıklı, Hafif Hastalıklı, Ağır Hastalıklı) otomatik olarak sınıflandırılması amaçlanmıştır.

Çalışma kapsamında, literatürdeki açık kaynaklı veri setlerinden yararlanılmış ve önerilen yöntemin başarımı referans çalışmalarla (GoogleNet) karşılaştırılmıştır. Metodolojik süreçte ilk olarak, karmaşık arka plan unsurlarını (toprak, malç filmi, bitki) elimine etmek ve sadece bitki alanlarına odaklanmak amacıyla K-means kümeleme algoritması ve Oto-kodlayıcı destekli hibrit bir görüntü segmentasyon mimarisi kullanılmıştır. Sınıflandırma aşamasında ise, klasik Evrişimli Sinir Ağları (CNN) yerine, özdenetimli öğrenme yeteneğine sahip ve "Vision Transformer (ViT)" tabanlı modern bir mimari olan DİNOv2 tercih edilmiştir. Modelin eğitimi sırasında veri artırma (data augmentation) teknikleri uygulanarak sınıf dengesizliği giderilmiş ve model ince ayar (fine-tuning) yöntemiyle optimize edilmiştir. Deneysel sonuçlar, sınıf başına 500 adet görüntüden oluşan toplam 1500 adetlik saf test kümesi üzerinde değerlendirilmiştir. DİNOv2 tabanlı model, %94,67 genel doğruluk oranına ulaşarak, literatürdeki klasik CNN tabanlı GoogleNet modelinin (%91,00) performansını belirgin bir şekilde geride bırakmıştır. Ayrıca hesaplanan genel F1-skoru (0,9466), modelin özellikle görsel olarak ayırt edilmesi en zor olan "hafif hastalıklı" geçiş sınıfında bile (0,9203 F1-Skoru) yüksek kararlılık sergilediğini ortaya koymuştur. Elde edilen bulgular, modern Transformer mimarilerinin tarımsal hastalık tespitinde, görüntüdeki küresel bağlamı yakalama yeteneği sayesinde klasik yöntemlere kıyasla daha etkin ve güvenilir bir alternatif olduğunu göstermektedir.

ANAHTAR KELİMELE: Derin Öğrenme, Hassas Tarım, Vision Transformer, İnsansız Hava Aracı (İHA), DİNOv2, Bitki Hastalığı Tespiti

ABSTRACT

MASTER'S THESIS

DETECTION OF DISEASE SEVERITY IN RADISH PLANTS USING DRONE IMAGERY AND DINOv2 DEEP LEARNING ARCHITECTURE

Emin BAKIRCI

**HARRAN UNIVERSITY
GRADUATE SCHOOL
COMPUTER ENGINEERING**

Thesis Advisor: Assoc. Prof. Mehmet Emin TENEKECİ

Year: 2026, Page: 62

Early and accurate detection of plant diseases is of great importance to minimize yield losses and ensure sustainability in agricultural production. The time-consuming, costly, and subjective nature of traditional observation-based methods, especially in large agricultural lands, has increased the need for automated and high-accuracy monitoring systems. In this thesis, it is aimed to automatically classify the severity levels (Healthy, Light Disease, Heavy Disease) of wilt disease in radish plants using high-resolution images obtained by Unmanned Aerial Vehicle (UAV).

Within the scope of the study, open-source datasets in the literature were utilized, and the performance of the proposed method was compared with reference studies (GoogleNet). In the methodological process, first, a hybrid image segmentation architecture supported by K-means clustering algorithm and Auto-encoder was used to eliminate complex background elements (soil, mulching film, shadow) and focus only on plant areas. In the classification phase, instead of classical Convolutional Neural Networks (CNN), DINOv2, a modern architecture based on "Vision Transformer (ViT)" with self-supervised learning capability, was preferred. During the training of the model, data augmentation techniques were applied to eliminate class imbalance, and the model was optimized using the fine-tuning method.

Experimental results were evaluated on a pure test set consisting of 500 images per class, totaling 1500 images. The DINOv2-based model achieved an overall accuracy of 94,67%, significantly outperforming the classical CNN-based GoogleNet model (91,00%) in the literature. Furthermore, the calculated overall F1-score (0,9466) revealed that the model exhibited a highly stable structure, specifically demonstrating high reliability (0,9203 F1-score) even in the "light disease" transition class, which is visually difficult to distinguish. The obtained findings indicate that modern Transformer architectures are a more effective and reliable alternative to classical methods in agricultural disease detection due to their ability to capture the global context in the image.

KEYWORDS: Deep Learning, Precision Agriculture, Vision Transformer, Unmanned Aerial Vehicle (UAV), DINOv2, Plant Disease Detection

ÇİZELGELER DİZİNİ

Çizelge 4.1.	Softmax sınıflandırması için çapraz doğrulama karışıklık matrisi	41
Çizelge 4.2.	Segmentasyon Aşaması Performans Metrikleri (Makro Ortalama)	42
Çizelge 4.3.	Çapraz Deneysel Senaryoların Genel Başarım Matrisi	43
Çizelge 4.4.	Farklı başlangıç tohumları ile elde edilen bağımsız doğruluk oranları	44
Çizelge 4.5.	Linear Probing Senaryoları Sınıf Bazlı Performans Raporu . . .	45
Çizelge 4.6.	Full Fine-Tuning Senaryoları Sınıf Bazlı Performans Raporu . .	46
Çizelge 4.7.	Klasik CNN ve Önerilen ViT Mimari Karşılaştırması	48

ŞEKİLLER DİZİNİ

Şekil 3.1.	Turp Tarlası (Turp Tarlasını Oluşturan Üç Alan: Turp, Toprak ve Malç Filmi)	16
Şekil 3.2.	Turp bitkisinde hastalık şiddetinin belirlenmesi için önerilen İHA ve DINOv2 tabanlı sistemin genel çalışma şeması.	19
Şekil 3.3.	İHA görüntülerinden turp bitkisi alanlarının belirlenmesi için önerilen hibrit segmentasyon mimarisinin akış şeması	22
Şekil 3.4.	Segmentasyon algoritmasının gerçek saha verileri üzerindeki çalışma prensibi. (a) Heterojen tarla unsurlarını barındıran orijinal yüksek çözünürlüklü İHA görüntüsü; Arka plan gürültülerinden arındırılarak modele girdi olarak beslenen standartlaştırılmış (128 x 128 piksel) saf turp bitkisi yamaları.	27
Şekil 3.5.	Turp yapraklarının HSV renk dönüşümü, Binary Thresholding işlemi ve R_w oranına göre hastalık sınıflarının belirlenmesi. . .	28
Şekil 3.6.	Vision Transformer (ViT) mimarisinin genel çalışma prensibi. Görüntü 14 x 14 piksellik yamalara bölünür, doğrusal izdüşümle vektörlere dönüştürülür ve Transformer kodlayıcıya beslenir (Dosovitskiy vd. , 2020)	32
Şekil 3.7.	Önerilen DINOv2 tabanlı sınıflandırma mimarisi: Ön eğitilmiş Transformer kodlayıcı , [CLS] token çıkarımı ve özelleştirilmiş sınıflandırma başlığı entegrasyonu.	35
Şekil 4.1.	Transfer öğrenme stratejilerinin doğruluk dağılımları ve Wilcoxon istatistiksel anlamlılık analizi.	44

KISALTMALAR

CNN	Evriřimli Sinir Ađları (Convolutional Neural Network)
DINOv2	Self-distillation with no labels v2
ExG	Ařırı Yeřil İndeksi (Excess Green Index)
ExR	Ařırı Kırmızı İndeksi (Excess Red Index)
FAO	Birleřmiř Milletler Gıda ve Tarım Örgütü
FN	False Negative
FP	False Positive
GSD	Yer Örnekleme Mesafesi (Ground Sampling Distance)
HSV	Hue, Saturation, Value (Renk tonu, doygunluk ve deđer renk uzayı)
İHA	İnsansız Hava Aracı
LBP	Yerel İkili Örüntü (Local Binary Pattern)
PCA	Temel Bileřenler Analizi (Principal Component Analysis)
RGB	Red, Green, Blue (Kırmızı, yeřil ve mavi renk uzayı)
ROI	İlgi Bölgesi (Region of Interest)
SAE	Yıđınlı Oto-kodlayıcı (Stacked Autoencoder)
TN	True Negative
TP	True Positive
ViT	Vision Transformer
VRT	Deđiřken Oranlı Uygulama (Variable Rate Application)

1. GİRİŞ

Küresel nüfusun hızla artması ve iklim değişikliğinin tarımsal üretim üzerindeki baskısı, gıda güvenliğini 21. yüzyılın en kritik sorunlarından biri haline getirmiştir. Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) verilerine göre, dünya genelindeki bitkisel üretimde her yıl hastalık ve zararlılar nedeniyle %20 ila %40 oranında verim kaybı yaşanmaktadır. Savary vd. (2019) ile Oerke (2006) tarafından yapılan kapsamlı çalışmalarda belirtildiği üzere, bu kayıplar sadece ekonomik bir zarar oluşturmakla kalmamakta, aynı zamanda üreticilerin rekolteyi koruma içgüdüsüyle aşırı kimyasal (pestisit ve fungisit) kullanımına yönelmesine neden olmaktadır. Bilinçsiz kimyasal kullanımı ise üretim maliyetlerini artırmanın ötesinde, toprak ve su kaynaklarında geri dönüşü zor kirliliklere yol açarak sürdürülebilir tarım ilkelerini tehdit etmektedir.

Bu küresel sorunun yerel ölçekteki yansımaları, özellikle ekonomik değeri yüksek açık alan sebze üretiminde hissedilmektedir. Turp (*Raphanus sativus*), kısa vejetasyon süresi ve yüksek besin değeri nedeniyle yaygın olarak yetiştirilen ancak fungal hastalıklara karşı oldukça hassas olan bir bitkidir. Mace (2012)'nin belirttiği üzere, turp bitkisinde görülen solgunluk hastalıkları, bitkinin iletim demetlerini tıkayarak su ve besin taşınımını fizyolojik olarak engellemektedir. Bu patolojik süreç; bitkide gelişme geriliği, yapraklarda sararma ve ileri aşamalarda tam bitki ölümü ile sonuçlanmaktadır. Sorunun temelinde, bu tür hastalıkların erken evre belirtilerinin (hafif renk tonu değişimleri veya lokalize solgunluklar) insan gözüyle ayırt edilmesinin son derece güç olması yatmaktadır. Belirtilerin tarlada gözle görünür hale geldiği aşama, genellikle hastalığın epidemik olarak yayıldığı ve müdahale eşiğinin aşıldığı noktadır.

Geleneksel tarım pratiklerinde hastalık tespiti, "tarla izleme" adı verilen ve uzmanların tarlayı fiziksel olarak gezerek bitkileri incelemesine dayanan yöntemlerle yapılmaktadır. Ancak modern tarımda artan işletme büyüklükleri göz önüne alındığında, yüzlerce dekarlık alanın düzenli, sürekli ve her bitkiyi kapsayacak şekilde insan gücüyle taranması fiziksel ve ekonomik olarak sürdürülebilir değildir. Ayrıca, geleneksel gözlem yöntemleri doğası gereği öznel; bir hastalığın teşhisi, gözlemcinin tecrübesine, yorgunluk durumuna ve ışık koşullarına göre değişkenlik gösterebilmektedir. Bu durum, hassas tarım uygulamaları için

gereken veri doğruluğunu ve standardizasyonunu sağlamaktan uzaktır.

Tarımsal üretimde verimliliği doğrudan etkileyen bitki hastalıklarının tespitinde, geleneksel insan gözlemine dayalı yöntemlerin emek yoğun, zaman alıcı ve öznel değerlendirmelere açık yapısı, sürdürülebilir tarım uygulamaları için önemli bir kısıt oluşturmaktadır. Bu bağlamda, bu tez çalışmasının temel amacı; söz konusu kısıtları aşmak ve hassas tarım prensiplerine uygun çözümler üretmek üzere, yüksek çözünürlüklü görüntüleme yeteneğine sahip İnsansız Hava Araçları (İHA) ile görsel verileri küresel bağlamda işleyebilen yeni nesil Derin Öğrenme teknolojilerini (Vision Transformer) entegre eden, tam otonom, nesnel ve yüksek doğruluklu bir karar destek sistemi geliştirmektir.

Bu temel gaye doğrultusunda, çalışmanın alt amaçları şu şekilde belirlenmiştir:

- İHA Tabanlı Yüksek Çözünürlüklü Veri Seti Oluşturulması: İnsan gözlemine dayalı tarla izleme yöntemlerinin fiziksel ve operasyonel zorluklarını aşmak amacıyla, tarımsal alanın havadan görüntülenerek hastalık durumunu yansıtan yüksek nitelikli ve geniş kapsamlı bir görüntü veri setinin literatüre kazandırılması.
- Karmaşık Arka Plan Gürültülerinin Elimine Edilmesi: Hedef bitkiyi; çıplak toprak, malç filmi ve gölge gibi analiz doğruluğunu düşüren heterojen arka plan unsurlarından başarılı bir şekilde izole ederek, derin öğrenme modelleri için standartlaştırılmış ve gürültüden arındırılmış bir girdi alt yapısının oluşturulması.
- Modern Derin Öğrenme Mimarilerinin (Vision Transformer) Tarımsal Analize Entegrasyonu: Literatürde yaygın olarak kullanılan klasik Evrişimli Sinir Ağlarının (CNN) yerel özelliklere odaklanma kısıtını aşmak üzere, görüntüyü küresel bağlamda analiz edebilen özdenetimli DINOv2 mimarisinin hastalık tespit sürecine entegre edilmesi ve performansının değerlendirilmesi.
- Hastalık Şiddetinin Otonom ve Nesnel Olarak Sınıflandırılması: Sadece hastalığın varlığını tespit etmekle kalmayıp, tarımsal mücadele stratejilerine doğrudan yön verebilmek için hastalığın şiddetini (Sağlıklı, Hafif Hastalıklı, Ağır Hastalıklı) insan öznelliğinden bağımsız, matematiksel metriklere dayalı olarak kategorize eden bir sistemin geliştirilmesi.

Literatürdeki İHA tabanlı bitki hastalığı tespit çalışmalarında GoogleNet, ResNet ve VGG gibi Evrişimli Sinir Ağları baskın mimariler olarak öne çıkmaktadır. Özellikle turp

bitkisi özelindeki solgunluk hastalığı tespiti (Dang vd., 2017) gibi referans çalışmalar, klasik CNN mimarilerinin temel başarı standartlarını belirlemiştir. Ancak klasik CNN mimarileri, sahip oldukları "tümevarımcı önyargı" nedeniyle ağırlıklı olarak kenar ve lokal doku gibi yerel özelliklere odaklanma eğilimindedir. Bu durum, bitkinin genel formunun ve küresel bağlamının göz ardı edilmesine yol açarak, özellikle erken evrelerdeki "hafif hastalık" semptomlarının ayırt edilmesinde performans darboğazlarına neden olabilmektedir.

Bu tez çalışmasını literatürden ayıran temel fark; bilgisayarlı görü alanında paradigma değişimi yaratan, ViT tabanlı ve özdenetimli öğrenme yeteneğine sahip DINOv2 mimarisinin tarımsal patoloji analizine entegre edilmesidir. DINOv2, "Çok Başlı Öz-Dikkat" mekanizması sayesinde görüntüdeki pikseller arasındaki uzun mesafeli anlamsal ilişkileri kurarak, hastalık belirtilerini sadece lokal bir doku bozulması olarak değil, yaprağın bütünlüğü içerisindeki yapısal bir değişim olarak analiz etmektedir

Çalışma, DINOv2'nin tarımsal görüntü analizinde klasik CNN modellerine kıyasla, özellikle geçiş evrelerinde ve dengesiz veri setlerinde çok daha üstün bir genelleme yeteneğine sahip olduğunu ortaya koyması açısından bilimsel bir yenilik taşımaktadır. Ayrıca, geliştirilen otonom karar destek sisteminin ve uygulanan veri artırma stratejilerinin çıktıları; tarladaki tarım ilacı kullanımının tüm alana değil, yalnızca enfekte bölgelere noktasal ilaçlama uygulanmasına yönelik somut ve sürdürülebilir bir teknolojik zemin sunmaktadır.

Bu tez çalışması, Giriş bölümünü takip eden altı ana bölümden oluşmaktadır. İkinci bölümde, hassas tarımda İHA kullanımı, görüntü işleme teknikleri ve derin öğrenme (CNN ve Transformer) mimarilerinin bitki patolojisindeki yeri üzerine kapsamlı bir literatür taraması sunulmuştur. Üçüncü bölümde, araştırmada kullanılan materyaller ile karmaşık arka planların ayrıştırılmasını sağlayan hibrit segmentasyon mimarisi ve DINOv2 tabanlı sınıflandırma modelinin metodolojik adımları tüm teknik detaylarıyla açıklanmıştır. Dördüncü bölümde, bağımsız test veri seti üzerinden elde edilen sınıflandırma performans metrikleri (Doğruluk, F1-Skoru, Karışıklık Matrisi) ve referans CNN modeli ile yapılan karşılaştırmalı analiz sonuçları ortaya konmuştur. Beşinci bölümde, elde edilen bu deneysel bulguların biyolojik ve mimari nedenleri, literatürdeki çalışmalar ışığında derinlemesine tartışılmıştır. Son olarak Altıncı ve Yedinci bölümlerde, çalışmanın genel sonuçları

özetlenmiş, sisteme yönelik sektörel kazanımlar belirtilmiş ve gelecekte yapılacak akademik çalışmalar ile pratik uygulamalar için öneriler sunulmuştur.

2. ÖNCEKİ ÇALIŞMALAR

Bitki hastalıklarının erken tespiti ve yönetimi, hassas tarım uygulamalarının en kritik bileşenlerinden birini oluşturmaktadır. Bu bölümde, çalışmanın teorik ve metodolojik altyapısını oluşturan literatür çalışmaları üç ana başlık altında detaylandırılmıştır. İlk olarak İnsansız Hava Araçlarının (İHA) tarımsal izlemedeki rolü, ikinci olarak görüntü işleme ve segmentasyon teknikleri, son olarak ise derin öğrenme tabanlı sınıflandırma mimarileri (CNN ve Transformer) üzerine yapılan güncel araştırmalar incelenmiştir.

2.1. Hassas Tarımda İHA Kullanımı

Geleneksel uydu tabanlı uzaktan algılama yöntemleri, geniş tarım arazilerinin izlenmesinde uzun yıllardır kullanılsa da sahip oldukları düşük mekânsal ve zamansal çözünürlük, bitki hastalıklarının erken aşamada tespit edilmesinde ve hassas fenotipleme çalışmalarında sıklıkla yetersiz kalmaktadır. Uyduların yörünge tekrar sürelerinin uzunluğu ve bulutluluk gibi atmosferik engellerden etkilenmeleri, tarımsal müdahale için gereken anlık veri düzeyindeki tarla içi değişkenliklerin yakalanması gerekliliğini ortaya çıkarmış ve İnsansız Hava Araçları (İHA) teknolojilerinin hassas tarım süreçlerine entegrasyonunu hızlandırmıştır.

Konuyla ilgili temel kaynaklardan biri olan Zhang ve Kovacs (2012) çalışmalarında, küçük ölçekli İHA sistemlerinin hassas tarım uygulamalarındaki potansiyelini kapsamlı bir şekilde irdelemişlerdir. Araştırmacılar, uydu görüntülerinde veri kalitesini düşüren en önemli faktörlerden olan bulutluluk ve atmosferik saçılma sorunlarının, İHA'ların düşük irtifa uçuş yetenekleri sayesinde aşılabildiğini vurgulamışlardır. Çalışmada, İHA platformlarının sağladığı santimetre seviyesindeki yüksek mekânsal çözünürlüğün, tarla içi değişkenliklerin örneğin toprak nemi, bitki sağlığı, besin durumu ve biyoçeşitlilik gibi parametrelerin hassas bir şekilde haritalanmasında kritik bir rol oynadığı belirtilmiştir. Ayrıca, bu sistemlerin maliyet etkinliği ve talep edildiği anda veri toplama esnekliğinin, çiftçilere ve tarım uzmanlarına karar destek süreçlerinde sağladığı operasyonel avantajlar detaylandırılmıştır.

İHA teknolojilerinin kullanım alanlarının çeşitliliğine odaklanan Tsouros vd. (2019),

incelemelerinde bu sistemlerin sadece pasif birer görüntüleme aracı olarak değil; aynı zamanda verim tahmini, biyokütle izleme, sulama yönetimi ve yabancı ot tespiti gibi çok boyutlu tarımsal yönetim süreçlerinde de etkin birer araç olduğunu rapor etmişlerdir. Elde edilen bulgular, İHA'ların sağladığı esnek ve hızlı veri toplama imkanının, özellikle hastalıkların dinamik takibinde ve acil müdahale gerektiren biyotik stres durumlarında, geleneksel uydu sistemlerine ve manuel tarla kontrollerine kıyasla çok daha maliyet etkin, hızlı ve pratik bir çözüm sunduğunu ortaya koymaktadır.

Bitki fizyolojisi ve uzaktan algılama perspektifiyle konuyu ele alan Maes ve Steppe (2019) ise, bitkilerin abiyotik (su stresi, kuraklık) ve biyotik (hastalık, zararlı) stres faktörlerine verdiği tepkilerin izlenmesinde farklı İHA sensörlerinin (RGB, termal, multispektral) önemini değerlendirmişlerdir. Araştırmacılar, stres kaynaklı fizyolojik değişimlerin, yaprak yüzey sıcaklığı ve spektral yansıma özelliklerindeki mikroskobik değişimlerle kendini gösterdiğini, bu değişimlerin ise insan gözünün algılayamayacağı kadar erken evrelerde, uygun sensörlerle donatılmış İHA'lar sayesinde tespit edilebileceğini belirtmişlerdir. Bu durum, hastalık semptomları henüz gözle görülür hale gelmeden müdahale edilmesine olanak tanıdığı için önleyici tarım uygulamaları açısından hayati önem taşımaktadır.

İHA platformlarının tarımsal yönetim süreçlerine entegrasyonu, sadece görüntüleme kapasitesini artırmakla kalmamış; aynı zamanda otonom karar destek sistemlerinin temelini oluşturmuştur. Agrawal ve Arafat (2024) tarafından gerçekleştirilen kapsamlı derleme çalışmasında, İHA sistemlerinin yapay zekâ ve makine öğrenmesi algoritmalarıyla bütünleştirilmesinin hassas tarım uygulamalarında verimliliği, sürdürülebilirliği ve veri odaklı karar alma süreçlerini temelden dönüştürdüğü ifade edilmiştir. Araştırmacılar, İHA'lar üzerine monte edilen multispektral ve termal sensörlerin, tarımsal kaynakların yönetiminde ve bitki sağlığının gerçek zamanlı takibinde kritik bir rol oynadığını vurgulamışlardır (Agrawal & Arafat, 2024).

Son olarak, hassas tarım ekosistemini daha geniş bir perspektifle, siber güvenlik ve veri işleme süreçleri dahilinde ele alan Radoglou-Grammatikis vd. (2020), İHA'ların artık otonom karar destek sistemlerinin ayrılmaz bir parçası haline geldiğini ifade

etmişlerdir. Çalışmada, İHA'lardan elde edilen büyük verinin yapay zekâ ve derin öğrenme algoritmalarıyla işlenmesinin, tarımsal girdilerin (ilaç, gübre, su) optimizasyonunda ve dolayısıyla tarımın çevresel ayak izinin azaltılmasında devrim niteliğinde sonuçlar doğurduğu vurgulanmıştır. Bu yaklaşım, sadece verim artışı sağlamakla kalmayıp, aynı zamanda sürdürülebilir tarım hedeflerine ulaşılmasında da kilit bir rol oynamaktadır.

İHA'lardan elde edilen yüksek çözünürlüklü verilerin işlenmesi bağlamında, otonom tarım sistemlerinin karşılaştığı en temel sınırlamalardan biri de hesaplama maliyetleridir. Khan vd. (2023) tarafından yürütülen çalışmada, derin öğrenme algoritmalarının bulut tabanlı sunuculara bağımlılığının, tarımsal sahalardaki gerçek zamanlı müdahaleleri kısıtladığı vurgulanmıştır. Araştırmacılar, İHA'lar veya tarımsal robotlar üzerine entegre edilebilen uç bilişim cihazlarının önemine dikkat çekerek, modellerin (MobileNet vb. gibi) uç cihazlarda çalışacak şekilde optimize edilmesinin (örneğin donanım tabanlı kuantizasyon işlemleriyle) gerekliliğini ortaya koymuşlardır. Bu yaklaşım, yüksek işlem gücü gerektiren analizlerin doğrudan veri kaynağında yapılarak karar alma süresini minimize etmesini sağlamakta ve derin öğrenme modellerinin tarımsal sahadaki gerçek dünya koşullarına entegrasyonunu uygulanabilir kılmaktadır.

İHA tabanlı otonom hastalık tespit sistemlerinin geliştirilmesindeki nihai amaç, yalnızca teknolojik bir otomasyon sağlamak değil; aynı zamanda tarımsal üretimde çevresel ve ekonomik sürdürülebilirliği güvence altına almaktır. Bu bağlamda, Laveglia vd. (2024) tarafından yapılan kapsamlı derleme çalışmasında, hassas tarım ve algılama teknolojilerinin entegrasyonunun, aşırı zirai ilaç kullanımının yarattığı ekolojik tahribatı önlemedeki kritik rolü vurgulanmıştır. Araştırmacılar, bitki sağlığının görüntü işleme ve yapay zeka destekli sistemlerle yüksek hassasiyette izlenmesinin, değişken oranlı ilaçlama teknolojilerine doğrudan temel oluşturduğunu belirtmişlerdir. Hastalıkların sadece varlığının değil, aynı zamanda şiddet seviyelerinin bölgesel olarak tespit edilmesi, pestisit kullanımının optimize edilmesini sağlayarak tarımın karbon ayak izini ve su kirliliğini azaltmakta; eş zamanlı olarak girdi maliyetlerini düşürmektedir. Dolayısıyla, İHA tabanlı derin öğrenme sistemleri, sadece verim artışı sağlamakla kalmayıp, küresel gıda güvenliği ve sürdürülebilir ekosistem yönetimi açısından da vazgeçilmez bir strateji olarak öne çıkmaktadır.

2.2. Bitki Hastalıklarının Tespitinde Görüntü İşleme

Tarımsal sahalardan elde edilen görüntülerin analiz edilerek bitki hastalıklarının doğru sınıflandırılabilmesi, öncelikle bitki alanlarının görüntüdeki karmaşık arka plan unsurlarından (toprak, gölge, malç filmi, yabancı otlar) başarılı bir şekilde ayrıştırılmasına bağlıdır. Bu bağlamda, Hamuda vd. (2016) tarafından yapılan kapsamlı derleme çalışmasında, kontrollü laboratuvar ortamlarının aksine, tarla koşullarında elde edilen görüntülerden bitki ekstraksiyonu ve segmentasyonu süreçlerinin zorlukları detaylı bir şekilde incelenmiştir. Araştırmacılar, dış ortamdaki dinamik aydınlatma değişimlerinin (güneşli, parçalı bulutlu hava vb.) ve gölge etkisinin segmentasyon başarımını doğrudan ve olumsuz etkilediğini vurgulamışlardır. Çalışmada, Aşırı Yeşil İndeksi (ExG) ve Aşırı Kırmızı İndeksi (ExR) gibi renk indeksi tabanlı yöntemlerin, bitkilerin yeşil dokusunu topraktan ayırmada hesaplama maliyeti düşük ve hızlı çözümler sunduğu belirtilmiştir. Ancak, ışık şiddetinin anlık değiştiği dinamik ortamlarda, tek başına eşikleme yöntemlerinin yetersiz kalabildiği ve bu nedenle renk ile doku bilgisini birleştiren daha karmaşık hibrit yaklaşımlara duyulan ihtiyacın arttığı rapor edilmiştir.

Görüntü üzerindeki gürültünün azaltılması ve hastalık semptomlarının daha net ortaya çıkarılması amacıyla literatürde kümeleme tabanlı yöntemler de sıklıkla tercih edilmektedir. Wang vd. (2018), bitki hastalığı görüntülerinin segmentasyonunda K-means kümeleme algoritmasının geliştirilmiş bir versiyonunu önererek bu alanda önemli bir katkı sağlamışlardır. Çalışmalarında, hastalık lekelerinin sağlıklı yaprak dokusundan ayrıştırılmasında, standart RGB renk uzayının parlaklık ve renk bilgisini birbirine bağımlı tutan yapısının yetersiz kaldığını; bunun yerine insan algısına daha yakın olan ve parlaklık bilgisini renkten ayıran Lab ve HSV renk uzaylarının kullanılmasının segmentasyon başarısını önemli ölçüde artırdığını kanıtlamışlardır. Araştırmacılar, K-means algoritması ile yapılan bu ön işlemenin, derin öğrenme modelleri için veriyi gürültüden arındırdığını ve sınıflandırma öncesi verinin temizlenmesi açısından modelin öğrenme performansını doğrudan etkileyen kritik bir adım olduğunu ortaya koymuşlardır.

Renk ve kümeleme tabanlı bu yaklaşımları bir adım öteye taşıyan Khan ve Narvekar (2022), tarımsal sahalardan elde edilen görüntülerde ışık değişimleri ve karmaşık arka plan

unsurlarının (toprak, malç vb.) yarattığı zorlukları aşmak adına renk dengeleme ve süper-piksel temelli hibrit bir segmentasyon yaklaşımı geliştirmişlerdir. Çalışmada, görüntüdeki düzensiz aydınlatma etkilerinin minimize edilmesi ve ardından süper-piksel kümeleme ile hedef bitki dokusunun arka plandan hassas bir şekilde izole edilmesi sağlanmıştır. Araştırmacılar, özellikle toprak rengi ile hastalık lekesi renginin benzerlik gösterdiği durumlarda, doku tabanlı özniteliklerin (GLCM ve PHOG gibi) kullanılmasının modelin ayırt ediciliğini güçlendirdiğini kanıtlamışlardır. Bu yaklaşım, gerçek dünya koşullarındaki görüntülerde yüksek başarı sağlanabileceğini ortaya koymasından önem taşımaktadır.

Özellikle İnsansız Hava Araçları ile elde edilen görüntülerde, yüksek çekim mesafesi ve geniş görüş açısı nedeniyle arka plan karmaşası çok daha belirgin ve yanıltıcı bir sorun haline gelmektedir. Barbedo (2019), İHA görüntüleri kullanılarak bitki hastalıklarının tespit edilmesindeki temel zorlukları incelediği çalışmasında, en büyük engelin "arka plan karmaşası" olduğunu vurgulamıştır. Barbedo, etkin bir segmentasyon işlemi yapılmadan, yani "İlgi Bölgesi" çıkarılmadan eğitilen derin öğrenme modellerinin ciddi bir yanlışlık riski taşıdığını belirtmiştir. Bu durumlarda model, hastalık belirtileri yerine arka plandaki alakasız özelliklere (örneğin belirli bir toprak rengine, taşlara veya gölge desenlerine) odaklanarak hatalı öğrenme gerçekleştirebilmektedir. Bu durum, modelin eğitim setinde yapay olarak yüksek başarı göstermesine rağmen, farklı arka planlara sahip yeni tarla görüntülerinde başarısız olmasına neden olmaktadır. Dolayısıyla, sınıflandırma öncesinde bitki alanının maskelenmesi, modelin sadece ilgili biyolojik dokuya odaklanmasını sağlayan hayati bir zorunluluktur.

2.3. Tarımda Derin Öğrenme Uygulamaları

Geleneksel makine öğrenmesi yöntemlerinin, görüntü işleme süreçlerinde el yordamıyla öznitelik çıkarımı gerektirmesi, değişken ve karmaşık yapıdaki tarımsal problemlerin çözümünde çoğu zaman yetersiz kalmasına neden olmuştur. Işık değişimleri, bitki morfolojisindeki farklılıklar ve arka plan gürültüleri gibi faktörler, klasik algoritmaların performansını sınırlayan temel etkenlerdir. Bu bağlamda, büyük veri setlerinden öznitelikleri otomatik olarak öğrenme yeteneğine sahip olan Derin Öğrenme yaklaşımları, son yıllarda literatürde baskın hale gelmiş ve hassas tarım uygulamalarında devrim niteliğinde gelişmelerin önünü

açmıştır.

2.3.1. CNN Tabanlı Çalışmalar

Evrişimli Sinir Ağları, görüntü verilerinden mekânsal hiyerarşileri, kenar bilgilerini, doku özelliklerini ve yüksek seviyeli anlamsal öznitelikleri otomatik olarak öğrenme konusundaki üstün yetenekleri sayesinde, tarımsal hastalık tespiti ve bitki fenotiplemesi alanında en sık başvurulmuş derin öğrenme mimarileri haline gelmiştir. Klasik yöntemlerin aksine, insan müdahalesine gerek duymadan ham veriden öğrenen bu mimariler, yeterli büyüklükteki veri setleri üzerinde eğitildiklerinde yüksek genelleme başarısı göstermektedirler.

Bu alandaki en önemli referans çalışmalardan biri olan Dang vd. (2017) tarafından yürütülen araştırma, bu tez çalışmasının deneysel kurgusuna ve karşılaştırmalı analizlerine doğrudan temel teşkil etmektedir. Araştırmacılar, turp bitkisinde ciddi ekonomik kayıplara yol açan solgunluk hastalığının tespiti için İHA tabanlı otonom bir sistem önermişlerdir. Çalışma kapsamında veri toplama süreci, Kore'nin Jungsun, Gangwon ve Hongchun bölgelerindeki gerçek üretim alanlarında, hastalığın en yoğun görüldüğü Temmuz ve Eylül 2016 tarihleri arasında gerçekleştirilmiştir. Veri toplama aracı olarak 12 megapiksel RGB sensöre sahip DJI Phantom 4 model İHA kullanılmış ve uçuşlar, yer örnekleme mesafesini optimize etmek amacıyla yer seviyesinden 10 metre irtifada icra edilmiştir. Metodolojik olarak, ham görüntülerdeki toprak, malç filmi ve gölge gibi arka plan gürültülerini elimine etmek amacıyla K-means kümeleme algoritmasına dayalı bir segmentasyon yöntemi geliştirilmiştir. Elde edilen bitki odaklı görüntüler, transfer öğrenme yöntemiyle GoogleNet mimarisine uygulanarak "Sağlıklı", "Hafif Hastalıklı" ve "Ağır Hastalıklı" olmak üzere üç farklı şiddet seviyesinde sınıflandırılmıştır.

Çalışma sonucunda, önerilen CNN tabanlı GoogleNet modelinin hastalık evrelerini %91,00 doğrulukla ayırt edebildiği rapor edilmiştir. Değerlendirme aşaması, her sınıf için 500 adet olmak üzere toplam 1500 görüntülük bir test kümesi üzerinde gerçekleştirilmiştir. Bu tez çalışmasında da, adil ve doğrudan bir performans kıyaslaması yapabilmek amacıyla Dang vd. (2017) ile birebir aynı test seti kapasitesi (3x500) referans alınmış; ancak CNN'lerin yerel özellik çıkarma kısıtları, "Vision Transformer" (ViT) tabanlı DINOv2 mimarisinin küresel bağlam yeteneği ile aşarak literatürdeki bu başarımla oranın ileriye taşınmıştır.

CNN mimarilerinin farklı sensör tipleriyle entegrasyonuna odaklanan Kerkech vd. (2018), bağ alanlarında hastalık tespiti üzerine gerçekleştirdikleri çalışmada, standart RGB kameraların sınırlarını aşarak İHA entegre multispektral sensörler kullanmışlardır. Araştırmacılar, problemi sadece bir sınıflandırma görevi olarak ele almak yerine, görüntüyü piksel seviyesinde anlamlandıran ve her pikseli etiketleyen SegNet tabanlı bir semantik segmentasyon yaklaşımı benimsemişlerdir. Çalışma sonucunda, asma yapraklarındaki mildiyö gibi hastalık belirtileri %95'in üzerinde bir doğruluk oranıyla tespit edilmiştir. Bu çalışma, CNN modellerinin multispektral verilerle beslendiğinde, insan gözünün algılayamadığı veya standart RGB kameraların yakalayamadığı erken evre hastalık semptomlarını tespit etmedeki başarısını ortaya koyması açısından literatürde kritik bir öneme sahiptir.

Derin öğrenme modellerinin optimizasyonu üzerine odaklanan Tetila vd. (2020) ise, soya fasulyesi tarlalarında zararlı tespiti üzerine gerçekleştirdikleri kapsamlı çalışmada, farklı derinlik ve mimarilere sahip CNN modellerinin (ResNet-50, VGG-16, AlexNet vb.) performanslarını karşılaştırmalı olarak analiz etmişlerdir. Çalışmanın en çarpıcı bulgusu, "sıfırdan eğitim" yerine, önceden eğitilmiş modeller üzerinde yapılan ince ayar işlemlerinin model başarısına olan katkısıdır. Araştırmacılar, transfer öğrenme ve ince ayar stratejilerinin uygulanmasıyla model başarılarında %5 ila %10 oranında belirgin bir artış sağlandığını rapor etmişlerdir. Ayrıca, ResNet gibi daha derin mimarilerin (skip connection yapısı sayesinde), karmaşık zararlı desenlerini ve arka plan varyasyonlarını öğrenmede sıkı ağlara (AlexNet) göre istatistiksel olarak daha üstün ve kararlı sonuçlar verdiği kanıtlanmıştır.

Tarımsal hastalık tespitinde CNN tabanlı modellerin karşılaştığı en büyük zorluklardan biri, laboratuvar ortamından çıkıp karmaşık doğal ortamlara geçildiğinde modelin gürbüzlüğü ve genelleme yeteneğini koruyabilmesidir. Bu bağlamda Wang vd. (2025) tarafından yapılan güncel ve kapsamlı derleme çalışmasında, CNN modellerinin hiyerarşik öznitelik öğrenimi ve yerel algılama mekanizmaları sayesinde karmaşık öznitelikleri başarıyla çıkardığı vurgulanmıştır. Ancak klasik mimarilerin, farklı çevresel koşullar ve değişen hastalık morfolojileri karşısında yetersiz kalabildiği belirtilmiştir. Bu kısıtları aşmak ve model gürbüzlüğü artırmak amacıyla; yerel detaylar ile küresel öznitelikleri aynı

anda yakalayabilen farklı boyutlardaki konvolüsyon çekirdeklerine sahip InceptionNet gibi mimariler ile karmaşık ortamlarda dinamik öznitelikler çıkarabilen Konvolüsyonel Korelasyon Sinir Ağları (CCNN) gibi geliştirilmiş modellerin ön plana çıktığı rapor edilmiştir. Bununla birlikte araştırmacılar, dinamik yapılı bu yeni modellerin tespit doğruluğunu ve gürbüzlüğünü artırmasına rağmen; büyük ölçekli etiketli veri setlerine olan yüksek bağımlılığın devam ettiğini ifade etmiştir. Ayrıca, derin öğrenme modellerinin karmaşık doğal ortamlardaki genelleme ve açıklanabilirlik kapasitelerinin halen daha fazla geliştirilmeye ihtiyaç duyduğunu, bu durumun da daha gelişmiş mimarilere geçişi zorunlu kıldığını açıkça ortaya koymuşlardır.

2.3.2. Transformer ve Özdenetimli Öğrenme Çalışmaları

Uzun yıllar boyunca bilgisayarlı görü alanında standart kabul edilen Evrişimli Sinir Ağları, kenar ve doku gibi yerel öznitelikleri çıkarmadaki başarısına rağmen, görüntüdeki uzak mesafeli pikseller arasındaki ilişkileri ve küresel bağlamı yakalamada sınırlı kalmıştır. Ayrıca, CNN modellerinin yüksek performansa ulaşabilmesi için binlerce etiketli veriye ihtiyaç duyması, veri etiketlemenin uzmanlık gerektirdiği ve maliyetli olduğu tarımsal uygulamalarda önemli bir darboğaz oluşturmuştur. Bu yapısal ve operasyonel kısıtları aşmak amacıyla, son yıllarda Doğal Dil İşleme alanından bilgisayarlı görüye uyarlanan Vision Transformer mimarileri ve etiket bağımlılığını ortadan kaldıran özdenetimli öğrenme yaklaşımları literatürde ön plana çıkmıştır.

Bilgisayarlı görü alanında yaşanan bu paradigma değişimini kapsamlı bir şekilde inceleyen Han vd. (2022), geleneksel Evrişimli Sinir Ağlarının yerel öznitelik kısıtlarına karşın, Vision Transformer mimarilerinin sahip olduğu öz-dikkat mekanizmasının gücünü ortaya koymuştur. Araştırmacılar, ViT modellerinin CNN'lerde bulunan ve modele belirli bir yapısal kısıtlama getiren tümevarımcı önyargılara daha az ihtiyaç duyduğunu; bu sayede görüntü üzerindeki uzak mesafeli pikseller arasındaki küresel ilişkileri çok daha esnek bir şekilde modelleyebildiğini vurgulamışlardır. Bu çalışma, yüksek temsil yetenekleri sayesinde Transformer tabanlı mimarilerin nesne tespiti, görüntü sınıflandırma ve bölümlendirme gibi görsel görevlerde klasik ağ yapılarının yerini almaya başladığını kanıtlamaktadır.

Bu alandaki en güncel ve etkili gelişmelerden biri, Meta AI araştırmacıları Caron

vd. (2021) ile Oquab vd. (2023) tarafından geliştirilen DINO ve DINOv2 yaklaşımlarıdır. Caron vd. (2021), Vision Transformer mimarilerinin etiketlenmemiş veri setleri üzerinde özdenetimli olarak eğitilmesini sağlayan DINO yöntemini tanıtmışlardır. "Öğretmen-öğrenci" ağ yapısını kullanan bu yaklaşım, modelin herhangi bir etiket bilgisi olmadan görüntünün anlamsal bütünlüğünü öğrenebildiğini göstermiştir. Bu çalışmayı bir adım öteye taşıyan Oquab vd. (2023), DINOv2 modelini 142 milyonluk küratörlü devasa bir veri seti (LVD-142M) üzerinde eğiterek literatüre kazandırmışlardır. Araştırmacılar, DINOv2'nin nesnelerin sadece renk veya şekil gibi yüzeysel özelliklerini değil; derinlik, doku ve yapısal geometri gibi karmaşık özelliklerini de "insan benzeri" bir algıyla öğrendiğini belirtmişlerdir. Tarımsal açıdan bakıldığında bu mimarinin en çarpıcı özelliği; eğitim verisinin sınırlı olduğu görevlerde ve ciddi sınıf dengesizliği yaşanan durumlarda, klasik CNN modellerine kıyasla çok daha kararlı ve ayırt edici öznitelikler çıkarabilmesidir. Bu durum, etiketli veri bulmanın zor olduğu bitki hastalığı tespiti çalışmaları için devrim niteliğinde bir gelişme olarak kabul edilmektedir.

DINOv2 mimarisinin literatürdeki bu teorik üstünlüğü, tarımsal patoloji ve fenotipleme alanındaki güncel saha çalışmalarıyla da kanıtlanmıştır. Espejo-Garcia vd. (2024) tarafından gerçekleştirilen çalışmada, temel modellerin tarımsal görevlerdeki (hastalık tespiti ve yabancı ot sınıflandırma) etkinliği kapsamlı bir şekilde analiz edilmiştir. Araştırmacılar, klasik CNN mimarilerinin kısıtlı veri setlerinde yerel özniteliklere odaklanarak küresel anlamsal bütünlüğü kaçırdığını; buna karşın DINOv2 mimarisinin etiketli veriye olan bağımlılığı büyük ölçüde azalttığını vurgulamışlardır. İHA ve tarla görüntülerinden elde edilen kısıtlı veri setleri üzerinde yapılan testlerde, DINOv2'nin veriyi ezberlemeden diğer özdenetimli öğrenme algoritmalarını geride bıraktığı ve farklı çevresel koşullarda yüksek genelleme kapasitesine sahip olduğu kanıtlanmıştır. Bu bulgular, DINOv2'nin tarımsal sınıflandırma problemleri için son derece gürbüz bir temel model olduğunu deneysel olarak doğrulamaktadır.

Vision Transformer mimarilerinin tarımsal sınıflandırma problemlerindeki etkinliği üzerine odaklanan Reedha vd. (2022) çalışmalarında, bu modellerin performansını deneysel olarak incelemişlerdir. Yabancı ot ve kültür bitkisi ayrımı gibi görsel benzerliğin yüksek

olduğu zorlu bir problemde, ViT mimarisini EfficientNet ve ResNet gibi güçlü CNN modelleriyle karşılaştıran araştırmacılar, ViT'nin sahip olduğu "Öz-Dikkat" mekanizmasının önemini vurgulamışlardır. Çalışma sonucunda, bu mekanizma sayesinde modelin bitkilerin karmaşık yapısını ve ince doku detaylarını yakalamada CNN'lere göre daha başarılı olduğu kanıtlanmıştır. Modelin karar verme sürecini görselleştiren dikkat haritaları incelendiğinde; CNN'lerin bazen arka plandaki toprağa veya gölgeye odaklanarak hatalı çıkarımlar yapabildiği, buna karşın ViT modellerinin doğrudan bitkinin yaprak kenarları, damar yapısı ve karakteristik doku bozulmaları gibi ayırt edici bölgelere odaklandığı rapor edilmiştir. Bu bulgu, ViT tabanlı modellerin gürültülü tarla görüntülerinde daha güvenilir ve açıklanabilir sonuçlar verdiğini doğrulamaktadır.

Derin öğrenme modellerinin başarısını sınırlayan en önemli faktörlerden biri olan "veri dengesizliği" ve "veri yetersizliği" sorunlarına yönelik olarak ise Barbedo (2018) ile Shorten ve Khoshgoftaar (2019) kapsamlı çözüm stratejileri sunmuşlardır. Tarımsal veri setlerinde genellikle "Sağlıklı" bitki görüntüleri çoğunlukta iken, "Hastalıklı" (özellikle erken evre) görüntülerin azınlıkta olması sık karşılaşılan bir durumdur. Barbedo (2018), bu dengesizliğin, modelin istatistiksel olarak çoğunluk sınıfına (sağlıklı) meyilli olmasına ve hastalıkları tespit edememesine yol açtığını vurgulamıştır. Bu sorunu aşmak için Shorten ve Khoshgoftaar (2019), Veri Artırma tekniklerinin önemini sistematik olarak incelemişlerdir. Geometrik dönüşümler (döndürme, çevirme, ölçekleme) ve radyometrik dönüşümler (parlaklık, kontrast değişimi) gibi yöntemlerin, eğitim setini yapay olarak zenginleştirdiğini ve modelin ezberlemesini engellediğini belirtmişlerdir. Bu tekniklerin uygulanmasıyla, modelin farklı ışık ve açı koşullarına karşı genelleme yeteneğinin belirgin şekilde arttığı sonucuna varılmıştır. Bu tez çalışmasında da literatürdeki bu öneriler dikkate alınarak hibrit bir veri artırma stratejisi izlenmiştir.

3. GEREÇ ve YÖNTEM

Bu bölümde; araştırmanın yürütülmesinde kullanılan materyaller, açık kaynaklı veri setinin elde edildiği çalışma sahasının karakteristik özellikleri ve veri toplama sürecinde kullanılan donanım altyapısı detaylandırılmıştır. Ardından, çalışmanın deneysel kurgusunu oluşturan; ham görüntülerin ön işlenmesi, karmaşık arka planların ayrıştırılması için geliştirilen hibrit segmentasyon mimarisi, veri setinin yapılandırılması ve DINOv2 tabanlı Vision Transformer modelinin eğitimi adımlarını kapsayan bütüncül metodolojik yaklaşım tüm teknik detaylarıyla ele alınmıştır.


3.1. Materyal

3.1.1. Çalışma Alanı ve Çevresel Koşullar

Bu tez çalışmasında, model eğitimi ve test süreçlerinde Dang vd. (2017) tarafından literatüre kazandırılan ve açık erişime sunulan hazır İHA (İnsansız Hava Aracı) görüntü veri seti kullanılmıştır. İlgili veri setinin temelini oluşturan saha çalışmaları, turp üretiminin yoğun olarak yapıldığı ve bu ürünün bölgesel ekonomik değerinin yüksek olduğu Kore'nin Jungsun, Gangwon ve Hongchun bölgelerinde gerçekleştirilmiştir. Veri toplama operasyonları, bitkilerin vejetatif gelişimlerinin en aktif olduğu, yaprak yüzey alanının maksimuma ulaştığı ve aynı zamanda sıcaklık/nem koşullarına bağlı olarak fungal hastalık baskısının en üst seviyeye çıktığı Temmuz ve Eylül 2016 tarihleri arasında yürütülmüştür.

Kullanılan veri setindeki görüntüleme işlemleri, kontrollü laboratuvar ortamı yerine gerçek tarla koşullarını yansıtmak amacıyla doğal aydınlatma altında gerçekleştirilmiştir. Hazır veri seti; tam güneşli, parçalı bulutlu ve yoğun bulutlu günlerde farklı saat dilimlerinde yapılan uçuşlarla oluşturulmuş olup, bu çeşitlilik geliştirilen DINOv2 modelinin değişken ışık şiddetlerine ve gölge etkilerine karşı dayanıklılığının test edilmesi için büyük bir avantaj sağlamıştır.

Çalışma alanının fiziksel yapısı, görüntü işleme algoritmaları için önemli zorluklar barındırmaktadır. Şekil 3.1'de sunulan örnek hava fotoğrafında net bir şekilde görüldüğü üzere; tarla yüzeyi sadece turp bitkilerinden ibaret değildir. Bitkiler, toprak nemini korumak ve yabancı ot kontrolü sağlamak amacıyla serilen siyah malçlama filmi ile kaplı



Şekil 3.1. Turp Tarlası (Turp Tarlasını Oluşturan Üç Alan: Turp, Toprak ve Malç Filmi)

sıralar üzerinde yetiştirilmektedir. Sıra aralarında ise açık renkli çıplak toprak alanları bulunmaktadır. Şekil 3.1’deki bu heterojen yapı; özellikle spektral yansımaları düşük olan siyah malç filmi ile bitki gölgelerinin karışması ve açık renkli toprağın yüksek yansımaya yapması nedeniyle, otomatik segmentasyon aşamasında bitki ile arka planın ayrıştırılmasını zorlaştıran en kritik çevresel faktör olarak ele alınmıştır.

3.1.2. Veri Toplama Aracı ve Görüntüleme Sistemi

Açık kaynaklı referans veri setinin oluşturulması aşamasında, rüzgârlı dış ortam koşullarında dahi yüksek stabilizasyon yeteneği ve uçuş kararlılığı sunan ticari sınıf döner kanatlı bir İHA platformu olan DJI Phantom 4 kullanıldığı bildirilmiştir. Platform üzerinde, uçuş sırasındaki titreşimleri sönmöleyen 3 eksenli (pitch, roll, yaw) stabilize gimbal sistemine entegre edilmiş bir RGB kamera bulunmaktadır. Görüntüleme sistemi, 12.4 Megapiksel efektif çözünürlüğe sahip 1/2.3” CMOS sensör ve f/2.8 diyafram açıklığına sahip bir lens ile donatılmıştır.

Literatürdeki araştırmacılar tarafından veri toplama uçuşları için operasyonel parametreler, hastalığın erken evre tespiti için kritik olan detay seviyesi ile tarama verimliliği

arasındaki denge gözetilerek optimize edilmiştir. Uçuşlar, yer seviyesinden yaklaşık 10 metre sabit irtifada ve kamera açısı yere tam dik olacak şekilde gerçekleştirilmiştir. Bu spesifik uçuş irtifası, bitki yaprakları üzerindeki milimetrik boyutlardaki hastalık lekelerinin, doku bozulmalarının ve renk değişimlerinin ayırt edilebilmesi için gereken yüksek Yer Örnekleme Mesafesini (GSD) sağlamak amacıyla seçilmiştir. 10 metre irtifadan yapılan çekimler, hem tek bir bitkinin detaylı analizine imkân veren piksel yoğunluğunu korumuş hem de makul bir alanın tek karede taranmasına olanak tanımıştır. Elde edilen ham görüntüler 4000x3000 piksel çözünürlüğünde olup, görüntü işleme aşamasında sıkıştırma kaynaklı veri kaybı yaşanmaması için yüksek kaliteli JPEG formatında sunulmuştur.

3.1.3. Veri Setinin Yapısı ve Organizasyonu

Araştırma kapsamında kullanılan hazır İHA veri setindeki 4000x3000 piksellik yüksek çözünürlüklü ham görüntüler, doğrudan derin öğrenme modellerine beslenmek için hesaplama maliyeti açısından elverişsizdir. Ayrıca, bu tezde önerilen sistemin iki aşamalı (önce arka planı temizle, sonra hastalığı tanı) yapısı, veri setinin de bu amaca hizmet edecek şekilde özelleştirilmesini zorunlu kılmıştır. Bu temel gereksinimler doğrultusunda, elde edilen açık kaynaklı veri havuzu baz alınan literatüre (Dang vd., 2017) uygun olarak iki farklı birincil veri setine dönüştürülmüştür:

Veri Seti A (Bölge Sınıflandırması ve Softmax Eğitimi İçin): Bu veri seti, tarladaki farklı fiziki bölgelerin anlamsal olarak ayırt edilebilmesi ve bu amaçla modele entegre edilen Softmax sınıflandırıcısının eğitilmesi amacıyla yapılandırılmıştır. Geleneksel tam görüntü işleme yaklaşımlarının aksine, hazır ham görüntülerden manuel olarak kırılmış ve etiketlenmiş homojen yama örneklerinden oluşur.

- **Veri Hacmi ve Sınıf Dağılımı:** Heterojen tarla yapısını temsil eden çıplak toprak , siyah malç filmi ve turp bitkisi bölgelerinden uzman görüşüyle manuel olarak kırılmış ve etiketlenmiş 1500 adet İlgi Bölgesi ayrıştırılmıştır. Şekil 3.1’de örneklendiği üzere, makine öğrenmesi modelinde sınıf dengesizliğini (class imbalance) önlemek adına her bir sınıf için tam bir denge sağlanmış; 500 adet Turp Bitkisi, 500 adet Çıplak Toprak ve 500 adet Siyah Malç Filmli örneği veri setine dahil edilmiştir.
- **Kullanım Amacı:** Bu yama tabanlı veri seti, sistemin renk ve doku öznelik uzayını

öğrenmesinin ardından, karar katmanında yer alan Softmax sınıflandırıcısının eğitilmesi için birincil veri olarak kullanılmıştır. Modelin, kendisine sunulan izole bir bölgenin turp mu, toprak mı yoksa malç filmi mi olduğuna dair nihai olasılık hesaplama ve doğru sınıfı atama yeteneği doğrudan bu veri seti üzerinden optimize edilmiş ve değerlendirilmiştir.

Veri Seti B (Hastalık Sınıflandırma ve Model Performansı İçin) : Bu veri seti, çalışmanın nihai çıktısı olan otomatik solgunluk tespit hattının gerçek saha koşullarındaki doğruluğunu ve performansını ölçmek için kullanılan ham test veri setidir.


- **Veri Hacmi ve Çözünürlük:** Saha testleri ve otomatik pipeline'ın doğrulanması için, tarla koşullarını tüm karmaşıklığıyla (gölge, toprak, malç karışımı vb.) yansıtan Dang vd. (2017) tarafından sağlanan orijinal 4000x3000 piksellik yüksek çözünürlüklü ham İHA görüntüleri kullanılmıştır.

3.2. Yöntem (Önerilen Mimari)

Bu tez çalışmasında önerilen yöntem; ham İHA görüntülerinin işlenerek bitki alanlarının karmaşık arka plandan izole edilmesi, veri setinin dengelenip zenginleştirilmesi, elde edilen verilerin hastalık şiddetine göre etiketlenmesi ve Vision Transformer tabanlı derin öğrenme modeli ile sınıflandırılmasını kapsayan uçtan uca bir mimariye dayanmaktadır. Şekil 3.2'de görselleştirilen ve 'Veri Toplama'dan 'Karar Verme' aşamasına kadar tasarlanan genel sistem mimarisi doğrultusunda, çalışmanın iş akışını oluşturan beş temel aşama aşağıda özetlenmiştir:

1. Yüksek Çözünürlüklü Veri Toplama: Sistemin ilk aşaması, Şekil 3.2'in sol tarafında İHA sembolü ile gösterildiği üzere, tarımsal alanın havadan görüntülenmesi sürecidir. İnsan gözlemine dayalı yöntemlerin fiziksel zorluklarını aşmak için, İHA kullanılarak tarladaki bitki sağlığı durumunu yansıtan yüksek çözünürlüklü ve geniş kapsamlı RGB görüntü veri seti oluşturulmuştur. Bu aşama, sistemin "gözü" niteliğinde olup, sonraki analizlerin başarısını doğrudan etkileyen ham veriyi sağlamaktadır.

2. Karmaşık Arka Planların Ayırıştırılması ve Girdi Hazırlığı: İHA vasıtasıyla elde edilen ham görüntüler; yalnızca hedef bitkiyi değil, çıplak toprak, gölge ve malç filmi gibi karmaşık arka plan unsurlarını da içermektedir. Şekil 3.2'de şematize edildiği



Şekil 3.2. Turp bitkisinde hastalık şiddetinin belirlenmesi için önerilen İHA ve DINOv2 tabanlı sistemin genel çalışma şeması.

üzere, bu aşamada söz konusu arka plan bileşenleri analiz sürecinden tamamen dışlanmıştır. Görüntülerden çok modlu renk (HSV/Lab) histogramları ve dönme varyansına dirençli Yerel İkili Desen (LBP) doku öznitelikleri çıkarılarak dengeli bir öznitelik uzayı oluşturulmuştur. Oluşan yüksek boyutlu veri, Yığınlı Oto-kodlayıcı mimarisine (SAE) beslenerek rafine edilmiş ve ardından K-means kümeleme algoritması (K=10) ile Softmax sınıflandırıcıdan oluşan hibrit bir hat üzerinden geçirilmiştir. Bu sayede izole edilen 128x128 piksel boyutundaki turp bitkisi yamaları, ana sınıflandırma hattına tamamen gürültüsüz bir veri akışı sağlamıştır.

3. Veri Artırma ve Sınıf Dengelenmesi: Derin öğrenme modellerinin en büyük kısıtlarından biri olan ezberleme problemini aşmak ve modelin arazi koşullarındaki genelleme yeteneğini artırmak amacıyla, segmentasyon adımından çıkan temiz verilere sistematik veri artırma teknikleri uygulanmıştır. Şekil 3.2’deki ”Veri Artırma” bloğunda ifade edildiği gibi, sadece eğitim setindeki bitki görsellerine havadan bakış açısının doğasına uygun olarak; rastgele döndürme , yatay/dikey aynalama ve hafif parlaklık/kontrast değişimleri uygulanmıştır. Bu işlem sayesinde eğitim verisi hacmi her bir sınıf için orantılı olarak iki katına çıkarılmış (1500’den 3000’e), modelin güneş açısı ve İHA uçuş yönü gibi fiziksel değişimlere karşı daha dirençli olması sağlanırken, test setinin orijinalliği (500’er adet) kesinlikle korunmuştur.

4. Modern ve Özgün Bir Mimari Entegrasyonu (Vision Transformer- DINOv2):

Tarımsal görüntü analizinde yaygın olarak kullanılan klasik CNN mimarileri yerine, bu çalışmada görsel temsilleri daha güçlü öğrenen özdenetimli bir yaklaşım benimsenmiştir. Şekil 3.2'in merkezinde gösterilen DINOv2 mimarisi sayesinde, modelin görüntüyü sadece pikseller yığını olarak değil, yaprağın formu ve leke dağılımı arasındaki ilişkileri kurarak "küresel bağlamda" analiz etmesi sağlanmıştır. Ayrıca, eğitim sürecinde modelin önceden eğitilmiş ağırlıklarının tümü serbest bırakılarak (Fine-Tuning) hedef veri setine tam uyumu gerçekleştirilmiştir.

5. Hastalık Şiddetinin Otomatik ve Nesnel Sınıflandırılması : Şekil 3.2'in en sağındaki çıktı katmanında görüldüğü üzere, sistem izole edilen ve eğitim süreci tamamlanan turp bitkisi görüntülerini matematiksel analizlere dayalı nesnel metrikler kullanarak sınıflandırmaktadır. Sistem; yeşil doku bütünlüğünü koruyan "Sağlıklı", geçiş formu olan "Hafif Hastalıklı" ve nekrotik alanların baskın olduğu "Ağır Hastalıklı" olmak üzere üç farklı şiddet seviyesinde otonom ve yüksek doğruluklu bir kategorizasyon yapmaktadır.

3.2.1. Görüntü Ön İşleme ve Hibrit Segmentasyon Mimarisi

Tarımsal alanlarda insansız hava araçları (İHA) veya yüksek çözünürlüklü sensörler ile elde edilen ham görüntülerde bitkiler, laboratuvar ortamlarındaki gibi izole ve homojen bir arka plan üzerinde yer almamaktadır. Aksine, gerçek tarla koşullarının doğası gereği; farklı nem oranlarına sahip çıplak toprak dokusu, güneş açısına bağlı olarak gün içinde sürekli değişen bitki gölgeleri ve ışığı yüksek oranda yansıtarak piksel bozulmalarına yol açan siyah malç filmleri ile iç içe, son derece karmaşık bir matris formunda bulunmaktadır.

Bu karmaşık çevresel faktörler, özellikle bitki hastalıklarının teşhisi gibi hassas özniteliklerin analiz edildiği derin öğrenme uygulamalarında, arka plan gürültüsünün modelin öğrenme sürecini olumsuz etkilemesine ve yanlış sınıflandırmalara yol açmasına neden olmaktadır. Ana modelin gereksiz veriyi işlemesini engellemek, hesaplama yükünü azaltmak ve yalnızca analiz edilecek bitki dokusunu hedef modele sunabilmek amacıyla geleneksel, tek kanallı eşikleme yöntemlerinin ötesine geçilmiştir.

Bu doğrultuda; piksellerin hem renk uzayındaki (örneğin RGB/HSV) ayırt edici profillerini hem de yapısal/geometrik özelliklerini eşzamanlı olarak çıkaran ve kaynaştıran

hibrit bir segmentasyon mimarisi kurgulanmıştır. Bu hibrit yaklaşım, birbirine renk olarak benzeyen ancak yapısal olarak farklı olan unsurların (örneğin gölgede kalarak kararmış yeşil bir yaprak ile siyah malç filminin veya kurumuş kahverengi bir yaprak ile çıplak toprağın) sadece piksel yoğunluklarına göre değil, aynı zamanda yüzey pürüzlülüğü ve doku örüntülerine göre de yüksek bir doğrulukla arka plandan izole edilmesini sağlamaktadır.


3.2.1.1. Çok Modlu Öznitelik Çıkarımı

Görüntü işleme tabanlı tarımsal analizlerde, hedef nesnelerin (bitki yaprakları, hastalıklı lezyonlar vb.) doğru bir şekilde tanımlanabilmesi ve karmaşık arka plandan izole edilebilmesi için tek bir öznitelik uzayına (yalnızca spektral/reng veya yalnızca uzamsal/şekil) dayanmak çoğu zaman yetersiz kalmaktadır. Açık tarla koşulları, laboratuvar ortamlarının aksine yüksek derecede dinamik ve kontrol edilemez çevresel değişkenlere sahiptir.

Örneğin; rüzgâr etkisiyle yaprakların sürekli yön değiştirmesi (yaprak altı ve üstü dokularının farklı yansımalar oluşturmaları), bitkilerin birbirinin üzerine binerek görsel bütünlüğü bozması (oklüzyon problemi) ve gün içindeki güneş açısına ya da bulutluluk oranına bağlı olarak gelişen dramatik ışık değişimleri, tek boyutlu analiz yaklaşımlarını büyük ölçüde başarısız kılmaktadır. Sadece renge dayalı çalışan sık bir model, gölgede kalan sağlıklı yeşil bir yaprağı siyah malç filmi sanarak eleyebilirken; sadece dokuya dayalı bir model ise düzensiz toprak yüzeyi ile kurumuş/hastalıklı bir yaprağı birbirine karıştırabilmektedir.

Bu kritik sınırlamaların üstesinden gelmek ve algoritmanın çevresel gürültülere karşı gürbüzlüğünü maksimize etmek amacıyla, bu çalışmada hem spektral hem de uzamsal özniteliklerin eşzamanlı olarak çıkarılıp entegre edildiği çok modlu bir yaklaşım benimsenmiştir. Renk uzayları (RGB, HSV vb.) piksellerin kimliğini ve kimyasal/biyolojik durumunu (sararma, klorofil kaybı) belirlerken; yerel doku tanımlayıcıları yaprağın damar yapısı, yüzey pürüzlülüğü ve fiziksel formu gibi yapısal karakteristikleri yakalamaktadır. Bu iki bağımsız bilgi kaynağının birleştirilmesi, aydınlatma ve geometri değişimlerine karşı oldukça dirençli, yüksek temsil gücüne sahip kapsamlı bir öznitelik uzayı oluşturulmasını sağlamıştır.

a) Doku Öznitelikleri : Değişken dış ortam aydınlatma koşullarına karşı dirençli olması ve hesaplama maliyetinin düşüklüğü nedeniyle Yerel İkili Örüntü (LBP) algoritması tercih edilmiştir. Şekil 3.3'ün üst bloğunda ("Doku Özellik Çıkarımı (LBP)") gösterildiği üzere, ham renkli görüntü öncelikle gri seviyeye ("Gri Ton Dönüşümü") dönüştürülmekte ve ardından piksel komşulukları ("LBP Hesaplama") analiz edilmektedir.



Şekil 3.3. İHA görüntülerinden turp bitkisi alanlarının belirlenmesi için önerilen hibrit segmentasyon mimarisinin akış şeması

İHA görüntülerinde bitkilerin yönelimlerinin rastgele olması nedeniyle, öznitelik çıkarımında rotasyon değişmezliğini sağlamak kritik önem taşımaktadır. Bu amaçla, sadece sabit bir komşuluk yerine, farklı yarıçap (R) ve komşuluk sayısı (P) değerlerinde çok ölçekli analiz yapılmıştır. Çalışmada kullanılan parametre setleri şunlardır:

$$(P = 8, R = 1), (P = 16, R = 2), (P = 24, R = 3) \quad (1)$$

Her bir piksel için LBP değeri, merkez piksel (g_c) ile çevresindeki komşu pikseller (g_p) arasındaki yoğunluk farkına dayalı olarak şu matematiksel modelle hesaplanmaktadır:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (2)$$

Burada $s(x)$ fonksiyonu, eşikleme işlemini gerçekleştiren bir basamak fonksiyonudur

ve şu şekilde tanımlanır:

$$s(x) = \begin{cases} 1, & x \geq 0, \\ 0, & x < 0. \end{cases} \quad (3)$$

Bu işlem sonucunda, görüntünün kenar, köşe ve düzlem gibi yapısal özelliklerini temsil eden “Doku Özellik Haritaları” elde edilir.

b) Renk Öznelikleri (HSV ve CIE L*a*b* Tabanlı Renk Çıkarımı) :Görüntü işleme tabanlı tarımsal analizlerde en sık karşılaşılan engellerden biri, çevresel aydınlatma koşullarındaki kararsızlıktır. Standart RGB (Kırmızı, Yeşil, Mavi) renk uzayı, donanım sensörleri (kamera) için temel kayıt formatı olsa da, parlaklık bilgisini her bir renk kanalıyla yüksek korelasyon içinde taşır. Bu durum, açık tarladan alınan görüntülerde bir bulut geçişi, yaprak gölgesi veya siyah malç filmi üzerindeki aşırı güneş yansıması (speküler parlama) gibi durumlarda, piksellerin RGB değerlerinin dramatik şekilde değişmesine neden olur. Görüntüdeki turp bitkisi gerçekte aynı yeşil tonda kalsa bile, salt ışık değişimi nedeniyle algoritma bunu farklı bir doku veya nesne gibi algılayarak segmentasyon hatalarına düşebilir.

Bu aydınlatma bağımlılığını aşmak ve modele optik bir gürbüzlük kazandırmak amacıyla, ham görüntüler Şekil 3.3’ün alt bloğunda (“Renk Özellik Çıkarımı (HSV/Lab)”) detaylandırıldığı gibi, renk bilgisini parlaklıktan ayıran iki farklı renk uzayına dönüştürülmüştür:

- HSV (Hue, Saturation, Value) Renk Uzayı: Bu uzay; rengin özünü veya dalga boyunu (Hue) ve rengin doygunluğunu/saflığını (Saturation), aydınlatma şiddetinden (Value) tamamen izole eder. Bu ayırıştırma sayesinde, tarladaki bir bitki yaprağı ister doğrudan güneş ışığı altında ister yoğun gölgede kalsın, ‘Hue’ değeri büyük oranda sabit kalarak algoritmaya rengin “gerçekte ne olduğunu” iletir. Böylece topografik gölge ve yansıma etkilerinin yarattığı optik yanılsamalar minimize edilir.
- CIE L*a*b* Renk Uzayı: İnsan görme sisteminin algısal doğrusallığına en yakın ve cihazdan bağımsız renk uzayıdır. Bu yapıda “L” (Lightness) kanalı yalnızca parlaklık/lüminans bilgisini üzerinde toplayarak dışarıda bırakırken, asıl renk bilgisi iki zıt kanala aktarılır: “a” kanalı yeşilden kırmızıya, “b” kanalı ise maviden sarıya olan renk spektrumunu temsil

eder. Tarımsal görüntü işlemede özellikle "a" kanalı hayati bir öneme sahiptir; çünkü bitkinin klorofil kaynaklı sağlıklı yeşil dokusunu, sararmış dokulardan ve kahverengi çıplak topraktan ayırt etmede doğal ve güçlü bir ayırıcı görevi görür.

Uygulanan bu dönüşümler ve ardından gelen kanal ayırma işlemleri sonucunda, her bir ROI'nin renk dağılımını istatistiksel olarak özetleyen renk histogramları elde edilir. Bu histogramlar, aydınlatma farklılıklarına karşı bağımsızlık kazanmış bir öznitelik vektörü oluşturarak; turp bitkisinin yeşil dokusunu, toprağın kahverengi ve malç filminin siyah tonlarından yüksek bir kesinlikle ayırmak (ve ardından uygulanacak K-means merkezlerini doğru beslemek) için modelin ihtiyaç duyduğu ayırt edici matematiksel temeli sağlar.

3.2.1.2. Çok Boyutlu Öznitelik Dengeleme ve Yıgınlı Oto-kodlayıcı (SAE) ile Optimizasyon

Görüntü analizinde nesnelerin yüksek doğrulukla tespit edilebilmesi için tek bir öznitelik türüne dayanmak genellikle yanıltıcı sonuçlar doğurmaktadır. Örneğin, yalnızca spektral öznitelikler kullanıldığında model, aydınlatma değişimleri veya gölge oyunları nedeniyle yanılgıya düşebilir; yalnızca uzamsal öznitelikler kullanıldığında ise fiziksel yüzey pürüzlülüğü benzeyen ancak anlamsal olarak farklı olan unsurlar (örneğin yaprak damarları ile kurumuş toprak toprakları) birbirine karıştırılabilir. Bu zafiyetleri gidermek ve her iki veri türünün birbirinin eksiklerini telafi ederek hedef nesnenin çok daha gülbüz ve bütüncül bir matematiksel temsilini oluşturmasını sağlamak amacıyla, elde edilen renk ve doku özellikleri birleştirilmektedir .

Ancak, görüntüden çıkarılan bu farklı karakteristiklerdeki özniteliklerin birleştirilmesi aşamasında araştırmacıların karşılaştığı en temel zorluklardan biri "Boyutsal Dengesizlik" problemidir. Bu çalışmada elde edilen doku öznitelik vektörleri, çok ölçekli LBP analizi nedeniyle yaklaşık 703000 boyutlu devasa ve seyrek bir yapıya sahipken; renk histogramlarından elde edilen vektörler yoğun fakat yalnızca 768 boyutludur. Bu denli büyük bir hacim farkı söz konusu olduğunda, vektörlerin uç uca eklenmesiyle yapılan basit bir birleştirme işlemi, yüksek boyutlu doku özniteliklerinin renk bilgisini istatistiksel olarak baskılamasına yol açmaktadır. Bu durum, modelin optimizasyon sürecinde ağırlık güncellemelerini ağırlıklı olarak doku verisine göre yapmasına ve modelin renk değişimlerine karşı körleşmesine

(duyarsızlaşmasına) neden olmaktadır.

Bu asimetrik problemi aşmak, her iki öznitelik grubunun ağ üzerindeki temsil gücünü dengelemek ve hesaplama karmaşıklığını yönetilebilir bir seviyeye çekmek amacıyla, Şekil 3.3'ün "Doğrusal Dönüşüm ve Dengeleme" modülünde gösterilen iki aşamalı bir mimari süreç uygulanmıştır:

a) Doğrusal Dönüşüm ve Varyans Eşitleme : İlk aşamada, her iki öznitelik grubu (renk ve doku) kendi içlerinde istatistiksel olarak normalize edilmiş ve varyansları eşitlenerek ortak bir sayısal uzaya yansıtılmıştır . Bu standartlaştırma işlemi, farklı ölçeklerdeki veri setlerinin sinir ağına girdiğinde gradyan patlaması veya sönümlenmesi gibi sorunlar yaratmasını engellemiş; özelliklerin eşit şartlarda rekabet etmesini sağlayarak derin öğrenme modelinin yakınsama hızını ve kararlılığını artırmıştır.

b) Yığınlı Oto-kodlayıcı (SAE) ile Boyut İndirgeme : Normalize edilmiş ancak hala çok yüksek boyutlu olan bu birleşik veriyi sıkıştırmak, gereksiz tekrarları elimine etmek ve veriyi çevresel gürültülerden arındırmak amacıyla Şekil 3.3'ün sağ üst köşesinde mimarisi verilen gözetimsiz bir derin öğrenme modeli olan Yığınlı Oto-kodlayıcı (SAE) kullanılmıştır. Temel Bileşenler Analizi (PCA) gibi doğrusal yöntemlerin aksine SAE, verideki doğrusal olmayan (non-linear) karmaşık ilişkileri modelleyebilme kapasitesine sahiptir.

- **Mimari Yapı:** Model, dıştan içe doğru daralan ve simetrik olarak yerleştirilmiş kodlayıcı ve kod çözücü bloklarından oluşan 5 katmanlı derin bir ağ yapısına sahiptir. Merkezde yer alan darboğaz katmanı, verinin en yoğun halini barındırır.
- **Gizli Temsil ve Öğrenme:** SAE, giriş verisini alıp, kodlayıcı katmanlar aracılığıyla daha düşük boyutlu bir gizli katmana kodlamakta ve ardından bu kodlanmış formdan tekrar orijinal giriş verisini yeniden oluşturmaya çalışmaktadır. Eğitim sürecinde, ağın temel amacı giriş ve çıkış arasındaki yeniden oluşturma hatasını en aza indiren ağırlıkları öğrenmektir. Bu süreç matematiksel olarak genellikle aşağıdaki kayıp fonksiyonu ile ifade edilir:

$$\mathcal{L}(x, \hat{x}) = \|x - \hat{x}\|^2 \quad (4)$$

- **Kompakt Temsil Sonucu:** Bu gözetimsiz eğitim sürecinin sonunda, giriş katmanındaki

yüz binlerce boyutlu ham ve karmaşık veri yığını; gürültüden tamamen arındırılmış, turp bitkisi ile arka planı ayırt etmeye yarayan en belirgin özellikleri barındıran ve hesaplama maliyeti açısından son derece verimli olan 1770 boyutlu kompakt bir öznitelik vektörüne başarılı bir şekilde indirgenmiştir. Sistemin bir sonraki aşamasında karar verecek olan algoritmalar (Softmax), bu optimize edilmiş kompakt vektör üzerinden beslenmektedir.

3.2.1.3. K-means Kümeleme ve Olasılıksal Bitki Maskeleye

Yığılı Oto-kodlayıcı (SAE) tarafından üretilen ve görüntünün ayırt edici "özünü" taşıyan bu kompakt öznitelik vektörleri, piksellerin anlamsal bütünlük içinde gruplandırılması için temel oluşturmuştur. Doğrudan piksel tabanlı bir sınıflandırma yaklaşımı yerine, Şekil 3.3'ün "K-means Kümeleme ve Softmax" bloğunda detaylandırılan kümeleme tabanlı hiyerarşik bir yaklaşım izlenmiştir:


- **Çok Boyutlu K-means Kümeleme:** Boyutu 1770'e indirgenmiş ve optimize edilmiş bu öznitelik uzayı üzerinde K-means algoritması çalıştırılarak, görüntüdeki tüm pikseller $K=10$ adet ayrık kümeye bölünmüştür. Bu sayı, tarla ortamının sunduğu yüksek varyansı (farklı ışık ve toprak koşulları) kapsayabilmek için deneysel olarak optimize edilmiştir.
- **Softmax ile Anlamsal Karar Mekanizması:** K-means algoritması doğası gereği denetimsiz çalıştığından, bu 10 kümenin hangi fiziksel nesneye ait olduğunu belirlemek için daha önce etiketli verilerle ("Veri Seti A") eğitilmiş bir Softmax Sınıflandırıcısı devreye girmiştir. K-means merkez vektörleri Softmax'e beslenerek her bir kümenin "Turp Bitkisi", "Çıplak Toprak" veya "Malç Filmi" sınıflarına ait olma olasılıkları hesaplanmıştır.
- **İkili Maskeleye ve Arka Plan Eliminasyonu:** Yalnızca "Turp" sınıfına ait olma olasılığı yüksek olan kümeler korunurken, toprak ve malç kümelerine ait piksellerin uzaysal değerleri sıfırlanmıştır. Bu işlem sonucunda elde edilen İkili Bitki Maskesi orijinal yüksek çözünürlüklü İHA görüntüsüne uygulanarak arka plan tamamen siyaha boyanmış ve geriye yalnızca saf turp bitkisi dokuları bırakılmıştır.

3.2.1.4. Kayan Pencere Algoritması ile Yama Üretimi

Segmentasyon işlemi ile arka plan gürültülerinden arındırılmış yüksek çözünürlüklü tarla görüntüsünün tamamını derin öğrenme modeline tek seferde beslemek, hem donanımsal olarak verimsiz hem de yerel hastalık lezyonlarının (küçük sararma veya kurumaların) tespiti

açısından isabetsiz bir yaklaşımdır. Bu nedenle, izole edilmiş turp bölgeleri üzerinden yapısal yamalar elde etmek amacıyla Kayan Pencere algoritması uygulanmıştır.

Bu işlemde, belirli bir piksel boyutuna sahip kare bir sanal pencere, segmentasyonu tamamlanmış görüntünün sol üst köşesinden başlayarak belirli bir adım aralığıyla tüm görseli taramaktadır. Görüntü içindeki siyah arka plan piksellerinin ağırlıkta olduğu boş yamalar sistem tarafından otomatik olarak elenmiş; yalnızca bitki dokusunun yoğun olduğu yamalar veri setine dahil edilmiştir. Literatürdeki referans çalışma (Dang vd., 2017) baz alınarak, hastalığın ne çok genel ne de çok mikroskobik detaylarda kaybolmasını engellemek ve en optimal yerel özellikleri yakalamak adına pencere boyutu 128x128 piksel olarak belirlenmiştir. Şekil 3.4'te görselleştirildiği üzere, bu kayan pencere süreci, heterojen tarla unsurlarını barındıran orijinal yüksek çözünürlüklü İHA görüntüsünün (işlenerek, DINOv2 mimarisine doğrudan girdi olarak beslenecek saf turp bitkisi yamalarına dönüştürülmesini otonom olarak sağlamaktadır.



Şekil 3.4. Segmentasyon algoritmasının gerçek saha verileri üzerindeki çalışma prensibi. (a) Heterojen tarla unsurlarını barındıran orijinal yüksek çözünürlüklü İHA görüntüsü;Arka plan gürültülerinden arındırılarak modele girdi olarak beslenen standartlaştırılmış (128 x 128 piksel) saf turp bitkisi yamaları.


Nihai Çıktı ve Ana Modele Geçiş: Geleneksel yöntemlerin yaşadığı arka plan karmaşasından arındırılmış ve 128x128 piksel boyutlarında standartlaştırılmış bu yüksek nitelikli bitki yamaları, çalışmanın ana hastalık teşhis motoru olan ve kendi kendine dikkat mekanizmasıyla çalışan DINOv2 modelinin doğrudan girdi verisi olarak kullanılacaktır.

3.2.2. Çıkarılan Yamaların Objektif Etiketlenmesi ve Veri Artırımı

Derin öğrenme modellerinin başarısı, eğitim verisinin kalitesine ve etiketleme sürecindeki mantıksal tutarlılığa doğrudan bağlıdır. Bu çalışmada, bir önceki kayan pencere aşamasında elde edilen 128x128 piksel boyutundaki arka planı temizlenmiş turp yamalarının, modelin öğrenme performansını maksimize edecek şekilde nesnel bir metrikle etiketlenmesi süreci titizlikle yapılandırılmıştır.

3.2.2.1. Renk Tabanlı Hastalık Kategorizasyonu

Hastalık şiddetinin belirlenmesinde insan gözüne dayalı sübjektif değerlendirmelerin (uzman görüşü dahi olsa) yaratabileceği istatistiksel tutarsızlıkları ve algısal yanılgıları ortadan kaldırmak amacıyla; bu çalışmada, matematiksel temellere dayanan ve tekrarlanabilirliği kesin olan bir Renk Tabanlı Otomatik Kategorizasyon yöntemi kullanılmıştır. Segmentasyon algoritması ile arka plan gürültüsünden tamamen arındırılan 128x128 boyutundaki bitki yamaları, hastalık şiddetinin nesnel bir metriğe dönüştürülmesi için aşağıdaki çok aşamalı analizden geçirilmiştir.



Şekil 3.5. Turp yapraklarının HSV renk dönüşümü, Binary Thresholding işlemi ve R_w oranına göre hastalık sınıflarının belirlenmesi.

HSV Dönüşümü ve Adaptif Eşikleme: Standart RGB (Kırmızı-Yeşil-Mavi) renk uzayı, ışık şiddetindeki değişimlerden fazlasıyla etkilendiği için hastalık tespiti gibi hassas renk ayrımlarında yetersiz kalabilmektedir. Bu nedenle, ilk aşamada Şekil 3.5'in ikinci sütununda ("HSV Conversion") görüldüğü üzere, tüm bitki yamaları RGB uzayından HSV (Hue, Saturation, Value) renk uzayına dönüştürülmüştür. Bu dönüşüm sayesinde, bitkinin sağlıklı yeşil dokusu ile sararmış ve kurumuş/kahverengi hastalıklı dokuları, renk özü (*Hue*) kanalı üzerinden net bir şekilde ayrıştırılabilmektedir. HSV uzayında, sağlıklı dokuları temsil eden "Yeşil" renk aralığı ile hastalıklı dokuları temsil eden "Sarı-Kahverengi" renk aralığı belirlenerek Binary Thresholding uygulanmıştır. Bu işlem sonucunda Şekil 3.5'in üçüncü sütununda gösterilen ikili maskeler elde edilmiştir; burada beyaz pikseller sağlıklı yaprak dokusunu, siyah pikseller ise hastalıklı bölgeleri temsil etmektedir.

Hastalık Şiddeti İndeksinin Hesaplanması ve Sınıflandırma: Her bir 128x128 yama için hastalığın şiddetini sayısal bir değere indirmek amacıyla, literatürde kabul gören Beyaz Piksel Oranı metriği kullanılmıştır. Bu metrik, söz konusu yama içerisindeki toplam bitki alanına kıyasla sağlıklı doku miktarını oransal olarak ifade eder. Hesaplanan değerleri kullanarak veri setindeki her bir görüntü, Dang vd. (2017) tarafından önerilen referans aralıklar baz alınarak otomatik ve nesnel olarak üç ana sınıfa (etikete) ayrılmıştır. Şekil 3.5'in son sütununda ("Classification") örnekleri verilen bu sınıflar ve kesin karar sınırları şu şekildedir:

- **Sağlıklı:** Bitki yaprağının büyük çoğunluğunun yeşil doku bütünlüğünü koruduğu ve fotosentetik aktivitenin yüksek olduğu durumdur.

Kriter:

$$R_w \geq 0.90 \quad (5)$$

(Sağlıklı doku oranı %90 ve üzeri)

- **Hafif Hastalıklı:** Hastalığın başlangıç evresidir. Yaprak üzerinde lokal sararmalar ve küçük nekrotik lekeler görülmeye başlar, ancak bitki genel formunu korur. Erken müdahale için en kritik aşamadır.

Kriter:

$$R_w \leq 0.65 \quad (6)$$

(Sağlıklı doku oranı %65 ve altı)

- Ağır Hastalıklı: Hastalığın ileri evresidir. Yaprak yüzeyinin önemli bir kısmı kurumuş, kahverengiye dönmüş veya dökülmüştür. Bitki hayati fonksiyonlarını büyük ölçüde kaybetmiştir.

Kriter:

$$R_w \leq 0.65 \quad (7)$$

(Sağlıklı doku oranı %65 ve altı)

3.2.2.2. Veri Artırma Stratejileri

Derin öğrenme modellerinin, özellikle Vision Transformer gibi devasa parametre sayısına sahip mimarilerin karşılaştığı en büyük problem; eğitim verisini ezberleyerek gerçek dünyadaki yapısal varyasyonlara karşı gürbüzlüklerini kaybetmeleridir. Bu çalışmada, modelin arazideki farklı uçuş açlarına, ışık değişimlerine ve donanım yönelimlerine karşı optik bağışıklığını artırmak amacıyla, PyTorch ekosisteminin yerleşik torchvision.transforms kütüphanesi kullanılarak çevrimdışı bir veri artırma mimarisi kurgulanmıştır.

Uygulanan bu veri hazırlama süreci, metodolojik olarak şu temel adımlardan oluşmaktadır:

a) Veri Sızıntısının Önlenmesi ve Test Seti İzolasyonu: Derin öğrenme süreçlerindeki en kritik hatalardan biri, eğitim sırasında sentetik olarak üretilen varyasyonların test setine karışmasıdır (veri sızıntısı). Bu durumu kesin olarak engellemek amacıyla, ham veri seti hiçbir artırma işlemine tabi tutulmadan önce "Eğitim" ve "Test" olarak fiziksel klasörlere ayrılmıştır. Geliştirilen algoritma, modelin nihai performansının nesnel olarak ölçüleceği Test setini tamamen korumuş, artırma işlemlerini yalnızca Eğitim seti klasörleri içerisinde gerçekleştirmiştir.

b) Hacim Genişletme ve Sınıf Dengeleme: Modelin her bir hastalık seviyesine

("Sağlıklı", "Hafif Hastalıklı", "Ağır Hastalıklı") eşit istatistiksel ağırlık verebilmesini garanti altına almak ve performansını objektif olarak ölçmek için net bir sayısal dağılım izlenmiştir. Modelin değerlendirilmesinde kullanılmak üzere her sınıftan 500 adet olmak üzere toplam 1500 adet görüntü test seti olarak ayrılmış ve orijinal haliyle izole edilmiştir. Modelin eğitim havuzunu zenginleştirmek için ise, sınıflar bazında 1500'er adet olan mevcut orijinal eğitim görüntülerinin her biri algoritmik dönüşümlerden geçirilerek birer adet sentetik varyasyon üretilmiştir. Bu işlem sayesinde her sınıf için eğitim seti tam iki katına (3000 adet) çıkarılmış ve modele beslenen toplam eğitim veri havuzu 9000 görüntü ile matematiksel olarak kusursuz bir dengeye kavuşturulmuştur.

c) Stokastik Artırma İşlem Hattı: Orijinal görüntülerden yeni varyasyonlar üretilirken, tarla ortamındaki fiziksel rastgeleliği simüle edebilmek için belirli olasılık değerleriyle çalışan transforms.Compose işlem hattı kurgulanmıştır. Python kod bloğunda uygulanan spesifik dönüşümler şunlardır:

- **Geometrik ve Mekânsal Dönüşümler:** İHA ile kuşbakışı açıda çekilen görüntülerde, yaprağın rüzgar veya dikim yönü hastalığın varlığını değiştirmez. Modelin bu "yönelim değişmezliğini" öğrenebilmesi için görüntülere %50 olasılıkla yatay ekseninde aynalama (RandomHorizontalFlip, p=0,5), %50 olasılıkla dikey ekseninde aynalama (RandomVerticalFlip, p=0,5) ve -90 ile +90 derece arasında rastgele döndürme (RandomRotation, degrees=90) uygulanmıştır.
- **Aydınlatma ve Renk Uzayı Simülasyonu:** Farklı gün saatlerindeki güneş açılarını, bulut gölgelerini ve bitkiler üzerindeki speküler parlamaları modellemek amacıyla; görüntülerin parlaklık, kontrast ve doygunluk değerleri rastgele olarak $\pm\%15$ oranında değiştirilmiştir (ColorJitter, brightness=0,15, contrast=0,15, saturation=0,15). Bu adım, modelin yalnızca yeşil/sarı renk tonuna ezber yapmasını engelleyerek DINOv2 mimarisinin dokusal ve anlamsal özelliklere odaklanmasını sağlamıştır.


3.2.3. DINOv2 Tabanlı Sınıflandırma Modeli

Çalışmanın sınıflandırma aşamasında, geleneksel Evrişimli Sinir Ağlarının (CNN) yalnızca yerel özniteliklere odaklanan yapısının ötesine geçmek amacıyla; Meta AI tarafından geliştirilen, Vision Transformer (ViT) mimarisine dayanan ve devasa veri setleri

üzerinde özdenetimli öğrenme stratejisiyle eğitilmiş olan DINOv2 modeli temel alınmıştır.

3.2.3.1. Vision Transformer (ViT) Teorisi ve DINOv2 Mimarisi

Klasik CNN mimarileri (ResNet, VGG, vb.), görüntüler üzerinde kayan filtrelerle işlem yaparak yalnızca yakın piksel komşuluklarını analiz eder. Bu yöntem kenar ve yerel doku özelliklerini yakalamada başarılı olsa da, görüntünün tamamına hakim olma konusunda "alıcı alan" sınırlamalarına takılmaktadır. Bir CNN'in görüntünün sol üst köşesi ile sağ alt köşesi arasındaki ilişkiyi kurabilmesi için çok sayıda derin katmandan geçmesi gerekir. Buna karşın DINOv2 (ViT mimarisi), görüntü işleme problemine Doğal Dil İşlemede (NLP) olduğu gibi bir "dizi işleme" problemi olarak yaklaşır.



Şekil 3.6. Vision Transformer (ViT) mimarisinin genel çalışma prensibi. Görüntü 14 x 14 piksellik yamalara bölünür, doğrusal izdüşümle vektörlere dönüştürülür ve Transformer kodlayıcıya beslenir (Dosovitskiy vd. , 2020)

Şekil 3.6'da genel mimarisi sunulan bu yaklaşımda $H \times W$ boyutundaki ve C kanallı (RGB için $C = 3$) bir giriş görüntüsü (x), öncelikle sabit boyutlu ($P \times P$) yamalara (*patches*) bölünür. Bu işlem matematiksel olarak şu şekilde ifade edilir:

$$x \in R^{H \times W \times C} \rightarrow x_p \in R^{N \times (P^2 \cdot C)} \quad (8)$$

Burada $N = \frac{H \cdot W}{P^2}$ toplam yama sayısını ifade eder. Bu çalışmada kullanılan DINOv2 modeli için yama boyutu $P=14$ olarak belirlenmiştir. Her bir yama düzleştirilerek doğrusal

bir vektöre dönüştürülür ve modelin mekânsal bilgiyi kaybetmemesi için bu vektörlere Konumsal Kodlama eklenir.

Çok Başlı Öz-Dikkat Mekanizması: DINOv2'nin çekirdeğini oluşturan ve onu CNN'lerden üstün kılan asıl güç, Transformatör Kodlayıcısı içindeki "Öz-Dikkat" mekanizmasıdır. Bu mekanizma, görüntüdeki her bir yamanın diğer tüm yamalarla olan ilişkisini ve önem derecesini eşzamanlı olarak hesaplar. Bir giriş vektörü dizisi, üç farklı vektöre dönüştürülür: Sorgu (Q), Anahtar (K) ve Değer (V). Dikkat ağırlıkları şu formülle hesaplanır:

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (9)$$

Burada $\sqrt{d_k}$, gradyanların çok büyümesini engelleyen ölçekleme faktörüdür. Bu formül sayesinde model; bir yaprağın ucundaki lokal bir sararmanın, yaprağın gövdesindeki genel klorofil kaybıyla ilişkisini, aradaki piksel mesafesi ne olursa olsun anında kurabilmektedir. CNN'lerin aksine DINOv2, daha ilk katmandan itibaren küresel bağlama erişebilir. Böylece model, sadece bölgesel bir lekeye bakıp yanılmak yerine, bitkinin genel duruşunu, damar yapısını ve lezyon dağılımını bütüncül olarak analiz ederek, özellikle "Sağlıklı" ile "Hafif Hastalıklı" gibi birbirine çok benzeyen sınır sınıflarda üstün bir ayırım gücü sağlar.

3.2.3.2. DINOv2'nin Özdenetimli Öğrenme ve Öğrenci-Öğretmen Mimarisi

DINOv2'nin klasik ViT modellerinden (örneğin ImageNet üzerinde tamamen etiketli veriyle eğitilmiş ViT'lerden) en büyük farkı, insan tarafından etiketlenmiş verilere ihtiyaç duymadan devasa veri setleri üzerinde "kendi kendine damıtma" stratejisiyle eğitilmiş olmasıdır. Bu özdenetimli sistemin merkezinde, yapısal olarak birbirinin tamamen aynısı olan ancak ağırlık güncellemeleri farklı işleyen iki sinir ağı bulunur: Öğrenci Ağı ve Öğretmen Ağı.

- **Öğrenci Ağı:** Ağırlıkları geleneksel geri yayılım algoritmaları ve gradyan inişi ile aktif olarak güncellenen asıl öğrenci modeldir. Sisteme verilen bir görüntünün sadece küçük, dar ve yerel olarak kırılmış kısımlarını görür.
- **Öğretmen Ağı :** Ağırlıkları geri yayılım ile güncellenmez. Bunun yerine, Öğrenci ağının ağırlıklarının Üstel Hareketli Ortalaması alınarak çok daha yavaş, istikrarlı ve stabil bir şekilde güncellenir. Öğretmen ağı, görüntünün dar kısımlarını değil, çok daha geniş ve

bütüncül kırılmış versiyonlarını görür.

Öğrenme Mekanizması ve Tarımsal Avantajı: Eğitim sürecinde sistemin temel amacı, Öğrenci ağının Öğretmen ağını "taklit etmesini" sağlamaktır. Aynı görüntünün farklı görünüşleri iki ağa verilir. Öğrenci ağından istenen görev; sadece dar bir lokal yamaya (örneğin yaprağın sadece sararmış küçük bir kenarına) bakarak, Öğretmen ağının tüm yaprağa bakarak ürettiği küresel matematiksel temsili başarılı bir şekilde tahmin etmesidir. İki ağın Sınıf Belirteçleri arasındaki fark, bir kayıp fonksiyonu ile hesaplanarak Öğrenci ağı cezalandırılır veya ödüllendirilir.


Bu "parçadan bütünü tahmin etme" zorlaması, modelin pikselleri ezberlemek yerine nesnelerin anlamsal bütünlüğünü kendi kendine keşfetmesini sağlar. Öğrenci ağ, sadece kurumuş bir lezyona bakarak bunun "hasta bir turp yaprağına" ait olduğunu hiçbir insan etiketi olmadan kavrar. Bu devasa asimetrik ön eğitim sayesinde DINOv2, tarımsal görüntüler gibi yapısal olarak karmaşık, arka plan gürültüsü yüksek ve etiketlemesi zor alanlarda uygulanacak transfer öğrenme görevleri için mükemmel bir temel öznitelik çıkarıcı haline gelmiştir.

3.2.3.3. Transfer Öğrenme ve İnce Ayar (Fine-Tuning) Stratejisi

Derin öğrenme modellerini "sıfırdan" (from scratch) eğitmek, devasa veri setleri ve yüksek hesaplama gücü gerektirmektedir. Bu kısıtı aşmak için çalışmada, facebook/dinov2-base ön eğitilmiş ağırlıkları başlangıç noktası olarak kullanılmıştır. Bu model, Meta AI tarafından oluşturulan ve 142 milyonluk küratörlü bir veri setini (LVD-142M) içeren devasa bir havuzda eğitilmiştir. DINOv2, bu süreçte etiketlere ihtiyaç duymadan, nesnelerin derinlik, doku ve parça-bütün ilişkilerini öğrenmiş ve "gürbüz" görsel temsiller geliştirmiştir.

Modelin genel görsel yeteneklerini, spesifik "Turp Hastalığı Sınıflandırma" görevine uyarlamak için modele özel bir Sınıflandırma Başlığı (Classification Head) entegre edilmiştir. Şekil 7'te ayrıntılı mimarisi sunulan bu süreç, aşağıdaki adımları içermektedir:

CLS Token Çıkarımı: Şekil 3.7'nin üst kısmında gösterildiği üzere, DINOv2 giriş dizisinin başına özel bir sınıflandırma jetonu ([CLS] token) ekler. 12 adet Transformer kodlayıcı bloğu boyunca işlenen bu jeton, çıkış katmanında görüntünün tamamını temsil eden yoğun bir öznitelik vektörü (genellikle 768 boyutlu) haline gelir. Bu vektör, görüntünün "küresel



Şekil 3.7. Önerilen DINOv2 tabanlı sınıflandırma mimarisi: Ön eğitilmiş Transformer kodlayıcı , [CLS] token çıkarımı ve özelleştirilmiş sınıflandırma başlığı entegrasyonu.

bağlamını” taşımaktadır.

- **Doğrusal Katman :** Elde edilen bu öznitelik vektörü, şemada ”Custom Classification Head” olarak belirtilen tam bağlantılı bir katmana iletilir. Bu katman, 768 boyutlu vektörü hedef sınıf sayısına ($N_{class}=3$: Sağlıklı, Hafif, Ağır) indirgeyen doğrusal bir dönüşüm uygular:

$$y = Wh_{[CLS]} + b \quad (10)$$

Burada W ağırlık matrisini, b sapma değerini ve $h_{[CLS]}$ ise omurgadan gelen öznitelik vektörünü temsil eder.

- **Tam İnce Ayar (Full Fine-Tuning) ve Karşılaştırmalı Strateji Analizi:** Literatürdeki standart transfer öğrenme yaklaşımlarının aksine, bu çalışmada yalnızca sınıflandırıcı son katmanın eğitilmesiyle (Linear Probing) yetinilmemiştir. Gerçekleştirilen karşılaştırmalı deneysel analizler, modelin sadece son katmanı eğitildiğinde hastalık evreleri arasındaki ince sınırları öğrenmekte yetersiz kaldığını göstermiştir. Bu nedenle, modelin tarımsal görüntülerin spesifik dokusuna ve özellikle ”Hafif Hastalıklı” sınıfındaki hassas renk geçişlerine tam adaptasyonunu sağlamak amacıyla, Şekil 3.7’deki mavi blokta yer alan

omurga mimarisi de dahil olmak üzere tüm ağırlıkların serbest bırakılıp güncellendiği ”Full Fine-Tuning” stratejisi izlenmiştir. Bu sayede model, devasa veri setlerinden önceden öğrendiği evrensel görsel özellikleri, turp yaprağı hastalıklarına özgü hücrel ve dokusal detaylarla harmanlayarak sınıflandırma başarısını ve genelleme yeteneğini maksimize etmiştir.

3.2.4. Eğitim Parametreleri, Donanım ve Performans Metrikleri

Çalışma kapsamında gerçekleştirilen veri ön işleme (hibrit segmentasyon, LBP ve HSV/Lab öznitelik çıkarımı) ve bitki yamalarının yapılandırılması aşamaları; VMware sanallaştırma platformu üzerinde yapılandırılmış yüksek işlem kapasitesine sahip yerel bir sunucu altyapısında yürütülmüştür. Deneysel kurgunun temelini oluşturan bu donanım ortamı; çift işlemcili Intel® Xeon® Silver 4216 (2.10 GHz) mimarisine, geniş veri setlerinin bellek içi işlenmesine olanak tanıyan 64 GB RAM kapasitesine ve yüksek hızlı veri okuma/yazma operasyonları için 500 GB SSD depolama birimine sahiptir.

DINOv2 gibi yüksek hesaplama maliyeti gerektiren Vision Transformer (ViT) mimarilerinin eğitimi, Çok Başlı Öz-Dikkat mekanizmaları nedeniyle yoğun tensör ve matris çarpımı işlemleri gerektirmektedir. Bu nedenle, modelin derin öğrenme tabanlı eğitim ve ince ayar aşamalarında bulut tabanlı Google Colab platformuna geçiş yapılmış ve ağırlık güncellemeleri NVIDIA T4 GPU (16 GB VRAM) donanım hızlandırıcısı üzerinde gerçekleştirilmiştir. Modelin başlangıç noktası olarak, Meta AI tarafından geliştirilen ve PyTorch Hub üzerinden sağlanan ön eğitilmiş DINOv2 (dinov2-base) mimarisi sisteme entegre edilmiştir. Literatürdeki benzer çalışmaların aksine modelin sıfırdan eğitilmemesinin temel nedeni; ViT mimarilerinin bilinen ”veri açlığı” kısıtını aşmak ve ön eğitilmiş modelin milyonlarca veriden kazandığı ”gülbüz” öznitelik temsillerini turp hastalıklarına özgü hücrel parametrelerle harmanlamaktır.

Bu doğrultuda modelin optimizasyonu; yukarıda belirtilen CPU tabanlı yerel sunucu altyapısında yürütülen segmentasyon hattının ardından, bulut tabanlı GPU altyapısında gerçekleştirilen Karşılaştırmalı Strateji Analizi ile yürütülmüştür. Bu aşamada, ön eğitilmiş ağırlıkların kullanıldığı iki farklı transfer öğrenme yaklaşımı test edilmiştir: Modelin omurgasının dondurularak sadece son sınıflandırma katmanının eğitildiği Doğrusal

Sınıflandırma (Linear Probing) ve tüm mimari ağırlıkların hedef veriye adapte edildiği Tam İnce Ayar (Full Fine-Tuning) stratejileri ardışık olarak uygulanıp kıyaslanmıştır. Gerçekleştirilen bu sistematik yaklaşım, modelin sıfırdan eğitilmesine kıyasla hesaplama maliyetini, bellek gereksinimini ve eğitim süresini minimize ederken; aynı zamanda hangi stratejinin tarımsal hastalık tespitinde en yüksek kararlılık ve doğruluğu sağladığının bilimsel metriklerle ispatlanmasına olanak tanımıştır.

3.2.4.1. Hiperparametre Optimizasyonu ve Eğitim Konfigürasyonu

Modelin sınıflandırma katmanı , DINOv2'nin omurgasından üretilen 768 boyutlu gömülüm vektörlerini 3 farklı hastalık sınıfına ("Sağlıklı", "Hafif Hastalıklı", "Ağır Hastalıklı") indirecek şekilde özel olarak yapılandırılmıştır. Hata (kayıp) fonksiyonunu minimize etmek ve genelleme yeteneğini maksimize etmek amacıyla kullanılan hiperparametreler empirik denemeler sonucunda optimize edilmiştir. Python eğitim betiğinde kullanılan temel eğitim parametreleri ve seçilme gerekçeleri aşağıda detaylandırılmıştır:

- Görüntü Boyutu (Input Resolution): 128 x 128 piksel. Gerekçe: Çalışma kapsamında segmentasyon aşamasından izole edilerek elde edilen turp yaprağı yamaları, DINOv2 mimarisinin yama tabanlı dikkat mekanizmasının tutarlı çalışabilmesi için 128x128 piksel boyutuna standartlaştırılmıştır. Bu boyut, yaprak üzerindeki lokal hastalık lezyonlarının doku detaylarını korurken, donanım kaynaklarının (RAM) verimli kullanılmasını ve hesaplama maliyetinin optimum dengede kalmasını sağlamıştır. DINOv2 mimarisi, kendisine verilen bu bütünsel girdiyi kendi işlem hattında 14 x14 piksellik alt yamalara bölerek analiz etmektedir.
- Küme Boyutu (Batch Size): 32. Gerekçe: Gradyan inişi optimizasyonunda gradyanların gürültülü olmasını engellemek ve kararlı bir öğrenme süreci sağlamak için 32'lik yığın boyutu tercih edilmiştir. Bu değer, modelin ağırlık güncellemelerinin ne çok sık (kararsızlık riski) ne de çok seyrek (yavaş yakınsama) olmasını sağlayarak öğrenme dinamiği ile GPU bellek (VRAM) kullanımını optimize etmiştir.
- Epok Sayısı (Epochs): 20. Gerekçe: Modelin eğitim döngüsü toplam 20 epok olarak planlanmıştır. Ancak derin katmanların tüm ağırlıklarının eğitime açıldığı Tam İnce Ayar (Full Fine-Tuning) sürecinde modelin eğitim verilerini ezberleme (overfitting)

eğilimine girdiği gözlemlenmiştir. Bu akademik kısıtı aşmak adına kod mimarisine ”En İyi Model Denetimi” (Best Model Checkpoint) mekanizması dahil edilmiştir. Sistem 20 epok boyunca çalıştırılmış, ancak eğitim verilerini ezberlemeye başlamadan hemen önce doğrulama başarısının zirve yaptığı epoktaki (artırılmış veri setinde 4. epok) optimal ağırlıklar nihai model olarak kalıcı kaydedilmiştir.

- Öğrenme Oranı (Learning Rate): (1×10^{-5}) . Gerekçe: Bu parametre, model ağırlıklarının her adımda ne kadar güncelleneceğini belirler. DINOv2’nin önceden öğrendiği güçlü evrensel öznitelik temsillerini ”felaketsel unutma” reaksiyonuyla kaybetmemesi için öğrenme oranı ince ayar (fine-tuning) standartlarına uygun olarak son derece düşük tutulmuştur. Bu sayede model, mevcut görsel hafızasını koruyarak sadece turp hastalıklarının mikroskopik lezyon geçişlerine odaklanmıştır.
- Ağırlık Azaltma (Weight Decay): 0,0001 Gerekçe: Modelin eğitim verisini ezberlemesini önlemek için bir L2 Regularizasyon tekniği olan ağırlık azaltma uygulanmıştır. Bu parametre, ağırlık değerlerinin aşırı büyümesini cezalandırarak modelin karmaşıklığını kontrol altında tutmuş ve test verisi üzerindeki başarımını artırmıştır.
- Optimizasyon Algoritması: AdamW (Adaptive Moment Estimation with Weight Decay). Gerekçe: Standart Adam optimizasyonuna göre ağırlık azaltma (L2 regülasyonu) işlemini doğrudan maliyet fonksiyonuna uygulayarak ağırlıkları daha doğru güncelleyen AdamW algoritması tercih edilmiştir. Transformer tabanlı modellerde kararlı gradyan akışı sağlama ve hızlı yakınsama konusundaki başarısı nedeniyle bu tercih yapılmıştır.
- Kayıp Fonksiyonu (Loss Function): Çapraz Entropi Kaybı (Cross Entropy Loss). Gerekçe: Ele alınan problem, birbirini dışlayan üç ayrık sınıftan (”Sağlıklı”, ”Hafif Hastalıklı”, ”Ağır Hastalıklı”) oluştuğu için, modelin tahmin ettiği olasılık dağılımı ile gerçek çoklu etiketler arasındaki farkı cezalandıran Çapraz Entropi fonksiyonu kullanılmıştır. Matematiksel olarak şu modelle ifade edilir:

$$L = - \sum_{c=1}^M y_{o,c} \log(p_{o,c}) \quad (11)$$

Burada M sınıf sayısını (3), y gerçek etiketi ve p tahmin edilen olasılığı temsil eder.

3.2.4.2. Performans Değerlendirme Metrikleri

Geliştirilen DINOv2 tabanlı derin öğrenme modelinin başarımı, sadece eğitim verisi üzerindeki kayıp değerleriyle değil, daha önce model tarafından hiç görülmemiş test verileri üzerindeki genelleme yeteneği ile ölçülmüştür. Sınıflandırma sonuçlarının güvenilirliğini ve tutarlılığını kantitatif olarak ortaya koymak amacıyla, literatürde kabul gören aşağıdaki nesnel performans metrikleri kullanılmıştır. Bu metriklerin hesaplanmasında; Doğru Pozitif (TP), Doğru Negatif (TN), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) değerleri temel alınmıştır.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

Bu çalışmada sınıflar (Sağlıklı, Hafif, Ağır) dengeli dağıtıldığı için doğruluk oranı güvenilir bir gösterge olarak kabul edilmiştir.

Kesinlik (Precision): Modelin "pozitif" (örneğin hasta) olarak tahmin ettiği örneklerin ne kadarının gerçekten o sınıfa ait olduğunu gösterir. Tarımsal uygulamalarda kesinlik, gereksiz ilaçlamanın önlenmesi açısından kritiktir; yani modelin sağlıklı bir bitkiye yanlışlıkla "hasta" dememesi (Düşük FP) istenir.

$$Precision = \frac{TP}{TP + FP} \quad (13)$$

Duyarlılık (Recall / Sensitivity): Gerçekte hasta olan bitkilerin ne kadarının model tarafından doğru bir şekilde tespit edilebildiğini ölçer. Bir hastalık tespit sisteminde en hayati metriklerden biridir; çünkü hastalığın gözden kaçırılması (Yüksek FN), enfeksiyonun tarlada yayılmasına neden olabilir.

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

F1-Skoru (F1-Score): Kesinlik ve Duyarlılık metriklerinin harmonik ortalamasıdır. Özellikle sınıf dengesizliğinin olduğu veya Yanlış Pozitif ve Yanlış Negatif hatalarının eşit derecede önemli olduğu durumlarda modelin kararlılığını gösteren en kritik metriktir. Aritmetik ortalama yerine harmonik ortalamanın kullanılması, uç değerlerin etkisini azaltarak modelin her iki metriği de (Precision ve Recall) dengeli bir şekilde optimize

etmesini zorunlu kılar:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (15)$$

Karışıklık Matrisi (Confusion Matrix): Sayısal metriklerin ötesinde, modelin hangi sınıfı hangi sınıfla karıştırdığını görselleştirmek ve hatanın kaynağını analiz etmek için kullanılan N x N boyutlu (bu çalışmada 3 x 3) bir tablodur.

- Matrisin köşegen elemanları doğru sınıflandırma sayılarını gösterirken, köşegen dışı elemanlar hataları temsil eder.
- Bu çalışma özelinde; biyolojik olarak birbirine benzeyen "Hafif Hastalıklı" sınıfı ile "Sağlıklı" sınıfı arasındaki geçişlerin (karışıklıkların) analizi bu matris üzerinden detaylandırılmıştır.

4. BULGULAR

Bu bölümde, turp bitkisinde hastalık şiddetinin tespiti amacıyla önerilen ve "Gereç ve Yöntem" bölümünde detaylandırılan bütüncül derin öğrenme mimarisinin performansı kapsamlı bir şekilde analiz edilmiştir. Elde edilen bulgular; (1) karmaşık tarla görüntülerinin işlenmesini sağlayan hibrit segmentasyon aşamasının istatistiksel sonuçları, (2) DINOv2 tabanlı sınıflandırma modelinin farklı transfer öğrenme modları altındaki eğitim süreçleri ve yakınsama karakteristikleri ve (3) bağımsız test veri seti üzerinde hesaplanan nesnel sınıflandırma metrikleri (Doğruluk, Kesinlik, Duyarlılık, F1-Skoru) olmak üzere üç ana başlık altında sunulmuştur. Ayrıca, elde edilen deneysel sonuçlar literatürdeki referans çalışmalarla kıyaslanarak, önerilen yöntemin hassas tarım uygulamalarındaki özgün katkısı ve potansiyeli tartışılmıştır.

4.1. Turp Bölgesi Sınıflandırma Sonuçları ve Değerlendirmesi

Çizelge 4.1. Softmax sınıflandırması için çapraz doğrulama karışıklık matrisi

Gerçek/Tahmin	Turp	Çıplak Toprak	Malç Filmi
Turp	463	35	2
Çıplak Toprak	0	471	29
Malç Filmi	0	32	468

Tablo 4.1 incelendiğinde, modelin 500 adet turp bitkisi örneğinin 463'ünü tam doğrulukla sınıflandırdığı; 35 örneğin çıplak toprak, 2 örneğin ise malç filmi olarak yanlış etiketlendiği gözlemlenmiştir. Çıplak toprak sınıfında 500 örneğin 471'i (%94,20) başarılı şekilde tespit edilmiş, malç filmi sınıfında ise 468 örnek doğru sınıflandırılmıştır. Özellikle turp bitkisi ile malç filmi arasındaki karışıklık oranının (yalnızca 2 örnek) son derece düşük düzeyde kalması, modelin klorofil içeren yeşil canlı doku ile spektral yansıması düşük olan siyah polietilen malç dokusunu ayırt etmedeki başarısını kanıtlamaktadır.

Sınıflandırma hatalarının genel olarak çıplak toprak ve malç filmi geçiş sınırlarında (sırasıyla 32 ve 29 hatalı tahmin) kümelenmiş olması, İHA fotoğraflarındaki gün içi güneş açısı değişimlerinin yarattığı yerel gölgelenmelerin ve toprak parlamalarının piksel spektrumları üzerindeki doğal bir sonucudur. Karışıklık matrisi verileri üzerinden sistemin

genel performans metrikleri makro ortalama baz alınarak hesaplanmış ve Tablo 4.2’de listelenmiştir.

Çizelge 4.2. Segmentasyon Aşaması Performans Metrikleri (Makro Ortalama)

Performans Metriği	Hesaplanan Oran (%)
Kesinlik	%93,61
Duyarlılık	%93,60
F-Ölçütü	%93,60

Yapılan analiz sonucunda; hibrit segmentasyon hattının Kesinlik oranı %93,61, Duyarlılık oranı %93,60 ve iki metriğin harmonik ortalaması olan F-Ölçütü %93,60 olarak bulunmuştur. Elde edilen bu yüksek başarımlı seviyesi sayesinde, tarla görüntülerinin segmentasyonu ve arka plan temizleme görevleri için önerilen hattın güvenilirliği kanıtlanmıştır. Nitekim bu algoritma hattı, 40 adet orijinal yüksek çözünürlüklü ham İHA fotoğrafına ("Veri Seti B") kayan pencere yöntemiyle uygulanarak, ana hastalık teşhis motoru (DINOv2) için arka plan gürültülerinden arındırılmış yaklaşık 50000 adet saf turp yaprağı girdi yaması (piksel) üretmiş ve gürbüz bir metodolojik temel oluşturmuştur.

4.2. DINOv2 Sınıflandırma Performans Bulguları ve Karşılaştırmalı Analiz

Geliştirilen DINOv2 tabanlı derin öğrenme modelinin nihai hastalık şiddeti kategorizasyon performansı; model eğitimi, doğrulama veya veri artırma aşamalarında sisteme kesinlikle gösterilmemiş, tamamen izole edilmiş bağımsız bir test kümesi üzerinde değerlendirilmiştir. Modelin gerçek dünya koşullarındaki (açık tarla) genelleme kabiliyetini objektif ve adil bir biçimde ölçmek amacıyla, bu test kümesi her bir hastalık aşamasından ("Sağlıklı", "Hafif Hastalıklı", "Ağır Hastalıklı") tam adaletli olarak 500'er adet olmak üzere toplam 1500 adet saf görüntüden oluşturulmuştur.

Önerilen derin öğrenme yaklaşımının özgün değerini ve matematiksel üstünlüğünü ortaya koymak amacıyla, transfer öğrenme metodolojisinin iki temel modu olan Doğrusal Sınıflandırma (Linear Probing) ve Tam İnce Ayar (Full Fine-Tuning) stratejileri, hem orijinal eğitim verisi (4500 yama) hem de zenginleştirilmiş artırılmış eğitim verisi (9000 yama) durumları altında çapraz olarak test edilmiştir. Yürütülen bu deneysel kurgunun

genel doğruluk (Accuracy) ve makro F1-skoru sonuçları bütünsel olarak Tablo 4.3'te karşılaştırılmıştır.

Çizelge 4.3. Çapraz Deneysel Senaryoların Genel Başarım Matrisi

Deney No	Uygulanan Öğretim Modu	Eğitim Verisi Durumu (Sınıf Başına / Toplam)	Genel Doğruluk (Accuracy)	Makro F1-Skoru
1	Doğrusal Sınıflandırma (Linear Probing)	Orijinal Eğitim Seti (1500 / 4500)	%76,87	0,7696
2	Doğrusal Sınıflandırma (Linear Probing)	Artırılmış Eğitim Seti (3000 / 9000)	%77,53	0,7726
3	Tam İnce Ayar (Full Fine-Tuning)	Orijinal Eğitim Seti (1500 / 4500)	%94,27	0,9424
4	Tam İnce Ayar (Full Fine-Tuning)	Artırılmış Eğitim Seti (3000 / 9000)	%94,67	0,9466


Tablo 4.3'teki makro veriler incelendiğinde, derin öznitelik çıkarıcı transformatör omurgasının dondurularak sadece son doğrusal katmanın eğitildiği Linear Probing senaryolarının (Deney 1 ve Deney 2) %76-77 seviyesinde bir başarıım sınırına takıldığı görülmektedir. Buna karşın, ağırlık tüm katman katman ağırlıklarının öğrenme oranıyla serbest bırakılarak hedef tarımsal patoloji uzayına uyarlandığı Full Fine-Tuning stratejisi (Deney 3 ve Deney 4) performansı doğrudan %94 bandının üzerine taşımıştır. Çevrimdışı veri artırma metodolojisi ile desteklenen Tam İnce Ayar modeli (Deney 4), %94,67 genel doğruluk ve 0,9466 makro F1-skoru elde ederek bu tez çalışmasının şampiyon mimarisi olarak tescillenmiştir.

4.2.1. Transfer Öğrenme Modellerinin İstatistiksel Anlamlılık ve Kararlılık Analizi

Tablo 4.3'te sunulan Doğrusal Sınıflandırma (Linear Probing) ile Tam İnce Ayar (Full Fine-Tuning) stratejileri arasındaki performans farkının rastlantısal olup olmadığını belirlemek ve modellerin kararlılık durumlarını görselleştirmek amacıyla, kutu grafiği destekli istatistiksel analiz gerçekleştirilmiştir (Şekil 4.1). Bu istatistiksel analize temel sağlamak amacıyla, her iki model on farklı rastgele başlangıç tohumu ile bağımsız olarak yeniden eğitilmiş ve elde edilen doğruluk metrikleri Tablo 4.4'te detaylandırılmıştır.

Çizelge 4.4. Farklı başlangıç tohumları ile elde edilen bağımsız doğruluk oranları

Deneme No	Linear Probing	Full Fine-Tuning
1	%77,80	%94,27
2	%78,00	%95,07
3	%77,87	%94,93
4	%78,40	%94,40
5	%77,73	%94,68
6	%77,95	%94,55
7	%77,65	%94,82
8	%78,10	%94,60
9	%77,82	%94,75
10	%77,90	%94,63

**Şekil 4.1.** Transfer öğrenme stratejilerinin doğruluk dağılımları ve Wilcoxon istatistiksel anlamlılık analizi.

Şekil 4.1’de sunulan görsel dağılımlar incelendiğinde; model omurgasının dondu-
rulduğu Linear Probing stratejisine ait doğruluk oranının nispeten dar bir varyansla %77

bandında baskılandığı görülmektedir. Buna karşın, tüm mimari ağırlıkların güncellendiği Full Fine-Tuning modelinin gövde dağılımı, net bir ayrışma göstererek %94,67'lik genel doğruluk seviyesi etrafında istikrarlı bir şekilde yoğunlaşmıştır. Kutuların örtüşmemesi ve üst bantta yer alması, modelin dışsal çevresel gürültülere karşı kazandığı kararlılığı simgelemektedir.

İki model arasındaki bu belirgin performans sıçramasının bilimsel geçerliliği, Tablo 4.4'te sunulan değerler üzerinden parametrik olmayan Wilcoxon İşaretli Sıralar Testi ile analiz edilmiştir. Yapılan istatistiksel test sonucunda elde edilen p değeri ($p = 0,0020$), Full Fine-Tuning modelinin sergilediği başarının, Linear Probing modeline kıyasla istatistiksel olarak çok yüksek anlamlılık düzeyinde ($p < 0,01$) üstün olduğunu kanıtlamaktadır. Bu görsel ve istatistiksel bulgular bütünü; elde edilen performans artışının tesadüfi bir veri dağılımından kaynaklanmadığını, klasik CNN modellerine kıyasla önerilen mimarinin hedef tarımsal patoloji uzayına yapısal olarak çok daha üstün bir adaptasyon sağladığını kesin olarak doğrulamaktadır.

4.3. Doğrusal Sınıflandırma (Linear Probing) Bulgularının Yapısal Analizi

Vision Transformer omurgasının sabit tutulduğu ve sadece karar katmanının eğitildiği deney senaryolarında, 1500 görüntülük bağımsız test seti üzerinde elde edilen sınıf bazlı detaylı metrikler ve hata raporları Tablo 4.4'te alt başlıklar halinde sınıflandırılmıştır.

Çizelge 4.5. Linear Probing Senaryoları Sınıf Bazlı Performans Raporu

Veri Seti Modeli	Hastalık Sınıfı	Kesinlik	Duyarlılık	F1-Skoru	Görüntü Desteği
Orijinal Veri	Sağlıklı	%78,03	%83,80	%80,81	500
(Genel Doğruluk: %76,87)	Ağır Hastalıklı	%87,80	%79,20	%83,28	500
	Hafif Hastalıklı	%66,02	%67,60	%66,80	500
Artırılmış Veri	Sağlıklı	%79,29	%85	%82,05	500
(Genel Doğruluk: %77,53)	Ağır Hastalıklı	%82,85	%85	%83,91	500
	Hafif Hastalıklı	%69,40	%62,60	%65,83	500

Linear Probing modellerinin hata karakteristiği incelendiğinde, en belirgin zafiyetin Hafif Hastalıklı sınıfında kümelendiği görülmektedir. Orijinal eğitim verisinde bu sınıf için 0,6680 olan F1-skoru, veri artırımı desteğiyle ancak 0,6583 - 0,6940 hassasiyet dengesine gelebilmiştir. Bu durumun teorik dayanağı; genel amaçlı internet görüntülerinden (ImageNet) özdenetimli olarak öğrenilen evrensel DINOv2 ağırlıklarının, tarımsal yapraklar üzerindeki çok erken evre kloroz lezyonları gibi mikro-dokusal ve patolojik renk geçişlerini izole sınıflandırıcı katmana aktarabilecek spesifik öznetelik duyarlılığına sahip olmamasıdır. Bu kısıt, tüm ağırlıkların güncellenmesini zorunlu kılmıştır.

4.4. Tam İnce Ayar (Full Fine-Tuning) ve Sınıf Sınırı Bulgularının Değerlendirilmesi

Model omurgasının dondurulmayıp, klorofil kaybına uğramış yaprak dokularına tam uyarlandığı Full Fine-Tuning model çıktılarının sınıf bazlı metrik analizi Tablo 4.5'te sunulmuştur.

Çizelge 4.6. Full Fine-Tuning Senaryoları Sınıf Bazlı Performans Raporu

Veri Seti Modeli	Hastalık Sınıfı	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skoru	Görüntü Desteği (Support)
Orijinal Veri	Sağlıklı	%94,77	%94,20	%94,48	500
(Genel Doğruluk: %94,27)	Hafif Hastalıklı	%95,36	%98,60	%96,95	500
	Ağır Hastalıklı	%92,59	%90	%91,28	500
Artırılmış Veri	Sağlıklı	%95,88	%93	%94,42	500
(Genel Doğruluk: %94,67)	Ağır Hastalıklı	%96,48	%98,60	%97,53	500
	Hafif Hastalıklı	%91,67	%92,40	%92,03	500

Full Fine-Tuning stratejisine geçilmesiyle birlikte tüm sınıfların başarımlarında çok büyük bir sıçrama yaşanmıştır. Orijinal veri eğitim logları incelendiğinde, modelin 12. epoktan itibaren eğitim kaybını sıfıra yaklaştırarak eğitim verisinde %100 doğruluğa vurduğu, yani ezberleme (overfitting) eğilimi gösterdiği tespit edilmiştir. Ancak bu yapısal risk, 9000 görüntülük Artırılmış Veri kurgusu ve doğrulama setini anlık takip eden checkpoint denetimiyle tamamen sönmülmüştür. Şampiyon model, ezberlemeye düşmeden

önce test setinde en yüksek kararlılığa ulaştığı 4. epokta (%94,67 doğruluk) nihai ağırlıklarını kilitlemiştir.

Hata doğrulamalarının yapay zekadan ziyade biyolojik temellerini ortaya koyabilmek adına, şampiyon modelin bağımsız test seti üzerinde ürettiği nihai Karışıklık Matrisleri analiz edilmiştir:

- Uç Sınıf İzolasyonu (Sağlıklı ve Ağır Hastalıklı): Görsel olarak birbirine en uzak karakteristik sunan Sağlıklı ve Ağır Hastalıklı yaprak pikselleri model tarafından kusursuz ayrıştırılmıştır. Gerçekte "Ağır Hastalıklı" olan 500 örneğin tek bir tanesi bile "Sağlıklı" sanılmamış, 493'ü (%98,60) tam isabetle yakalanmıştır. Tarladaki salgını gözden kaçırmama (False Negative oranını düşürme) noktasında bu %98,60'lık Duyarlılık (Recall) değeri tarımsal ekonomi için hayati bir güvencedir.
- Biyolojik Geçiş Bölgesi Analizi (Hafif Hastalıklı): Sınıflandırma kayıplarının neredeyse tamamı, adeta sürekli bir spektrum gibi ilerleyen "Hafif Hastalıklı" sınıfının sınırlarında gerçekleşmiştir. Gerçekte Sağlıklı olan 35 yaprak "Hafif Hastalıklı" olarak tahmin edilirken; Hafif Hastalıklı olan 20 yaprak "Sağlıklı", 18 yaprak ise "Ağır Hastalıklı" olarak etiketlenmiştir. Bitki patolojisinde Fusarium solgunluğu keskin bir eşikle değil, mikroskopik klorozlardan makro nekrozlara doğru hücrel olarak ilerlediği için bu sınır belirsizlikleri doğaldır. Buna rağmen, şampiyon modelin bu zorlu geçiş evresinde bile 0,9203 F1-skoru gibi yüksek bir kararlılık yakalaması, DINOv2 mimarisindeki Çok Başlı Öz-Dikkat mekanizmasının küresel bağlam yakalama gücünü tescillemektedir.

4.5. Literatür Karşılaştırması ve Benchmarking Tartışması

Önerilen derin öğrenme mimarisinin literatürdeki yerini ve özgün katkısını doğrulamak amacıyla; bu tezin veri tabanını, tarla lokasyonlarını ve uçuş parametrelerini doğrudan referans aldığımız Dang vd. (2017) çalışması ile doğrudan bir benchmarking analizi gerçekleştirilmiştir (Tablo 4.6).

Çizelge 4.7. Klasik CNN ve Önerilen ViT Mimari Karşılaştırması

Araştırma Referansı	Kullanılan Derin Öğrenme Modeli	Değerlendirme Test Kümesi Yapısı	Genel Doğruluk Oranı
Dang vd. (2017)	Klasik Evrişimli Sinir Ağı (CNN)- GoogleNet	3 Sınıf x 500 Görüntü (Toplam 1500)	%91,00
Bu Çalışma (Önerilen)	Vision Transformer (ViT)- DINOv2 (Fine-Tuned)	3 Sınıf x 500 Görüntü (Toplam 1500)	%94,67

Dang vd. (2017), transfer öğrenme yoluyla eğittikleri evrişimli sinir ağı tabanlı GoogleNet mimarisiyle, 1500 görüntülük test setinde %91,00 genel doğruluk elde ettiklerini raporlamışlardır. Doğrudan ve adil bir kıyaslama yapılabilmesi adına birebir aynı test veri seti kapasitesi (adet ham yama) üzerinde yürüttüğümüz bu tez çalışmasında ise, önerilen DINOv2 tabanlı transformatör modeli %94,67 genel doğruluk oranına ulaşarak literatür başarımını belirgin bir şekilde ileriye taşımıştır.

Klasik evrişimli (CNN) mimariler, yerel filtre pikselleri üzerinden kaydırılarak çalıştıkları için yaprağın sadece lokal bir bölgesindeki renk değişimine odaklanmakta ve katmanlar derinleştikçe uzamsal çözünürlük kaybına uğramaktadırlar. Bu durum, karmaşık tarla ortamında GoogleNet'in anlamsal bağlamı kaçırmaya yol açmıştır. Önerilen özdenetimli DINOv2 modeli ise, sahip olduğu self-attention katmanları sayesinde yaprağın form bütünlüğü, damar yapısı ve lezyon dağılımı arasındaki uzamsal ilişkileri aradaki piksel mesafesinden bağımsız olarak bütüncül bir düzlemde haritalandırmıştır. Bu bilimsel bulgular, Vision Transformer yaklaşımlarının, İHA tabanlı otonom hassas tarım taramalarında klasik yöntemlere kıyasla çok daha etkin, güvenilir ve yenilikçi bir alternatif olduğunu kesin olarak ortaya koymaktadır.

5. TARTIŞMA

Bu tez çalışmasında, hassas tarım uygulamalarında verimliliği doğrudan etkileyen ve ciddi ekonomik kayıplara yol açan turp bitkisi hastalıklarının erken ve doğru tespiti için; İnsansız Hava Aracı (İHA) teknolojileri ile Vision Transformer (ViT) mimarisine dayanan özdenetimli DINOv2 modelini entegre eden yenilikçi bir otonom karar destek sistemi geliştirilmiştir. Geleneksel yöntemlerin aksine, problemi sadece bir görüntü sınıflandırma işi olarak değil; veri toplama, gürültü giderme, hibrit segmentasyon ve derin öznitelik analizi aşamalarını kapsayan bütüncül bir süreç olarak ele alan bu çalışmada elde edilen deneysel bulgular; (1) biyolojik faktörlerin ve fenotipik değişimlerin sınıflandırma başarısı üzerindeki etkisi, (2) derin öğrenme mimarilerinin yapısal farklılıklarının (CNN ve ViT karşılaştırması) performansa yansımaları, (3) uygulanan transfer öğrenme modlarının (Linear Probing ve Full Fine-Tuning) yakınsama dinamikleri ve (4) veri işleme stratejilerinin model kararlılığına katkısı olmak üzere dört ana ekseninde derinlemesine tartışılmıştır.

5.1. Model Performansının Biyolojik ve İstatistiksel Değerlendirilmesi

Geliştirilen DINOv2 tabanlı şampiyon modelin 1500 görüntülük bağımsız test kümesi üzerindeki davranışları, performans metrikleri ve nihai karışıklık matrisi üzerinden analiz edildiğinde; sınıflandırma başarısının, bitkinin hastalık sürecindeki biyolojik ve fenotipik değişimleriyle doğrudan ve güçlü bir korelasyon gösterdiği tespit edilmiştir.

- **Uç Sınıflarda Yüksek Spektral Ayırt Edicilik:** Model, hastalığın biyolojik olarak en belirgin uç noktalarını temsil eden "Sağlıklı" ve "Ağır Hastalıklı" sınıflarını birbirinden ayırmada kusursuza yakın bir performans sergilemiştir. Bu başarının temelinde yatan biyolojik faktör; sağlıklı yaprakların yüksek fotosentetik aktiviteye ve klorofil yoğunluğuna bağlı olarak sergilediği homojen yeşil doku ile, ağır hastalıklı yaprakların Fusarium wilt kaynaklı hücre ölümü ve pigment kaybı sonucu oluşan kahverengi/sarı deformasyonları arasındaki yüksek spektral kontrasttır. Model, bu iki sınıf arasındaki öznitelik uzayı mesafesini maksimize etmeyi başarmıştır. Özellikle tarımsal mücadelede kesinlikle kaçırılmaması gereken vaka grubu olan "Ağır Hastalıklı" sınıfının, sağlıklı bitki olarak yanlış sınıflandırılma oranının %0 (500 örnekte 0 adet) olması ve sınıf içi duyarlılığın %98,60 gibi muazzam bir seviyede kalması, önerilen sistemin saha güvenilirliğinin

ve Yanlış Negatif riskinin minimal düzeyde olduğunun en güçlü kanıtıdır. Bu durum, modelin hastalık semptomlarını sadece yüzeysel renk değişimleri olarak değil, yaprak morfolojisindeki yapısal bozukluklar seviyesinde öğrendiğini göstermektedir.

- **Biyolojik Geçiş Bölgesi ve "Hafif Hastalıklı" Sınıfı Sınırları:** Karışıklık matrisindeki hataların neredeyse tamamının bir ara form olan "Hafif Hastalıklı" sınıfının sınırlarında (35 adet sağlıklı yaprağın hafif hasta sanılması ve 20 adet hafif hasta yaprağın sağlıklı sanılması) yoğunlaşması, modelin bir zafiyeti olmaktan ziyade, hastalığın patolojik gelişim sürecinin doğal ve beklenen bir sonucudur. "Hafif hastalık" evresi, sağlıklı dokudan nekrotik dokuya geçişin yaşandığı, semptomların henüz tam oturmadığı ve görsel sınırların bulanıklaştığı dinamik bir süreçtir. Bu evredeki bir yaprak hem sağlıklı yeşil alanları hem de başlangıç aşamasındaki mikroskobik lekelenmeleri aynı anda barındırmaktadır. Görsel öznelitliklerin her iki komşu sınıfa da spektral benzerlik göstermesi, modelin karar sınırlarında istatistiksel bir belirsizlik yaratmıştır. Literatürde Dang vd. (2017) ve Barbedo (2019) gibi araştırmacıların da vurguladığı üzere, bilgisayarlı görü modellerinde en düşük performansın genellikle bu tür geçiş sınıflarında görülmesi, elde ettiğimiz bulguların literatürle uyumlu olduğunu ve problemin doğasından kaynaklandığını doğrulamaktadır. Buna rağmen, sınırda yer alan bu karmaşık geçiş formlarındaki toplam hatanın minimumda tutulması ve hafif hastalık sınıfında 0,9203 F1-skoru gibi yüksek bir kararlılık yakalanması, modelin bu belirsiz alanlarda bile üstün bir ayırt etme yeteneği sergilediğini ortaya koymaktadır.

5.2. Mimari Üstünlük Tartışması: Konvolüsyonel Ağlar (CNN) ve Vision Transformer (ViT)

Bu çalışmanın literatüre sağladığı en özgün katkılardan biri, tarımsal görüntü analizinde uzun yıllardır standart kabul edilen CNN tabanlı modeller ile yeni nesil ViT tabanlı modellerin karşılaştırmalı analizidir. Referans çalışma olan Dang vd. (2017) tarafından kullanılan GoogleNet (CNN) mimarisi ile bu çalışmada önerilen DINOv2 (ViT) mimarisi arasındaki net performans farkı (%91'e karşı %94,67) sadece sayısal bir yarış değil, mimari yapıların veriyi işleme mantığındaki temel farklılıkların somut bir sonucudur.

- **Yerel Özelliklerden Küresel Bağlama:** CNN mimarileri (GoogleNet, ResNet vb.), sahip oldukları "tümevarımcı önyargı" ve sınırlı yerel alıcı alanlar nedeniyle, görüntüdeki özelliklere parçalı yaklaşma eğilimindedir. Bir CNN, matematiksel olarak yaprağın bir köşesindeki sarı lekeyi (yerel doku) mükemmel tespit edebilirken, bu lekenin yaprağın genelindeki dağılımı veya diğer lekelerle olan geometrik ilişkisini (uzun mesafeli bağımlılıklar) kurmakta zorlanabilir. Buna karşın, DINOv2 mimarisinin çekirdeğini oluşturan "Çok Başlı Öz-Dikkat" mekanizması, görüntüdeki her bir pikselin veya yamanın, diğer tüm piksellerle olan ilişkisini eş zamanlı olarak hesaplamaktadır. Bu yetenek sayesinde model, sadece lokal bir lekeyi değil; bitkinin genel duruşunu, yaprak geometrisindeki bozulmayı ve doku bütünlüğünü bir arada değerlendirerek küresel bağlamı yakalamaktadır. Hastalık tespiti gibi bağlamsal bütünlüğün önemli olduğu görevlerde ViT mimarisinin bu üstünlüğü, doğruluk artışının temel nedenidir.
- **Özdenetimli Öğrenme ve Gürbüz Öznitelikler:** GoogleNet gibi modeller etiketli veriye dayalı gözetimli öğrenme ile eğitilirken; temel aldığımız DINOv2 mimarisi, milyonlarca görüntü üzerinde etiket olmadan, özdenetimli öğrenme prensibiyle ön eğitilmiştir. Bu süreç, modelin nesnelerin sadece rengini veya şeklini değil; derinlik, doku, parça-bütün ilişkisi ve anlamsal bütünlük gibi çok daha karmaşık ve dayanıklı özniteliklerini öğrenmesini sağlamıştır. Bu çalışmada, görsel ayrımların zor olduğu durumlarda DINOv2'nin daha yüksek performans göstermesi, transfer öğrenme yoluyla aktarılan bu güçlü öznitelik temsili yeteneği ile açıklanabilir.

5.3. Öğretme Stratejisinin Yakınsama ve Kararlılık Üzerindeki Etkisi

Tez kapsamında yürütülen Karşılaştırmalı Strateji Analizi, modelin optimizasyon sürecinde sadece karar katmanına müdahale etmenin tarımsal patolojideki yetersizliğini açıkça ortaya koymuştur.

- **Linear Probing vs. Full Fine-Tuning:** Sadece son katmanın eğitildiği Linear Probing senaryolarında, model omurgası ImageNet dünyasındaki ağırlıklarında sabit kaldığı için genel doğruluk %76,87- %77,53 bandında bloke olmuştur. Bu durum, genel amaçlı nesne özniteliklerinin, turp yapraklarındaki *Fusarium solgunluğu* gibi spesifik mikroskobik semptomları yakalamada kör kaldığını göstermektedir. Ancak Tam İnce Ayar (Full

Fine-Tuning) stratejisiyle tüm derin katmanların ağırlıkları eğitime açıldığında, öğrenme oranı gibi kontrollü bir seviyede tutularak modelin evrensel görsel hafızası korunmuş ve ağır turp patolojisine tam adaptasyonu sağlanmıştır. Bu stratejik hamle, modelin genel başarısını doğrudan %94,67 seviyesine fırlatmıştır.

5.4. Veri Stratejisinin Etkisi: Dengesizlik, Varyasyon ve Ezber Yönetimi

Derin öğrenme modellerinin başarısı, sadece mimari üstünlüğe değil, aynı zamanda veri setinin kalitesine, çeşitliliğine ve temsil gücüne de sıkı sıkıya bağlıdır. Bu çalışmada izlenen veri stratejisi, modelin genelleme yeteneğini doğrudan etkileyen kritik bir faktör olmuştur.

- **Sınıf Dengesizliği Probleminin Yönetimi:** Orijinal veri setinden kırılan yamaların doğası gereği ortaya çıkabilecek sınıf dengesizliği riskini ortadan kaldırmak amacıyla uygulanan dengeli örnekleme mimarisi, modelin çoğunluk sınıfına karşı yanlılık geliştirmesini kesin olarak engellemiştir. Modelin genel F1-skorunun (0,9466), genel doğruluk oranıyla (%94,67) neredeyse tamamen paralel seyretmesi; modelin hiçbir sınıfa karşı istatistiksel bir önyargı geliştirmedeğinin, "tembel tahmin" yapmadığının ve tüm kategorilere karşı adil ve optimum bir karar sınırı hizaladığının en güçlü matematiksel kanıtıdır.
- **Veri Artırma ve Ezber Kontrolü:** Modelin tüm katmanlarının eğitime açıldığı Full Fine-Tuning sürecinde, orijinal veri seti kullanıldığında (Deney 3) modelin 12. epoktan itibaren eğitim verilerini ezberleme eğilimine girdiği log analizlerinde net bir şekilde gözlemlenmiştir. Bu kısıt, torchvision.transforms kütüphanesiyle kurgulanan; rastgele döndürme, yatay/dikey aynalama ve %15'lik renk/parlaklık oynamalarını içeren çevrimdışı veri artırma stratejisiyle aşılmıştır. Eğitim veri hacminin 4500'den 9000'e çıkarılması veri çeşitliliğini artırmış ve modelin ezberleme duvarına çarpmasını engellemiştir. Doğrulama setini anlık takip eden checkpoint denetimi sayesinde, şampiyon model test setinde en yüksek kararlılığa ulaştığı 4. epokta ağırlıklarını sabitleyerek en yüksek genelleme kapasitesine ulaşmıştır. Veri sızıntısını önlemek adına test setinin (1500 adet saf görüntü) hiçbir artırma işlemine tabi tutulmadan tamamen izole edilmesi ise, elde edilen sonuçların bilimsel geçerliliğini ve akademik güvenilirliğini pekiştirmiştir.

6. SONUÇLAR

Hızla artan dünya nüfusu ve değişen iklim koşulları, tarımsal üretimde verimliliğin maksimize edilmesini ve ürün kayıplarının minimize edilmesini zorunlu kılmaktadır. Bu bağlamda gerçekleştirilen bu tez çalışmasında; hassas tarım teknolojilerinin en güncel bileşenleri olan İnsansız Hava Araçları (İHA) ve bilgisayarlı görü alanında devrim yaratan Vision Transformer (ViT) tabanlı derin öğrenme mimarileri entegre edilerek, turp bitkisinde ciddi ekonomik kayıplara yol açan solgunluk hastalığının tespitine yönelik otonom, nesnel ve yüksek doğruluklu bir karar destek sistemi geliştirilmiştir. Çalışma süresince yürütülen kapsamlı literatür taraması, titizlikle uygulanan metodolojik adımlar ve elde edilen deneysel bulgular ışığında varılan temel sonuçlar ve sektörel çıkarımlar aşağıda maddeler halinde detaylandırılmıştır:

- **Bütüncül ve Gürbüz Bir İzleme Mimarisi:** Bu tez çalışması, problemi sadece bir görüntü sınıflandırma görevi olarak ele almamış; ham görüntülerin sahadan toplanmasından nihai hastalık kararına kadar geçen tüm süreçleri kapsayan uçtan uca ve gürbüz bir çözüm mimarisi ortaya koymuştur. Özellikle çalışmanın metodolojik özgünlüğünü oluşturan Hibrit Segmentasyon Modeli, sistemin başarısındaki en kritik yapı taşıdır. K-means kümeleme algoritması ve derin öğrenme tabanlı Yığılmış Otoenkoder (Stacked Autoencoder - SAE) yapısının entegrasyonu sayesinde; İHA görüntülerinde sıkça karşılaşılan ve sınıflandırma modellerini yanıltma potansiyeli yüksek olan karmaşık arka plan unsurları (siyah malçlama filmi, bitki gölgeleri, farklı nemlilikteki toprak dokusu) %93,60 F1-skoru başarıyla elimine edilmiştir. Bu ön işlem başarısı, sınıflandırma modeline gürültüsüz, sadece ilgili bitki dokusuna odaklanmış ve yüksek kaliteli verilerin aktarılmasını sağlayarak, sistemin değişken saha koşullarındaki güvenilirliğini maksimize etmiştir.
- **Literatür Standartlarını Aşan Sınıflandırma Performansı** Geliştirilen DINOv2 tabanlı sınıflandırma modeli, sınıf dengesizliğinin giderildiği ve istatistiksel geçerlilik açısından her sınıf için 500 adet görüntünün (toplam 1500) bulunduğu bağımsız ve zorlu bir test kümesi üzerinde değerlendirilmiştir. Tam İnce Ayar (*Full Fine-Tuning*) yöntemiyle elde edilen %94,67 genel doğruluk ve 0,9466 makro F1-skoru, modelin literatürdeki mevcut

standartları aştığını somut verilerle kanıtlamaktadır. Bu sonuçlar, aynı veri tabanı hacmini ve benzer ön işleme prosedürlerini kullanan ancak klasik Evrişimli Sinir Ağı (CNN) mimarisi olan GoogleNet'e dayalı referans çalışmanın (Dang vd., 2017) elde ettiği %91,00'lik doğruluk oranını açık ara geride bırakmıştır. Referans çalışmayla birebir aynı kapasitede (1500 görüntü) ve adil şartlarda gerçekleştirilen testlerde sağlanan bu %3,67'lik net performans artışı, önerilen yöntemin genelleme yeteneğinin istatistiksel olarak daha üstün ve kararlı olduğunu doğrulamaktadır.

- **Mimari Üstünlük:** CNN ve Vision Transformer Farkı: Elde edilen deneysel bulgular, bilgisayarlı görü alanında yaşanan paradigma değişiminin (CNN'den Transformer'a geçiş) tarımsal uygulamalardaki yansımaları teorik ve pratik olarak ortaya koymuştur. Klasik CNN modelleri (GoogleNet, ResNet vb.), sahip oldukları yerel alıcı alanlar ve tümevarımcı önyargı nedeniyle görüntüdeki özelliklere parçalı yaklaşırken; DINOv2'nin sahip olduğu "Çok Başlı Öz-Dikkat" mekanizması, görüntüdeki pikseller arası uzun mesafeli ilişkileri kurarak küresel bağlamı yakalayabilmektedir. Bu yapısal avantaj, modelin sadece lokal bir lekeyi değil; yaprağın genel duruşunu, doku bütünlüğünü ve leke dağılımını bir arada analiz etmesini sağlamıştır. Sonuç olarak DINOv2, özellikle görsel belirtilerin belirsiz olduğu ve biyolojik geçişin yaşandığı "Hafif Hastalıklı" sınıfın tespitinde (0,9203 F1-Skoru), klasik mimarilere kıyasla çok daha kararlı bir performans sergilemiştir.
- **Veri Stratejisinin Kararlılığa Etkisi ve Yanlılığın Önlenmesi** Tez çalışmasında uygulanan veri işleme stratejileri, derin öğrenme modellerinin en büyük handikaplarından biri olan "sınıf dengesizliği" (*class imbalance*) problemini başarıyla çözmüştür. Eğitim aşamasında uygulanan çevrimdışı sentetik veri üretimi (*data augmentation*) stratejisi, modelin çoğunluk sınıfına ezber yapmasını engellemiş ve olası bir yanlılığı (*bias*) tamamen ortadan kaldırmıştır. Karışıklık matrisi analizleri, modelin tarımsal mücadele ve karantina tedbirleri açısından en kritik grup olan "Ağır Hastalıklı" sınıfını sağlıklı bitkilerden ayırmada %98,60 Duyarlılık düzeyinde bir isabete ulaştığını göstermiştir. Bu sonuç, geliştirilen sistemin tarlada ileri evre hastalık vakalarını kaçırma riskinin (Yanlış Negatif / *False Negative*) minimal düzeyde olduğunu ve pratik uygulamalar için yüksek güvenlik marjına sahip olduğunu teyit etmektedir.
- **Özdenetimli Öğrenmenin Tarımsal Potansiyeli** Çalışmanın teorik açıdan en önemli çıktısı-

larından biri, etiketli verinin sınırlı ve maliyetli olduğu tarımsal problemlerde özdenetimli öğrenme yaklaşımlarının başarısının kanıtlanmasıdır. DINOv2'nin devasa ve etiketsiz veri setlerinde önceden öğrendiği güçlü görsel temsiller, transfer öğrenme yöntemiyle bu çalışmaya başarıyla aktarılmıştır. Bu durum, gelecekte yapılacak çalışmalarda binlerce veriyi manuel olarak etiketleme zahmetine girmeden, az sayıda veriyle yüksek başarılı modellerin geliştirilebileceğini göstermesi açısından umut vericidir. DINOv2, sadece bir sınıflandırıcı değil, tarımsal görüntüler için evrensel bir öznetelik çıkarıcı olarak potansiyelini kanıtlamıştır.

- **Sektörel Katkı ve Gelecek Vizyonu** Sonuç olarak bu tez çalışması; modern yapay zeka mimarilerinin hassas tarım uygulamalarına entegrasyonunun, geleneksel insan gözlemine dayalı yöntemlere kıyasla çok daha hızlı, ekonomik, tekrarlanabilir ve nesnel çözümler sunduğunu ortaya koymuştur. Geliştirilen sistem, geniş tarım arazilerinin otonom İHA'larla taranmasına, hastalık haritalarının yüksek hassasiyetle çıkarılmasına ve kimyasal ilaçlamanın tarlanın tamamına değil, sadece enfekte bölgelere yapılmasına olanak tanımaktadır. Bu yaklaşım, sadece üreticinin girdi maliyetlerini düşürmekle kalmayacak, aynı zamanda aşırı pestisit kullanımının önüne geçerek çevresel sürdürülebilirliğe, ekolojik dengenin korunmasına ve gıda güvenliğine doğrudan katkı sağlayacaktır. Gelecek çalışmalarda, sistemin multispektral kameralarla desteklenmesi ve modelin mobil platformlarda gerçek zamanlı çalışacak şekilde optimize edilmesi, bu teknolojinin "Tarım 5.0" vizyonu çerçevesindeki etkisini daha da artıracaktır.

7. ÖNERİLER

Bu tez çalışması kapsamında, hassas tarım teknolojilerinin en güncel bileşenleri olan İnsansız Hava Araçları (İHA) ve bilgisayarlı görü alanında devrim yaratan Vision Transformer (DINOv2) mimarisi entegre edilerek; turp bitkisinde önemli verim kayıplarına yol açan solgunluk hastalığının tespitine yönelik otonom, nesnel ve yüksek doğruluklu bir karar destek sistemi geliştirilmiştir. Elde edilen başarılı deneysel sonuçlar ve çalışma sürecinde edinilen teknik deneyimler ışığında; hem akademik literatürdeki mevcut boşlukları dolduracak gelecek çalışmalara hem de geliştirilen sistemin sahaya entegrasyonu ile üreticilere katma değer sağlayacak pratik uygulamalara yönelik kapsamlı öneriler aşağıda iki ana ekseninde sunulmuştur.

1.Akademik ve Gelecek Çalışmalara Yönelik Öneriler:Bilimsel araştırmaların sürekliliği ve kümülatif ilerleme ilkesinden hareketle, bu çalışmanın kapsamını genişletecek, modelin yeteneklerini artıracak ve literatüre özgün katkılar sunacak teknik öneriler şunlardır:

- **Modelin Genellenebilirliği ve Alan Adaptasyonu:** Bu çalışmada DINOv2 modeli spesifik olarak turp bitkisi veri seti üzerinde optimize edilmiştir. DINOv2 mimarisinin en güçlü yanı olan transfer öğrenme ve az veriyle öğrenme yeteneklerinin sınırlarını test etmek amacıyla; geliştirilen modelin morfolojik olarak benzer (şalgam, havuç, pancar) veya tamamen farklı (mısır, buğday) bitki türlerindeki hastalıklara uyarlanması önerilmektedir. Gelecek çalışmalarda, modelin sadece tek bir hastalığı değil; külleme, yaprak lekesi, pas ve mildiyö gibi semptomları birbirine benzeyen farklı fungal ve bakteriyel hastalıkları aynı anda ayırt edebilecek Çoklu Sınıflandırma yeteneğine kavuşturulması, sistemin tanısal gücünü artıracaktır.
- **Çoklu Sensör Veri Füzyonu :**Mevcut çalışma, yüksek çözünürlüklü RGB görüntüleri ile sınırlıdır. Ancak bitki patolojisi literatürü, hastalıkların yaprak rengini değiştirmeden (semptomatik evre) çok önce, bitkinin stoma iletkenliğini, su stresini ve yaprak yüzey sıcaklığını değiştirdiğini göstermektedir. Gelecek çalışmalarda, sisteme termal ve multispektral sensörlerin entegre edilmesi kritik önem arz etmektedir. RGB sensörden alınan yapısal doku bilgisi ile multispektral/termal kameradan alınan stres verisinin Erken Füzyon veya Geç Füzyon teknikleriyle yapay zeka düzeyinde birleştirilmesi; hastalığın

henüz gözle görülür belirti vermediği Semptomsuz Evrede tespit edilmesini sağlayarak akademik literatüre öncü bir katkı sunacaktır.

- **Gerçek Zamanlı Tespit ve Uç Bilişim :** Mevcut sistemde görüntüler İHA ile kaydedildikten sonra yer istasyonundaki güçlü donanımlarda işlenmektedir. Hastalıkla mücadelede müdahale süresini minimuma indirmek için, geliştirilen DINOv2 modelinin optimize edilerek (örneğin *Model Quantization* veya *Pruning* yöntemleriyle küçültülerek) NVIDIA Jetson veya benzeri enerji verimli gömülü sistemler (*Edge Devices*) üzerinde çalıştırılması önerilmektedir. Böylece İHA, henüz havadayken görüntüyü işleyip, yer istasyonuna anlık olarak "Enfeksiyon Tespit Edildi" uyarısı ve GPS koordinat bilgisi gönderebilecek tam otonom bir yapıya kavuşturulabilir.
- **Uzamsal-Zamansal (*Spatiotemporal*) Analiz ve Epidemik Modelleme:** Hastalık, statik bir durum değil, dinamik bir süreçtir. Tek bir zaman diliminde alınan görüntüler yerine, bitkinin fenolojik büyüme periyodu boyunca belirli aralıklarla (örneğin haftalık) alınan görüntülerin zaman serisi olarak incelenmesi önerilmektedir. Gelecek çalışmalarda, Vision Transformer mimarisinin LSTM (*Long Short-Term Memory*) gibi zaman serisi modelleriyle birleştirilmesi sayesinde; hastalığın tarladaki yayılma hızı ve yayılma vektörü (rüzgar veya sulama hattı yönü) modellenenebilir. Bu sayede tarımsal alanlar için "Epidemik Risk Haritaları" oluşturularak proaktif koruma stratejileri geliştirilebilir.

2.Sektörel ve Uygulamaya Yönelik Öneriler

Geliştirilen akademik çıktının laboratuvar ortamından çıkarılıp gerçek tarımsal üretim döngüsüne entegre edilmesi, sürdürülebilir tarım hedefleri ve tarımsal ekonomi açısından hayati öneme sahiptir. Bu bağlamda önerilen pratik saha uygulamaları şunlardır:

- **Değişken Oranlı Uygulama (VRT) ve İlaçlama Dronlarına Entegrasyon:** Geleneksel tarımda tüm tarla, hastalık olsun ya da olmasın homojen bir şekilde ilaçlanmaktadır. Bu çalışmada elde edilen yüksek hassasiyetli hastalık şiddeti haritalarının, koordinatlı uçuş yapabilen otonom tarımsal ilaçlama dronlarına (Örn: DJI Agras serisi) bir Reçete Haritası formatında yüklenmesi önerilmektedir. Böylece dron, tarlanın tamamını değil, sadece sistemin "Hasta" olarak işaretlediği bölgeleri (*Hotspots*) hedef alarak Noktasal İlaçlama yapabilecektir. Bu yaklaşım, pestisit ve kimyasal kullanımını radikal bir şekilde azaltarak

hem üreticinin girdi maliyetlerini düşürecek hem de toprak/su kaynaklarının kirlenmesini önleyecektir.

- **Mobil Karar Destek Sistemi ve Bulut Entegrasyonu:** Çiftçilerin, ziraat mühendislerinin ve tarım danışmanlarının sahada herhangi bir teknik donanım ihtiyacı duymadan sistemi doğrudan kullanabilmesi için, geliştirilen DINOv2 modelinin bulut tabanlı bir akıllı telefon uygulamasına API aracılığıyla entegre edilmesi önerilmektedir. Çiftçinin cep telefonu kamerasıyla çektiği şüpheli bir yaprak fotoğrafının sunucuya iletilip saniyeler içinde "*Hastalık Şiddeti: Ağır Hasta - Önerilen İlaç Grubu: Fungisit X*" şeklinde raporlanması, sahada son kullanıcıya büyük bir pratik fayda sağlayacaktır.
- **Otonom Hasat Planlaması ve Rekolte Tahmini:** Hastalık tespiti ile elde edilen verilerin, tarımsal rekolte tahmini modelleriyle entegre edilmesi önerilmektedir. Sezon başında ağır hastalık tespit edilen ve tedaviye yanıt vermeyen bölgelerin rekolte kaybı hesaplanarak, üreticinin sezon sonu verim beklentisini önceden revize etmesi ve tedarik ziraati planlamasını buna göre yapması sağlanabilir. Ayrıca, geleceğin otonom hasat robotları için; hastalıklı ve kalitesi düşük ürünlerin hasat edilmeden tarlada bırakılması veya sağlıklı ürünlerden ayrı depolanması gibi kalite kontrol süreçlerinde bu sistemin bir "görsel denetleyici" olarak kullanılması mümkündür.
- **Sürdürülebilirlik ve Yeşil Mutabakat Uyumu:** Bu sistemin otonom kullanımı, Avrupa Birliği Yeşil Mutabakatı ve Çiftlikten Çatala stratejisi kapsamında hedeflenen "tarımsal pestisit kullanımının %50 azaltılması" hedefine doğrudan hizmet etmektedir. Tarım politikası yapıcılarına, yerel yönetimlere ve ziraat odalarına; yapay zekâ destekli bu tür hassas tarım teknolojilerini kullanan üreticilere teşvik/hibe vermeleri, dijital tarım okuryazarlığını artırmaları ve bu sistemlerin yaygınlaşmasını desteklemeleri güçlü bir şekilde önerilmektedir.

KAYNAKLAR

- Agrawal, J., & Arafat, M. Y. (2024). Transforming Farming: A Review of AI-Powered UAV Technologies in Precision Agriculture. *Drones*, 8(11), 664. <https://doi.org/10.3390/drones8110664>
- Barbedo, J. G. A. (2018). Impact of Dataset Size and Variety on the Effectiveness of Deep Learning and Transfer Learning for Plant Disease Classification. *Computers and Electronics in Agriculture*, 153, 46–53. <https://doi.org/10.1016/j.compag.2018.08.013>
- Barbedo, J. G. A. (2019). A Review on the Use of Unmanned Aerial Vehicles and Imaging Sensors for Monitoring and Assessing Plant Stresses. *Drones*, 3(2), 40. <https://doi.org/10.3390/drones3020040>
- Caron, M., Touvron, H., Misra, I., Jégou, H., Mairal, J., Bojanowski, P., & Joulin, A. (2021). Emerging Properties in Self-Supervised Vision Transformers. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 9650–9660.
- Dang, L. M., Hassan, S. I., Im, S., Sangaiah, A. K., Mehmood, I., Rho, S., Seo, S., & Moon, H. (2017). UAV Based Wilt Detection System via Convolutional Neural Networks. *Sustainable Computing: Informatics and Systems*, 16, 33–41. <https://doi.org/10.1016/j.suscom.2017.09.001>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). An Image Is Worth 16x16 Words: Transformers for Image Recognition at Scale. *International Conference on Learning Representations*. <https://openreview.net/forum?id=YicbFdNTTy>
- Espejo-Garcia, B., Güldenring, R., Nalpantidis, L., & Fountas, S. (2025). Foundation Vision Models in Agriculture: DINOv2, LoRA and Knowledge Distillation for Disease and Weed Identification. *Computers and Electronics in Agriculture*, 239, 110900. <https://doi.org/10.1016/j.compag.2025.110900>
- Hamuda, E., Glavin, M., & Jones, E. (2016). A Survey of Image Processing Techniques for Plant Extraction and Segmentation in the Field. *Computers and Electronics in Agriculture*, 125, 184–199. <https://doi.org/10.1016/j.compag.2016.04.024>
- Han, K., Wang, Y., Chen, H., Chen, X., Guo, J., Liu, Z., & Tao, D. (2022). A Survey on Vision Transformer. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(1), 87–110. <https://doi.org/10.1109/TPAMI.2022.3152247>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep Learning in Agriculture: A Survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Kerkech, M., Hafiane, A., & Canals, R. (2020). Vine Disease Detection in UAV Multispectral Images Using Optimized Image Registration and Deep Learning Segmentation

- Approach. *Computers and Electronics in Agriculture*, 174, 105446. <https://doi.org/10.1016/j.compag.2020.105446>
- Khan, A. T., Jensen, S. M., Khan, A. R., & Li, S. (2023). Plant Disease Detection Model for Edge Computing Devices. *Frontiers in Plant Science*, 14, 1308528. <https://doi.org/10.3389/fpls.2023.1308528>
- Khan, S., & Narvekar, M. (2022). Novel Fusion of Color Balancing and Superpixel Based Approach for Detection of Tomato Plant Diseases in Natural Complex Environment. *Journal of King Saud University-Computer and Information Sciences*, 34(6), 3506–3516. <https://doi.org/10.1016/j.jksuci.2021.01.008>
- Laveglia, S., Altieri, G., Genovese, F., Matera, A., & Renzo, G. C. D. (2024). Advances in Sustainable Crop Management: Integrating Precision Agriculture and Proximal Sensing. *AgriEngineering*, 6(3), 3084–3120. <https://doi.org/10.3390/agriengineering6030177>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Mace, M. E. (2012). *Fungal Wilt Diseases of Plants*. Elsevier Academic Press.
- Maes, W. H., & Steppe, K. (2019). Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. *Trends in Plant Science*, 24(2), 152–164. <https://doi.org/10.1016/j.tplants.2018.11.007>
- Oerke, E. C. (2006). Crop Losses to Pests. *The Journal of Agricultural Science*, 144(1), 31–43. <https://doi.org/10.1017/S0021859605005708>
- Oquab, M., Darcet, T., Moutakanni, T., Vo, H., Szafraniec, M., Khalidov, V., & Bojanowski, P. (2023). DINOv2: Learning Robust Visual Features Without Supervision. *arXiv preprint arXiv:2304.07193*.
- Radoglou-Grammatikis, P., Sarigiannidis, P., Lagkas, T., & Moscholios, I. (2020). A Compilation of UAV Applications for Precision Agriculture. *Computer Networks*, 172, 107148. <https://doi.org/10.1016/j.comnet.2020.107148>
- Reedha, R., Dericquebourg, E., Canals, R., & Hafiane, A. (2022). Transformer Neural Network for Weed and Crop Classification of High Resolution UAV Images. *Remote Sensing*, 14(3), 592. <https://doi.org/10.3390/rs14030592>
- Savary, S., vd. (2019). The Global Burden of Pathogens and Pests on Major Food Crops. *Nature Ecology & Evolution*, 3, 430–439. <https://doi.org/10.1038/s41559-018-0793-y>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A Survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6, 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Sokolova, M., & Lapalme, G. (2009). A Systematic Analysis of Performance Measures for Classification Tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>

- Tetila, E. C., Machado, B. B., Astolfi, G., de Souza Belete, N. A., Amorim, W. P., Roel, A. R., & Pistori, H. (2020). Detection and Classification of Soybean Pests Using Deep Learning with UAV Images. *Computers and Electronics in Agriculture*, 179, 105836. <https://doi.org/10.1016/j.compag.2020.105836>
- Tsouros, D. C., vd. (2019). A Review on UAV-Based Applications for Precision Agriculture. *Information*, 10(11), 349. <https://doi.org/10.3390/info10110349>
- Wang, S., Xu, D., Liang, H., Bai, Y., Li, X., Zhou, J., Su, C., & Wei, W. (2025). Advances in Deep Learning Applications for Plant Disease and Pest Detection: A Review. *Remote Sensing*, 17(4), 698. <https://doi.org/10.3390/rs17040698>
- Wang, Z., Wang, K., Pan, S., & Han, Y. (2018). Segmentation of Crop Disease Images with an Improved K-Means Clustering Algorithm. *Applied Engineering in Agriculture*, 34(2), 277–289.
- Zhang, C., & Kovacs, J. M. (2019). The Application of Small Unmanned Aerial Systems for Precision Agriculture: A Review. *Precision Agriculture*, 20(4), 693–712. <https://doi.org/10.1007/s11119-019-09636-3>