T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

İNSANSIZ HAVA ARACI GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENME TABANLI YABANİ OT TESPİTİ VE SINIFLANDIRILMASI

Fatih ÇELİK

DOKTORA TEZİ

Harita Mühendisliği Anabilim Dalı

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı

Danışman

Prof. Dr. Fusun BALIK ŞANLI

İkinci Danışman

Prof. Dr. Yusuf KURUCU

Şubat, 2026

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

İNSANSIZ HAVA ARACI GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENME TABANLI YABANİ OT TESPİTİ VE SINIFLANDIRILMASI

Fatih ÇELİK tarafından hazırlanan tez çalışması 18.02.2026 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Prof. Dr. Fusun BALIK ŞANLI Yıldız Teknik Üniversitesi Danışman	Prof. Dr. Yusuf KURUCU Ege Üniversitesi İkinci-Danışman

Jüri Üyeleri

Prof. Dr. Fusun BALIK ŞANLI, Danışman
Yıldız Teknik Üniversitesi _____

Prof. Dr. Saygın ABDİKAN, Üye
Hacettepe Üniversitesi _____

Doç. Dr. Tolga BAKIRMAN, Üye
Yıldız Teknik Üniversitesi _____

Doç. Dr. Anime Melis UZAR, Üye
Yıldız Teknik Üniversitesi _____

Doç. Dr. Resul ÇÖMERT, Üye
Eşkişehir Teknik Üniversitesi _____

Danışmanım Prof. Dr. Fusun BALIK ŞANLI sorumluluğunda tarafımca hazırlanan "İnsansız Hava Aracı Görüntüleri Üzerinden Derin Öğrenme Tabanlı Yabani Ot Tespiti Ve Sınıflandırılması" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Fatih ÇELİK

İmza

Her durumda yanımda olan aileme.

TEŞEKKÜR

Bu tez çalışmasının başlangıcından tamamlanmasına kadar geçen süreçte bana yol gösteren, bilgi ve deneyimlerini paylaşan akademik gelişimime katkıda bulunan değerli danışman hocam Prof. Dr. Fusun BALIK ŞANLI' ya en derin şükranlarımı sunarım. Kendisi sadece bir danışman değil, aynı zamanda bağımsız bir araştırmacı olmamda en büyük destekçim olmuştur. Zorlu anlarda beni motive eden eleştirel düşünme yetimi geliştiren ve her aşamada detaylara gösterdiği özenle araştırmamı iyileştirmeme yardımcı olan değerli fikirleri için kendisine ne kadar teşekkür etsem azdır. Kendisi bilimsel bakış açımı genişletmiş ve daha büyük hedefler koymam için beni cesaretlendirmiştir.İkinci danışman hocam Prof. Dr. Yusuf KURUCU' ya, araştırma konusu seçimi, sürekli desteği ve yapıcı önerileri için derin minnettarlığımı ifade etmek isterim. Ayrıca, tez izleme komitesi üyelerim Saygın ABDIKAN ve Tolga BAKIRMAN'a değerli geri bildirimleri ve yönlendirmeleri için teşekkürlerimi sunarım. Onların bakış açıları araştırmamın kalitesini artırmada önemli katkılar sağlamıştır.

Son olarak, en büyük şükranımı sevgili aileme sunmak isterim. Bu doktora yolculuğunun en zorlu anlarında yanımda olan bana sonsuz sevgi ve destek veren canım eşim Ayşe'ye ne kadar teşekkür etsem azdır. Her zaman beni motive eden ve bu süreçte tüm yükü benimle birlikte omuzlayan eşime sonsuz minnettarım. O sadece hayat arkadaşım değil aynı zamanda bu başarının en büyük destekçisidir. Hayatım boyunca sonsuz sevgi ve desteklerini esirgemeyen her zaman yanımda olan bugüne kadar emeğini esirgemeyen anneme ve babama sonsuz teşekkürlerimi sunarım. Onlar benim en büyük motivasyon kaynağım ve gurur verici başarılarımın temelindeki sarsılmaz dayanaklarımdır. Ayrıca bu süreçte evde fedakarlıklarını hiç esirgemeyen değerli kayınvalideme derin minnettarlığımı ifade etmek isterim. Hayatıma anlam katan her gülümsemesiyle yorgunluğumu unutturan ve bu tez çalışmasının en büyük motivasyon kaynakları olan sevgili kızlarım Beren ve Bilge'ye sonsuz sevgilerimi sunarım. Bu sizin için, sizinle daha çok vakit geçirebilmem için…

Fatih ÇELİK

İÇİNDEKİLER

İÇİNDEKİLER **v**

SİMGE LİSTESİ **viii**

KISALTMA LİSTESİ **ix**

ŞEKİL LİSTESİ **x**

TABLO LİSTESİ **xii**

HARİTA LİSTESİ **xiii**

ÖZET **xiv**

ABSTRACT **xvi**

1 GİRİŞ **1**

1.1 Yabani Ot ve Tarımdaki Yeri 3

1.2 Ayçiçeğinin Önemi ve Ekonomik Değeri 9

1.3 Tezin Amacı ve Hipotez 11

2 YABANİ OT TESPİTİ UYGULAMARI **17**

2.1 İnsansız Hava Aracı Uygulamaları 17

2.2 Makineli Yabani Ot Tespit Uygulamaları 21

3 MAKİNE ÖĞRENMESİ **26**

3.1 Makine Öğrenmesi (Machine Learning) 26

3.2 Denetimli Öğrenme (Supervised Learning) 28

3.3 Denetimsiz Öğrenme (Unsupervised Learning) 29

4 DERİN ÖĞRENME VE GÖRÜNTÜ DÖNÜŞTÜRÜCÜLER **30**

4.1 Evrişimli Sinir Ağları (Convolutional Neural Networks(CNN)) 32

4.2 Görüntü Dönüştürücüler (Vision Transformers (ViT)) 35

4.3 Hiper Parametreler ve Optimizerler 41

4.4 Transfer Öğrenimi (Transfer Learning) 45

5 VERİ SETİ HAZIRLAMA **47**

5.1 Çalışma Alanı ve Görüntü Alımı 48

5.2 Ortofoto Üretimi 51

5.3 Hibrit Veri Artırımı 54

6 METODOLOJİ VE DEĞERLENDİRME 57

6.1 Hafif Derin Öğrenme Mimari Ağları 57

6.2 MobileNet Mimari Modeli 57

6.3 NASNetMobile Mimari Modeli 61

6.4 Hafif Dönüştürücü Mimari Model Algoritması 63

6.5 Değerlendirme Metrikleri 65

7 BULGULAR 68

7.1 Uygulama 1 ve Bulgular 69

7.2 Uygulama 1 ve Genel Performans Metrikleri 70

7.3 Hata Analizi ve Karışıklık Matrisi 72

7.4 Uygulama 2 ve Karşılaştırmalı Bulgular 75

7.5 Uygulama 2 ve Genel Performans Metrikleri 76

7.6 Hata Analizi ve Karışıklık Matrisi 82

7.7 Test Alanları ve Reçete Haritaları 92

7.8 Uygulama 1 Yabani Ot Tespiti ve Reçete Haritası 92

7.9 Uygulama 1 Test Sınıflandırması Sonuçları 93

7.10 Uygulama 2 Yabani Ot Tespiti ve Reçete Haritası 95

8 TARTIŞMA 98

8.1 Model Sınıflandırma Başarısının Değerlendirilmesi 99

8.2 Erken Dönem Yabani Ot Tespiti ve Önleyici Yönetim 102

8.3 Tarlaya Özgü Yabani Ot Yönetimi ve Herbisit Tasarrufu 105

8.4 Multispektral Bantların Katkısı ve RGB ile Karşılaştırma 107

8.5 Dönüştürücü Mimarinin Üstünlüğü ve CNN ile Karşılaştırma 110

8.6 Yama Bazlı Yaklaşımın Avantajları ve Sınırlamaları 113

8.7 Model Genelleştirme Kapasitesi ve Güvenilirlik 117

8.8 Pratik ve Gerçek Zamanlı Uygulama Potansiyeli 122

8.9 Etkin Kullanım Senaryo 1: Ön Planlama (Offline Prescription Mapping) 123

8.10 Etkin Kullanım Senaryo 2: Gerçek Zamanlı Uygulama 124

8.11 Diğer Çalışmalarla Kıyaslama ve Kısıtlılıklar 126

9 SONUÇ **129**

9.1 Araştırmanın Genel Sonuçları 129

9.2 Araştırma Soruları ve Hipotez Testi Sonuçları 131

9.3 Bilimsel ve Pratik Katkılar 136

9.4 Türkiye Tarımı için Referans Model ve Ayçiçeği Üretimine Özel Çözüm 140

9.5 Öneriler 140

9.6 Açıklamalar 142

KAYNAKÇA **144**

TEZDEN ÜRETİLMİŞ YAYINLAR **157**

SİMGE LİSTESİ

K	Anahtar vektörü (Key)
d_k	Anahtar vektörünün boyutu (scaling factor)
V	Değer vektörü (Value)
TP	Doğru Pozitif (True Positive)
TN	Doğru Negatif (True Negative)
H	Görüntü yüksekliği (Height)
W	Görüntü genişliği (Width)
C	Renk kanalı sayısı (Color channels)
Q	Sorgu vektörü (Query)
N	Toplam yama sayısı
FP	Yanlış Pozitif (False Positive)
FN	Yanlış Negatif (False Negative)
P	Yama (patch) boyutu

KISALTMA LİSTESİ

ADAM	Adaptive Moment Estimation, Adaptif Momentum Tahmini
CBS	Coğrafi Bilgi Sistemleri
CNN	Convolutional Neural Networks, Konvülüsyonel Nöral Ağlar
DÖ	Derin Öğrenme
İHA	İnsansız Hava Aracı
KYM	Kırmızı - Yeşil - Mavi
MSA	Multi-head Self-attention, Çok Başlık Öz Dikkat
ReLU	Rectified Linear Unit, Düzeltilmiş Doğrusal Birim
RMSProp	Root Mean Square Propagation, Kök Ortalama Kare Yayılım
SGD	Stochastic Gradient Descent, Stokastik Gradyan Düşü
ViT	Vision Transformer, Görüntü Dönüştürücü
YZ	Yapay Zekâ

ŞEKİL LİSTESİ

Şekil 1.1 Ayçiçeği tarlasındaki yabani otlar 4
Şekil 1.2 Ayçiçek yağı üretiminde ki önemli ülkeler USDA 9
Şekil 1.3 Ayçiçeği evreleri 10
Şekil 2.1 Dji mavic 3 M 18
Şekil 2.2 Dji agri ilaçlama senaryosu örneği 19
Şekil 2.3 Bonirob Bosch mekanik yabani ot söküm makinesi 22
Şekil 2.4 Farklı yabani ot kontrol robotları 24
Şekil 3.1 Rastgele orman sınıflandırması gösterimi 27
Şekil 3.2 Karar ağaçları gösterimi 28
Şekil 3.3 Temel bileşenler analizi gösterimi 29
Şekil 4.1 Derin öğrenme yöntemiyle tespit edilen yabani otlar 31
Şekil 4.2 Genel CNN yapısı 32
Şekil 4.3 Evrişim katmanı görseli 33
Şekil 4.4 Havuzlama katmanı görseli 34
Şekil 4.5 Düzleştirme katmanı görseli 34
Şekil 4.6 Dönüştürücü ana model şeması 36
Şekil 4.7 Çoklu ve öz dikkat mekanizması 39
Şekil 5.1 Görüntülerin hazırlanması ve eğitim modeli 47
Şekil 5.2 Görüntülerin elde edilme tarihleri 49
Şekil 5.3 Örnek KYM bantlı görüntü 50
Şekil 5.4 Multispektral bantlardan örnek görüntüler 51
Şekil 5.5 Fotoğrafları yöneltme adımı 52
Şekil 5.6 Sayısal yüzey modeli oluşturma adımı 52
Şekil 5.7 Ortofoto üretim aşaması 53
Şekil 5.8 Hibrit veri iyileştirme metodu 56
Şekil 6.1 İş akışları adımları 57
Şekil 6.2 Derinlik bilgisine göre evrişim katmanı ve nokta evrişimi temsili 58
Şekil 6.3 MobileNet mimarilerim katmanları 59
Şekil 6.4 MobileNetV2 mimari modeli 60
Şekil 6.5 NasNet evrişim hücre modeli 62

Şekil 6.6 Hata matrisi 65
Şekil 7.1 Sınıfların veri örnekleri (a:boş arazi, b: ayçiçeği, c: yabani ot) 69
Şekil 7.2 Uygulama 2 sınıfların veri örnekleri (d: boş arazi, e:ayçiçeği, f: yabani ot) 76
Şekil 7.3 Model performans karşılaştırması 77
Şekil 7.4 Sınıfların bazlı performans karşılaştırması 78
Şekil 7.5 Doğruluk ve görüntü hacmi hızı değişim analizi 79
Şekil 7.6 Sınıf bazlı doğruluk ısı haritası 81
Şekil 7.7 Çok metrikli radar çizelge kıyaslama 85
Şekil 7.8 VIT pruned detaylı karşılaştırma tablosu 87
Şekil 7.9 Yabani ot tespiti kritik metrik analizi 88
Şekil 7.10 Ayçiçeği ve yabani ot sınıflandırması için öz-dikkat ısı haritaları 91

TABLO LİSTESİ

Tablo 4.1 ViT model parametreleri ve katmanları 40
Tablo 4.2 Hiperparametreler ve değer aralıkları 43
Tablo 6.1 Vision transformer ağ budama yöntemi 64
Tablo 7.1 Uygulama 1 veri seti özellikleri 69
Tablo 7.2 Model eğitim parametreleri 70
Tablo 7.3 Genel performans metrikleri 70
Tablo 7.4 Doğru ve yanlış tahmini sayıları 70
Tablo 7.5 Sınıf bazlı performans metrikleri 71
Tablo 7.6 Sınıf bazlı doğruluk değerleri 71
Tablo 7.7 Vision transformer hata dağılımı 72
Tablo 7.8 MobileNetV2 hata dağılımı 72
Tablo 7.9 NASNetMobile hata dağılımı 72
Tablo 7.10 Ayçiçeğinden yabani ot yönündeki karışıklık oranları 73
Tablo 7.11 Tüm modellerin karşılaştırmalı performans özeti 73
Tablo 7.12 Tüm modellerin yabani ot tespit performansı 74
Tablo 7.13 McNemar testi özet tablosu 74
Tablo 7.14 Uygulama 2 veri seti özellikleri 75
Tablo 7.15 Uygulama 2 performans metrikleri 77
Tablo 7.16 Uygulama 2 doğru ve yanlış tahmin sayıları 78
Tablo 7.17 Uygulama 2 sınıf bazlı performans metrikleri 80
Tablo 7.18 Uygulama 2 sınıf bazlı doğruluk değerleri 82
Tablo 7.19 Uygulama 2 ViT hata dağılımı 82
Tablo 7.20 Uygulama 2 ViT pruned hata dağılımı 83
Tablo 7.21 Uygulama 2 NASNetMobile hata dağılımı 83
Tablo 7.22 Uygulama 2 performans verimlilik özeti 84
Tablo 7.23 Uygulama 2 McNemar testi sonuçları 89
Tablo 7.24 Uygulama 1 erken dönem test alanı sınıf dağılımı 94
Tablo 7.25 Uygulama 2 erken dönem test alanı sınıf dağılımı 95

HARİTA LİSTESİ

Harita 5.1 Çalışma alanı 48
Harita 7.1 Uygulama 1 yabani ot tespiti ve reçete haritası 93
Harita 7.2 Yabani ot tespiti ve herbisit uygulama alanı (Uygulama 2) 96

ÖZET

İnsansız Hava Aracı Görüntüleri Üzerinden Derin Öğrenme Tabanlı Yabani Ot Tespiti Ve Sınıflandırılması

Fatih ÇELİK

Harita Mühendisliği Anabilim Dalı

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı

Doktora Tezi

Danışman: Prof. Dr. Füsun BALIK ŞANLI

İkinci-Danışman: Prof. Dr. Yusuf KURUCU

Bu tez çalışması, ayçiçeği üretiminde verim kaybını önlemek amacıyla erken dönem yabani ot tespitine yönelik Görüntü Dönüştürücü tabanlı derin öğrenme modellerinin geliştirilmesini ve İnsansız Hava Araçları platformlarındaki pratik uygulanabilirliğini kapsamlı biçimde ele almaktadır. Bu doğrultuda İHA'dan elde edilen yüksek çözünürlüklü KYM ve multispektral ortofoto görüntüleri kullanılarak dört farklı derin öğrenme mimarisi karşılaştırmalı olarak değerlendirilmiştir. İki farklı test alanında ayçiçeği bitkilerinin kritik gelişim evresi olan 3-4 yapraklı fenolojik aşamada gerçekleştirilmiş ve sahaya özgü üç sınıflı veri setleri oluşturulmuştur. Görüntüler, 50×50 piksellik yama bazlı bir sınıflandırma yaklaşımıyla işlenmiş; bu boyutun hem lokal detayları hem bağlamsal bilgiyi dengeli biçimde kapsadığı ve saha uygulama sistemlerinin hassasiyetiyle uyumlu olduğu gösterilmiştir. Modellerin eğitiminde öğrenme aktarımı tercih edilmiş hiperparametre optimizasyonu gerçekleştirilmiştir. ViT mimarisinin geleneksel konvolüsyonel sinir ağlarına kıyasla belirgin bir üstünlük sergilediğini ortaya koymuştur. ViT, KYM bantlarında %99.18, multispektral bantlarda ise %99.48 test doğruluğuna ulaşırken yabani ot tespitinde %99-100 kesinlik değeri elde etmiştir.

Hesaplama verimliliğini artırmak amacıyla uygulanan budama işlemi sonucunda geliştirilen ViT Pruned modeli, %50 boyut küçülmesi ve %87 hız artışı sağlarken doğrulukta yalnızca %0.73'lük bir kayıpla optimal bir doğruluk verimlilik dengesi sunmuştur. MobileNetV2 en yüksek işleme hızına ulaşmış olmakla birlikte multispektral verilerde performans kaybı yaşamıştır. NASNetMobile ise %95.83-96.08 doğrulukla dört mimari arasında en düşük başarıyı göstermiştir. Tez kapsamında öne çıkan bir diğer bulgu multispektral bantların sınıflandırma doğruluğuna katkısının beklenenin oldukça altında kalmasıdır. ViT'te yalnızca %0.30 puanlık iyileşme sağlayan multispektral veriler konvolüsyonel modellerde ise olumsuz etki göstererek doğruluğu düşürmüştür. Bu sonuçlar KYM bantlarının ayçiçeği, yabani ot ve boş alan sınıflandırması için tek başına yeterli olduğunu ve maliyeti yaklaşık 10 kat daha yüksek olan multispektral sensörlerin maliyet fayda dengesinin ciddi biçimde sorgulanması gerektiğini ortaya koymaktadır. Sahaya özgü yabani ot yönetimi boyutunda ise her iki test alanında %40-46 arasında yüksek yabani ot yoğunluğu saptanmış ve ancak görüntüleme yapılan fenolojik aşamada ayçiçeği bitkileri henüz ciddi bir rekabet baskısıyla karşılaşmamıştır. Bu kritik pencerede gerçekleştirilen erken müdahale ilerleyen dönemde oluşabilecek %20-40'lık verim kayıplarının önüne geçmiş ve %54-60 oranında herbisit tasarrufu sağlamıştır. Sonuç olarak bu tez sahaya özgü yabani ot kontrolünün teorik bir konseptin ötesinde, somut ve ölçülebilir ekonomik aynı zamanda çevresel faydalar sunan pratik bir çözüm olduğunu kanıtlamıştır. Geliştirilen modeller arasından ViT çevrimdışı reçete haritalama için, ViT Pruned ise gerçek zamanlı saha uygulamaları için önerilmektedir. Elde edilen %99.18-99.48 doğruluk ve %54-60 herbisit tasarrufu değerleri hassas tarım teknolojilerinin sürdürülebilir ayçiçeği üretimindeki stratejik önemini ve bu çalışmanın bilimsel literatüre sunduğu özgün katkıyı doğrulamaktadır.

Anahtar Kelimeler: Görüntü dönüştürücü, yabani ot tespiti, insansız hava aracı, derin öğrenme, model budama

ABSTRACT

Deep Learning Based Weed Detection and Classification via Unmanned Aerial Vehicle Imagery

Fatih CELIK

Department of Geomatic Engineering
Program of Remote Sensing and GIS

Doctor of Philosophy Thesis

Supervisor: Prof. Dr. Fusun BALIK SANLI
Co-supervisor: Prof. Dr. Yusuf KURUCU

This thesis comprehensively addresses the development of Vision Transformer based deep learning models for early-stage weed detection and their practical applicability on Unmanned Aerial Vehicle platforms to prevent yield loss in sunflower production. In this regard four different deep learning architectures were comparatively evaluated using high-resolution RGB and multispectral orthophoto imagery obtained from UAVs. The research was conducted in two different test areas during the 3-4 leaf phenological stage which is a critical developmental phase for sunflower plants and field specific three class datasets were generated. The images were processed using a 50×50 pixel patch based classification approach; it was demonstrated that this patch size balanced local details and contextual information effectively while aligning with the precision requirements of field application systems. Transfer learning was employed for model training followed by hyperparameter optimization. The results revealed that the ViT architecture exhibits a significant superiority over traditional Convolutional Neural Networks. While ViT achieved a test accuracy of 99.18% in RGB bands and 99.48% in

multispectral bands it attained a precision value of 99-100% in weed detection. The "ViT Pruned" model developed through a structured pruning process to enhance computational efficiency provided an optimal accuracy efficiency balance achieving a 50% reduction in model size and an 87% increase in processing speed with only a marginal 0.73% loss in accuracy. Although MobileNetV2 reached the highest processing speed it suffered performance degradation when using multispectral data. NASNetMobile showed the lowest performance among the four architectures with an accuracy range of 95.83-96.08%. Another prominent finding of the thesis is that the contribution of multispectral bands to classification accuracy remained significantly below expectations. Multispectral data provided only a 0.30 percentage point improvement in the ViT model while it adversely affected the accuracy of convolutional models. These results indicate that RGB bands alone are sufficient for the classification of sunflower, weed and bare soil suggesting a critical reevaluation of the cost benefit ratio for multispectral sensors which are approximately ten times more expensive. In the context of site-specific weed management high weed densities between 40-46% were detected in both test areas. However at the captured phenological stage the sunflower plants had not yet encountered severe competitive pressure. Early intervention conducted within this critical window prevented potential yield losses of 20-40% in later stages and resulted in herbicide savings of 54-60%. Consequently, this thesis proves that site-specific weed control is not merely a theoretical concept but a practical solution offering tangible and measurable economic and environmental benefits. Among the developed models ViT is recommended for offline prescription mapping while ViT Pruned is suggested for real-time field applications. The achieved accuracy of 99.18-99.48% and herbicide savings of 54-60% validate the strategic importance of precision agriculture technologies in sustainable sunflower production and confirm the original contribution of this study to the scientific literature.

Keywords: Vision transformer, weed detection, unmanned aerial vehicle, deep learning, model pruning

1
GİRİŞ

Yabani otlar, tarımsal üretim için önemli bir tehdit oluşturan istenmeyen bitki türleridir. Su, besin, güneş ışığı, alan ve karbondioksit gibi temel kaynaklar için mahsullerle rekabet ederek çiftçilerin verim hedeflerine ulaşmasını zorlaştırırlar. Bu istilacı bitkiler toprak tohum bankasından türeyerek yayılmaktadır [1], [2]. Yabani otlarla mücadele yalnızca günümüz tarımının değil gelecekteki gıda güvenliği ihtiyacının karşılanması için de kritik bir öneme sahiptir [3]. Bu nedenle yabani ot yönetimi el emeği, kimyasal herbisitler, mekanik çözümler, çevre dostu yaklaşımlar ve yapay zekâ gibi ileri teknolojileri içeren yenilikçi yöntemlerin birleşimini kapsamaktadır [4].

Tarım sektöründe ekosistem sağlığını ve biyolojik çeşitliliği koruma değeri giderek artarken çevre dostu çözümler ön plana çıkmaktadır [5], [6]. Bu yaklaşımlar arasında biyolojik stratejiler büyük bir potansiyele sahiptir. Örneğin örtü bitkilerinin ekilmesi güneş ışığı, su ve besinler için rekabet ederek yabani otların büyümesini doğal bir şekilde engeller. Bazı örtü bitkileri yabani ot gelişimini baskılayan kimyasallar salgılamaktadır [7], [8]. Bu tür stratejiler kimyasallara olan bağımlılığı azaltırken toprağın sağlığını ve uzun vadeli sürdürülebilirliği teşvik etmektedir. İnsansız hava araçları (İHA) ve yapay zekâ (YZ) teknolojilerinin yabani ot yönetimi stratejilerine entegre edilmesiyle, çiftçiler herbisit kullanımını daha verimli hale getirebilmektedir. Dirençli yabani otların yayılmasını sınırlayabilir ve daha sürdürülebilir tarım uygulamalarından faydalanabilir. Bu teknolojik gelişmeler tarımsal üretkenliği artırırken çevresel sürdürülebilirliği sağlamada büyük bir potansiyele sahiptir.

Herbisitler yabani otlarla mücadelede vazgeçilmez bir araç haline gelmiştir [5], [9]. Yabani ot yoğunluğunu ve biyokütlesini azaltma konusundaki etkinlikleri geleneksel mekanik yöntemleri genellikle geride bırakmaktadır. Herbisitler maliyet etkinliği ve esneklikleriyle modern tarımda önemli bir yer tutar. Ancak bu yaygın

kullanımın bir bedeli vardır. Herbisitlere dirençli yabani ot türlerinin ortaya çıkışı sürdürülebilir tarım için ciddi bir tehdit oluşturmaktadır. Bu direnç kimyasal kullanımın çevresel ve sağlık üzerindeki olumsuz etkileriyle birleştiğinde üretkenliği korurken alternatiflerin araştırılmasının önemini ortaya koymaktadır [1], [2].

Entegre yabani ot yönetimi diye adlandırılan tarz çok disiplinli yöntemler kimyasal, mekanik, biyolojik ve teknolojik yaklaşımların en iyi yönlerini bir araya getirerek bütünsel bir çözüm sunmaktadır. Bu strateji herbisit direnci riskini azaltmanın yanı sıra daha dirençli ve sürdürülebilir bir tarım sistemi oluşturmaktadır [5], [10]. Geleneksel tarım uygulamaları ve İHA görüntülerinin birleştirilmesi gerçek zamanlı verilere dayalı olarak yabani ot tespit sonuçlarını etkilemektedir.

Hassas ilaçlama uygulaması yabani ot yönetiminde yenilikçi ve dönüştürücü çözümler sunmaktadır. Haritalama robotik sistemler ve ileri düzey görüntü tanıma teknolojileri gibi dijital tarım araçları kullanılarak yabani ot kontrolü daha hassas ve verimli hale getirilmektedir. Bu teknolojiler iş gücü ihtiyacını azaltırken çevresel etkileri en aza indirerek sürdürülebilir tarıma önemli bir katkı sağlamaktadır.

Bu bağlamda mevcut çalışmada hassas yabani ot yönetiminin teknik temelini oluşturmak amacıyla derin öğrenme tabanlı görüntü sınıflandırma yaklaşımı benimsenmiştir. Geleneksel makine öğrenmesi yöntemleri elle tasarlanmış öznitelik çıkarımına dayanırken derin öğrenme modelleri ham görüntü verisinden doğrudan anlamlı örüntüler öğrenebilmektedir. Bu özellik farklı ışıklandırma koşulları bitki gelişim aşamaları ve yabani ot çeşitliliği gibi sahaya özgü değişkenliklerin yüksek olduğu tarımsal ortamlarda önemli bir avantaj sağlamaktadır. Özellikle ViT mimarisi, global dikkat mekanizması sayesinde görüntü içindeki uzak bölgeler arasındaki ilişkileri modelleyebildiğinden birbirine morfolojik olarak benzeyen ayçiçeği ve yabani ot gibi sınıfların ayrımında konvolüsyonel ağlara kıyasla daha güçlü bir temsil kapasitesi sunmaktadır. İHA platformunun tercih edilmesi ise geniş tarım arazilerinin kısa sürede yüksek çözünürlükte ve tekrarlanabilir biçimde görüntülenmesine olanak tanıması nedeniyledir. Bu kombinasyon İHA tabanlı veri toplama ile dönüştürücü tabanlı sınıflandırma sahaya özgü ölçeklenebilir ve düşük maliyetli bir yabani ot yönetim sistemi kurmanın pratik bir yolunu sunmaktadır.

Bu tezde mevcut yöntemlerin doğrudan uygulanmasının ötesinde birkaç özgün katkı sunmaktadır. Görüntü dönüştürücü mimarisinin ayçiçeği ve yabani ot sınıflandırmasına uygulanması literatürde oldukça sınırlı kalmakta olup bu çalışma söz konusu alanda öncü araştırmalardan birini temsil etmektedir. Bunun yanı sıra model budama tekniğinin tarımsal görüntü sınıflandırmasına entegrasyonu ile %50 model boyutu küçülmesi ve %87 hız artışı sağlanırken doğrulukta yalnızca %0.73'lük bir kayıpla optimal verimlilik doğruluk dengesi elde edilmiştir. Bu kombinasyon literatürde daha önce gösterilmemiştir. KYM ve multispektral bantların sistematik karşılaştırmalı analizi aracılığıyla multispektral sensörlerin ayçiçeği ve yabani ot sınıflandırmasındaki maliyet fayda dengesi ilk kez sorgulanmış ve KYM bantlarının tek başına yeterli olduğu ortaya konmuştur. Son olarak sahaya özgü herbisit reçete haritası üretiminin gerçek tarla koşullarında uygulanabilirliği gösterilerek %54-60 oranında herbisit tasarrufu sağlanmıştır. Tüm bu katkılar bir arada değerlendirildiğinde çalışmanın yalnızca mevcut yöntemleri tekrar eden değil, hassas tarım literatürüne ölçülebilir ve yeniden üretilebilir özgün bulgular sunan bir araştırma niteliği taşıdığıdır.

1.1 Yabani Ot ve Tarımdaki Yeri

Teknolojideki gelişmeler yabani ot yönetimine tamamen yeni bir boyut kazandırmaktadır. Robotik, YZ ve coğrafi bilgi sistemlerinin (CBS) entegrasyonu hassas tarımın kapılarını aralamıştır [9]. Gelişmiş sensörler ve makine öğrenimi algoritmalarıyla donatılmış insansız kara araçları ve İHA yabani otları doğrulukla tespit edebilmektedir [11]. Bu sistemler insan emeği ihtiyacını azaltırken tarımsal verimliliği artırır. Pestisit püskürtmek için kullanılan insansız hava araçları yabani otları hedef alarak israfı ve çevresel etkiyi en aza indirebilir.

İHA tarafından alınan görüntüler yabani otların erken tespiti için güçlü araçlar sunmaktadır. Yeni teknolojilerle mahsul büyümesinin ilk aşamalarında yabani ot fideleri ile mahsuller arasında spektral benzerlikler varken dahi doğru bir şekilde ayrım yaparak kritik bir avantaj sağlamaktadır [12]. Erken tespit yapılarak yönetilen arazilerde yabani ot sorunlarının büyümeden önce ele alınmasını sağlayarak kaynakların etkin kullanılmasını ve mahsul zararının en aza indirilmesini mümkün kılmaktadır. Şekil 1.1’de mahsul ve yabani ot içeren görüntü örneği verilmiştir.

Hassas tarım üretkenlik ile çevresel korumayı dengeleme kapasitesiyle tarımın geleceğini temsil etmektedir. Gelişmiş sensörler, robotik ve yapay zekâ teknolojilerini kullanarak çiftçiler yabani otları büyüme sezonunun erken döneminde tespit edip yönetebilmektedir. Çiftçilerin işletme maliyetlerini azaltabilir ve ekolojik zararları en aza indirmektedir [13]. Bu teknolojilerin daha erişilebilir hale gelmesiyle yabani ot yönetimi verimli ve sürdürülebilir bir süreç haline dönüşme potansiyeline sahiptir.



Şekil 1.1 Ayçiçeği tarlasındaki yabani otlar

Gıda arzı bir önceki yılın tarımsal uygulamalarına sıkı sıkıya bağlıdır. Geçmiş verilerinden faydalanarak bilim insanları gıda üretiminin artan nüfusun ihtiyaçlarını karşılayıp karşılamayacağını öngörebilir. Davis ve arkadaşlarına göre, tarımsal üretime bağlı çevresel yükün analiz edilmesi ve azaltılması bu sorunun çözümünde önemli bir adımdır [14]. Örneğin su, azot, karbon ve arazi kullanımı gibi faktörlerin çevresel ayak izlerini analiz ederek kaynak kullanımını ve sera gazı emisyonlarını değerlendirmek mümkündür. Bu sayede belirli temel gıdalara olan bağımlılığın azaltılması ve kaynakların daha verimli bir şekilde kullanılması, gelecekteki gıda arzı kısıtlamalarının önüne geçebilir.

Artan nüfus sonucu ekilebilir arazi ve bu arazilerde elde edilmesi gereken verimler üzerinde büyük bir baskı oluşturmaktadır [15].

Mevcut gıda üretim sistemlerindeki açıkları kapatmak bir zorunluluk haline gelmiştir. 2015 yılında, toplam ekili alan miktarı 1965 yılı ile neredeyse aynı kalmış ve gelecekte de önemli bir artış beklenmemektedir [15]. Birleşmiş Milletler Gıda ve Tarım Örgütüne göre dünya çapındaki gıda üretiminin gelecekteki talebi karşılayabilmesi için %70 oranında artırılması gerekmektedir. Bu durum ekilebilir arazilerde hektar başına verimin artırılmasını zorunlu kılmaktadır. Özellikle de yabani otlar nedeniyle meydana gelen verim kayıpları tarım sektöründe önemli bir sorun olmaya devam etmektedir [8], [16]. Yabani ot yönetimi tarımsal üretkenliği artırmanın yanı sıra gıda güvenliği ve güvenilirliğini sağlamada kritik bir role sahiptir.

Sonuç olarak sürdürülebilir gıda güvenliğinin sağlanması, kaynak optimizasyonu, ileri teknolojilerin entegrasyonu ve uyarlanabilir tarım uygulamalarını birleştiren çok yönlü bir yaklaşımı gerektirir. Çevresel, ekonomik ve teknolojik zorlukların ele alınmasıyla tarım sektörü hızla büyüyen nüfusun taleplerine daha iyi yanıt verebilir ve gıda sistemlerinin dayanıklı, verimli ve sürdürülebilir olmasını sağlayabilir.

Küresel sıcaklıkların artması atmosferdeki karbon dioksit seviyelerinin yükselmesi ve düzensiz nem değişiklikleri iklim değişikliğinin üç ana bileşenidir [17]. Bu durum tarımsal uygulamalarda yabani ot yönetimi için ciddi zorluklar yaratmaktadır. İklim değişikliği önemli bir sorundur çünkü hem mahsul hem de yabani otların doğal fenolojik özelliklerini değiştirebilmekte ve bu durum yeni türlerin istilacı türler olarak ortaya çıkmasına neden olabilmektedir. Yeni Zelanda'da yapılan bir çalışmada bölgede iklim değişikliğinin bir sonucu olarak birçok istilacı yabani ot türü keşfedilmiştir [18].

İklim değişikliğinin tarım üzerindeki etkileri geçmişte uzun bir süre boyunca kademeli olarak hissedilmiş olsa da, günümüzde bu etkiler daha belirgin hale gelmiş ve harekete geçme gerekliliği artmıştır. Son on yıldaki hava durumu önceki yirmi yıla kıyasla ciddi şekilde değişim göstermiştir ve iklimdeki hızlı bir dönüşümün işaretçisi olmuştur. Bu yeni iklimsel düzeni incelemek, yabani otların yayılmasını kontrol altına almak için kritik bir önlem niteliğindedir [19].

Modern tarımda mahsulün hayatta kalması değişen iklim koşulları sınırlı toprak nemi ve artan sıcaklık gibi çeşitli faktörlere bağlıdır. Mahsullerin bu zorluklara

uyum sağlaması için yapılan ıslah çalışmaları etkili olmasının yanında birçok yabani ot türü aynı koşullar altında olağanüstü bir direnç göstermektedir.

Bu nedenle çiftçilerin evrimsel biyoloji prensiplerinden yararlanarak daha gelişmiş yabani ot kontrol stratejileri benimsemesi gerekmektedir [17]. Artık insanlar iklim değişikliğinin yabani otlar üzerindeki etkileri konusunda sürekli olarak bilinçli olması gerekmektedir. Yeni yabani otlar mevcut bitkilerle rekabete gireceğinden çiftçiler, araştırmacılar ve yerel halk arasında iş birliği yapılarak bu sorunun çözülmesi için ortak bir yaklaşım geliştirilmelidir [20].

Deniz seviyesindeki yükselme ve tektonik hareketler gibi faktörlerin tarımsal ekosistemler üzerindeki etkisi de vardır. Bu faktörler doğal afetleri, nüfus yoğunluğunu, toprak özelliklerini ve topografik değişimleri etkileyerek tarımsal üretim ve ekosistemler üzerinde doğrudan ya da dolaylı etkiler yaratır. Tarım üzerinde en büyük etkiye sahip olan faktörler arasında yüksek sıcaklıklar ve kuraklık yer almaktadır [21].

İHA ve hava balonları, hava kirliliği ve emisyon çalışmaları için yeni araştırma olanakları sağlarken aynı zamanda iklim değişikliğiyle ilgili atmosferik eğilimlerin gözlemlenmesine katkıda bulunur. Bu teknolojiler kentsel ve endüstriyel alanlarda hava güvenliğini sağlamada önemli bir rol oynamaktadır. Ancak bunu gibi yapay zekâ teknolojilerinin tarım sektöründeki uygulamaları hâlâ sınırlıdır. Özellikle düşük gelirli kırsal bölgelerdeki çiftçiler için bu durum ekipmanların yüksek maliyeti ve uygulamadan önce gereken özel eğitim nedeniyle daha da zorlaşmaktadır.

Ülkemizde yapay zekâ tarımdaki uygulamalar açısından hâlâ başlangıç aşamasındadır. Bununla birlikte yapay zekâ teknolojisindeki ilerlemelerin tarım sektörünü dönüştürmede önemli bir rol oynayacağı öngörülmektedir. Hassas tarımı destekleyen bu teknolojiler doğru çözümleri, doğru yerlerde, doğru zamanlarda ve doğru miktarlarda uygulama imkânı sağlayarak tarımsal verimlilik ve sürdürülebilirlik açısından ayrılmaz bir parça haline gelecektir. Tarımdaki bu önemli endüstride yer alan paydaşlar için yapay zekâ tabanlı çözümlere yatırım yapmak gelecekte tarımsal uygulamaların temel taşı haline gelecektir.

Yabani otlarda herbisit direnci tarımsal üretimde önemli bir sorun oluşturmaktadır. Tarımsal faaliyetlerin çoğu yabani otların kontrolü ve herbisit direncinin

önlenmesine yönelik çalışmalara ayrılmaktadır. Herbisit dirençli yabani otlar, kimyasal kontrol yöntemleri uygulanmış olmasına rağmen büyümeye ve yayılmaya devam eden ve bu kimyasallara karşı direnç geliştirmiş bitkilerdir [22]. Bu direncin mekanizmalarının ve bağlamının anlaşılması etkili bir yönetim için kritik öneme sahiptir. Bu nedenle birçok çiftçi herbisit dirençli yabani ot yönetimi stratejileri uygulayarak bu sorunun önüne geçmeye çalışmaktadır [23].

Beckie ve Harker, etkili yabani ot yönetimi için on temel uygulama önermiştir. Bu uygulamalar referans rehber olarak kullanılabilecek kapsamlı veri tabanlarının oluşturulması, stratejik toprak işleme, alan ve yer bazlı yabani ot yönetimi, yabani ot temizliği, hedef dışı direnç önlemleriyle kombinasyon, herbisit etki noktası rotasyonu, herbisit karışımları, herbisit uygulaması öncesi ve sonrası izleme ve anketler, rekabetçi ürün yetiştirme sistemleri ve ürün çeşitliliği bulunmaktadır [24]. Bu yöntemlerden özellikle ürün çeşitliliği, yabani ot popülasyonlarını azaltmada ve dirençle mücadelede en etkili yöntemlerden biri olarak kabul edilmektedir. Dikotlar ve monokotlar arasında veya kış-yaz ve serin-sıcak sezon ürünleri arasında karışık ekim yapılması yabani ot direncini azaltmaktadır. Kniss, çalışmasında ürün çeşitliliği, ürün rotasyonu ve toprak işlemenin yabani otların yayılmasını ve direncini önlemede temel yöntemler olduğunu vurgulamaktadır [25].

Genetiği değiştirilmiş ve herbisit dirençli bitkilerin kullanımı özellikle Amerika ve birçok ülkede herbisit kullanımında önemli değişikliklere yol açmıştır. Bazı çiftçiler genetiğiyle oynanmış bitkilerin "süper otlar" olarak bilinen herbisit dirençli yabani otların ortaya çıkmasına neden olacağını iddia etmektedir. Uluslararası herbisit dirençli yabani otlar araştırmasına göre herbisit dirençli çeşitlerin kullanılması, pamuk ve soya gibi ürünlerde herbisit çeşitliliğini azaltmıştır. Yabani ot direncini azaltmak için herbisit çeşitliliğini korumak veya artırmak ve ürün rotasyonu ve toprak işleme gibi entegre uygulamaları benimsemek önemlidir. Bu yöntemlerin direnç seviyelerini düşürdüğü kanıtlanmıştır [25].

Modern teknoloji, entegre yabani ot yönetimine destek sağlayan ek araçlar sunmaktadır. İnsansız hava araçları yabani ot alanlarını hassas bir şekilde tespit etmek için kullanılabilir. Bu teknoloji yalnızca herbisit dirençli yabani ot popülasyonlarını azaltmakla kalmaz aynı zamanda kimyasal kullanımını ve çevresel etkileri de en aza indirir [26]. Yapay zekâ yabani ot istilasını erken aşamada tespit ederek yayılmasını önlemede çiftçilere büyük fayda sağlar [27].

Sürdürülebilir tarım çevrenin korunmasını ön planda tutar. Uzun vadeli üretkenliği garanti altına alan sosyal ve ekonomik unsurları bir araya getiren bir tarım yaklaşımıdır. Geleneksel tarımda yaygın olarak kullanılan kimyasal girdiler çevre üzerinde uzun vadede olumsuz etkiler yaratmaktadır. Toprak bozulması ve toprak verimliliğinin azalması gibi sorunlara neden olmaktadır. Bu etkileri azaltmak için kimyasal kullanımını düzenlemek ve en aza indirmek oldukça önemlidir. Organik tarım uygulaması sadece toprak sağlığını iyileştirmekle kalmaz aynı zamanda hayvanların ve insanların sağlığına da fayda sağlar ve sürdürülebilir tarım ilkeleriyle uyumludur. Organik tarım zararlı organizmalar ve yabani otların kontrolü için kimyasal işlemlerin kullanılmaması nedeniyle daha sağlıklı ve besin açısından zengin ürünler elde edilmesini sağlar [28]. Sürdürülebilir tarımı güvence altına almak için kimyasal kullanımına ilişkin doğru düzenlemelerin uygulanması gerekmektedir.

Organik tarımın pek çok avantajı olmasından mütevellit küçük ölçekli çiftçiler arasında yüksek maliyetler ve iş gücü yoğunluğu nedeniyle bu uygulamanın benimsenmesi sınırlı kalmaktadır. Sürdürülebilir tarım yalnızca organik tarımla sınırlı değildir. Bu yöntemler arasında örtü bitkileri kullanımı, entegre tarım sistemleri, ekim nöbeti ve entegre zararlı yönetimi gibi uygulamalar bulunmaktadır [25]. Kimyasal işlemlere ihtiyaç duymadan yabani otların etkin bir şekilde kontrol edilmesini sağlar. Entegre tarım sistemiyle plantasyonlarda yabani otlar hayvanlarla kontrol edilebilir ve bitki ile hayvan tarımı arasında karşılıklı fayda sağlayan bir ilişki oluşturur.

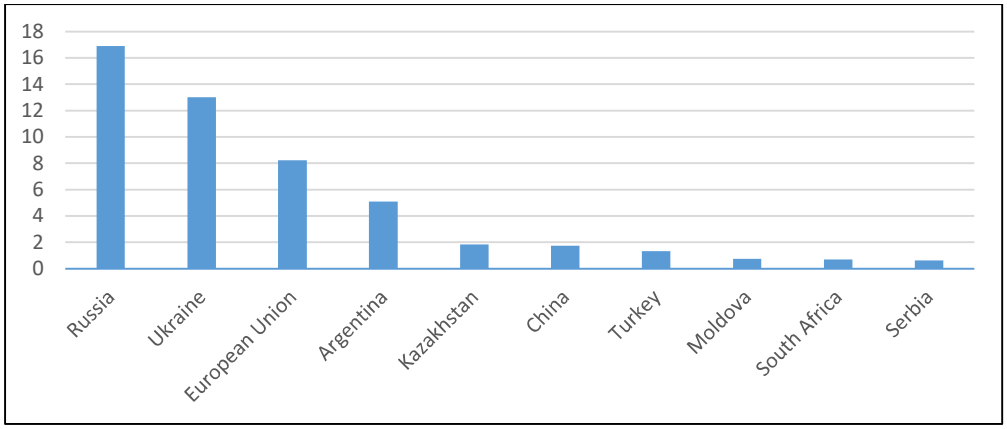
Gelecek nesiller için sürdürülebilir tarımı sağlayacak tarım uygulamalarının seçimi genellikle toplumsal tercihlere ve kültürel değerlere bağlıdır. Tarımın ekonomik, teknolojik ve çevresel gelişimi sosyal kurumlarla yakından ilişkilidir. Kurumlar sürdürülebilir tarımın başarısını şekillendirmede önemli bir rol oynar. Sosyal sermaye ile kavramsal ve deneysel içgörüler toplulukların tarıma nasıl yaklaştığını büyük ölçüde etkiler [29]. Bu nedenle sürdürülebilir tarım sadece çevresel hedeflere hizmet etmekle kalmaz aynı zamanda toplumsal kalkınma ve ekonomik büyüme için itici bir güç olarak hareket eder.

Sürdürülebilir tarımda ileri teknolojilerin entegrasyonu verimliliği artırmada ve gıda güvenliğini sağlamada kritik bir faktördür. Düşük teknolojili yenilikler bile daha yüksek verim elde edilmesine ve gıda tedarik sistemlerinin güçlendirilmesine

katkıda bulunabilir. Küçük ölçekli çiftçiler ekolojik risk analizi yapmak ve ekonomik güçlenmeyi sağlamak için teknolojiden yararlanabilmesiyle ulusal ekonomilere katkıda bulunabilir. Teknolojinin tarımsal süreçlere entegre edilmesi üretim, gıda ve tedarik sistemlerinde daha iyi uyum sağlayabilmekte ve sonuçta ekonomik kazanımları artırabilmektedir [29], [30]. Operasyonel kontrol, makine performans izleme, veri paylaşımı, model tahmini, veri analizi ve depolama gibi alanlarda yapay zekâ uygulamaları hassasiyet, verimlilik ve ölçeklenebilirlik sağlayarak sürdürülebilir tarım uygulamalarının daha etkili ve erişilebilir olmasını sağlar.

1.2 Ayçiçeğinin Önemi ve Ekonomik Değeri

Ayçiçeği dünya genelinde yaygın olarak yetiştirilen bir üründür. Hem besin değeri hem de ekonomik getirisi yüksek bir bitkidir. Yağ açısından zengin tohumları insan beslenmesinde temel bir rol oynarken hayvan yemi olarak da değerlendirilmektedir [31]. Tarım, sanayi ve çevre açısından geniş kullanım alanlarına sahip olan ayçiçeği biyoyakıt üretimi, toprak verimliliğini artırma ve arıcılık gibi sektörlerde de önemli bir yer tutmaktadır. Ayrıca fotosentez yoluyla atmosferdeki karbondioksiti emerek oksijen üreten bu bitki ekolojik dengeyi koruma açısından da katkı sağlamaktadır [32]. Şekil 1.2'de ayçiçek yağı üretimi yapan ülkeler gösterilmektedir.

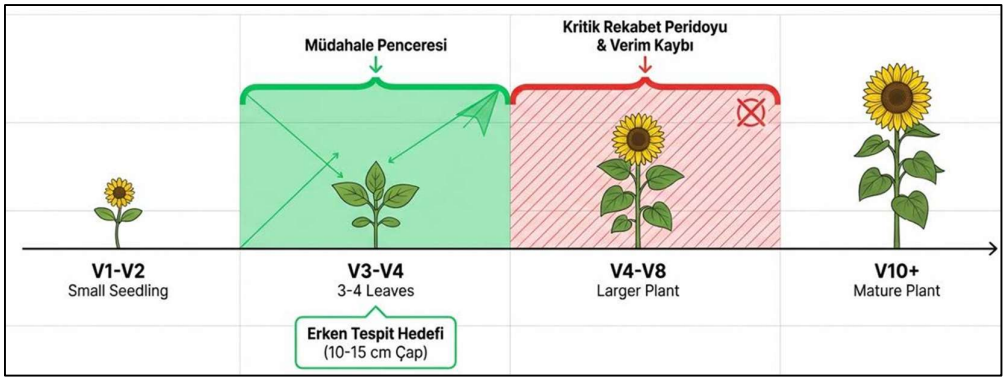


Şekil 1.2 Ayçiçek yağı üretiminde ki önemli ülkeler USDA (Milyon Ton, Web-1)

Besinsel açıdan incelendiğinde ayçiçeği tohumu protein, lif, B vitaminleri, magnezyum, fosfor ve selenyum gibi önemli besin maddelerini içerir. Özellikle yüksek protein içeriği sayesinde hem insan hem de hayvan beslenmesinde değerli bir kaynak olarak öne çıkmaktadır. Ayçiçeği yağı doymamış yağ asitleri bakımından zengin olup kalp sağlığını destekleyen özellikleriyle bilinmektedir.

Doymamış yağ asitleri kötü kolesterolü düşürmeye ve iyi kolesterolü artırmaya yardımcı olur. Ayrıca E vitamini ve antioksidan içeriği sayesinde hücreleri oksidatif stresten koruyarak yaşlanma karşıtı etkilere ve kronik hastalıkların önlenmesine katkıda bulunur [33].

Ayçiçeği farklı iklim koşullarına uyum sağlayabilen bir bitkidir. Geniş genetik çeşitliliği sayesinde değişen çevresel koşullara karşı direnç gösterebilmekte ve sürdürülebilir tarım uygulamalarına katkıda bulunmaktadır. Yağlı tohumlu bitkiler üretiminde ayçiçeğini en önemli ürünlerden biri olarak konumlandırmaktadır. Ülke genelinde ayçiçeği üretimi yerli tohum geliştirme projeleri ve çiftçilere sağlanan destekler sayesinde son yıllarda artış göstermiştir. Türkiye İstatistik Kurumu'nun 2022 yılı verilerine göre Türkiye'de ayçiçeği üretimi 1.6 milyon tona ulaşmıştır. Ancak 2023 yılında bu üretimde %13,8'lik bir düşüş yaşanarak 2 milyon 198 bin tona gerilemiştir. Yağlı tohumlar üretimindeki bu dalgalanmalar tarımsal sürdürülebilirlik açısından dikkatle ele alınması gereken bir konudur ve gıda güvenliğini sağlamak adına daha etkin tarım politikalarının uygulanmasını gerektirmektedir (Web-3). Şekil 1.3'de ayçiçeğinin evreleri örneklendirilmiştir.



Şekil 1.3 Ayçiçeği evreleri (Web-2)

Günümüzde tarım sektörü verimlilik, sürdürülebilirlik ve kaynak yönetimi gibi kritik zorluklarla karşı karşıyadır. Bu bağlamda, akıllı tarım uygulamaları ve yapay zekâ teknolojilerinin kullanımı kaçınılmaz hale gelmiştir. Yapay zekâ tarım verilerini analiz ederek çiftçilere karar desteği sağlamakta üretim süreçlerini optimize etmekte ve otomasyon sistemleriyle verimliliği artırmaktadır. Bu teknolojilerin tarıma entegrasyonu hem üretim kapasitesini artıracak hem de iklim

değişikliği gibi çevresel faktörlere karşı daha dirençli bir tarım sisteminin oluşturulmasına katkı sağlayacaktır.

1.3 Tezin Amacı ve Hipotez

Küresel gıda güvenliği ve tarımsal verimliliğin artırılması adına modern tarım tekniklerinin uygulanması ayçiçeği üretiminin daha etkin yönetilmesini zorunlu kılmaktadır. Bu süreçte tarladaki yabani ot mücadelesi büyük önem taşımakta olup uygun stratejilerle gerçekleştirildiğinde bitkinin sağlıklı ve verimli gelişimi desteklenmektedir. Yabani otlarla mücadelede yönetim anlayışı tek değildir. Yabani otun hassas yönlerine göre birden fazla kontrol ve mücadele yöntemi entegre edilebilir. Herbisit kullanımıyla mücadele büyük alanlarda bir kaç farklı türle mücadelede etkin yöntem olarak kullanılmaktadır.

Özellikle hassas ilaçlama yöntemleri düşük yabani ot yoğunluklarında bile etkili bir mücadele sağlayarak kullanılan herbisit miktarını önemli ölçüde azaltma potansiyeline sahiptir. Geleneksel geniş alan ilaçlamalarına kıyasla hassas ilaçlama teknikleri tarımsal maliyetleri düşürmenin yanı sıra çevresel etkileri en aza indirmeye de yardımcı olmaktadır. Bu yöntem, hem ekonomik hem de ekolojik açıdan sürdürülebilir bir tarım modeli oluşturulmasına katkıda bulunur.

Sonuç olarak modern tarım uygulamalarının entegrasyonu ayçiçeği üretiminde verimliliği artırmanın yanı sıra çevresel sürdürülebilirliği koruma açısından da kritik bir rol oynamaktadır. Yabani ot yönetimi ve hassas ilaçlama teknolojilerinin etkin kullanımı sayesinde hem ekonomik verimlilik sağlanabilir hem de doğal kaynaklar korunarak tarımın geleceği güvence altına alınabilir.

Görüntüleme ayçiçeğinin V3-V4 fenolojik aşaması olarak tanımlanan 3-4 yapraklı dönemde gerçekleştirilmiştir. Bu dönem yabani ot yönetimi açısından kritik bir pencere niteliği taşımaktadır. V3-V4 aşamasında ayçiçeği bitkileri henüz yabani ot rekabetinden ciddi zarar görmemiş olmakla birlikte, yabani otlar da tam anlamıyla gelişimini tamamlamamıştır. Bu durum düşük herbisit dozlarıyla maksimum kontrol etkinliğine ulaşılmasına imkân tanımaktadır. Dolayısıyla görüntüleme zamanlaması yalnızca teknik bir tercih değil aynı zamanda erken dönem önleyici müdahale stratejisinin temel bir bileşeni olarak tasarlanmıştır. Bu aşamada elde edilen görüntüler üzerinden geliştirilen modeller müdahale için en uygun zaman

penceresi olan bu kritik dönemde doğrudan kullanılabilir nitelikte olup sahaya özgü herbisit reçete haritalarının pratik uygulanabilirliğini desteklemektedir.

Gerçek zamanlı bilgisayarlı görü kullanarak yabancı ot tespiti yeni bir kavram olmasa da kısıtlı kaynaklara sahip kenar cihazlarda uygulanması hâlâ zorluklar barındırmaktadır [34]. En büyük engellerden biri olan derin öğrenme (DÖ) modellerinin yüksek doğruluk seviyesini koruyarak verimli bir şekilde çalıştırılabilmesidir [35]. Transfer öğrenimi, büyük ölçekli DÖ modellerinin bir araya getirilmesi ve sıkıştırma tekniklerinin kullanılmasıyla hesaplama yükünü azaltmayı amaçlayan bir yöntemdir. Ancak bu yaklaşım, birden fazla büyük modelin eğitilmesi gerektiğinden hâlâ yoğun kaynak kullanımı gerektirmekte, model ince ayarlarını içermemekte ve transfer öğrenme sürecinde katman seçimi gibi optimizasyon tekniklerini değerlendirmemektedir. Bu zorlukları aşmak için, kenar cihazlarda çalıştırılmak üzere tasarlanmış YOLO ve EfficientNet gibi hafif derin öğrenme modelleri geliştirilmiştir [36].

Araştırmalar genellikle yeni derin öğrenme mimarileri geliştirmeye odaklanırken, hiperparametre optimizasyonuna yeterince dikkat edilmemektedir [37]. Oysa hiperparametre ayarlarının örneğin mini küme seçimi, düşü oranları ve optimizasyon algoritmaları model doğruluğunu artırmada ve hesaplama verimliliğini sağlamada kritik bir rol oynadığı bilinmektedir [38], [39]. Bu eksikliklerin giderilmesi için uyarlanabilir eğitim stratejileri optimize edilmiş transfer öğrenme yöntemleri ve gelişmiş hiperparametre ayarlarının uygulanması cihazlarda daha verimli ve etkili bir şekilde çalıştırılmasını sağlayabilir.

Bir diğer zorluk olan veri seti eksikliğinin giderilmesidir. Zayıf veri kümesi eğitimlerinde zayıf sonuçları temsil eden bir söylem olan “zayıf data zayıf sonuç” ile dile getirilmektedir. Sahadan elde edilen görüntülerde tarlaya özgü yabani ot çalışmasında başarılı sonuçlar vermesi mümkündür. Toprak bankasından çoğalan yabani otlar bölgeye göre çeşitlilik gösterdiği için uygulama alanları spesifik olarak seçilmektedir [4].

Bu araştırmanın temel amacı, ayçiçeği tarlalarında erken dönem yabani ot tespiti için Görüntü dönüştürücü tabanlı derin öğrenme modellerinin geliştirilmesi ve sahaya özgü yabani ot uygulamalarının pratik fizibilitesinin gösterilmesidir. Öncelikli amacımız etiketli verilerin azlığı göz önüne alındığında İHA

görüntülerinde bitki tanıma gibi özel görevler için dönüştürücü mimarilerinin uygulanabilirliğini araştırmaktır. Bu zorluğun üstesinden gelmek için çapraz doğrulama çerçevesinde değişen oranlarda eğitim ve test verilerinde görsel dönüştürücüler kullanarak öz dikkat mekanizmasının değerlendirilmesiyle desteklenen veri artırma ve transfer öğrenme tekniklerini değerlendirmektir. İHA'lardan elde edilen düşük irtifa hava görüntülerinin mahsul yönetimi için öz dikkat algoritmalarıyla entegrasyonunu, yabani ot ve mahsul görüntü sınıflandırması için hafif dönüştürücü modellerinin öncü araştırmasını ve farklı model varyasyonları arasında mahsul ve bitki sınıflandırmasında derin öğrenme algoritması genelleme yeteneklerinin değerlendirilmesini kapsamaktadır.

Bu genel amaç çerçevesinde:

1. **Veri Seti Oluşturma:** İHA ile elde edilen yüksek mekansal çözünürlüklü (1 cm) RGB ve multispektral görüntülerden sahaya özgü, ayçiçeği yabanı ot ve boş alan sınıflarını içeren dengeli veri setlerinin oluşturulması,
2. **Model Karşılaştırması:** Vision Transformer (ViT-B/16), budanmış ViT (ViT Pruned), MobileNetV2 ve NASNetMobile mimarilerinin ayçiçeği ve yabani ot sınıflandırmasında kapsamlı ve karşılaştırmalı performans değerlendirmesi yapılması,
3. **Optimizasyon:** Bayes optimizasyonu ile hiperparametre ayarlaması, ImageNet öğrenme aktarımı etkinliğinin araştırılması ve ince ayar stratejilerinin değerlendirilmesi,
4. **Herbisit Reçete Haritası:** Yama bazlı sınıflandırma sonuçlarından GNSS koordinatlarıyla eşleştirilmiş herbisit reçete haritalarının oluşturulması,
5. **Ekonomik-Çevresel Analiz:** Tarlaya özgü uygulama ile elde edilen herbisit tasarrufunun, maliyet azalmasının ve çevresel faydaların nicel olarak hesaplanması,
6. **Bant Karşılaştırması:** Üç bantlı (Kırmızı-Yeşil-Mavi) ve multispektral (Yeşil-Kızılötesi-Kırmızı Kenar) bantların sınıflandırmasındaki etkinliğinin karşılaştırılması ve maliyet fayda analizinin yapılması,

7. **Sahaya Aktarım Stratejileri:** Reçete haritalama ve gerçek zamanlı uygulama senaryolarının tanımlanması, teknik gereksinimlerin detaylandırılması ve pratik uygulanabilirliğin gösterilmesi

amaçlanmaktadır.

Araştırma Sorusu 1: Ayçiçeği tarımında erken dönem yabani ot tespiti için oluşturulan sahaya özgü veri setinin farklı türler arasındaki morfolojik benzerliklere rağmen ayırt edici temsil gücü ne düzeydedir?

Araştırma Sorusu 2: Hiperparametre optimizasyonu yönteminin görüntü dönüştürücü mimarisinin genelleme yeteneği ve sınıflandırma kararlılığı üzerindeki etkisi hangi ölçüdedir?

Araştırma Sorusu 3: Yapısal budama (structured pruning) yöntemiyle geliştirilen hafif dönüştürücü modellerin standart evrişimli sinir ağları ile kıyaslandığında doğruluk-hız dengesi açısından sunduğu avantajlar nelerdir?

Araştırma Sorusu 4: Yama tabanlı sınıflandırma ve segmentasyon verilerine dayalı oluşturulan reçete haritalarının geleneksel yekpare ilaçlama yöntemine göre herbisit kullanım hacmi ve çevresel sürdürülebilirlik üzerindeki potansiyel tasarruf oranı nedir?

Araştırma Sorusu 5: Multispektral görüntü bantlarının yüksek çözünürlüklü KYM görüntülere kıyasla yabani ot tespitindeki ayırıcı spektral katkısı ve maliyet-etkinlik oranı nedir?

Bu tez kapsamında üstteki sorulara cevap vermeye çalışacak hafif mimari tasarımlı derin öğrenme modellerinin ve görüntü dönüştürücülerin sahadan alınan multispektral görüntülerden oluşturulan ortofotoların yama tabanlı sınıflandırma segmentasyonu sonucunda herbisit kullanımının azaltılmasını amaçlayan ve akıllı tarım makinelerinin çalışmasında kullanılabilecek bir yöntem önerilmektedir. Aynı zamanda İHA'lardan üç bantlı görüntülerden de elde edilen ortofoto haritalarında ilaçlama reçete haritası olarak kullanımının da kolaylaşacağı kısıtlı işlem kapasitesindeki kişilerin hassas tarım cihazlarında faydalanacağı bir yöntem önerisi sunulmaktadır.

Araştırma soruları ve amaçları doğrultusunda, bu çalışmada test edilecek temel hipotezler aşağıda sunulmaktadır. Bu hipotezler, araştırmanın beklenen sonuçlarını ve test edilebilir önermelerini içermektedir.

Birinci hipotez, Görüntü dönüştürücü mimarisinin sahip olduğu öz-dikkat mekanizması ayçiçeği ve yabani otlar arasındaki karmaşık uzamsal ilişkileri konvolüsyonel sinir ağlarından daha etkin modelleyerek sınıflandırma doğruluğunda ve yabani ot tespit kesinliğinde istatistiksel olarak anlamlı bir artış sağlar.

İkinci hipotez, yapılandırılmış budama yöntemi, görüntü dönüştürücü modelinin hesaplama karmaşıklığını ve parametre sayısını %50 oranında azaltırken modelin çıkarım hızını en az iki kat artırır ve sınıflandırma performansında %1'den daha az bir kayıpla verimlilik doğruluk dengesini optimize eder.

Üçüncü hipotez, ayçiçeği bitkilerinin V3-V4 fenolojik aşamasındaki morfolojik kısıtlılıklarına rağmen derin öğrenme modelleri bitki-toprak ayrımını ve tür bazlı sınıflandırmayı %95'in üzerinde bir doğruluk eşiğiyle gerçekleştirerek yabani otlara yönelik önleyici müdahale stratejilerine teknik imkân sunar.

Dördüncü hipotez, yama bazlı sınıflandırma verilerine dayalı oluşturulan değişken oranlı herbisit reçete haritaları geleneksel yekpare ilaçlama yöntemine kıyasla toplam herbisit kullanım hacminde en az %50 oranında azalma sağlayarak tarımsal girdileri minimize eder ve çevresel kimyasal yükü düşürür.

Beşinci hipotez, multispektral bantların sunduğu spektral imza zenginliği bitki-toprak ayrımındaki belirsizlikleri azaltarak KYM görüntülere göre daha yüksek bir yabani ot kesinlik değeri sağlar. Ancak bu performans artışının maliyet etkinlik rasyosu KYM tabanlı sistemlerin operasyonel avantajını geçmez.

Altıncı hipotez, yama boyutunun sınıflandırma başarısında kritik rol oynadığıdır. 50×50 piksellik yama boyutu, erken dönem bitkilerin morfolojik detayları ile tarlanın uzamsal dokusu arasındaki bilgi kaybını minimize eden optimal ölçeği temsil ederek sınıflandırma doğruluğunu maksimize eder.

Yedinci hipotez, geliştirilen modellerin güçlü genelleştirme kapasitesine sahip olacağıdır. Öğrenme aktarımı ve Bayesyen optimizasyonun birleşik etkisi, modellerin eğitim ve test doğrulukları arasındaki marjinal farkı %2'nin altında

tutarak modelin farklı saha koşullarına ve görmediği verilere yönelik güçlü bir genelleme yeteneği sergilemesini sağlar.

Bu hipotezlerin testi araştırmanın deneysel aşamasında sistematik olarak gerçekleştirilecek ve sonuçlar, bulgular bölümünde detaylı olarak raporlanacaktır. Her hipotezin doğrulanması veya reddedilmesi, hassas tarım alanında önemli bilimsel katkılar sağlayacak ve gelecek araştırmalar için yol gösterici olacaktır.

2
YABANİ OT TESPİTİ UYGULAMARI

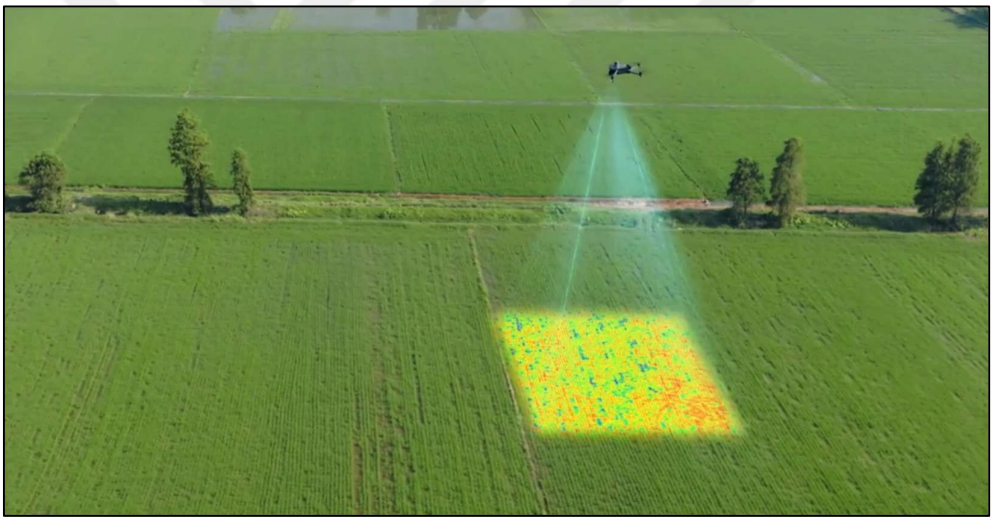
Modern tarım teknikleri verimliliği artırmak için girdilerin hassas bir şekilde uygulanması ve gelişmiş makinelerin kullanılması üzerine odaklanmaktadır. Bu yenilikler arasında insansız hava araçları hem büyük hem de küçük ölçekli tarımsal sorunların çözümünde güçlü bir araç olarak öne çıkmaktadır. İHA'ların kullanımıyla çiftçiler yabani ot kontrolü konusunda daha bilinçli kararlar alma kaynak kullanımını optimize etme ve çevresel etkileri en aza indirme fırsatı sunmaktadır. İHA teknolojisinin zamansal ve mekansal çözünürlüklü veri sağlama yeteneği tarımsal operasyonlarda esneklik sunmasıyla modern hassas tarım için vazgeçilmez bir araç haline gelmiştir. Yabani ot haritalama ve İHA teknolojisindeki gelişmeler sayesinde alan bazlı yabani ot yönetimi daha verimli ve sürdürülebilir hale gelmekte tarımsal zorluklara yönelik yaklaşımlar dönüştürülmektedir. Yabani ot kontrolü için akıllı ve otomatik makineler geliştirme endüstrisi büyük bir potansiyele sahiptir. Bu yaklaşım ekim sırasında mahsul bitkilerinin konumlarını haritalamayı ve bu haritayı yabani ot yönetimi gibi sonraki görevler için saklamayı içerir. Yabani otlar ortaya çıktığında bir yabani ot temizleme robotu bu mahsul haritasına gerçek zamanlı olarak erişerek mahsul bitkilerini ve yabani otları konumlarına göre ayırt edebilir.

2.1 İnsansız Hava Aracı Uygulamaları

İHA'ların tarımdaki temel uygulamaları arasında sulama planlaması, ürün takibi, toprak analizi ve arazi değerlendirmesi yer almaktadır. Ayrıca su kıtlığı veya zararlı istilaları gibi sorunları erken tespit ederek ürün kalitesini artırmada önemli bir rol oynar [30]. Özel kameralarla donatılmış araçlar olası sorunları erken aşamada belirleyerek ürünlerin daha iyi yönetilmesine olanak tanır [40]. Bu yaklaşım uydu ve İHA görüntülerini birleştirerek tarladaki yoğun ve seyrek alanları ayırt edebilmektedir [41]. Bitki biyokütlesi, zararlı istilası ve ayrıntılı yabani ot koşullarını yüksek mekânsal çözünürlükte gözlemlemeyi mümkün kılmaktadır. Geleneksel yöntemlerle karşılaştırıldığında operasyon süresini en az üçte bir oranında azaltarak çiftlik yönetimi için maliyet etkin bir çözüm sunmaktadır [41],

[42]. Ayrıca tarımsal sigorta süreçlerinde saha değerlendirmeleri ve sigorta talepleri için adli analiz gibi ek uygulamalarda da giderek daha fazla kullanılmaktadır [43].

İHA'lardan elde edilen dijital görüntüler kırmızı, yeşil ve mavi (KYM) renk kanallarının birleşiminden oluşan piksellerden meydana gelir ve bu görsel spektrum olarak bilinir [44], [45]. Standart bir tüketici sınıfı KYM kameradan elde edilen verilerle bitkilerin çiçek, meyve, dal ve gövde gibi yapılarının analizinde renk kombinasyonlarını ve derinlik bilgilerini hesaplayarak çeşitli yabani ot türlerini tespit edebilir ve sınıflandırabilir [46]. Bunun yanı sıra bitki boyutu, yaprak sayısı, yaprak şekli, yüzey dokusu, rengi ve mekânsal konum gibi diğer bitki özelliklerini de tespit edebilmektedir [47]. Şekil 2.1'de Multispektral algılama özelliğine sahip İHA görseli verilmiştir.



Şekil 2.1 Dji mavic 3 M (Web-4)

Sensörlerin küçülmesiyle birlikte İHA'lara entegre olabilen hiperspektral, multispektral ve termal görüntüleme imkânı kazanmıştır. Bu tarz verilerin analiz sonuçlarıysa çiftçilere sulama ihtiyaçlarını ve ürün kalitesini değerlendirme imkânı sunmaktadır. Bu sensörler yakın kızılötesi ve görünür ışık spektrumlarında veri toplayarak ürün sağlığının izlenmesini kolaylaştırır [48], [49]. Tarımsal ürün yönetiminin yanı sıra hayvancılık operasyonlarında da kullanılmaktadır. Hayvan hareketlerini izleyebilmekte ve gece görüşünün sınırlı olduğu durumlarda gece gözetimi yaparak pratik bir çözüm sunmaktadır. Daha düşük irtifalarda uçan İHA'lar tarlanın ayrıntılı görüntülerini yakalayarak zemindeki durumu daha doğru bir şekilde analiz edebilir [50], [51].

Geleneksel ilaçlama yöntemleri çiftçilerin tehlikeli kimyasallarla temas etmesi ve tekrarlayan maruz kalma nedeniyle ciddi riskler taşır. Bu tehlikeleri azaltmak için İHA tabanlı ilaçlama sistemleri geliştirilmiştir. Bunlar birkaç metre düşük irtifalarda uçacak şekilde tasarlanmış olup aktif alanlarda hassas ilaçlama kontrolü sağlar ve operatörlerin kimyasal maddelere maruz kalmasını en aza indirir. Sonuç olarak İHA'ların tarıma entegrasyonu modern tarım uygulamalarında önemli bir adımı temsil etmektedir. Verimliliği artıran, maliyetleri düşüren ve riskleri en aza indiren bu teknoloji çiftlik yönetimi, ürün takibi ve kaynak kullanımı açısından tarımı dönüştürmekte daha sürdürülebilir ve verimli tarımsal sistemlere olanak sağlamaktadır [43], [52]. Şekil 2.2'de ilaçlama senaryosu örneği gösterilmiştir.



Şekil 2.2 Dji agri ilaçlama senaryosu örneği (Web-5)

Yabani ot haritalaması hassas tarımda insansız hava araçlarının en öne çıkan uygulamalarından biri haline gelmiştir. Bu yöntem alan bazlı yabani ot yönetimi stratejilerinin uygulanmasında kritik bir rol oynar. Herbisitlerin tüm alana eşit şekilde olmasından ziyade belirli alanlarda değişken oranlarda uygulanmasını ifade eder. Yabani otların genellikle tarlanın yalnızca birkaç noktasında yoğunlaştığı göz önüne alındığında tarlalar yönetim bölgelerine ayrılır ve her bölgeye özel bir plan uygulanır. Bu yaklaşım, herbisit kullanımını optimize eder ve gereksiz uygulamaların önüne geçmektedir. Bu sürecin başarısı için herbisitlerin nerelerde yoğun şekilde, minimal düzeyde ya da hiç uygulanmaması gerektiğini belirleyen hassas bir yabani ot haritası oluşturulması gerekir.

Özellikle otlar ve mahsullerin erken büyüme aşamalarında benzer spektral ve görsel özelliklere sahip olması nedeniyle zorlu bir süreçtir [26], [53]. Geleneksel uzaktan algılama yöntemleri yalnızca piksel bazlı görüntü analizine dayanarak bu zorlukları aşmakta yetersiz kalabilir. Ancak, nesne tabanlı görüntü analizi bu sorunu çözmek için etkili bir yöntem sunar. Bitişik ve homojen spektral değerlere sahip pikselleri nesne olarak gruplandırır ve bu nesneleri spektral, topolojik ve bağlamsal özelliklere göre analiz ederek görüntü sınıflandırma doğruluğunu artırır. Wu ve arkadaşları, geniş sıralı ürünler için yabani ot tespitinde bitki nesnelerinin ürün sırası yapısındaki konumunun herbisit reçete haritaları oluşturulmasında kritik bir öneme sahip olduğunu belirtmiştir [54].

Erken sezon yabani ot haritalamada bir diğer önemli zorluk yüksek mekânsal çözünürlüklü görüntüleme sağlamak ve yabani otların hızlı bir şekilde kontrol edilmesini gerektiren kısa zaman aralığıdır. İHA'lar, bu ihtiyaçları karşılamak için uygun bir çözüm sunmaktadır. Milimetre veya santimetre seviyesinde çözünürlük sunabilen yüksek çözünürlüklü görüntüler yakalayabilen İHA'lar sayesinde küçük bitkileri veya yabani ot yığınlarını izleyebilirmektedir [55]. Ayrıca İHA'lar uçuş planlama ve operasyonlarında büyük bir esneklik sunar ve operasyon süresini önemli ölçüde azaltır.

Mink ve arkadaşları, İHA'lar tarafından çekilen hava görüntülerinin sıra ekimi yapılan mahsullerde yabani ot varlığını veya yokluğunu etkili bir şekilde tespit edebildiğini ve böylece hassas herbisit uygulamalarını mümkün kıldığını göstermiştir. Ayrıca, küçük insansız hava araçları yabani ot araştırmalarına kolayca entegre edilebilen ve alan bazlı yabani ot yönetim stratejilerinde büyük potansiyele sahip araçlardır [56], [57].

Yabani ot tespitinde yaygın olarak kullanılan kullanıcı dostu kameralar maliyeti düşük ve çoğu piyasada kolayca bulunabilen sensörlerdir. Bu kameralar, düşük bakım maliyetine sahiptir ve fotoğraf çekme ve görüntü analiz tekniklerini öğrenmek için az bir eğitim gerektirir [58], [59]. Örneğin, bitkideki klorofil ile polifenol oranlarını ölçerek azot eksikliğini tespit etmek amacıyla multispektral sensör verilerinden fark görüntüleri elde edilebilir. Ayrıca uzaktan algılama görüntülerindeki her bir piksele ait derinlik bilgisinin (yükseklik verisi) modele entegre edilmesi sınıflandırma doğruluğunu artırarak modelin genel performansını önemli ölçüde iyileştirmiştir [60].

Bunun yanı sıra, KYM görüntüler yapay zekâ uygulamalarında evrişimsel sinir ağlarını eğitmek için temel bir girdi sayılmaktadır. Bilgisayarlı görü tekniklerini kullanarak bu ağlar görsel desenleri analiz ederek yabani otlar ile mahsulleri ayırt edebilir [61]. Algoritmalar görüntülerdeki karelerini işlemek, özellikleri tespit etmek ve bitkileri doğru bir şekilde sınıflandırmak için tasarlanmıştır. Söz konusu veri işleme sürecinde, İHA üzerindeki sensörlerden elde edilen veriler bitki indekslerinin türetilmesi, nokta bulutlarının oluşturulması, makine öğrenimi modellerinin eğitilmesi ve kapsamlı istatistiksel analizlerin gerçekleştirilmesi gibi ileri düzey yöntemlerde temel girdi olarak kullanılmaktadır [59].

KYM kameralarda kullanılan sensörler, aydınlatma koşullarına karşı oldukça hassastır. Söz konusu sensörler bitki türleri arasında belirgin renk veya morfolojik (şekil) farklar bulunduğu durumlarda sınıflandırma görevini en yüksek doğrulukla yerine getirmektedir. Ancak üç ana bantla sınırlı spektral kapasitesi nedeniyle daha kapsamlı spektral bilgiler sunmakta yetersiz kalabilir. Sonuç olarak doğru kullanıldığında derinlik algılama ve makine öğrenimi gibi tamamlayıcı teknolojilerle birleştirildiğinde hassas tarımda yabani ot tespiti ve mahsul izleme için pratik ve etkili bir çözüm sunmaktadır [46], [62].

2.2 Makineli Yabani Ot Tespit Uygulamaları

2050 yılına doğru sebzeler, çiçekler ve otlar gibi ürünlerde yabani ot yönetimi uygulamalarında önemli değişiklikler beklenmektedir. Herbisit geliştirme ve dirençle ilgili mevcut eğilimler devam etse de benzersiz zorluklarla karşı karşıyadır. Bu zorlukların başında herbisit üreticilerinin potansiyel ürün hasarına bağlı mali sorumluluklar nedeniyle özel ürünleri herbisit etiketlerine dahil etmekte isteksiz olmaları gelmektedir. Ayrıca tarım sektöründeki iş gücü sıkıntısı ve el ile yabani ot temizleme maliyetlerindeki artarak geleneksel yabani ot yönetim yöntemlerini giderek daha pahalı ve sürdürülemez hale getirmiştir [3], [63]. Herbisit geliştirme maliyetlerinin yüksek kalması, pestisit üreticilerinin ürünlerdeki potansiyel sorumluluk risklerinden kaçınmaya devam etmesi ve iş gücü maliyetlerinin daha da artması muhtemeldir. Tüketicilerin sürdürülebilir ve kimyasalsız tarım uygulamalarını tercih etmesiyle organik gıda talebinin artması piyasayı geleneksel herbisit kullanımından giderek uzaklaştırmaktadır. Robotik ve makine görüşü, ürün-yabani ot tespit teknolojileri ve yenilenebilir enerji alanındaki ilerlemeler önümüzdeki otuz yıl içinde yabani ot yönetiminde devrim yaratmaya hazırlanıyor.

Bu yenilikler herbisitlere ve el iş gücüne olan bağımlılığı azaltarak verimli ve hassas yabani ot kontrol yöntemlerinin geliştirilmesine olanak tanımaktadır [64].

Arizona ve Kaliforniya gibi bölgelerde marul, genellikle 1-2 metre genişliğinde sırtlar üzerine sıralar halinde ve bitkiler arasında 4 ila 7 cm mesafe olacak şekilde ekilmektedir. Geleneksel olarak tarım işçileri çapa kullanarak bitkiler arasındaki mesafeyi 22 ila 30 cm'ye çıkarmak için elle seyreltme yaparlar. Bu iş gücü yoğun süreç seyrekleştirme ve el ile yabani ot temizliği dahil olmak üzere hektar başına yaklaşık 444 dolara mal olmaktadır [65]. Ancak seyreltme işlemlerinin zamanında yapılması kritik öneme sahiptir ve iş gücü sıkıntısı nedeniyle alternatif çözümler gerekmekteydi. Bu boşluğu doldurmak için firmalar otomatik marul seyrelticiler ve akıllı kültivatörler geliştirmiştir. Bu makineler makine görüşü kameraları, konum izleme sistemleri ve kültivatör bıçakları veya kontrollü püskürtme nozulları ile donatılmış aktüatörler gibi ileri teknolojiler kullanmaktadır. Makine görüşü kameraları bitki sırasını tanımak ve bitkiler arasındaki ideal mesafeyi hesaplamak için algoritmalar kullanan işlemcilerle veri toplayarak algoritmalar hassas seyreltme işlemleri gerçekleştirebilir. Şekil 2.3'de mekanik söküm aracı görseli verilmiştir.



Şekil 2.3 Bonirob Bosch mekanik yabani ot söküm makinesi

Mosqueda ve arkadaşlarının gerçekleştirdiği bir çalışmada, otomatik seyreltmenin manuel seyreltmeyle aynı şekilde bitkiler arasında 26 cm mesafe oluşturduğunu ancak otomatik sistemin 3.8 cm'lik standart sapma ile el ile seyreltmedeki 4.5 cm'ye kıyasla daha yüksek bir hassasiyet sağladığını göstermiştir. Otomatik seyreltme ve minimum el ile yabani ot temizliği kombinasyonu, toplam işlem süresini %36 oranında azaltarak manuel yöntemin hektar başına 29.3 saatlik süresinden daha verimli bir sonuç sağladı [66]. Geleneksel yöntemlere kıyasla maliyet etkin ve verimli bir alternatif sunmaktadır. İş gücüne olan bağımlılığı azaltmanın yanı sıra yabani ot yönetiminde tutarlılık ve hassasiyet sağlamaktadır. Bu da özellikle iş gücü ve herbisit kısıtlamalarıyla karşı karşıya olan özel ürünler için pratik bir çözüm sunmaktadır.

Robotik, ileri sensör teknolojileri ve yenilenebilir enerji çözümlerinin yabani ot yönetimine entegrasyonu tarımın geleceğini şekillendirecektir. Ticari ölçekte yabani ot kontrolü için entegre yaklaşımlar geliştirmek mekatronik makine öğrenimi ve otonom sistemler gibi gelişmiş teknolojik çözümlere büyük ölçüde bağlı olacaktır. Teknoloji yabani ot yönetiminde uzun bir geçmişe sahiptir ve bu alandaki ilk çalışmalar 1960'lara kadar uzanmaktadır [67]. İlk araştırmalar tarla görevlerini otomatikleştirmeye odaklanmış ve şeker pancarı seyreltme gibi işlemler için makineler geliştirilmiştir. Bu girişimler günümüzdeki modern teknolojik yeniliklerin temelini oluşturmuştur. 1990'larda hassas darbeli püskürtme sistemi tasarlayarak bu alanda önemli ilerlemeler kaydetmiştir. Bu robotik sistem, mobil bir platformdan yabani ot yapraklarına 1 cm kadar küçük alanlara mikro dozlarda herbisit uygulama yeteneğine sahip ilk makinelerdendir. Bu yenilik akıllı ve alan bazlı herbisit uygulamasının potansiyelini ortaya koymuş ve otomatik yabani ot kontrolünde gelecekteki gelişmelere öncülük etmiştir [68], [69].

Tamamen otonom yabani ot kontrolü sağlama yolundaki en büyük teknolojik engel bir yabani ot türünü algılayacak ve ayırt edecek sensörünün eksikliğidir. Bu sensör gerçek tarla koşullarında mahsuller ve yabani ot türleri arasında yüksek bir doğruluk oranıyla güvenilir bir şekilde ayrım yapabilmelidir. Geleneksel makine görüşü yaklaşımları yaprak veya bitki şekillerine dayalı özellik tanıma yöntemlerine dayanmaktadır. Yabani ot yoğunluğu düşük mahsullerin boyut ve ekim düzeni açısından belirgin olduğu erken büyüme aşamalarında başarı göstermiştir. Ancak yabani ot yoğunluğunun orta veya yüksek seviyelerde olduğu

durumlarda ya da mahsul ve yabani ot bitkilerinin benzer boyutlarda olduğu koşullarda bu yöntemler güvenilir olmaktan çıkmaktadır [70].

Otomatik yabani ot kontrol sistemleri için en umut verici iki sensör teknolojisi hiperspektral görüntüleme ve mahsul haritalama sensörleridir. Hiperspektral görüntüleme mahsul ve yabani otların benzersiz spektral imzalarına dayalı olarak daha hassas ayrım yapma yeteneği sunar. Ekim sırasında kullanılan mahsul haritalama sensörleri mahsul sıralarının uzamsal bir haritasını oluşturabilir ve bu harita daha sonra yabani otları mahsullerden ayırmak için referans olarak kullanılabilmektedir [71]. Şekil 2.4'te yabani ot kontrol robot örneği verilmiştir.



Şekil 2.4 Farklı yabani ot kontrol robotları [72].

Hiperspektral görüntüleme sensörlerinin etkinliği özellikle yabani ot yoğunluğunun yüksek olduğu ortamlarda, yabani ot tespiti için bir yöntem olarak öne çıkmıştır. Geleneksel şekil tabanlı tespit tekniklerinin aksine hiperspektral görüntüdeki her noktanın yansıtma spektrumunu ölçer ve bu sayede tüm bitkinin veya belirgin yaprak şekillerinin görünür olmasına gerek duymaz. Bu yöntem, bitki türlerini fiziksel yapılarından ziyade benzersiz spektral özelliklerine göre tanımlar [68], [72], [73]. Zhang ve Slaughter, hiperspektral görüntülemenin domates ile kara dul avrat otu gibi birbirine yakın türleri ayırt edebilme kapasitesini de göstermiştir. Bu durum yaprak şekilleri benzer olan türleri ayırt etmede karşılaşılan zorlukları aşma potansiyelini ortaya koymaktadır [68].

Hiperspektral görüntülemenin ticari anlamda başarıya ulaşması için ekipman üreticilerinin temel tarım ürünleri ve yabani ot türlerinin spektral yansıma özelliklerini geniş bir yetiştirme ortamı yelpazesi boyunca karakterize edebilecek gelişmiş makine öğrenimi algoritmaları geliştirmesi gerekmektedir [54]. Çevresel koşullara ait geçmiş spektral verileri kullanarak mahsul ile yabani otların doğru şekilde sınıflandırılmasını sağlar.

Çeşitli çalışmalar gerçek zamanlı hassas kinematik küresel konumlama sistemi kullanarak mahsul konumlarının ekim sırasında hassas bir şekilde haritalanabilirliğini göstermiştir. Pérez-Ruiz ve arkadaşları, bu sistemlerin mahsul konumlarını büyük bir hassasiyetle kaydedebileceğini kanıtlamıştır [73]. Mahsul konum haritasına gerçek zamanlı olarak erişebilen ve bu bilgiyi kullanarak sıra içindeki mahsuller arasında büyüyen yabani otları otomatik olarak temizleyen küçük bir robotik çapalar sistemi geliştirmiştir. Ayrıca santimetre hassasiyetindeki konumlama sistemleri tarımda halihazırda yaygın olarak kullanılmaktadır. Fiziksel olarak dayanıklı ve uyarlanabilir sistemlerdir. Bu sistemlerin maliyetlerinin düşmesi ve doğruluklarının gelişen teknoloji ile daha da artması beklenmektedir [72], [73].

Hassas ilaçlama yönteminin en büyük avantajlarından biri özellikle düşük yabani ot yoğunluklarında kullanılan herbisit miktarını büyük ölçüde azaltma potansiyelidir. Hassas ilaçlama ve geniş alan uygulamaları arasındaki herbisit kullanımı farkı maliyetleri düşürmek ve çevresel etkileri en aza indirmek açısından oldukça dikkat çekicidir. Sistem tabanlı yaklaşımlar, sıra içi kültivasyon teknolojileri ve hassas ilaçlama yenilikleri, yabani ot yönetiminde dönüşüm yaratacak adımlardır. Haritalama, robotik ve gelişmiş görüntü tanıma teknolojilerinden yararlanan bu sistemler daha verimli, hassas ve sürdürülebilir yabani ot kontrolü sağlar. Bu teknolojiler iş gücüne olan bağımlılığı azaltma ve yabani ot yönetiminin çevresel etkisini en aza indirme potansiyeline sahiptir.

3
MAKİNE ÖĞRENMESİ

Öğrenme insanların davranışlarının, bilgilerin, becerilerin ve değişimlerinin birbirleri arasında aktarımı sayesinde doğal olarak oluşmaktadır. Yapay zekâ, son dönemde büyük ilgi görerek gündemin merkezine otursa da aslında yeni bir kavram değildir. 1956 yılında ilk kez ortaya atılmıştır. İnsan zekâsı gerektiren görevleri gerçekleştirebilen akıllı makineler oluşturmayı amaçlayan bir alandır [74]. Yapay zekâ uygulamalarının temelinde doğrusal ve doğrusal olmayan karmaşık sorunları büyük veri kümelerinden çözme yeteneğiyle bilinen makine öğrenimi yer alır ve bu teknoloji çeşitli alanlarda uzun süredir kullanılmaktadır [75], [76].

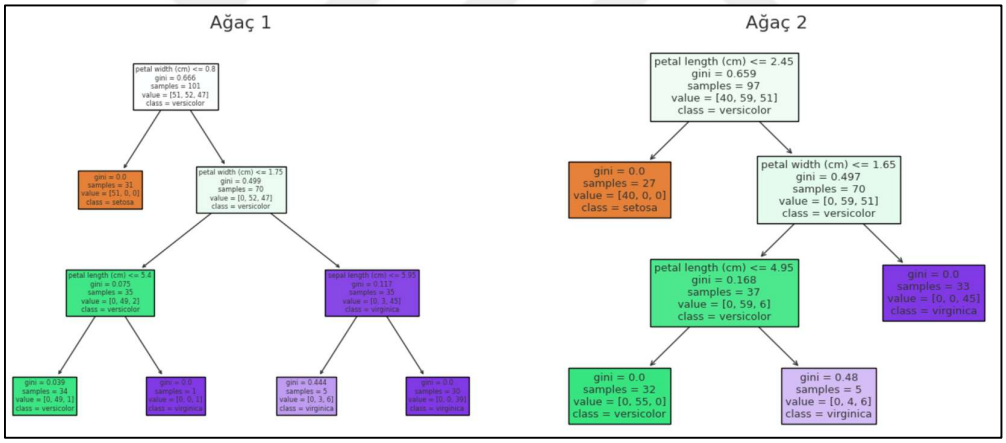
Yapay zekâ teorileri ve teknolojileri özellikle bilgisayarlı görü alanında büyük ilerleme kaydetmiştir [77]. Gelişmiş görüntüleme ekipmanlarının yaygınlaşmasıyla görüntülerden büyük miktarda veri oluşturulmuş ve bu verilerin işlenmesi geleneksel makine öğrenimi yöntemleri için önemli bir zorluk haline gelmiştir [54]. Makine öğreniminin bir alt dalı olan derin öğrenme bilgisayarlı görme, doğal dil işleme ve büyük veri analizi gibi alanlarda çığır açan ilerlemeler kaydederek en dikkat çekici sektörlerden biri haline gelmiştir [74].

3.1 Makine Öğrenmesi (Machine Learning)

Makine öğrenimi verileri anlamlı ve akıllı karar mekanizmalarına dönüştürmeyi hedefleyen bilgisayar tabanlı algoritmaların tasarımı ve geliştirilmesiyle ilgilenen bir alan olarak tanımlanır. Öğrenme insanlar için doğal bir süreç olup yeni bilgi, beceri, tutum, davranış ya da tercihlerin edinilmesi ya da mevcut olanların değiştirilmesini kapsar [78]. Makine öğrenmesi ise bu doğal öğrenme sürecine benzer şekilde makinelerin yani bilgisayarların dış müdahaleye gerek kalmadan kendi başlarına bilgi edinmelerini sağlayan bir yapay zekâ dalıdır. Bu sistemler gerçekleştirdikleri işlemleri daha doğru hale getirmek amacıyla sürekli olarak kendi davranışlarını güncellemeye çalışırlar. Burada doğruluk yapılan işlemlerin isabet oranı üzerinden değerlendirilir [79], [80]. Yapay zekânın bir alt dalı olan makine

öğrenmesi verilerden öğrenme yeteneğini esas alır ve elde edilen öğrenmeleri yeni veriler üzerinde uygulama prensibine dayanır.

Makine öğrenmesinde yer alan temel unsurlar sıralanabilir. Belirli bir problemi çözmeye yönelik oluşturulmuş prosedür dizisi olan algoritmalar, bu algoritmaların öğrendiklerini temsil eden modeller öğrenme sürecinde kullanılan etiketli ve çeşitli özelliklere sahip eğitim verisi ile bu modellerin genelleme gücünü test etmeye yarayan test verileridir. Modelin öğrenme başarısı doğrudan kullanılan verinin kalitesine ve içeriğine bağlıdır. Bu nedenle kullanılan verilerin ilgili problemle doğrudan ilişkili ve doğru bir şekilde etiketlenmiş olması kritik öneme sahiptir. Eğer eğitim verisi ile test verisi arasında ciddi farklılıklar varsa elde edilen sonuçların doğruluğu olumsuz etkilenebilir. Bu tür sapmaların önüne geçmek için veri etiketlemesinin özenli bir şekilde yapılması gerekmektedir [78], [81]. Şekil 3.1'de rastgele orman sınıflandırması verilmiştir.



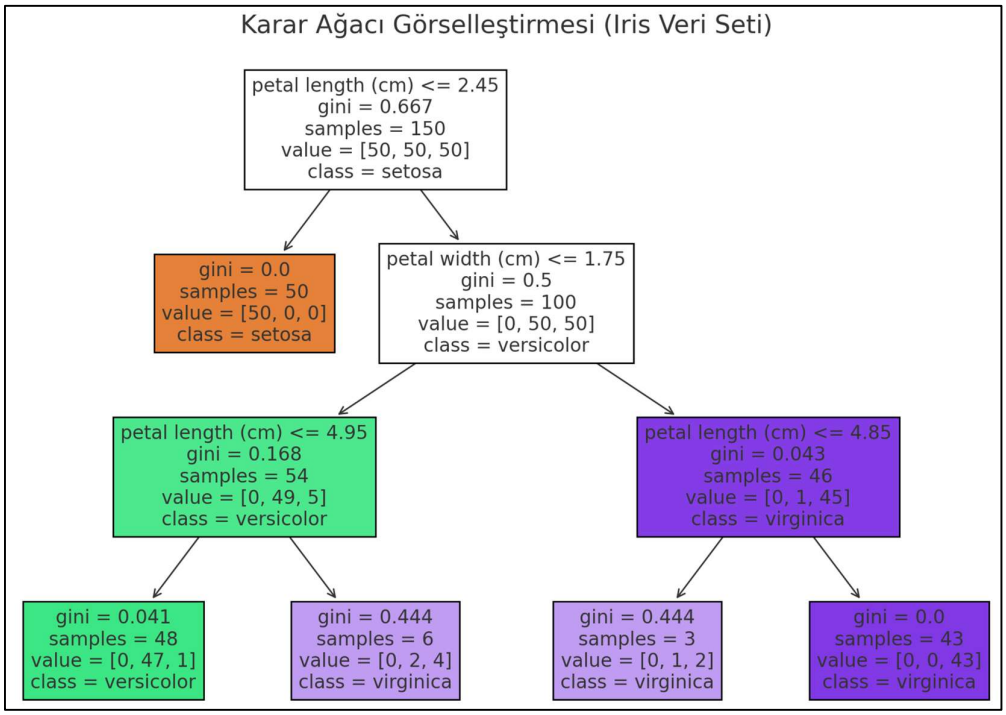
Şekil 3.1 Rastgele orman sınıflandırması gösterimi

Makine öğrenmesi, oldukça geniş bir kullanım alanına sahiptir ve hızla gelişen bir teknolojidir. Otonom araçlar, robotik sistemler, spam filtreleme, hastalık teşhisleri, ses işleme, finansal alanlarda sahtekarlık tespiti ve kredi risk analizleri gibi birçok farklı sektörde etkin bir şekilde kullanılmaktadır [11], [78]. Güçlü matematiksel altyapısı sayesinde karmaşık veri yapılarını analiz etmede oldukça başarılıdır. Geleneksel kural tabanlı sistemlerde kullanıcı tarafından belirlenen sabit parametrelerin aksine makine öğrenmesi modelleri gerekli parametreleri etiketlenmiş veriler üzerinden kendisi otomatik olarak çıkarabilir [82].

3.2 Denetimli Öğrenme (Supervised Learning)

Sınıflandırma problemlerinde en yaygın şekilde başvurulan yöntemlerden biri makineye insan tarafından tanımlanmış bir sınıflandırma yapısının öğretildiği denetimli öğrenme yaklaşımıdır. Bu yöntemde temel hedef belirli bir özellikler dizisiyle tanımlanan bir nesnenin ait olduğu sınıf etiketini doğru biçimde tahmin edebilecek bir tahmin modeli geliştirmektir. İlgili algoritma doğru sınıf etiketleriyle birlikte çeşitli nitelikleri içeren veri setlerini girdi olarak almaktadır. Tahmin edilen çıktı ile gerçek değer arasındaki farkları analiz ederek öğrenme sürecini gerçekleştirir.

Rastgele orman algoritması giriş verilerinden rastgele seçilen alt örneklem kümeleriyle oluşturulan çok sayıda karar ağacının çıktısını birleştiren bir topluluk yöntemidir [83]. Bu birleşim işlemi çoğunluk oylaması prensibiyle gerçekleştirilir ve sınıflandırma kararı bu şekilde verilir [84]. Algoritmanın uygulanmasında üretilecek karar ağacı sayısı her düğümde değerlendirilecek maksimum özellik sayısı ve bir düğümün ne derece ayrıntılı olarak bölünebileceğini belirleyen minimum yaprak sayısı gibi çeşitli hiperparametreler tanımlanır [85]. Şekil 3.2'de karar ağaçları şeması gösterilmiştir.

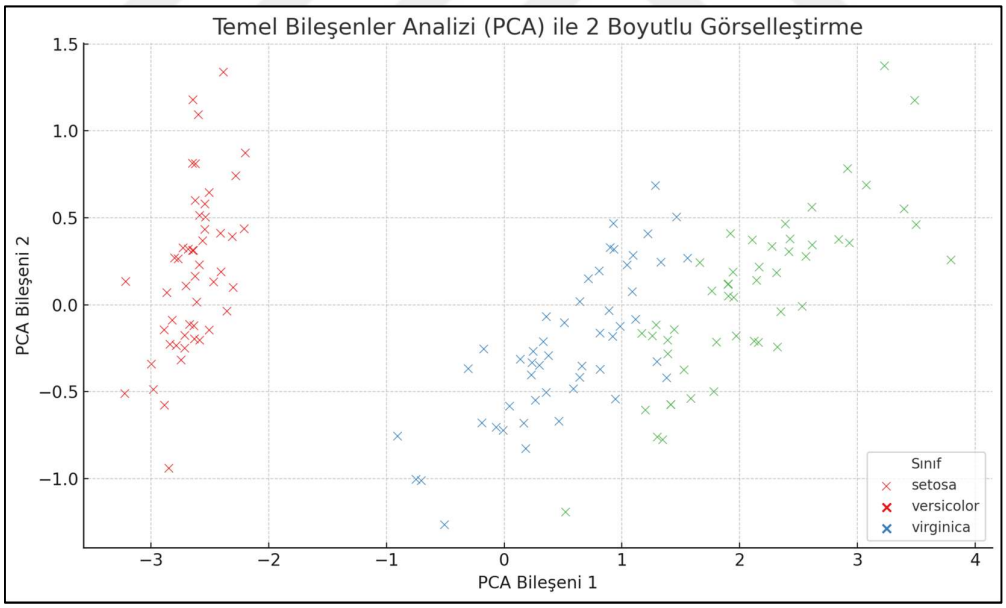


Şekil 3.2 Karar ağaçları gösterimi

3.3 Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenme yalnızca giriş verileri üzerinden işlem yapan ve bu verilerdeki iç yapıları, desenleri ya da kümeleri keşfetmeyi amaçlayan bir makine öğrenmesi tekniğidir [86], [87]. Bu yöntem, verilerin önceden etiketlenmediği durumlarda kullanılmakta olup sistemden beklenen çıktıların ne olması gerektiği önceden bilinmemektedir. Dolayısıyla model herhangi bir yönlendirme olmaksızın veri setindeki yapısal ilişkileri kendi başına belirlemeye çalışır [88].

Etiketli veriye ulaşmanın mümkün olmadığı ya da etiketleme sürecinin yüksek zaman ve iş gücü maliyeti gerektirdiği durumlarda denetimsiz öğrenme oldukça avantajlı hale gelmektedir. Özellikle veriler arasındaki yapısal bağların ortaya çıkarılmasının sınıf etiketlerinin belirlenmesinden daha önemli olduğu senaryolarda bu yaklaşım öne çıkmaktadır. Modelin başarımı ise büyük ölçüde kullanılan algoritmanın veriye uygunluğu ve veri kalitesi ile doğrudan ilişkilidir. Şekil 3.3'te temel bileşenler analizi görseli verilmiştir.

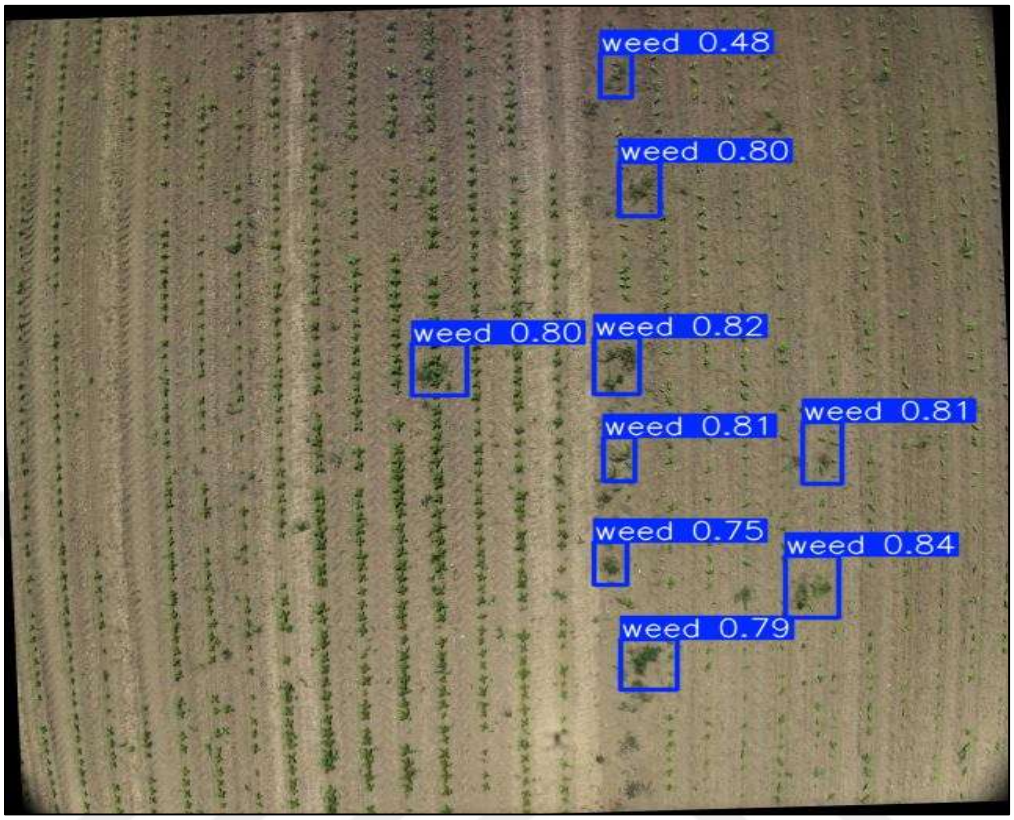


Şekil 3.3 Temel bileşenler analizi gösterimi

4
DERİN ÖĞRENME VE GÖRÜNTÜ DÖNÜŞTÜRÜCÜLER

Derin öğrenme birçok gizli katmana sahip yapay sinir ağlarını kullanarak ve büyük veri kümeleri üzerinde çalışarak temsili öğrenme gerçekleştiren bir teknolojidir. Geleneksel yöntemlerden farklı olarak algoritmaları karmaşık desenleri tanımlayabilir ve önemli ölçüde daha yüksek doğruluk sağlayabilir. Derin öğrenme algoritmaları verileri sıralı olarak katmanlardan geçirir ve her bir katman veriler üzerinde matematiksel işlemler gerçekleştirir. Son katman ise bir özellik çıkarımı veya sınıflandırma sonucu sunar [89].

DÖ'nin karmaşık ve ham verilerdeki desenleri modelleme yeteneği özellikle hassas tarım gibi alanlarda oldukça etkilidir. Teknolojiyi kullanarak tarımsal veri setlerinden karmaşık desenleri tanımlamakta ve kaynakları daha verimli kullanmayı sağlayan yenilikçi tarım yöntemleri geliştirmektedir [90]. Şekil 4.1'de yabani ot tespiti yapılan bir görüntü verilmiştir.



Şekil 4.1 Derin öğrenme yöntemiyle tespit edilen yabani otlar

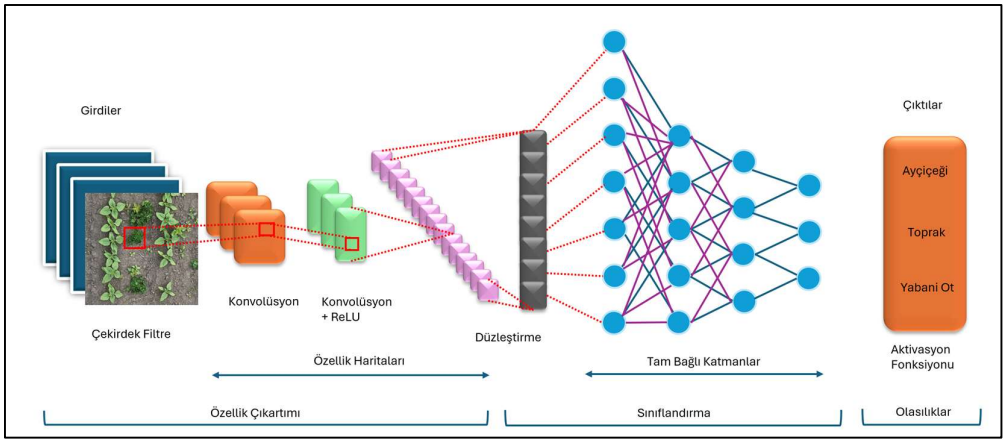
Yüksek hesaplama ihtiyaçları daha verimli modeller geliştirilmesine yönelik yoğun araştırmalara yol açmıştır. Çoğu çalışma model performansını artırmaya odaklanırken bazı araştırmalar model boyutunun küçültülmesi ve hiperparametre optimizasyonu üzerine yoğunlaşmıştır [37]. Hiperparametreler mini yığın, düşü oranı ve optimizasyon algoritmaları model doğruluğunu artırmada kritik bir rol oynamaktadır. Hiperparametrelerin optimize edilmiş kombinasyonlarının model performansını önemli ölçüde iyileştirdiği gözlemlenmiştir [38].

Aşırı öğrenme sinir ağlarında yaygın bir sorundur ve gradyan inişi gibi teknikler bu sorunun üstesinden gelmek için kullanılır. Bu yöntemde eğitim sırasında sinir ağındaki bazı birimler ve bağlantıları rastgele devre dışı bırakmaktadır. Derin öğrenme modellerinde optimizasyon algoritmaları kritik bir role sahiptir. Stokastik Gradyan İnişi (SGD) kayıp fonksiyonunu minimize etmek için kullanılan temel bir optimizasyon yöntemidir. Ancak ADAM (Adaptive Moment Estimation) ve RMSprop (Root Mean Square Propagation), gibi gelişmiş algoritmalar öğrenme oranlarını ve momentum değerlerini uyarlayarak optimizasyon sürecini hızlandırmaktadır [91], [92].

Derin öğrenme hızla gelişen bir alan olarak yüksek hesaplama doğruluğu ve gerçek zamanlı karar verme gereksinimlerini karşılamada önemli bir potansiyele sahiptir. Hesaplama zorlukları ve aşırı öğrenme gibi sorunların üstesinden gelinirken optimizasyon yöntemlerinde yapılan yeniliklerle DÖ'nin daha da esnek ve ölçeklenebilir bir teknoloji haline gelmesi beklenmektedir.

4.1 Evrişimli Sinir Ağları (Convolutional Neural Networks(CNN))

Konvolüsyonel (evrişimli) ağlar derin öğrenme uygulamalarında sıklıkla kullanılan bir yapay sinir ağı türüdür. Özellikle görsel veri analizi, görüntü tanıma ve sınıflandırma gibi görevlerde kullanılmaktadır. İlk kez 1990'larda Yann LeCun, Léon Bottou, Yoshua Bengio ve Patrick Haffner tarafından geliştirilen bu ağlar el yazısı rakamlarının tanınması gibi problemlerde etkili bir şekilde uygulanmıştır [93]. Evrişimli ağlar biyolojik görme sistemlerinden esinlenmiş modellerdir ve görüntü işleme görevlerinde kullanılmaktadır. Bu ağlar konvolüsyon, havuzlama ve tam bağlantılı katmanlardan oluşan bir yapıya sahiptir. Özellikle düşük seviyeli özellikleri yakalayan evrişimli katmanlar ve boyut azaltımı sağlayan havuzlama katmanları temel bileşenlerindendir. Şekil 4.2'de genel CNN yapısı verilmiştir.



Şekil 4.2 Genel CNN yapısı

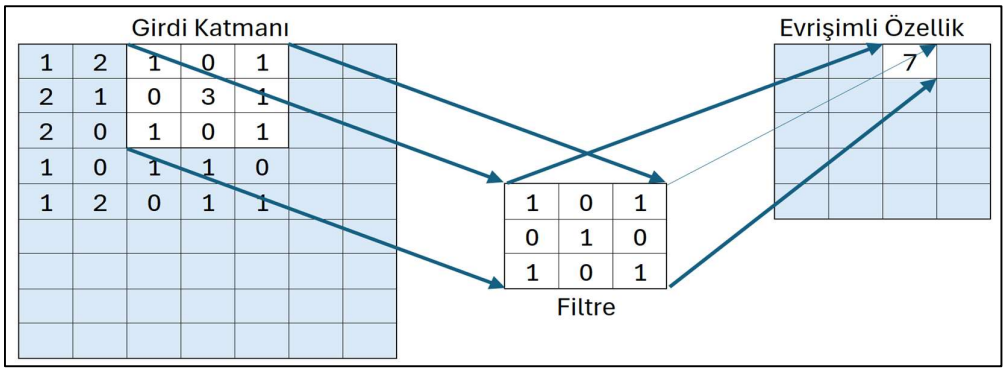
Bir CNN'in çalışma prensibi giriş verisini çeşitli katmanlar aracılığıyla işlemeye dayanır. Konvolüsyonel katmanlar, filtreler kullanarak görüntü üzerinde belirli özellikleri algılar ve özellik haritaları oluşturur. Bu filtreler kenar, köşe gibi belirli desenleri yakalamak için optimize edilir [93], [94]. Aktivasyon fonksiyonları bu özellik haritalarına doğrusal olmayan dönüşümler uygular. En yaygın kullanılan aktivasyon fonksiyonu ReLU'dur (Rectified Linear Unit) ve negatif değerleri

sıfırlayarak modelin doğrusal olmayan ilişkileri öğrenmesine olanak tanır [95]. Matematiksel olarak ifade edilirse RELU'nun girdisi x sıfırdan büyük olursa, sıfırdan küçük olursa ax olarak tanımlanmaktadır.

$$f(x) = \begin{cases} x & if\ x \geq 0 \\ ax & if\ x \leq 0 \end{cases} \tag{4.1}$$

Konvolüsyonlar, belirli bir boyutta bir dizi filtre çekirdeği oluşturarak çalışır ve yaygın olanı 3 × 3 × C ağırlıktır. Burada C giriş kanallarının sayısıdır. Filtre çekirdeklerinin sayısı evrişimsel katmanın çıkış kanallarının sayısına karar verir. Her çekirdek giriş boyunca kaydırılır ve çıkışa aktarılan her konum için ağırlıklı bir toplam hesaplanır.

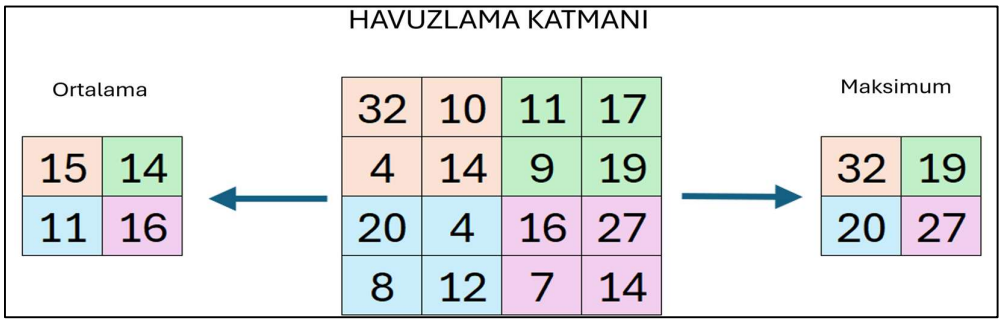
Çekirdeği 1 × 1'den büyük olan bir konvolüsyon, çıkış çözünürlüğünün azalmasına neden olur. Bu genellikle orijinal girdiyle aynı çözünürlükte bir çıktı elde etmek için girdi boyutunu yeterince artırmak amacıyla girdiyi sıfır değerlerle doldurarak karşılanır. Bu atlama adımı aynı zamanda sıfırdan daha yüksek bir sayıya da ayarlanabilir ve böylece çekirdek bir seferde birden fazla hücre kaydırabilir. Bu aynı zamanda daha düşük bir çıktı çözünürlüğü ile sonuçlanır [96]. Şekil 4.3'te evrişim katmanı örneği verilmiştir.



Şekil 4.3 Evrişim katmanı görseli

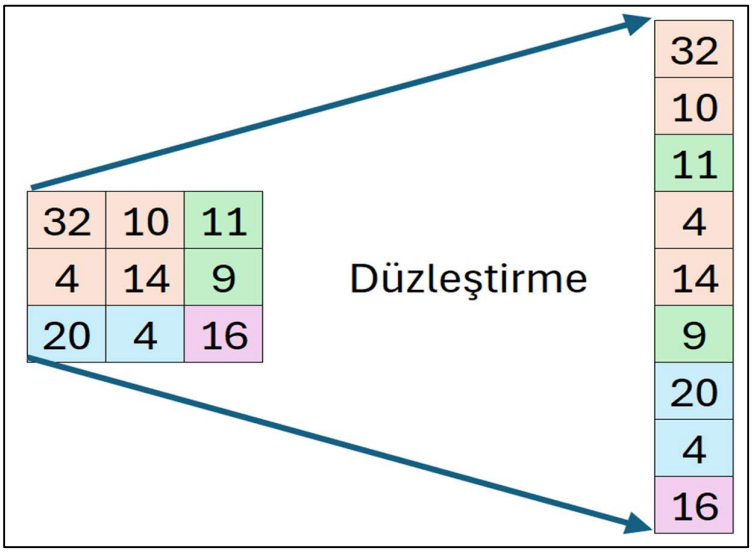
Havuzlama katmanları mimari ağda boyut azaltımı sağlayarak hem hesaplama yükünü azaltır hem de konumsal değişmezliği oluşturur. Maksimum havuzlama en yaygın kullanılan yöntemlerden biri olup bir penceredeki en büyük değeri seçerek özelliklerin daha kompakt temsillerini oluşturur [97]. Ancak dikkat tabanlı mekanizmalar havuzlamaya alternatif olarak önerilmiş ve daha iyi sonuçlar elde edilmiştir [98]. Normalizasyon katmanları ise ağın daha hızlı ve stabil bir şekilde öğrenmesi için kullanılır. Özellikle yığın normalizasyonu ve mini yığın içindeki

aktivasyonları normalize ederek eğitim sürecini hızlandırır ve genelleme yeteneğini artırır [99]. Şekil 4.4'te havuzlama işleminin görseli verilmiştir.



Şekil 4.4 Havuzlama katmanı görseli

Çıktının çözünürlüğünü azaltmak için bir konvolüsyonun adımını artırmanın bir alternatifi bir konvolüsyonel katmandan sonra adımlı bir havuzlama katmanı eklemektir. Bir havuzlama katmanı konvolüsyonlara benzer şekilde çalışır ve karşılık gelen piksel değerlerinin ağırlıklı bir toplamını hesaplamak yerine genellikle piksel değerlerinin maksimumunu veya ortalamasını çıkarmak için kullanılır. Bu katmanlar genellikle sırasıyla maksimum havuzlama veya ortalama havuzlama katmanları olarak adlandırılır. Bir maksimum veya ortalama havuzlama katmanı bir evrişim katmanının aksine herhangi bir ek eğitilebilir ağırlık getirmez [100]. Şekil 4.5'te düzleştirme katmanı sonuç örneği verilmiştir.



Şekil 4.5 Düzleştirme katmanı görseli

Tam bağlantılı katmanlar CNN'lerin son aşamasında yer alır ve sınıflandırma görevini üstlenir. Bu katmanlar düzleştirilmiş özellik haritalarını kullanarak tüm nöronları birbiriyle ilişkilendirir ve bu şekilde öğrenilen özellikleri sınıf etiketlerine bağlar [93]. Son dönemlerde tam bağlantılı katmanların yerine daha verimli bir çözüm olarak global ortalama havuzlama katmanları tercih edilmeye başlanmıştır. Modern CNN'ler, daha derin mimarilere ve daha küçük filtrelere yönelerek daha karmaşık özellikleri öğrenmeye çalışmaktadır [47], [101]. Genel olarak CNN'lerin başarısı katmanlar arasındaki iş birliği ve optimizasyon sürecine bağlıdır. Her bir bileşen görüntülerin farklı seviyelerde özelliklerini yakalamak ve işlemek için özel olarak tasarlanmıştır ve bu da CNN'leri görsel veri analizi için vazgeçilmez bir araç haline getirmiştir.

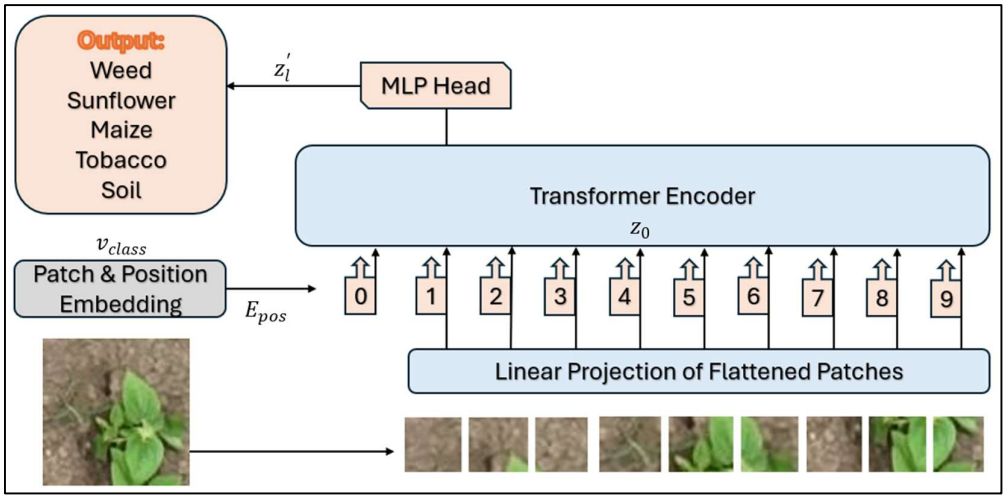
4.2 Görüntü Dönüştürücüler (Vision Transformers (ViT))

Görüntü dönüştürücüler başlangıçta doğal dil işleme için geliştirilen dönüştürücü modelini görüntü sınıflandırma alanına taşımaktadır. Geleneksel evrişimli sinir ağları görselleri yerel alıcı alanlar aracılığıyla işlerken, ViT bunun yerine öz dikkat (self-attention) mekanizmalarını kullanarak bir görüntüdeki uzak bağıntıları yakalar ve böylece görsel bilgiyi daha kapsamlı aynı zamanda bütüncül bir şekilde anlamlandırır [102]. Bu yaklaşım dil çevirisi ve metin işleme gibi görevlerde başarılı sonuçlar elde eden dönüştürücü mimarisinin üzerine inşa edilmiştir [103]. Tekrarlayan sinir ağlarının veriyi sıralı şekilde işlemesinin aksine kodlayıcı-çözücü (encoder-decoder) yapısı veriyi paralel olarak işler ve bu sayede verimliliği önemli ölçüde artırır [104]. ViT'nin başarısının temelinde diziler arasındaki ilişkileri koruyup analiz edebilen öz dikkat mekanizması bulunmaktadır. Bu mekanizma bağlamsal bilgiyi daha hassas bir şekilde yorumlamaya olanak tanır. Görüntü işleme görevlerinde ViT bir görüntüyü bir cümledeki kelimeleri işler gibi bir dizi küçük çakışmayan parçalara ayırarak işlemlere tabi tutar [105]. Bu yamaların her biri bir vektör temsiline dönüştürülerek önemli özelliklerin korunması sağlanır ve ardından bir dönüştürücü kodlayıcısına aktarılır. Bu yöntem, geleneksel CNN katmanlarına olan ihtiyacı ortadan kaldırırken ölçeklenebilir ve verimli görüntü analizi imkânı sunar [106].

ViT'nin mimarisi hem basit hem de etkili olacak şekilde tasarlanmıştır ve üç ana bileşenden oluşur. Gömme (embedding) katmanı, kodlayıcı ve sınıflandırma katmanı olarak adlandırılmaktadır. İlk olarak bir görüntü belirli boyutlarda

yamalara bölünerek her yama dönüştürücü modeli için bağımsız bir token olarak kullanılır [107]. Formülize edersek c×w×h boyutlarındaki bir görüntüde burada c kanal sayısını, h ve w ise yükseklik ve genişliği ifade eder. her biri c×p×p boyutunda olan yamalar çıkarılarak görüntü n adet yamaya dönüştürür. Burada $n = \frac{hw}{p^2}$ olarak hesaplanır [108]. Daha küçük yamalar 16×16 daha uzun diziler oluştururken, daha büyük yamalar 32×32 boyutları daha kısa diziler üretir [109].

ViT, her bir yamayı bağımsız bir token olarak ele alarak tıpkı doğal dil işlemedeki dönüştürücüler gibi bunları vektör alanına gömer ve her yamanın benzersiz özelliklerini yakalar [110]. Dönüştürücü kodlayıcısı bu yamalar arasındaki ilişkileri keşfetmek için öz dikkat mekanizmalarını kullanır ve böylece görüntü boyunca karmaşık desenleri ve yapıları algılamasını sağlar. CNN'lerin aksine bilgiyi hiyerarşik ve yerel olarak işlemek yerine ViT dizisel bir model kullanarak küresel bir dikkat (global attention) mekanizması uygular. Böylece detaylı görüntü analizi ve sınıflandırma için güçlü bir çerçeve sunar [111]. Sonuç olarak dönüştürücünün kapsamlı dikkat mekanizması ve uçtan uca tasarımı modelinin sadece dil işleme alanında değil bilgisayarlı görme görevlerinde de performans göstermesini sağlamaktadır [110]. Şekil 4.6'da dönüştürücü modelin yapısı gösterilmiştir.



Şekil 4.6 Dönüştürücü ana model şeması

Görüntü yamalarının düzleştirilmiş hali öğrenilebilir bir gömme matrisi (trainable embedding matrix) E aracılığıyla dönüştürülerek, modelle uyumlu özellik temsillerine çevrilir. Bu işlem görüntü parçalarının model tarafından işlenebilir hale getirilmesini sağlar. Ayrıca öğrenilebilir bir sınıflandırma parçası (v_{class})

sıralamanın başına eklenerek sınıflandırma sürecinde bir referans noktası görevi görür [112]. Dönüştürücü modeli bu gömülü yamaları birbirinden bağımsız parçalar olarak ele alır ve görüntü içindeki konumsal düzenlerini doğal olarak anlamaz.

Görüntünün orijinal uzamsal yapısını koruyabilmek için konum kodlaması (positional encoding) E_{pos} adı verilen eklemeler yapılır. Bu kodlama dizilim içindeki yamaların göreli konumlarını açık bir şekilde temsil eder ve modelin yamalar arasındaki mekansal ilişkileri daha iyi anlamasına yardımcı olmaktadır.

$$z_0 = [v_{class};\ x_1E; x_2E; \ldots; x_nE] + E_{pos}, \quad E \in \mathbb{R}^{(p^2c)\times d}, \quad E_{pos} \in \mathbb{R}^{(n+1)\times d} \tag{4.2}$$

Dizilim içindeki konumsal ilişkileri etkili bir şekilde yakalamak için genellikle daha basit olan 1 boyutlu kodlama tercih edilir [113]. ViT modeli hem konumsal bilgileri koruyarak hem de sınıflandırma sürecini daha stabil hale getirerek görüntü parçalarını işler ve analiz eder. Gömülü yama dizisi (z_0) modelin kodlayıcı (encoder) bölümüne aktarılır. Bu kodlayıcı giriş dizisinin temsillerini kademeli olarak iyileştirmek için tasarlanmış L adet özdeş katmandan oluşur [112]. Her katman iki ana bileşenden meydana gelmektedir. Çok başlıklı öz dikkat (multi-head self-attention, MSA) bloğu ve tam bağlantılı ileri beslemeli yoğun katmandır (fully connected feed-forward dense block) [102].

$$z_l' = \text{MSA}\ (\text{LN}(z_{l-1})) + z_{l-1}, \quad l = 1,\ldots,L \tag{4.3}$$

$$z_l = \text{MSA}\ (\text{LN}(z_{l-1})) + z_l', \quad l = 1,\ldots,L \tag{4.4}$$

Bu iki alt bileşen kalıntılı atlama bağlantıları (residual skip connections) ile güçlendirilmiş olup eğitim sürecini daha kararlı hale getirmek amacıyla normalizasyon katmanı tarafından ön işleme tabi tutulur [114]. Böylece kodlayıcı her bir yamanın daha anlamlı bir temsilini oluştururken modelin daha etkili ve stabil bir şekilde öğrenmesini sağlar.

Burada z_l' çok başlıklı öz dikkat mekanizması uygulandıktan sonra elde edilen çıktıyı ve z_l ise ileri beslemeli katmandan (feed-forward block) geçtikten sonraki nihai çıktıyı temsil eder. Bu katmanlı yapı kodlayıcının her aşamada yama gömülerini (patch embeddings) kademeli olarak iyileştirmesine olanak tanır. Böylece hem yerel hem de küresel bağıntıları öğrenerek sınıflandırma gibi sonraki görevler için gerekli olan kritik bilgileri yakalamaktadır [110].

$$y = \text{LN}(z_l^0) \tag{4.5}$$

Kodlayıcının son katmanında, başlangıçtaki dizi elemanı z_0^L çıkarılarak dış bir sınıflandırma başlığına iletilir. Bu bileşen modelin ilgili sınıf etiketini tahmin etmesini sağlar. Böylece kodlama süreci boyunca tüm yamalardan gelen bilgiyi bir araya getiren sınıflandırma tokeni tahmin görevinde etkin bir şekilde kullanılır [115].

Çok başlıklı dikkat bloğunun temel amacı dizilim içindeki her yama gömüsünün diğer yamalara kıyasla göreceli önemini değerlendirmektir. Bu blok dört temel bileşenden oluşmaktadır. Girişleri sorgu (query(Q)), anahtar (key(K)) ve değer (value(V)) vektörlerine çeviren doğrusal katman, dikkat skorlarını hesaplayan öz dikkat (self-attention) mekanizması farklı dikkat başlıklarından gelen çıktıları birleştiren birleştirme katmanı (concatenation layer) ve boyut indirgeme ve entegrasyon işlemlerini gerçekleştiren son doğrusal katmandır. Bu yapı modelin görüntü yamaları arasındaki karmaşık ilişkileri tanımlamasına olanak tanır ve böylece ilgili özelliklere odaklanmasını sağlamaktadır. Bu sayede modelin sınıflandırma gibi sonraki görevlerde daha etkili sonuçlar üretmesi mümkün hale gelmektedir [108].

$$[\mathrm{Q}, \mathrm{K}, \mathrm{V}] = zU_{QKV}, U_{QKV} \in \mathbb{R}^{d \times 3D_K} \tag{4.6}$$

Dikkat mekanizmasının temelinde bir dizilim içindeki her bileşenin önem derecesini belirlemek amacıyla dikkat ağırlıklarını (attention weights) hesaplamak yer alır. Bu ağırlıklar dizideki tüm değerlerin ağırlıklı toplamını temsil eder. Öz dikkat (self-attention) mekanizmasında ağırlıklar sorgu, anahtar ve değer çarpımı yöntemiyle elde edilmektedir [109].

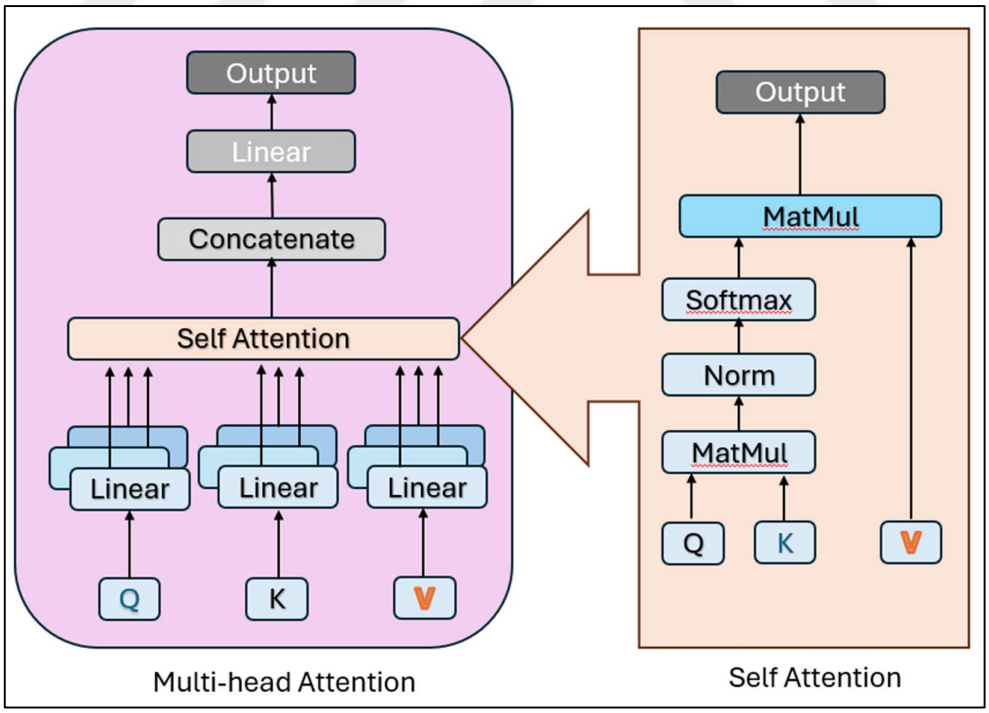
Her giriş bileşeni üç farklı öğrenilebilir matris U_Q, U_K ve U_V ile çarpılarak Q, K ve V vektörlerine dönüştürülür (Denklem 4.6). Bu süreç dizilimdeki her elemanın diğer bileşenlerle olan ilişkisini dinamik bir şekilde öğrenmesine olanak tanır ve modelin en alakalı özelliklere odaklanmasını sağlamaktadır [112].

$$\mathrm{A} = \mathrm{softmax}\left(\frac{QK^T}{\sqrt{D_K}}\right), A \in \mathbb{R}^{n \times n} \tag{4.7}$$

Bir dizilimdeki bir bileşenin diğerlerine göre ilişkililiğini değerlendirmek için ilgili bileşenin Q vektörü dizideki tüm diğer bileşenlerin K vektörleriyle nokta çarpımı işlemine tabi tutulur. Elde edilen bu değerler dizilimdeki farklı yamaların göreceli önemini sayısal olarak ifade eder [53].

$$SA(z) = A.V \tag{4.8}$$

Bu işlem sonucunda üretilen çıktılar anahtar vektörlerinin (K) boyutuna D_K ölçeklenerek gradyanların daha stabil hale gelmesi sağlanır. Daha sonra değerler olasılıklara dönüştürülmesi için softmax fonksiyonundan geçirilir (Denklem 4.7). Son aşamada bu olasılıklar ağırlıklar olarak kullanılarak V vektörlerinin ağırlıklı toplamı hesaplanır ve böylece dizideki en önemli öğeleri vurgulayan dikkat skorları (attention scores) elde edilir (Denklem 4.8) [115]. Bu süreç modelin her bileşenin bağlamsal önemini anlamasına ve en alakalı bilgileri öne çıkarmasına olanak tanır. Öz dikkat (self-attention) bloğunun dizilim içindeki en ilgili bölgelere odaklanmasını sağlayarak giriş verisindeki yamalar arasındaki ilişkileri tanımlamak ve modellemek için güçlü bir mekanizma haline gelmesini mümkün kılmaktadır. Çok başlıklı dikkat (Multi-Head Self-Attention) bloğu standart öz dikkat mekanizmasını geliştirerek ölçeklenmiş nokta çarpımı dikkat (scaled dot-product attention) hesaplamalarını birden fazla dikkat başlığı (attention head) üzerinden gerçekleştirir [116]. Şekil 4.7'de öz dikkat mekanizma örneği verilmiştir.



Şekil 4.7 Çoklu ve öz dikkat mekanizması

Çoklu dikkat bloğu teker teker sorgu, anahtar ve değer vektörleri ile işlem yapmak yerine farklı dikkat başlıklarını kullanarak giriş verisindeki çeşitli ilişkileri yakalar

[109]. Her dikkat başlığı giriş temsillerinin farklı alt alanlarını bağımsız olarak işler ve kendi başına dikkat mekanizmasını uygular. Ardından tüm dikkat başlıklarından elde edilen çıktılar tek bir vektörde birleştirilir ve öğrenilebilir W ağırlıkları içeren ileri beslemeli bir katmandan geçirilerek istenilen çıktı boyutuna dönüştürülür [103]. Bu yapı modelin farklı bakış açılarından gelen bilgileri etkili bir şekilde birleştirmesine olanak tanır ve dizilimdeki en alakalı özellikleri seçerek daha güçlü ve kapsamlı bir bilgi temsili oluşturmasını sağlamaktadır.

$$\mathrm{MSA}(z) = \mathrm{Concat}\left(\mathrm{SA}_1(z), \mathrm{SA}_2(z), \ldots, \mathrm{SA}_h(z)\right) W, \quad W \in \mathbb{R}^{hD_K \times D} \tag{4.9}$$

Burada, h dikkat başlıklarının (attention heads) sayısını, D_K her başlığın çıktı boyutunu ve D ise toplam çıktı boyutunu ifade etmektedir [110].

Bu çok başlıklı dikkat mekanizması bloğu aynı anda giriş dizisindeki farklı özelliklere odaklanarak daha zengin ve ayrıntılı temsiller öğrenmesini sağlar. Böylece model çeşitli ilişkileri paralel olarak analiz edebilir ve her dikkat başlığı farklı desenleri keşfederek modelin daha derin bağlamsal bilgiler edinmesine olanak tanımaktadır. Modelin giriş verisini daha geniş bir perspektiften işlemesini ve daha güçlü bir bilgi bütünlüğü oluşturmasını mümkün kılmaktadır. Tablo 4.1'de modellerin parametreleri ve katman sayıları gösterilmiştir.

Tablo 4.1 ViT model parametreleri ve katmanları

Model	Katman Sayısı	Gizli Boyut	MLP Boyutu	Başlık	Parametre
ViT-Base	12	768	3072	12	86 m
ViT-Large	24	1024	4096	16	307 m
ViT-Huge	32	1280	5120	16	632 m

Görüntü dönüştürücülerin çeşitli versiyonları model boyutunun sınıflandırma doğruluğu üzerindeki etkisini incelemek amacıyla geliştirilmiştir. Bu varyantlar arasında ViT-Base, ViT-Large ve ViT-Huge yer almakta olup her biri farklı mimari bileşenlere sahiptir. Kodlayıcı katmanlarının sayısı, gizli katman boyutları, çok başlıklı dikkat bloklarındaki dikkat başlıklarının sayısı ve MLP (Multi Layer

Perceptron) sınıflandırıcının büyüklüğü bu versiyonlar arasındaki temel farklılıklardır [117]. Bu çeşitlilik ViT yapısının farklı ihtiyaçlara uyarlanabilir ve ölçeklenebilir olduğunu göstermektedir. ViT-Huge gibi büyük modeller karmaşık ilişkileri yakalamada ve daha yüksek doğruluk elde etmede başarılı olsalar da aynı zamanda daha fazla hesaplama gücü gerektirirler. Farklı versiyonların karşılaştırılması hesaplama maliyeti ile sınıflandırma doğruluğu arasındaki dengeyi değerlendirmeye yardımcı olur ve modelin belirli görevler ile kısıtlamalara uygun hale getirilmesini sağlamaktadır [118].

Farklı boyutlardaki dönüştürücü modellerinin model ölçeği büyüdükçe daha yüksek doğruluk oranlarına ulaştığını ortaya koymaktadır. Daha küçük yama boyutlarının tercih edilmesi dizi uzunluğunu (n) artırarak modelin genel performansını iyileştirmektedir. Özellikle ViT'nin erken katmanlarındaki dikkat başlıkları görüntüde uzak bölgeler arasındaki ilişkileri yakalayabilme yeteneğine sahiptir. Modelin derinliği arttıkça bu özelliğin daha belirgin hale geldiği gözlemlenmiştir. Bu durum CNN tabanlı modellerden belirgin şekilde ayrılmaktadır. CNN'lerde erken katmanlar daha çok yerel özellikleri yakalarken geniş ölçekli özellikler ancak derin katmanlarda öğrenilmektedir. Bunun yanında dönüştürücüler hem yerel hem de uzak bölgeler arasındaki ilişkileri ilk katmanlardan itibaren değerlendirmesinden ötürü sınıflandırma için gerekli olan kritik görsel bilgileri daha verimli şekilde çıkarabilmektedir. Bu özellik ViT'nin karmaşık görsel verileri işleyebilme konusundaki üstün başarısını vurgulamaktadır [119].

4.3 Hiper Parametreler ve Optimizerler

Konvolüsyonel ağların ve dönüştürücü gibi diğer derin öğrenme modellerinin başarısını etkileyen en önemli faktörlerden biri hiperparametrelerdir. Bu parametreler modelin yapısını ve eğitim sürecini düzenleyen sonuç üzerinde büyük bir etkisi olan ve kullanıcı tarafından ayarlanan değerlerdir. Öğrenme hızı, yığın boyutu, katman sayısı, filtre boyutları, optimizasyon algoritmaları ve düzenlileştirme yöntemleri modelin öğrenme kapasitesini genelleme yeteneğini ve eğitim sürecinin verimliliğini doğrudan şekillendirir. Öğrenme hızı modelin ağırlık güncelleme hızını kontrol ederken yığın boyutu eğitimde kullanılan veri miktarını belirler. Ayrıca düzenlileştirme teknikleri aşırı öğrenmeyi önlemede kritik bir rol oynar [120]. Öte yandan dönüştürücü mimarisi yapay zekâ ve doğal dil işleme alanlarında devrim niteliğinde bir yapı sunmuş dikkat mekanizmasını kullanarak

uzun metinler arasındaki bağıntıları başarılı bir şekilde işleyebilme kapasitesiyle ön plana çıkmıştır. Özellikle GPT ve BERT gibi modellerin temel yapısını oluşturarak büyük veri kümeleriyle yüksek doğruluk elde edilmesine olanak tanımış ve paralel işleme yeteneğiyle derin öğrenme alanında önemli bir gelişme kaydetmiştir. Hiperparametrelerin optimize edilmesi ve dönüştürücü gibi yenilikçi mimarilerin geliştirilmesi derin öğrenme modellerinin performansını artırarak yapay zekâ alanındaki ilerlemelere önemli katkılar sağlamaktadır [121].

Yığın boyutu bir eğitim adımında modele aynı anda sunulan veri örneklerinin miktarını ifade eder ve derin öğrenme modellerinin eğitim sürecinde önemli bir yere sahiptir. Büyük yığın boyutları daha stabil ve tutarlı türev (gradyan) güncellemeleri sağlarken tek bir eğitim adımının süresini uzatarak toplam eğitim süresini etkileyebilir ve daha fazla bellek gereksinimine yol açabilir. Küçük yığın boyutları ise ağırlık güncellemelerinin daha sık yapılmasına olanak tanıyarak öğrenme sürecini hızlandırabilir. Ancak bu durumda hesaplama maliyeti artabilir ve türev tahminleri daha gürültülü hale gelebilir. Yığın boyutunun modelin doğruluğu ve genelleme kapasitesi üzerindeki etkisini vurgulayarak uygun boyut seçiminin modelin eğitim sürecinin başarısı için kritik olduğunu belirtmiştir. Optimal yığın boyutunu belirlemek için hesaplama kaynakları, veri özellikleri ve model performansı arasında dikkatli bir denge gerektirir [122].

Öğrenme hızı bir modelin ağırlıklarını her eğitim adımında ne kadar değiştireceğini belirleyen önemli bir hiperparametredir. Yüksek bir öğrenme hızı modelin ağırlık güncellemelerinin dengesizleşmesine ve optimizasyon sürecinin kararsız hale gelmesine yol açabilir. Düşük bir öğrenme hızı modelin hedefe ulaşmasını yavaşlatabilir ve eğitim süresini gereksiz yere uzatabilir [123], [124]. Eğitim sırasında öğrenme hızını optimize etmek için öğrenme hızı planlayıcıları kullanılabilir. Bu planlayıcılar eğitim boyunca öğrenme hızını otomatik olarak ayarlayarak modelin daha iyi sonuçlar elde etmesini sağlar. Ayrıca, Adam ve RMSprop gibi adaptif öğrenme hızı algoritmaları öğrenme hızını parametre güncellemelerine göre uyarlayarak eğitim sürecini daha verimli ve kararlı hale getirir [125]. Doğru bir öğrenme hızı seçimi modelin etkili ve hızlı bir şekilde öğrenmesini sağlamak açısından büyük önem taşımaktadır.

CNN'lerin performansı hiperparametrelerin doğru bir şekilde ayarlanmasıyla yakından ilişkilidir. Öğrenme hızı, yığın boyutu, katman sayısı, filtre boyutları,

optimizasyon algoritmaları ve düzenlileştirme teknikleri modelin başarısını doğrudan etkileyen temel faktörlerdir. Hiperparametre optimizasyonu bu parametrelerin en uygun kombinasyonunu belirleyerek modelin performansını maksimize etmeyi hedefler. Derin öğrenme araştırmacıları bu süreçleri daha etkili ve verimli hale getirmek amacıyla sürekli olarak yeni yaklaşımlar geliştirmektedir. Bir CNN'nin performansı katman derinliği ve her katmandaki filtrelerin boyutlarına da bağlıdır. Derin ağlar daha karmaşık desenleri öğrenme yeteneğine sahip olsa da aşırı derinlik aşırı öğrenmeye (overfitting) ve hesaplama zorluklarına neden olabilir. Filtre boyutları ise çıkarılan özelliklerin detay seviyesini belirlemektedir. Örneğin, küçük boyutlu filtreler (3x3) daha ince ayrıntıları yakalayabilirken, büyük filtreler (5x5 veya 7x7) daha geniş alanları analiz eder [126]. Şekil 4.2'de model hiperparametrelerin tablosu verilmiştir.

Tablo 4.2 Hiperparametreler ve değer aralıkları

Hiperparametreler	**Değer Aralıkları**
Optimizer Yöntemi	SGD, ADAM, RMSProp
Öğrenme Hızı	$1\text{-}e^{-4}$, $1\text{-}e^{-5}$
Girdi Boyutu	64, 128, 256
Epok Sayısı	10, 30

Düzenlileştirme yöntemleri modelin genelleme kabiliyetini artırmak ve aşırı öğrenmeyi önlemek için kullanılır. En yaygın düzenlileştirme teknikleri arasında dropout, L2 düzenlileştirme (weight decay) ve veri artırma yer alır. Dropout eğitim sırasında belirli nöronları rastgele devre dışı bırakarak modelin daha genel özellikler öğrenmesine yardımcı olur [127]. L2 düzenlileştirme model ağırlıklarının büyüklüğünü sınırlayarak daha stabil bir öğrenme süreci sağlar. Veri artırma ise eğitim verisini çeşitli dönüşümlerle zenginleştirerek modelin genelleme yeteneğini geliştirir [94]. Hiperparametre optimizasyonu model performansını iyileştirmek için bu parametrelerin ideal değerlerini bulmayı hedefler. En sık kullanılan yöntemler arasında ızgara arama (grid search), rastgele arama (random search) ve bayes optimizasyonu bulunmaktadır [93]. Son yıllarda otomatik makine öğrenimi

otomatik makine öğrenmesi araçları hiperparametre optimizasyonu süreçlerini otomatikleştirerek daha hızlı ve etkili çözümler sunmuştur [128].

Derin öğrenmede kullanılan optimizasyon algoritmaları modelin eğitimi sırasında ağırlıklar ve diğer parametreler üzerinde güncellemeler yaparak kayıp fonksiyonunu minimize etmeyi ve doğruluğu en üst düzeye çıkarmayı hedefleyen yöntemlerdir. Bu algoritmaların temel amacı kayıp fonksiyonunu en aza indirmek olsa da bunun ötesinde pek çok önemli işlevi bulunmaktadır. Türevlerin doğru bir şekilde hesaplanması, öğrenme oranını yönetmek ve yakınsama hızını optimize etmek gibi parametre güncellemeleri sırasında oluşabilecek dalgalanmaları azaltarak modelin stabil bir şekilde öğrenmesini sağlamaktadır. Adaptif güncellemelerle farklı parametrelerin farklı hızlarda öğrenmesini desteklemek ve aşırı öğrenmeyi önlemek bu işlevler arasındadır. Bu özellikler modelin daha etkili ve verimli bir şekilde eğitilmesine olanak tanıyarak derin öğrenme modellerinin başarı oranını artırmaktadır [129].

Stokastik amaç fonksiyonlarının birinci dereceden türev tabanlı optimizasyonu için tasarlanan ADAM algoritması düşük dereceli momentlerin adaptif tahminlerine dayanır. Bu algoritma uygulama kolaylığı, hesaplama verimliliği ve düşük bellek gereksinimiyle dikkat çeker. ADAM'ın performansı deneysel olarak incelendiğinde diğer stokastik optimizasyon yöntemlerine kıyasla etkili ve olumlu sonuçlar sağladığı görülmüştür [130]. ADAM algoritmasının standart Stokastik Gradyan İnişi ve RMSProp yöntemlerine kıyasla, büyük ölçekli görüntü sınıflandırma görevlerinde derin evrişimli sinir ağlarının eğitim hızını ve yakınsama performansını önemli ölçüde artırdığını göstermektedir [129]. ADAM ve RMSProp gibi iki popüler yöntemin avantajlarını birleştirerek her bir parametre için uyarlanabilir öğrenme oranları hesaplar. Bu adaptif yaklaşım uygulamada daha hızlı ve daha kararlı bir yakınsama süreci sağlar [131].

Stokastik Gradyan İnişi eğitim sırasında tüm veri seti yerine rastgele seçilen bir veri örneği üzerinde gradyan hesaplaması yaparak geleneksel gradyan inişi yöntemine bir alternatif olarak geliştirilmiştir. Bu yöntem büyük veri setleri üzerinde daha hızlı güncellemeler yapmayı, maliyeti düşürmeyi ve hesaplama kolaylığı sağlamayı mümkün kılar. Ancak gürültü ve kararsız yakınsama gibi dezavantajları bulunmaktadır [93]. İvme (momentum) optimizasyon algoritması bu kararsızlığı azaltmak için her yinelemede bir hız değişkenini günceller ve türevlerin yönünde

bir ivme oluşturarak parametre güncellemelerinde daha stabil bir süreç sağlar. Bu özellik eğitim sürecinde güncellemelerin hızını artırır ve salınımları azaltarak yakınsama kararlılığını sağlar [132].

Adaptif öğrenme oranları makine öğrenimi ve özellikle derin öğrenme algoritmalarında yaygın olarak kullanılan bir optimizasyon tekniğidir. Her bir model parametresi için dinamik olarak ayarlanan öğrenme oranları farklı parametrelerin farklı hızlarda öğrenmesini mümkün kılar. Bu durum eğitim sürecini daha etkili ve verimli hale getirirken öğrenme oranının manuel olarak ayarlanması gereksinimini de en aza indirir. Bazı teknikler önceki türevlerin ortalamasını ve ikinci momentlerini birleştirerek adaptif güncellemeler yapmaktadır. Böylece modelin daha stabil bir şekilde öğrenmesine olanak tanır [133].

4.4 Transfer Öğrenimi (Transfer Learning)

Daha önce farklı bir problem için eğitilmiş bir modelin, yeni ve benzer bir probleme uygulanması süreci aktarımlı öğrenme olarak adlandırılmaktadır. Derin öğrenme modellerinin yüksek başarı göstermesi, genellikle büyük ve gerçek yaşamı temsil edebilecek kalitede veri kümelerinin varlığına bağlıdır. Ancak uygulamada bu tür veri kümelerine ulaşmak çoğu zaman, maliyet ve uzmanlık gerektirir. Bu nedenle önceden eğitilmiş modellerin yeniden kullanımı veri bilimi açısından önemli avantajlar sunmaktadır [58]. Aktarımlı öğrenme sayesinde özellikle kaynak kısıtlı durumlarda milyonlarca etiketli veriye duyulan ihtiyaç azaltılarak model eğitimi daha pratik hale getirilebilmektedir.

Bu yöntemden maksimum fayda elde edebilmek için aktarılan veriler ile hedef problem arasında yapısal benzerlik bulunması oldukça kritiktir. Özellikle evrişimli ağlar gibi mimarilerde bazı evrişim katmanları benzer türde özellikleri öğrenebildiğinden bu katmanlardaki filtreler başka modellerde doğrudan yeniden kullanılabilir. CNN tabanlı transfer öğrenme olarak tanımlanır. Burada modelin bazı ağırlıkları başlangıçta dondurularak doğrudan aktarılır ve bu sayede modelin öğrenme sürecinde gereksiz parametre güncellemeleri azaltılmış olur ve hesaplama maliyeti önemli ölçüde düşürülür.

Transfer öğrenme derin öğrenme modelini sıfırdan eğitme gerekliliğini ortadan kaldırdığı için hem veri ihtiyacını azaltır hem de eğitim süresini kısaltır [59]. Bu çalışma kapsamında kullanılan veri kümesi görsel örnek sayısı bakımından

sınırlıdır. Bu nedenle transfer öğrenme stratejisi sınırlı veri içeren problemlerle başa çıkmada etkili bir çözüm sunar. ImageNet gibi geniş ve çeşitli veri kümeleri üzerinde eğitilmiş bir modelin sahip olduğu bilgi daha küçük veri kümelerine aktarılabilir ve böylece modelin öğrenme kapasitesi artırılabilir.

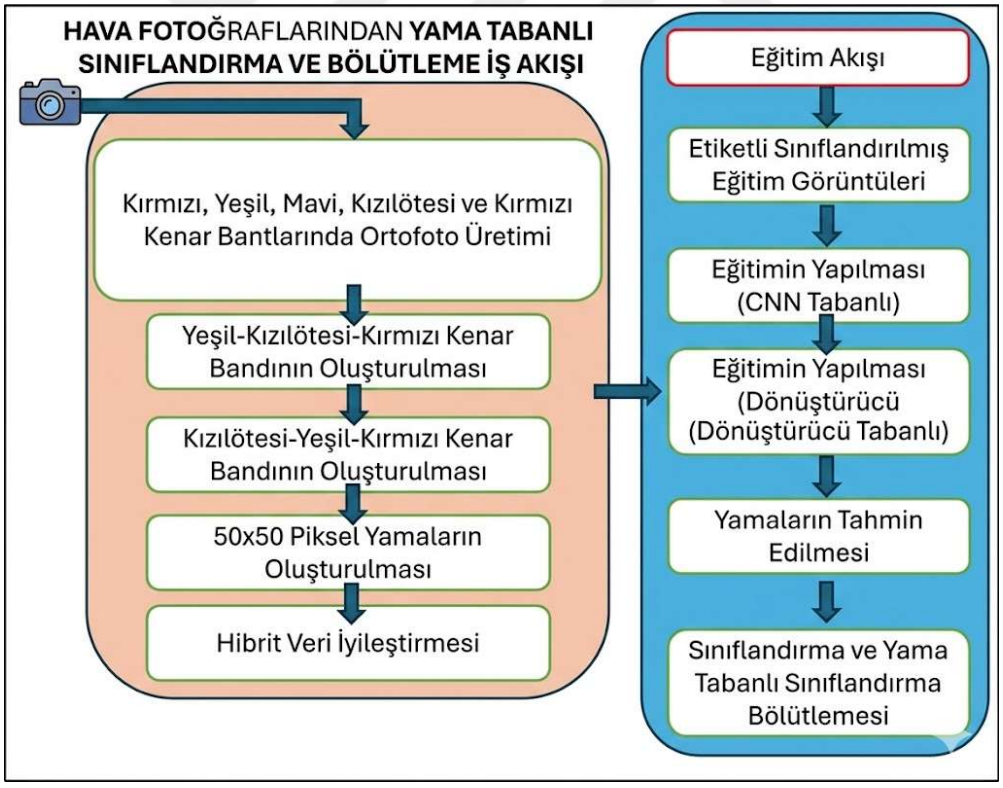
Transfer öğrenmede genellikle iki ana strateji benimsenmektedir. Evrişim tabanının dondurulmasıdır. Bu yöntemde ImageNet gibi büyük bir veri setiyle eğitilmiş modelin evrişimli kısmı olduğu gibi korunur. Bu katmanlar sabit tutulur ve sadece sınıflandırma katmanı hedef problem için yeniden tasarlanıp eğitilir. Bu sayede modelin genel özellik çıkarım yetisi korunur. Üst katmanların yeniden eğitilmesidir. Bu yaklaşımda alt katmanlardaki temel özellikleri öğrenmiş olan yapı korunurken üst katmanlardaki ağırlıklar veri kümesine özel olarak güncellenir. Böylece model yeni problem bağlamına özgü özellikleri öğrenme imkânı bulur.

Bu iki strateji sınırlı veriyle çalışırken model performansını artırmak ve hesaplama maliyetini düşürmek amacıyla etkili bir şekilde uygulanabilir.

5
VERİ SETİ HAZIRLAMA

İnsansız hava araçları donanım olarak mekanik ve elektronik bileşenlerden ve yazılım bileşenlerinden oluşmaktadır. Bunlar motor, pervane, ana gövde ve uçuş yazılımıdır. Tez kapsamında görüntüleri elde etmek için kullanılan cihaz DJI Mavic 3M modelidir. Elde edilen hava görüntüleri birleştirilerek oluşturulan ortofoto haritalar mekansal çözünürlüğü yüksek bilgiler sunmaktadır.

Elde edilen görüntülerin ve veri setinin nasıl işlendiğini gösteren akış Şekil 5.1 de gösterilmiştir. Bu kısımda ortada gösterilen alandaki işlemler sırasıyla ifade edilecektir.



Şekil 5.1 Görüntülerin hazırlanması ve eğitim modeli

5.1 Çalışma Alanı ve Görüntü Alımı

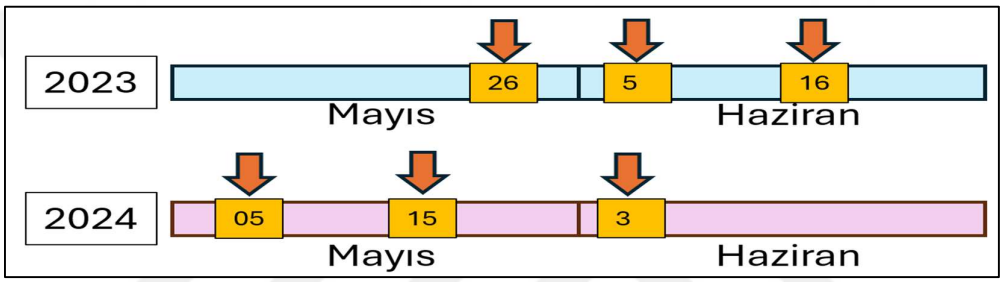
Çalışma alanının belirlenmesinde, araştırmacının bölgede ikamet etmesi ve çalışma sahasına olan yakınlığı lojistik bir avantaj sağlamıştır. Bu durum Sırbistan'ın Sremska Mitrovica bölgesindeki Kuzmin köyünde yer alan ayçiçeği tarlalarından sıklıkla ve kontrollü görüntü elde edilmesine imkân tanımıştır. Seçilen bu bölge Sırbistan'ın kuzeybatısında yer alan ve verimli toprak yapısıyla bilinen Voyvodina eyaletinin önemli bir tarım merkezi olması bakımından stratejik öneme sahiptir. Bölgede ayçiçeği, mısır ve tütün gibi endüstriyel bitkiler yetiştirilmektedir. Harita 5.1'de çalışma alanı gösterilmiştir.



Harita 5.1 Çalışma alanı (Görüntü: Google Earth)

Tez kapsamında kullanılan görüntüler, Sırbistan'da ayçiçeği tarımının yoğun olarak yapıldığı tarım arazilerinden İHA aracılığıyla elde edilmiştir. Sırbistan, Avrupa'nın önde gelen ayçiçeği üreticileri arasında yer almakta olup yıllık yaklaşık 700.000-800.000 hektar ekim alanı ve 2 milyon tona yaklaşan üretim miktarıyla kıta genelinde stratejik bir konuma sahiptir. Bu tercih yalnızca veri erişimi kolaylığından kaynaklanmamakta aynı zamanda metodolojinin gerçek üretim koşullarında farklı toprak yapısı ve iklim özellikleri barındıran bir sahada sınanmasına imkân tanımaktadır. Sırbistan tarım arazilerinde hâkim olan yabani ot türleri ve bitki yoğunluğu Türkiye başta olmak üzere Balkanlar ve Doğu Avrupa'daki ayçiçeği üretim bölgeleriyle önemli benzerlikler taşımaktadır. Veri seti hem ekolojik çeşitlilik hem de metodolojik genellenebilirlik açısından araştırmanın güvenilirliğini güçlendiren önemli bir unsur olarak değerlendirilmelidir.

Multispektral kamera olan İHA üzerinde güneş sensörü entegre halde hazır hale getirilmiştir. Uçuş yüksekliği minumumda tutulacak şekilde uçulacak alan işaretlenerek bindirme oranları ve fotoğraf çekim merkezleri belirlenmiştir. Hafıza kartına direk kaydedilen 1350, 3989 ve 4400 adet çok bantlı görüntüler bilgisayara aktarılmıştır. Uçuşlar 12 metre yükseklikten yapılmış olup mekansal çözünürlüğü yüksek fotoğraflar elde edilmiştir. Uçuşlarda cihazda entegre olan gerçek zamanlı kinematik anteniyle, ulusal sürekli mekansal ağ düzeltme sistemine bağlanarak fotoğraf çekim anında yüksek doğruluklu mekansal hassasiyetle kaydedilmiştir. Şekil 5.2'de görüntü alım tarihleri gösterilmiştir.



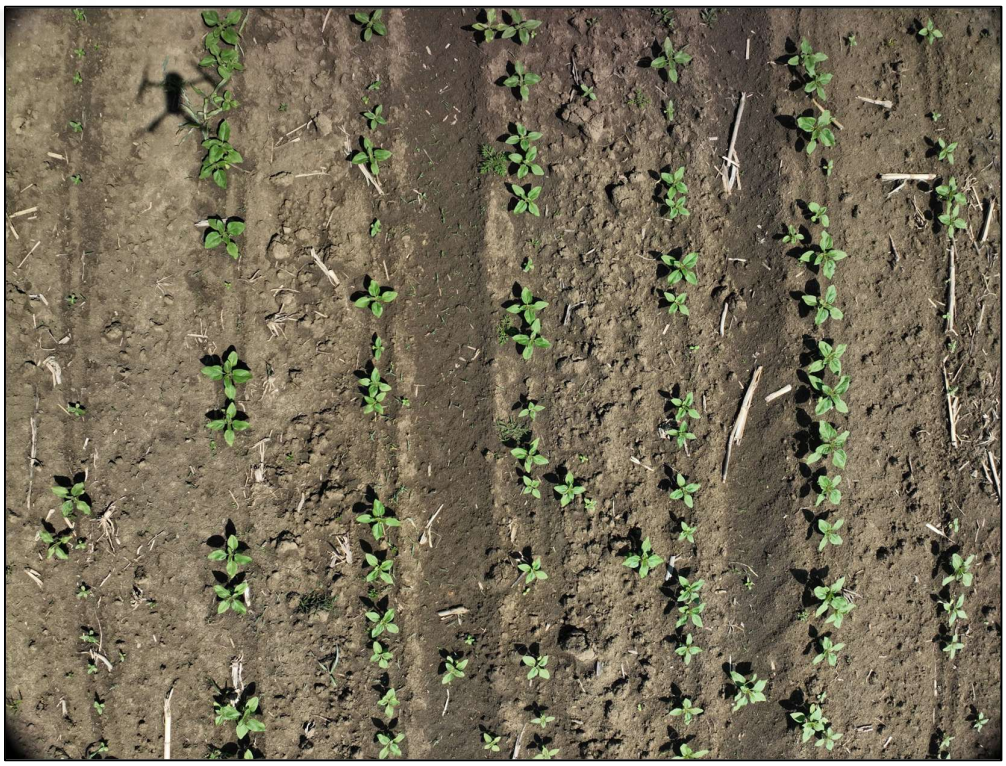
Şekil 5.2 Görüntülerin elde edilme tarihleri

Uçuşlar 2023 yılının mayıs ayında başlamıştır. Haziran ayının 16. gününe kadar veri alınmıştır. Aynı yerlerde 2024 yılında alınan görüntüler Mayıs ayının 5. gününde ve Haziranın 3. gününde tamamlanmıştır. Gün ışığının en dik geldiği öğle saatlarinde veri alımı yapılmasına dikkat edilmiştir.

Çekilen fotoğrafların boyutu 5280x3956 piksel genişlik ve yüksekliğindedir. Fotoğraflar tiff formatında 5 farklı spektral bant için ayrı ayrı veri seti oluşturulmuştur. DJI firması tarafından üretilen bu İHA, üzerinde entegre olarak bulunan multispektral kamera sayesinde hem insan gözünün algılayabildiği hem de algılayamadığı dalga boylarını tespit ederek çift görünüm sağlama yeteneğine sahiptir. Geniş uçuş menzili sayesinde (15 km) büyük alanların taranmasına olanak tanıdığı için bu çalışma kapsamında tercih edilmiştir. Güçlü bataryası sayesinde yaklaşık 40 dakika boyunca havada kalabilmekte ve bu süre zarfında ortalama 200 hektarlık bir alanın görüntülenmesi mümkün olmaktadır (Web-3). Şekil 5.3'te ve 5.4'te örnek görüntüler eklenmiştir.

DJI Mavic 3M modeline entegre edilmiş multispektral kamera, cihaz üzerinde sabit olarak yer almaktadır. 20 MP çözünürlüğe sahip KYM kamera ile dört ayrı spektral

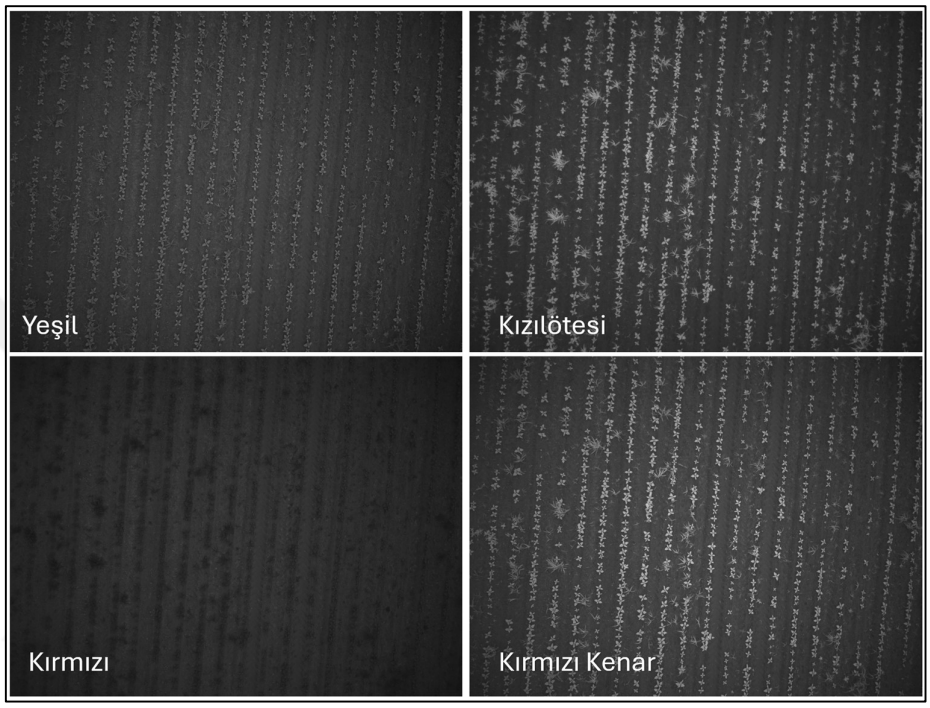
banda sahip multispektral kameranın sahip olduğu spektral bantlar şu şekildedir. kırmızı (Red) 650 nm ± 16 nm, yeşil (Green) 560 nm ± 16 nm, kırmızı kenar (Rededge) 730 nm ± 16 nm ve kızılötesi (NIR) 860 nm ± 26 nm (Şekil 3.8). Multispektral bantlar 5 MP çözünürlüğe sahip olup yüksek kaliteli veri elde edilmesine olanak tanımaktadır. Bu kamera sistemleri insan gözünün algıladığı dalga boylarının yanı sıra kırmızı kenar ve yakın kızılötesi bantlar ile insan gözünün göremediği dalga boylarını da algılayabilmektedir. Bu sayede farklı indekslerin oluşturulmasına ve bitkisel çeşitlilik ile bitki hastalıklarının izlenmesine katkı sağlamaktadır.



Şekil 5.3 Örnek KYM bantlı görüntü

Araştırmada kullanılan eğitim verileri 2023 yılında, test ve reçete haritası uygulamaları ise 2024 yılında elde edilen görüntüler üzerinde gerçekleştirilmiştir. 2024 yılında 16 Haziran tarihinde alınan görüntülerin V4-V8 fenolojik aşamasına denk geldiği tespit edilmiş, bu dönem kritik rekabet periyodunun içinde yer aldığından ve erken dönem önleyici müdahale stratejisinin hedeflediği V3-V4 aşamasını aşmış olduğundan söz konusu görüntüler eğitim setine dahil edilmemiştir. Bununla birlikte 2024 görüntüleri reçete haritası oluşturma ve saha doğrulama aşamalarında kullanılmıştır. Farklı yıllara ait görüntülerin kullanılması

modelin yalnızca eğitim verisine özgü doku ve renk örüntülerini ezberlemediğini gerçek anlamda sınıflar arası ayırt edici özellikler öğrendiğini ortaya koymaktadır. Bu durum aynı zamanda daha önce tartışılan veri sızıntısı endişesini de önemli ölçüde zayıflatan bir kanıt niteliği taşımaktadır.

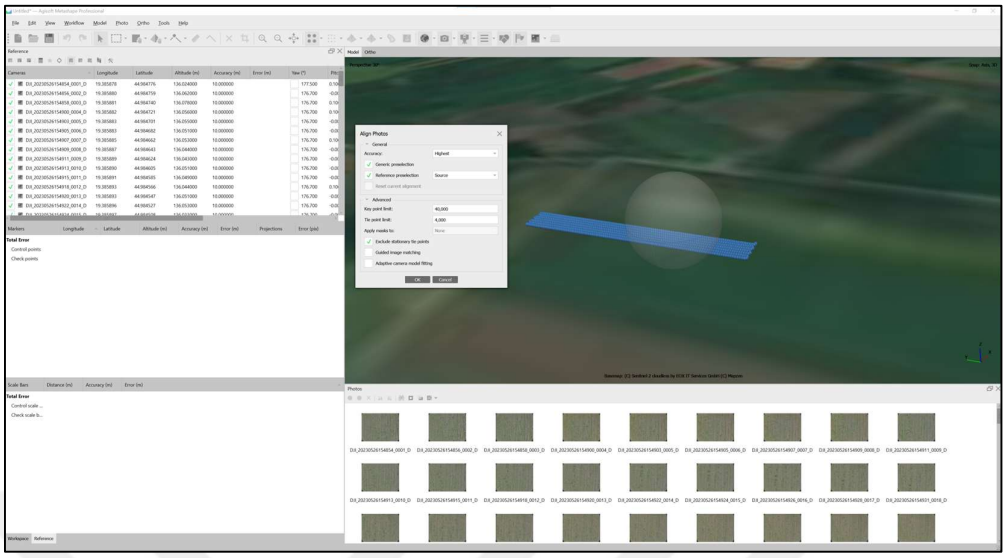


Şekil 5.4 Multispektral bantlardan örnek görüntüler

5.2 Ortofoto Üretimi

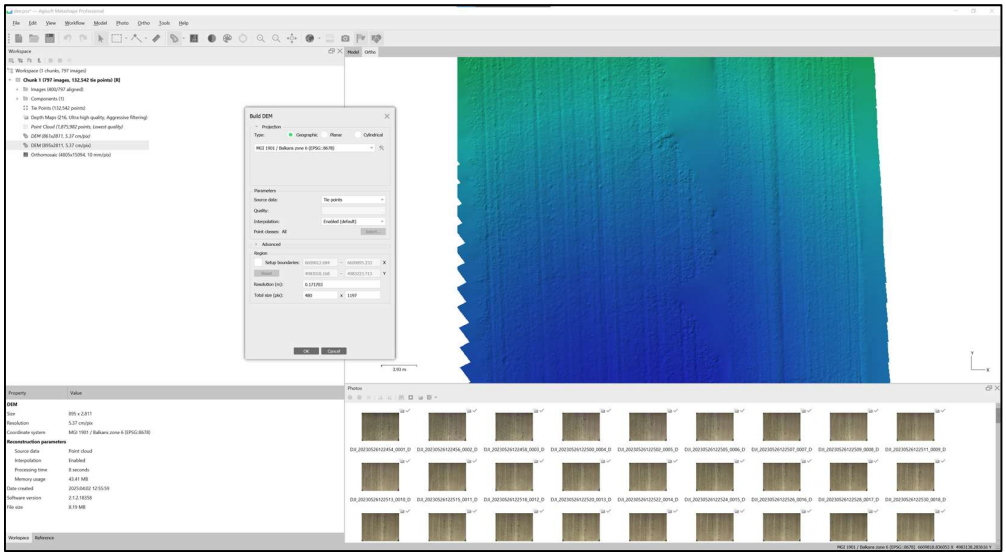
Uçuşlardan elde edilen çok bantlı görüntüler aktarım kablosuyla bilgisayarımıza aktarılmıştır. Her fotoğrafın çekim bilgilerini içeren dosyalarla birlikte Agisoft Metashape yazılımınına çok bantlı işlem seçeneği seçilerek aktarılmıştır. Her fotoğrafın yüksek hassasiyetli mekansal bilgilerinin kullanılarak fotoğraflar arasındaki bağlar kurularak ön dengeleme işlemi yaptırılmıştır. Her fotoğrafın çekim anında elde edilen güneş ışığının sensör verileride yazılımda otomatik olarak algılanarak işlenmiştir.

Fotoğrafların uçuş planına göre sıralanarak odak merkezlerinden ve bağlama noktalarından faydalanarak yapılan hesaplamalarla birlikte birbirlerine göre yöneltme parametreleri hesaplanmıştır. Şekil 5.5'te dengeleme işlem adımı gösterilmiştir.



Şekil 5.5 Fotoğrafları yöneltme adımı

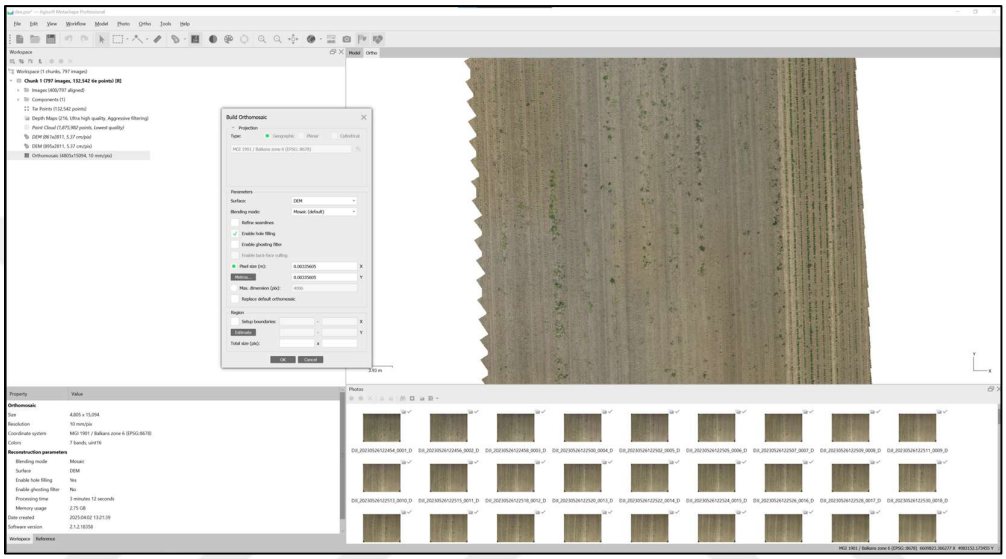
En yüksek hassasiyetle çalışıtırlan algoritma sonucunda bağlama noktası tespiti sağlanmıştır. Nokta bulutu oluşturulması sonrasında sayısal yüzey modeli oluşturulması adımları takip edilmiştir. Bu adımlar lokal koordinat sistemi olan Balkan Zone 6 (EPSG:8678) sisteminde olacak şekilde ayarlanmıştır. Şekil 5.6'da yüzey modeli oluşturma adımı gösterilmiştir.



Şekil 5.6 Sayısal yüzey modeli oluşturma adımı

Kameranın eğikliği ve uçuş parametrelerinin değişikliklerinden kaynaklanan farklılıkların düzeltilerek elde edilen birleştirilmiş ve konumlandırılmış dik görüntülerden oluşturulan harita temsillerine ortofoto denilmektedir. Bu tez

kapsamında hem KYM bantlarında hem de kızılötesi bantlarında ortofoto üretimi yüksek hassasiyetle üretilmiştir. Uygun yazılımla yüksek konum doğruluğuna sahip ve mekansal çözünürlüğü 1 piksel 10 mm'ye karşılık gelmektedir. Bu veri çok yüksek kapasitede veri alanı kapsamaktadır. Şekil 5.7'de ortofoto üretim aşaması gösterilmiştir.



Şekil 5.7 Ortofoto üretim aşaması

Fotogrametrik değerlendirme yazılımının araçlar menüsü altında raster hesaplama modülünün farklı bantları göstermeye ve temsilini sağlayan kısımdan her bant ayrı ayrı açılarak dışarıya aktarılmıştır. Bu menüde farklı bantlar kullanılarak bitki indeksleri üretilmektedir. Piksel değerlerini kullanarak ve sıkıştırma yapılmadan her bant ayrı ayrı kaydedilmiştir. Renk kombinasyonları Kırmızı-Yeşil-Mavi, Yeşil-Kızılötesi-KırmızıKenar bantlarının birleştirilmesiyle oluşturulan ortofotolar oluşturulmuştur. Üretilen ortofotolardan elde edilen 50x50 piksellik yamalar sınıflandırılarak etiketlendiği veri sınıfına atanmıştır. Üretilen ortofotolardan 5000x5000 piksel ve 200x200 boyutlarında çalışma alanları belirlenerek model performansları değerlendirilmiştir.

Bu veri seti kapsamında multispektral görüntüleme için DJI Mavic 3M'in sunduğu dört banttan Yeşil (Green), Kırmızı Kenar (RedEdge) ve Yakın Kızılötesi (NIR) bantları tercih edilmiştir. Kırmızı (Red) bandının 650 nm merkez dalgaboyuyla KYM kameranın kırmızı kanalıyla büyük ölçüde örtüşmesi nedeniyle bu bant analize dahil edilmemiştir. KYM görüntülerinde kırmızı spektral bilgi zaten mevcut

olup tekrar eklenmesi modele özgün bir katkı sağlamak yerine bilgi tekrarına yol açacaktır. Buna karşın seçilen üç bant, bitki fizyolojisini birbirini tamamlayan farklı açılardan temsil etmektedir. Yeşil bant klorofil absorbsiyonuyla doğrudan ilişkili olup bitki örtüsünü boş alandan ayırt etmede belirleyici bir rol üstlenmektedir. RedEdge bandı bitki stresi ve erken dönem gelişim farklılıklarının en hassas biçimde gözlemlendiği spektral bölge olması nedeniyle özellikle ayçiçeği ile yabani otun ince fizyolojik farklılıklarının ortaya konmasında en ayırt edici bant olarak öne çıkmaktadır. NIR bandı ise biyokütle ve yaprak yoğunluğuyla güçlü korelasyon göstererek NDVI gibi bitki indekslerinin hesaplanmasında temel girdi işlevi görmektedir. Bu üç bandın bir arada kullanılması gereksiz bilgi tekrarından kaçınırken sınıflandırma için en fazla özgün spektral bilgiyi sağlayan optimal bir kombinasyon olarak belirlenmiştir.

5.3 Hibrit Veri Artırımı

Veri artırma eğitim veri setlerinin boyutunu ve çeşitliliğini artırmak için kullanılan güçlü ancak basit bir tekniktir. Özellikle büyük ve etiketlenmiş veri setlerinin yetersiz olduğu durumlarda büyük önem taşır. Bu yöntem mevcut verileri çeşitli manipülasyon teknikleriyle değiştirerek yeni eğitim örnekleri üretir ve böylece sınıf etiketlerini bozmadan veri setini genişletir. Aşırı öğrenmeyi azaltmak modelin genelleme yeteneğini artırmak ve daha sağlam hale getirmek veri artırmanın başlıca amaçlarıdır.

Geleneksel veri artırma yöntemleri görüntü üzerinde çeşitli geometrik dönüşümler uygulamayı içerir. Bunlar döndürme, ölçekleme, kırpma, kaydırma ve yansıtma gibi işlemleri kapsar ve bu işlemler tek başına ya da birlikte kullanılabilir [134]. Bu dönüşümler görüntünün temel özelliklerini koruyarak veri setinde farklı varyasyonlar oluşturur [135]. Renk uzayı dönüşümleri gibi yöntemler de veri çeşitliliğini artırmak için kullanılır. Bu tür işlemler, parlaklık, kontrast ve renk doygunluğu ayarlarını değiştirerek farklı eğitim örnekleri oluşturur. Nöral stil transferi gibi gelişmiş yöntemler ise görüntülerin temel dokularını değiştirerek bir görüntünün stilini başka bir görüntüye uygular ancak hedef görüntünün anlamını korur.

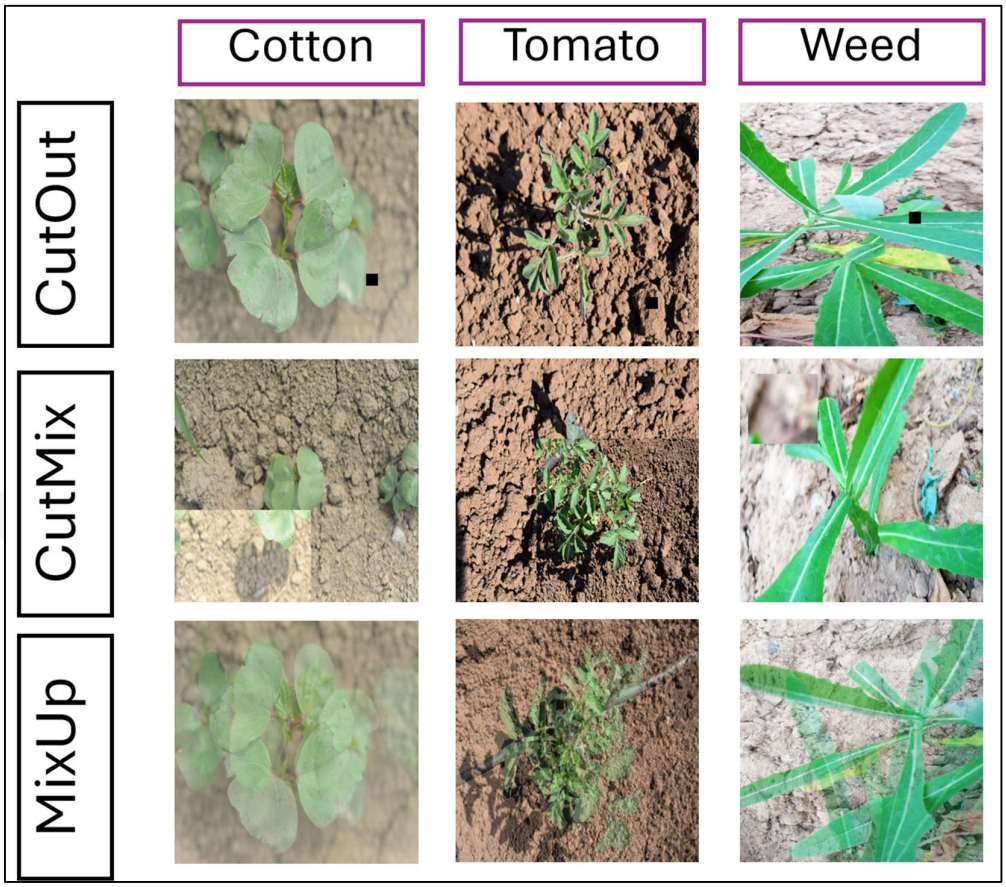
Daha gelişmiş veri artırma yöntemlerinden biri Üretici Ağlar (Generative Adversarial Networks - GAN) kullanılarak sentetik veri üretmektir. GAN'lar

orijinal veri dağılımına oldukça yakın gerçekçi örnekler oluşturarak veri setinin çeşitliliğini artırır. Modern makine öğrenimi süreçlerinde veri artırma modelin görülmemiş verilere genelleme yapabilme yeteneğini güçlendiren temel bileşenlerden biri haline gelmiştir. Son yıllarda Cutout, Mixup ve CutMix gibi gelişmiş veri artırma teknikleri geliştirilerek modelin sadece belirli özelliklere bağımlı kalmasını önleyip daha derin bir anlayış geliştirmesi hedeflenmiştir [63], [136].

Cutout bir görüntünün belirli bir bölgesini siyah pikseller veya rastgele gürültü ile doldurarak modelin yalnızca belirli görsel detaylara odaklanmasını engelleyen bir yöntemdir. Bu sayede model görüntünün genel bağlamını daha iyi öğrenebilir. Ancak Cutout'un en büyük sınırlamalarından biri önemli görsel bilgileri tamamen gizleyebilmesi ve bu nedenle bazı kritik detayların kaybolmasına neden olabilmesidir [63].

$$\chi = \lambda\chi_i + (1-\lambda)\chi_j,\ \gamma = \lambda\gamma_i + (1-\lambda)\gamma_j \tag{5.1}$$

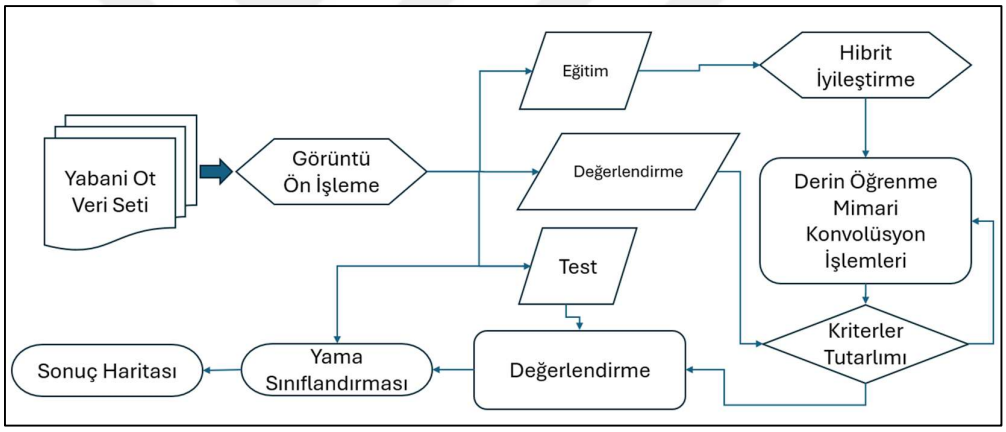
Bu bilgi kaybını en aza indirmek için CutMix bir görüntünün belirli bir kısmını veri setindeki başka bir görüntüden bir bölümle değiştirerek veri çeşitliliğini artırır [136]. Mixup ise farklı bir yaklaşım benimseyerek iki görüntüyü ve bunlara karşılık gelen etiketleri doğrusal enterpolasyon yoluyla karıştırır [137]. Bu yöntemde, χ_i ve χ_j görüntüleri ile y_i ve y_j etiketleri, belirli bir oranda birleştirilerek yeni eğitim örnekleri oluşturulur. Böylece model farklı sınıflar arasındaki sınırları daha iyi öğrenebilir ve eğitim sürecinde daha genelleştirilebilir bir yapıya kavuşur. Şekil 5.8'de hibrit veri artırımı gösterilmiştir.



Şekil 5.8 Hibrit veri iyileştirme metodu

6
METODOLOJİ VE DEĞERLENDİRME

Bu tez kapsamında hazırlanan yöntemler hesaplama kaynaklarını ve boyutunu azaltmayı amaçlayan hafif mimari modellerden yaygın olarak kullanılan sınırlı verilerle transfer öğrenmesi ve hiperparametre optimizasyonundan yararlanarak en uygun yüksek başarılı mimari model belirlemeye çalışılmıştır. Mimari modelin ağırlıkları kaydedilerek deneme alanı olarak belirlediğimiz alanı yama boyutlarında sınıflandırarak çözüm haritası elde edilmeye çalışılmıştır. Şekil 6.1'de iş akışı gösterilmiştir.



Şekil 6.1 İş akışları adımları

6.1 Hafif Derin Öğrenme Mimari Ağları

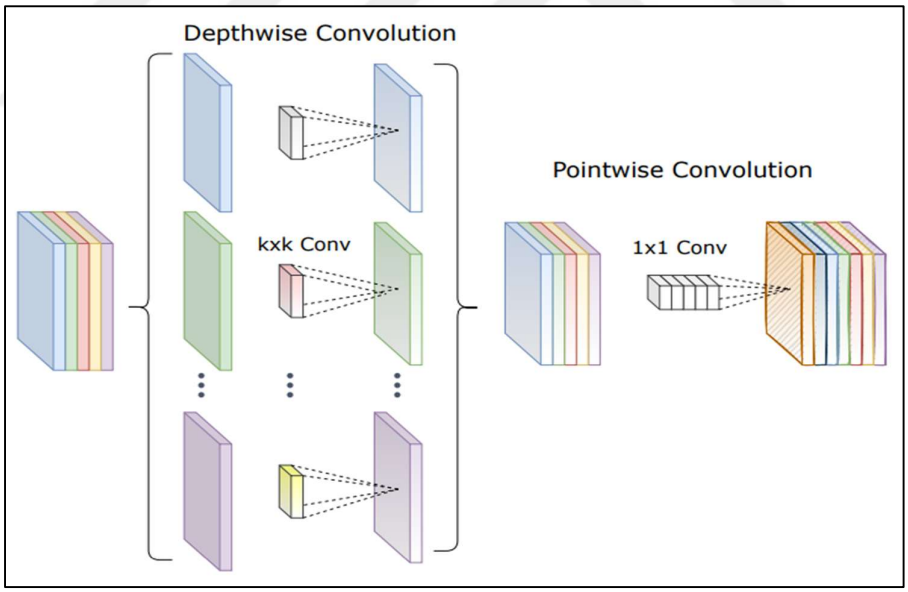
Hafif mimari modellerinin sinir ağlarında bulunan parametrelerin sayısı mimari ağın boyutunun korunmasına önem verilerek cep telefonları veya küçük robotlar gibi cihazların verimli ve hızlı bir şekilde kullanmasını sağlayacak şekilde gömülü uygulamalar düşünülerek seçilmiştir. Tez kapsamında MobileNet ve NASNetMobile seçilmiş ve eğitilmiştir.

6.2 MobileNet Mimari Modeli

Mobil ve gömülü sistemlerde derin öğrenme uygulamaları sınırlı işlem gücü, bellek kapasitesi ve enerji tüketimi gibi kısıtlamalar nedeniyle önemli kısıtlar içermektedir. Howard ve arkadaşları, tarafından geliştirilen MobileNet v1 sınırlı

kaynaklara sahip cihazlarda görüntü sınıflandırma nesne tanıma ve benzeri görevleri etkin biçimde yerine getirebilecek hafif ve verimli bir konvolüsyonel sinir ağı mimarisi olarak literatüre kazandırılmıştır. MobileNet v1 düşük gecikme süresi, küçük model boyutu ve yüksek hesaplama verimliliği ile mobil yapay zekâ uygulamaları için önemli bir çözüm sunmaktadır [138].

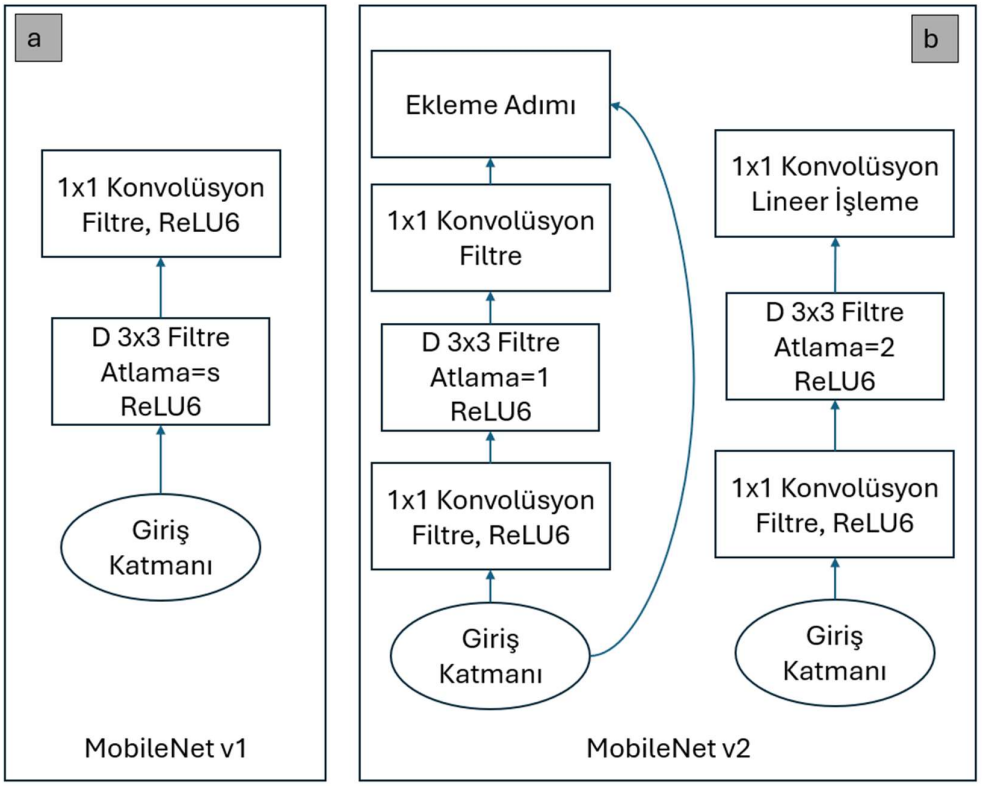
MobileNet v1'in temelinde geleneksel evrişimsel katmanların yerine kullanılan derinlemesine ayrılabilir evrişim (depthwise separable convolution) yapısı yer almaktadır. Klasik evrişim işleminin iki ayrı adımda gerçekleştirilmesini sağlamaktadır. İlk aşamada, her bir giriş kanalına ayrı bir konvolüsyon filtresi uygulayan ayrılabilir evrişim ardından bu ara çıktıları kanal bazında birleştiren 1×1 noktasal evrişim (pointwise convolution) uygulanır. Bu iki adımın birleşimi klasik konvolüsyon katmanlarına göre yaklaşık 8 kat daha düşük hesaplama ve parametre sayısı ile çalışır. Bu özellik MobileNet'i düşük kaynak gereksinimiyle çalışabilen uygulamalar için ideal hale getirir [138]. Şekil 6.2'de evrişim temsili eklenmiştir.



Şekil 6.2 Derinlik bilgisine göre evrişim katmanı ve nokta evrişimi temsili. [138]

MobileNet mimarisi modelin ölçeklenebilirliğini artırmak için iki temel hiperparametre içmektedir. Genişlik çarpanı (α) her katmandaki filtre sayısını α oranında azaltarak modelin daha ince bir versiyonunu oluşturur. Çözünürlük çarpanı (ρ) giriş görüntüsünün çözünürlüğünü ölçekleyerek hesaplama maliyetini düşürür. Bu hiperparametreler sayesinde geliştiriciler uygulama ihtiyaçlarına uygun olarak doğruluk, hız ve boyut arasında bir denge kurabilirler.

Matematiksel olarak standart bir evrişimde kullanılan filtreler boyutunda olup M giriş kanalı ve N çıkış kanalı içerir. Buna karşılık derinlemesin evrişim yalnızca M adet D_KxD_K boyutlu filtre kullanarak her giriş kanalına ayrı işlem uygular. Ardından, noktasal evrişim aşamasında her biri 1×1 boyutunda ve toplamda N adet filtre ile bu ara çıktılar birleştirilir [138]. Böylece klasik evrişimsel yapıya kıyasla doğrulukta küçük bir kayıpla ciddi ölçüde işlem tasarrufu sağlanır. Şekil 6.3 ve 6.4'te mimarinin katmanları gösterilmiştir.

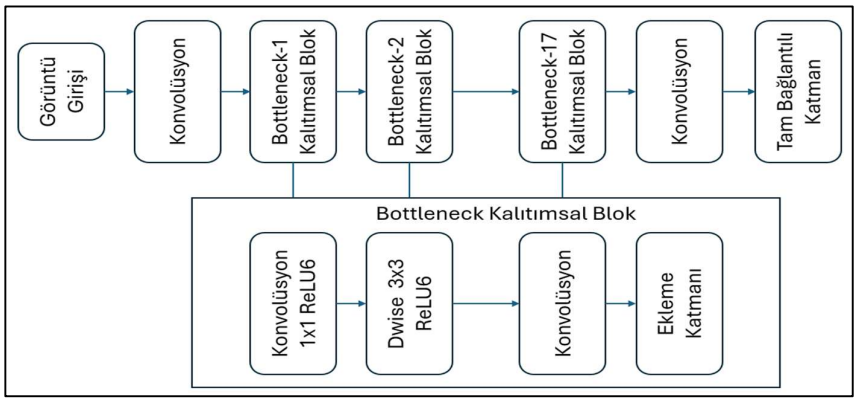


Şekil 6.3 MobileNet mimarilerim katmanları

MobileNetV1 mimarisi, ilk katmanda geleneksel 3×3 evrişim uygulamakta; takip eden tüm katmanlar ise derinlemesine ayrışan evrişim blokları şeklinde düzenlenmiştir. Her blokta sırasıyla depthwise evrişim, pointwise evrişim, ardından girdi normalizasyonu ve ReLU6 aktivasyon fonksiyonu yer alır. ReLU6 çıktısında 0-6 arasında değerler vermektedir. Son katmanda ise sınıflandırma amacıyla tam bağlı katman ve softmax fonksiyonu kullanılır. Bu yapı toplamda 28 katmandan oluşan derin fakat oldukça hafif bir model sunar. Yapılan çalışmalar MobileNetv1'in ImageNet gibi büyük ölçekli veri kümeleri üzerinde geleneksel derin ağ mimarileri olan VGG16 veya GoogleNet ile benzer doğruluk seviyelerine

ulaşabildiğini ve buna karşılık hesaplama maliyetinin ve model boyutunun önemli ölçüde düşük olduğunu göstermektedir. Ayrıca nesne algılama, yüz özellik çıkarımı, yer tahmini ve benzeri birçok görevde başarılı sonuçlar sunmaktadır. Sonuç olarak MobileNetv1 hesaplama açısından verimli parametre bakımından küçük ve performans bakımından tatmin edici bir mimari sunarak mobil ve gömülü sistemler için derin öğrenme uygulamalarının yaygınlaştırılmasında önemli bir adım teşkil etmektedir [138].

MobileNetV2 mobil ve gömülü sistemlerde derin öğrenme uygulamalarının verimli şekilde gerçekleştirilmesi amacıyla geliştirilmiş hafif ve optimize edilmiş bir konvolüsyonel sinir ağı mimarisidir. Önerilen bu yapı MobileNetV1'in başarısı üzerine inşa edilerek model doğruluğunu ve bilgi aktarım verimliliğini artırmayı hedeflemektedir [138]. Mimari temel olarak inverted residual blokları ve lineer darboğaz (bottleneck) katmanlarını içermektedir. Inverted residual yapısı klasik artık bağlantılardan farklı olarak girişin önce genişletilip ardından daraltılması esasına dayanır ve bu sayede model içinde düşük boyutlu temsillerle bilgi kaybı minimuma indirilir. Ayrıca düşük boyutlu katmanlarda doğrusal olmayan aktivasyon yerine lineer aktivasyon kullanılması öğrenme sürecinde daha fazla bilginin korunmasına olanak tanır. Derinlemesine ayrılabilir evrişim yapısını koruyan MobileNetV2 parametre verimliliği açısından önceki sürüme kıyasla daha gelişmiş olup sınırlı işlem gücüne sahip cihazlarda bile yüksek doğrulukla çalışabilmektedir.



Şekil 6.4 MobileNetV2 mimari modeli

6.3 NASNetMobile Mimari Modeli

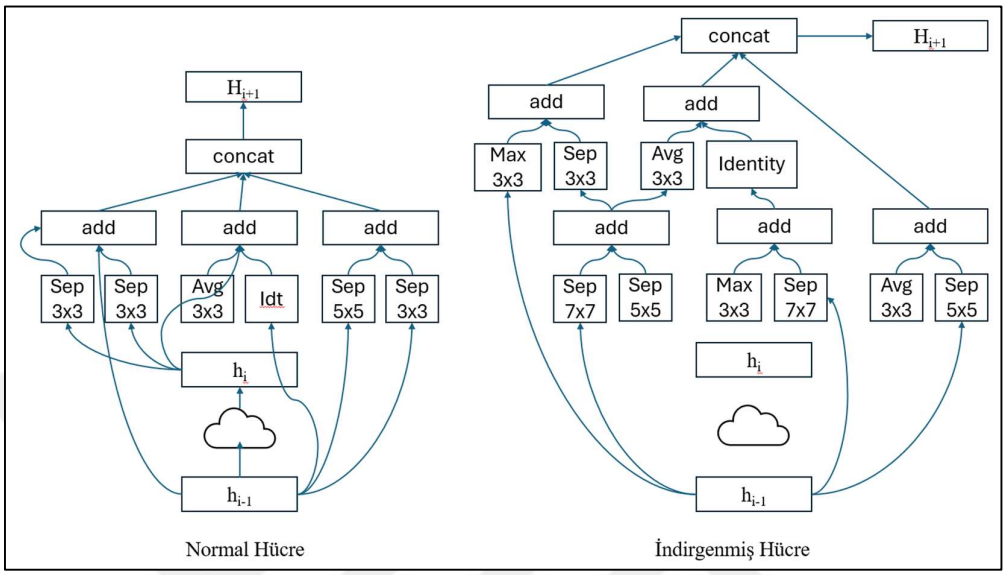
Son yıllarda derin öğrenme modelleri özellikle konvolüsyonel sinir ağları bilgisayarla görü alanında büyük başarılar elde etmiş ve çok sayıda uygulama alanına entegre edilmiştir. Ancak bu başarıların arkasında yatan mimari tasarımlar çoğu zaman insan uzmanlığına dayalı olarak geliştirilmiştir ve bu durum zaman ve kaynak açısından önemli maliyetler doğurmaktadır. Bu nedenle ağ mimarilerinin otomatik olarak tasarlanmasını amaçlayan Neural Architecture Search (NAS) yöntemleri son dönemde ön plana çıkmıştır. NAS bir sinir ağının topolojisini insan müdahalesi olmadan optimize etmeyi amaçlayan algoritmik bir yaklaşımdır [139].

Bu bağlamda Google tarafından geliştirilen NASNet sinir ağı mimarisi tasarım sürecini bir pekiştirmeli öğrenme (reinforcement learning) problemine dönüştürerek önemli bir yenilik sunmuştur. NASNet mimarisi, önceden tanımlanmış filtre boyutları, katman türleri, kanal sayısı ve sıçrama değerleri gibi üzerinden bir denetleyici RNN kullanılarak mimari adayları üretir. Her bir aday mimari, belirli bir görev için eğitilir ve doğrulama veri kümesi üzerindeki başarımı ölçülerek denetleyici modele geri bildirim olarak iletilir. Böylece daha iyi performansa sahip mimarilerin seçilmesi sağlanır. Bu süreç belirli bir performans eşiğine veya iterasyon sınırına ulaşılana dek devam eder ve sonunda optimuma yakın bir mimari elde edilir [139].

NASNet mimarisinin temel yapı taşı normal hücre ve indirgenmiş hücre adı verilen modüler bloklardır. Normal hücreler giriş boyutlarını sabit tutarken özellik çıkarımı yapar. İndirgenmiş hücreleri ise uzamsal çözünürlüğü düşürerek daha soyut temsiller üretir. Bu hücreler keşfedilen yapılarına göre yeniden kullanılarak büyük ölçekli sinir ağları inşa edilir. ImageNet veri kümelerinde yapılan denemelerde NASNet dönemin en başarılı performanslarını elde etmiştir. Ancak bu yüksek başarı beraberinde yüksek hesaplama maliyeti ve parametre sayısı gibi dezavantajları da getirmiştir.

Bu nedenle mobil cihazlar ve gömülü sistemlerde uygulanabilir bir versiyonun gerekliliği doğrultusunda geliştirilen NASNetMobile mimarisinin daha küçük, hafif ve enerji açısından verimli bir türevidir. NASNetMobile aynı mimari arama stratejisi ile elde edilmiş hücre yapısını kullanır. Az sayıda filtre, daha düşük katman derinliği ve sınırlı parametrelerle donatılmıştır. Böylece mobil ortamlar için

uygun bellek ve işlem kapasitesi gereksinimleriyle çalışabilir hale gelmiştir [140]. Şekil 6.5'te evrişim hücre temsili gösterilmiştir.



Şekil 6.5 NasNet evrişim hücre modeli

NASNetMobile yüksek doğruluk elde etmenin yanı sıra düşük gecikme süresi ve enerji verimliliği gibi avantajları ile mobil yapay zekâ uygulamaları, nesne tanıma, gerçek zamanlı görüntü işleme ve kullanıcı tabanlı sınıflandırma sistemleri gibi alanlarda etkin olarak kullanılabilir. Genellikle giriş boyutu olarak 224×224 piksel boyutundaki görüntülerle çalışmakta ve ImageNet veri kümesinde rekabetçi sonuçlar elde etmektedir. TensorFlow ve Keras gibi popüler derin öğrenme kütüphaneleri tarafından da hazır olarak sunulması araştırmacı ve geliştiricilerin bu mimariyi çeşitli projelere entegre etmesini kolaylaştırmaktadır [139].

Sonuç olarak NASNetMobile derin öğrenme mimarilerinin manuel tasarımının ötesine geçerek yapay zekânın kendi mimarisini optimize etmesine olanak tanıyan bir yaklaşımı somutlaştırmaktadır. Sinir Mimarisi Araması yöntemi sayesinde minimum insan müdahalesi ile maksimum doğruluk ve verimliliğin elde edilmesi hedeflenmiştir. Mobil sistemlerde uygulanabilirliği olan bir model ortaya konmuştur. Özellikleriyle günümüzün gerçek zamanlı kaynak kısıtlı yapay zekâ uygulamaları için hem akademik hem de endüstriyel anlamda güçlü bir alternatif sunmaktadır.

6.4 Hafif Dönüştürücü Mimari Model Algoritması

Transformer tabanlı modeller doğaları gereği çok katmanlı yapıları çok başlı dikkat mekanizmaları ve milyonlarca öğrenilebilir parametre içeren karmaşık mimarilere sahiptir. Tablo 6.1'de gösterildiği üzere ViT-Base modeli 80 milyondan fazla parametre barındırmaktadır. Bu denli büyük modeller genellikle üstün sınıflandırma performansı sağlasa da yüksek bellek gereksinimleri ve yoğun hesaplama yükleri nedeniyle gerçek dünya uygulamaları için pratik olmaktan uzaklaşabilir. Ayrıca özellikle sınırlı veri setleri üzerinde çalışıldığında modelin aşırı öğrenme riski de önemli ölçüde artmaktadır.

Bu tür zorlukların üstesinden gelmek için derin öğrenme modellerinde ağ sıkıştırma teknikleri kullanılmaktadır. Sık kullanılan iki temel yöntem bilgi aktarımı (knowledge distillation) ve model budama (pruning) teknikleridir. Bilgi aktarımı büyük ve yüksek doğruluklu bir "öğretmen" modelin bilgisinin daha küçük ve verimli bir "öğrenci" modele aktarılması sürecini ifade eder. Öğrenci model öğretmen modelin çıktısını taklit ederek daha az parametreyle benzer performans sergilemeyi öğrenir. Model budama ise doğrudan model yapısındaki önemsiz veya düşük katkı sağlayan parametrelerin kaldırılmasına dayanır. Bu süreç ağırlık budama (weight pruning) veya ağırlık kuantizasyonu (weight quantization) gibi yöntemlerle gerçekleştirilebilir.

Transformer mimarilerinde özellikle ViT modellerinde, çok sayıdaki dikkat başlığı ve derin encoder katmanları nedeniyle fazlalık (redundancy) oldukça yüksektir. Bu yapısal fazlalıktan yararlanarak temel modeli üzerinde sistematik bir encoder katmanı budama stratejisi önerilmiştir. Uygulanan yöntem kapsamında encoder katmanlarının %50'si kademeli olarak kaldırılmış ve böylelikle daha küçük hesaplama açısından daha verimli model sürümleri oluşturulmuştur. Bu yaklaşımın temel hedefi model boyutu ile sınıflandırma doğruluğu arasında optimal bir denge sağlamak ve performans kaybı minimum seviyede tutulurken mümkün olan en kompakt mimariyi elde etmektir.

Modelin eğitim ve sıkıştırma süreci özetlenen algoritmaya göre yürütülmüştür. Eğitim aşamasında, 64'lük yığın boyutu ADAM optimizasyon algoritması öğrenme oranı 3e-4 ve çapraz entropi kaybı minimize edilerek model parametreleri

güncellenmiştir. Eğitim hem orijinal hem de seçilmiş artırma yöntemleriyle üretilmiş görüntüler üzerinde 10 iterasyon boyunca gerçekleştirilmiştir.

Tablo 6.1 Vision transformer ağ budama yöntemi

1. 224×224 piksele yeniden boyutlandırılmış eğitim görüntüleri
   a. Mini- yığın boyutu = 64
   b. Optimizasyon algoritması = ADAM (öğrenme oranı = 3e-4)
   c. İterasyon sayısı = 10
   d. Başlangıç modeli = Vision Transformer (ViT-Base)
2. Vision Transformer modeli, önceden eğitilmiş ağırlıklar kullanılarak başlatılır.Her bir eğitim iterasyonu için (toplam 10 iterasyon).
   a. Eğitim setinden 64 görüntüden oluşan bir mini-yığın örneklenir.
   b. CutMix, Cutout ve standart artırma yöntemleri uygulanarak ek bir artırılmış görüntü yığını oluşturulur.
   c. Model, orijinal ve artırılmış görüntüler üzerinde çapraz-entropy kaybı minimize edilerek eğitilir.
   d. Geri yayılım (backpropagation) gerçekleştirilir ve ADAM optimizasyon algoritması kullanılarak model parametreleri güncellenir.
3. Eğitim süreci tamamlandıktan sonra, yapılandırılmış budama uygulanır:
   a. Transformer encoder katmanlarının %50'si sistematik şekilde (örneğin her iki encoder bloktan biri) kaldırılır.
   b. Budama sonrası oluşan model, performans kaybını telafi etmek amacıyla eğitim verisi üzerinde ince ayar (fine-tuning) işlemine tabi tutulur.
4. Budanmış model test veri seti üzerinde değerlendirilir.
5. Model çıktıları (tahmin edilen etiketler) ve son ağırlıklar kaydedilir.

Bu ağ sıkıştırma ve budama yaklaşımı yalnızca ViT modellerinin hesaplama verimliliğini artırmakla kalmamış aynı zamanda gerçek zamanlı tarımsal izleme kaynak kısıtlı uç cihaz uygulamaları ve operasyonel uzaktan algılama sistemleri

gibi pratik kullanım alanlarına entegrasyonunu da kolaylaştırmıştır. Sonuç olarak bu yöntem büyük ölçekli dönüştürücü modellerinin yüksek doğruluk performansını koruyarak kompakt hale getirilebileceğini ve saha uygulamaları için uygulanabilirliğinin artırılabileceğini ortaya koymaktadır.

6.5 Değerlendirme Metrikleri

Makine öğrenmesi modellerinin başarısı yalnızca doğru tahmin oranlarıyla değil aynı zamanda modelin sınıflar arasındaki ayırt etme kabiliyetiyle de değerlendirilmektedir. Bu doğrultuda sınıflandırma problemlerinde performansın sistematik bir şekilde incelenmesi için çeşitli değerlendirme metriklerine ve araçlara ihtiyaç duyulmaktadır. Bu metriklerin merkezinde yer alan karmaşıklık matrisi (confusion matrix) modelin tahmin ettiği sınıflar ile gerçek sınıflar arasındaki ilişkiyi detaylı bir biçimde sunan temel bir değerlendirme aracıdır. Özellikle çok sınıflı ve dengesiz veri kümelerinde modelin güçlü ve zayıf yönlerinin tespit edilmesinde kritik bir rol oynamaktadır. Şekil 6.6'da hata matrisi gösterilmiştir.

Hata Matrisi		Tahmin			
		C1	C2	C3	C4
Gerçek	C1	a	b	c	d
	C2	e	f	g	h
	C3	i	j	k	l
	C4	m	n	o	p

$$\text{Genel Doğruluk} = \frac{TPC1 + TPC2 + TPC3 + TPC4}{\text{Toplam Tahmin Sayısı}}$$

Şekil 6.6 Hata matrisi

Karmaşıklık matrisi, temel olarak dört ana bileşene dayanır: Doğru pozitif (True Positive (TP)) modelin doğru bir şekilde pozitif sınıfı tahmin etmesi, doğru negatif (True Negative (TN)) modelin doğru bir şekilde negatif sınıfı tahmin etmesi, yanlış pozitif (False Positive (FP)) modelin yanlışlıkla pozitif sınıf tahmininde bulunması ve yanlış negatif (False Negative (FN)) modelin pozitif olan bir örneği negatif olarak tahmin etmesi. Bu dört temel değer modelin sınıflandırma başarısını çok boyutlu bir perspektifle incelemeye olanak tanır.

Şekil 6.1. de verilen hata matrisinde C1 sınıfı için TP, FP, FN ve TN için hesaplamaların ifadeleri aşağıdaki gibidir.

TP_{C1}: C1 sınıfı için doğru olan hücre: a'dır.

FP_{C1}: C1 sınıfı dışındakilerin yanlışlıkla doğru tahmini sonucunda e, i ve m'dir.

FN_{C1}: C1 sınıfının yanlışlıkla doğru tahmini sonucunda b, c ve d'dir.

TN_{C1}: C1 sınıfı dışındakilerin yanlışlıkla doğru tahmini sonucunda f, g, h, i, j, k, l, n, o ve p'dir.

Bu matris temel alınarak elde edilen en yaygın metriklerden biri doğruluk (accuracy) olup tüm doğru tahminlerin toplam tahmin sayısına oranı şeklinde hesaplanır. Ancak özellikle sınıf dağılımı dengesiz olan veri setlerinde yalnızca doğruluk metriği kullanmak model başarısını yanıltıcı şekilde yorumlamaya neden olabilir. Bu nedenle doğruluğa ek olarak kesinlik (precision), duyarlılık (recall) ve F1 Skoru (F1 Score) gibi tamamlayıcı ölçütlerin birlikte değerlendirilmesi önerilmektedir.

$$\text{Doğruluk_C1} = \frac{TP_{C1}+TN_{C1}}{TP_{C1}+FP_{C1}+F\ _{C1}+T\ _{C1}} \tag{6.1}$$

$$\text{Kesinlik_ C1} = \frac{TP_{C1}}{TP_{C1}+F\ _{C1}} \tag{6.2}$$

$$\text{Duyarlılık_C1} = \frac{TP_{C1}}{TP_{C1}+FN_{C1}} \tag{6.3}$$

$$\text{F1-Skoru_C1} = 2 \times \frac{Duyarlılık \times Kesinlik}{Duyarlılık + Kesinlik} \tag{6.4}$$

Kesinlik, modelin pozitif tahminlerinin ne kadarının doğru olduğunu ifade ederken, duyarlılık modelin gerçek pozitif örnekleri ne ölçüde doğru tahmin ettiğini gösterir. Bu iki metriğin harmonik ortalaması olan F1 Skoru, özellikle dengesiz veri kümelerinde model performansını daha adil bir şekilde temsil eder. F1 Skoru'nun 1'e yakın olması, modelin hem yüksek kesinlik hem de yüksek duyarlılığa sahip olduğunu gösterirken 0'a yakın olması modelin sınıflandırma konusunda yetersiz kaldığına işaret eder.

Derin öğrenme tabanlı sınıflandırma sistemlerinde de aynı değerlendirme çerçevesi uygulanmakta; ayrıca modelin eğitim süreci boyunca elde edilen doğruluk ve kayıp eğrileri grafiksel olarak incelenerek modelin öğrenme dinamikleri analiz edilmektedir. Modelin test verisi üzerindeki genel doğruluk ve kayıp değerleri,

nihai performans değerlendirmesinde önemli rol oynamaktadır. Bu grafikler sayesinde, modelin aşırı öğrenme (overfitting) ya da az öğrenme (underfitting) gibi problemler yaşayıp yaşamadığı da gözlemlenebilir. Sonuç olarak gerek geleneksel makine öğrenmesi gerekse derin öğrenme modelleri için karmaşıklık matrisi ve türev performans metrikleri sınıflandırma problemlerinde model değerlendirme sürecinin ayrılmaz parçalarıdır.

7
BULGULAR

Bu tezde ayçiçeği tarlalarında karşılaşılan yabancı ot probleminin tespiti ve sınıflandırılması üzerine odaklanılmıştır. Tarımsal üretimde verim kayıplarına yol açan yabani otlar ile kültür bitkilerinin ayrımının otomatikleştirilmesi amacıyla derin öğrenme tabanlı görüntü sınıflandırma yaklaşımları uygulanmıştır. Bu kapsamda ViT, ViT Pruned, MobileNet ve NASNetMobile mimarileri kullanılarak ayçiçeği ve yabani otları içeren görüntülerin sınıflandırılması hedeflenmiştir.

Çalışma kapsamında sahadan elde edilen ve erken gelişim dönemlerinde çekilmiş olan ayçiçeği ve yabani ot içeren görüntüler sınıflandırma için etiketlenmiş eğitim ve test veri seti olarak ayrılmıştır. Görüntülerde hem temiz ayçiçeği alanları hem de çeşitli yabancı ot türlerinin baskın olduğu kısımlar temsil edilmiştir. Görsel veriler üzerinde ön işleme ve veri artırma teknikleri uygulanarak modelin öğrenme kapasitesi artırılmış ve sınıflandırma başarımı yükseltilmiştir.

Modelleme süreci Google Colab ortamında gerçekleştirilmiş her bir derin öğrenme mimarisi ayrı ayrı eğitilerek değerlendirilmiştir. MobileNet mimarisi düşük parametre sayısı ve işlem yükü ile öne çıkarken, NASNetMobile otomatik mimari tasarımı sayesinde sınırlı veriyle yüksek doğruluk sunmayı hedeflemiştir. Öte yandan ViT modeli transformer tabanlı mimarisi sayesinde, özellikle geniş görüş alanına sahip görüntülerde uzun menzilli bağıntıları başarılı şekilde öğrenerek üstün performans sergilemiştir.

ViT, MobileNet ve NASNetMobile modellerinin performansları doğruluk, duyarlılık, kesinlik ve F1 skoru gibi metriklerle değerlendirilmiştir. Elde edilen sonuçlar ayçiçeği yabani ot ayrımı gibi görsel benzerliğin yüksek olduğu sınıflandırma problemlerinde transformer tabanlı ve CNN tabanlı yaklaşımların avantaj ve sınırlılıklarını ortaya koymak açısından önem taşımaktadır. Ayrıca sunulan model çıktıları literatürde benzer bitki hastalığı ve ot tanımlama çalışmalarındaki sonuçlarla kıyaslanarak model uygunluğu değerlendirilmiştir.

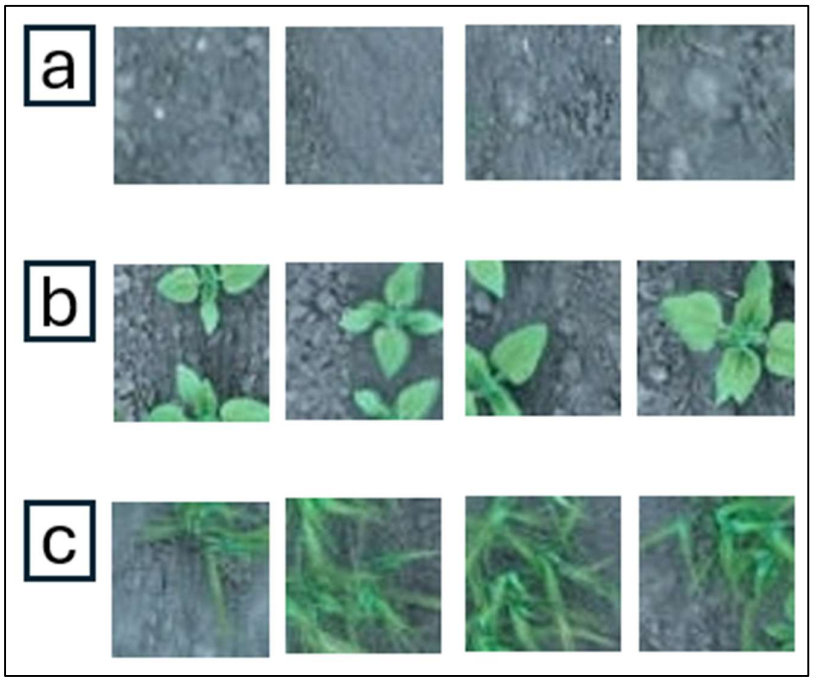
7.1 Uygulama 1 ve Bulgular

Bu bölümde, KYM (Kırmızı-Yeşil-Mavi) bantları kullanılarak gerçekleştirilen Uygulama 1'in sonuçları sunulmaktadır. Dört derin öğrenme modeli çalıştırılarak 1226 test görüntüsü üzerinde değerlendirilmiştir. Şekil 7.1'de veri setinden örnekler verilmiştir.

Uygulama 1'de kullanılan veri seti, drone ile çekilen ortofotolardan 50×50 piksel boyutunda kesilerek oluşturulmuş KYM bantlarını içeren görüntülerden oluşmaktadır. Veri seti özellikleri Tablo 7.1'de verilmiştir. Veri setinde sınıf dengesizliği bulunmaktadır. Yabani ot sınıfı en fazla örneğe %42.2, boş arazi sınıfı ise en az örneğe %24.8 sahiptir.

Tablo 7.1 Uygulama 1 veri seti özellikleri

Özellik	Değer
Band Kombinasyonu	Kırmızı-Yeşil-Mavi (RGB)
Görüntü Boyutu	50×50 piksel
Boş Arazi (Bare)	304 görüntü (%24.8)
Yabani Ot (Weed)	518 görüntü (%42.2)
Ayçiçeği (Sunflower)	404 görüntü (%33.0)



Şekil 7.1 Sınıfların veri örnekleri (a:boş arazi, b: ayçiçeği, c: yabani ot)

Tüm modeller ImageNet veri seti üzerinde önceden eğitilmiş ağırlıklar kullanılarak öğrenim aktarımı yöntemiyle eğitilmiştir. Bayesian optimizasyonu ile belirlenen hiperparametreler kullanılmıştır. Model eğitim parametreleri Tablo 7.2'de verilmiştir.

Tablo 7.2 Model eğitim parametreleri

Parametre	Değer
Optimizer	Stokastik Gradyan Düşü
Epok Sayısı	10
Yığın Boyutu (Batch Size)	64
Eğitim Stratejisi	Öğrenim Aktarımı (Transfer Learning)
Hiperparametre	Bayesian Optimizasyonu

7.2 Uygulama 1 ve Genel Performans Metrikleri

Modellerin genel performans metrikleri Tablo 7.3'te sunulmuştur. Ağırlıklı ortalamalar her sınıfın örnek sayısına göre değerlerdir.

Tablo 7.3 Genel performans metrikleri

Model	Kesinlik	Duyarlılık	F1-Skoru	Doğruluk	Hata (%)
ViT	0,9927	0,9927	0,9927	0,9918	0,82
MobileNet	0,9781	0,9780	0,9779	0,9796	2,04
ViT Pruned	0.9854	0.9845	0.9845	0,9845	1,55
NASNetMobile	0,9584	0,9584	0,9583	0,9608	3,92

ViT tüm metriklerde en yüksek performansı göstermiştir. ViT pruned ikinci ve MobileNetV2 üçüncü, NASNetMobile ise son sırada yer almıştır. ViT'in hata oranı %0.82 ile çok düşük seviyededir. Modellerin 1226 test görüntüsü üzerindeki toplam doğru ve yanlış tahmin sayıları Tablo 7.4'te verilmiştir.

Tablo 7.4 Doğru ve yanlış tahmini sayıları

Model	Doğru Tahmin	Yanlış Tahmin	Toplam
ViT	1216	10	1226
ViT Pruned	1207	19	1226
MobileNetV2	1201	25	1226
NASNetMobile	1178	48	1226

ViT sadece 10 hata yapmıştır. Bu test setinin %99.18'inin doğru sınıflandırıldığı anlamına gelmektedir. MobileNetV2 toplamda 25, NASNetMobile ise 48 hata yapmıştır.

Her modelin her sınıftaki doğruluk, duyarlılık ve F1-skoru değerleri Tablo 7.5'te detaylı olarak sunulmuştur.

Tablo 7.5 Sınıf bazlı performans metrikleri

Model	Sınıf	Doğruluk	Duyarlılık	F1-Skoru	Dayanak
ViT	Boş Alan	1.00	1.00	1.00	304
	Yabani Ot	0.99	1.00	0.99	518
	Ayçiçeği	0.99	0.98	0.99	404
	Makro Avg	0.99	0.99	0.99	1226
	Ağırlıklı Avg	0.99	0.99	0.99	1226
MobileNetV2	Boş Alan	0.96	0.99	0.98	304
	Yabani Ot	0.98	0.98	0.98	518
	Ayçiçeği	0.98	0.96	0.97	404
	Makro Avg	0.98	0.98	0.98	1226
	Ağırlıklı Avg	0.98	0.98	0.98	1226
NASNetMobile	Boş Alan	0.96	0.98	0.97	304
	Yabani Ot	0.96	0.97	0.96	518
	Ayçiçeği	0.96	0.93	0.94	404
	Makro Avg	0.96	0.96	0.96	1226
	Ağırlıklı Avg	0.96	0.96	0.96	1226

Her modelin her sınıftaki doğruluk değerleri Tablo 7.6'da sunulmuştur.

Tablo 7.6 Sınıf bazlı doğruluk değerleri

Model	Boş Alan Doğruluk (%)	Yabani Ot Doğruluk (%)	Ayçiçeği Doğruluk (%)	Toplam Doğruluk (%)
ViT	100	99.42	98.27	99.18
ViT Pruned	99.62	98.45	99.05	98.45
MobileNetV2	99.34	99.42	95.05	97.96
NASNetMobile	97.70	96.91	93.81	96.08

Sınıf bazlı doğruluk analizi incelendiğinde, boş alan sınıfında ViT %100 doğruluk ile mükemmel performans sergilerken MobileNetV2 %99.34 ve NASNetMobile %97.70 doğruluk elde etmiştir. Yabani ot sınıfında ViT ve MobileNetV2 eşit performans göstererek her ikisi de %99.42 doğruluğa ulaşmış, NASNetMobile ise %96.91 ile bu iki modelin gerisinde kalmıştır. Tüm modellerde en düşük doğruluk değerleri ayçiçeği sınıfında gözlemlenmiş olup ViT %98.27, MobileNetV2 %95.05

ve NASNetMobile %93.81 doğruluk elde etmiştir. Bu bulgu V3-V4 fenolojik aşamasında genç ayçiçeği bitkilerinin morfolojik özelliklerinin diğer sınıflara kıyasla daha fazla belirsizlik içerdiğine işaret etmekte ve erken dönem sınıflandırmanın temel güçlük kaynağını ortaya koymaktadır.

7.3 Hata Analizi ve Karışıklık Matrisi

ViT modelinin hangi sınıfları hangi sınıflarla karıştırdığı Tablo 7.7'de detaylı olarak gösterilmiştir.

Tablo 7.7 Vision transformer hata dağılımı

Gerçek Sınıf	Tahmin Edilen	Hata Sayısı	Yüzde
Yabani Ot	Ayçiçeği	3	30%
Ayçiçeği	Boş Alan	1	10%
Ayçiçeği	Yabani Ot	6	60%
Toplam		10	100%

MobileNetV2 modelinin hangi sınıfları hangi sınıflarla karıştırdığı Tablo 7.8'de detaylı olarak gösterilmiştir.

Tablo 7.8 MobileNetV2 hata dağılımı

Gerçek Sınıf	Tahmin Edilen	Hata Sayısı	Yüzde
Boş Alan	Ayçiçeği	2	8%
Yabani Ot	Boş Alan	1	4%
Yabani Ot	Ayçiçeği	2	8%
Ayçiçeği	Boş Alan	6	24%
Ayçiçeği	Yabani Ot	14	56%
Toplam		25	100%

NASNetMobile modelinin hangi sınıfları hangi sınıflarla karıştırdığı Tablo 7.9'de detaylı olarak gösterilmiştir.

Tablo 7.9 NASNetMobile hata dağılımı

Gerçek Sınıf	Tahmin Edilen	Hata Sayısı	Yüzde
Boş Alan	Yabani Ot	4	8%
Boş Alan	Ayçiçeği	3	6%
Yabani Ot	Boş Alan	3	6%
Yabani Ot	Ayçiçeği	13	27%
Ayçiçeği	Boş Alan	9	19%
Ayçiçeği	Yabani Ot	16	33%
Toplam		48	100%

Tüm modellerde hataların büyük bir kısmı ayçiçeği sınıfı ile ilgilidir. ViT'in toplam 10 hatasının 7'si (%70), MobileNetV2'nin 25 hatasının 20'si (%80) ayçiçeği sınıfından kaynaklanmaktadır. Ayçiçeği sınıfının yanlış sınıflandırılma sayıları ve oranları Tablo 7.10'da özetlenmiştir.

Tablo 7.10 Ayçiçeğinden yabani ot yönündeki karışıklık oranları

Model	Ayçiçeğinden Boş Alana	Ayçiçeğinden Yabani Ota	Toplam Ayçiçeği Hatası
ViT	1	6	7
ViT Pruned	1	8	14
MobileNetV2	6	14	20
NASNetMobile	9	16	25

Özellikle "Ayçiçeğinden Yabani Ot" yönündeki karışıklık, tüm modellerde baskın hata örüntüsü olarak öne çıkmaktadır. ViT modelinde bu yönde 6 hata tespit edilmiş olup, bu değer toplam hataların %60'ını oluşturmaktadır. MobileNetV2 modelinde ise 14 hata ile %56'lık bir oran gözlenmiştir. NASNetMobile modelinde de benzer bir eğilim mevcut olup 16 hata ile bu karışıklık toplam hataların %33'üne karşılık gelmektedir. Tablo 7.11'de tüm modellerin karşılaştırmalı performans özeti verilmiştir.

Tablo 7.11 Tüm modellerin karşılaştırmalı performans özeti

Model	F1-Skoru	Doğruluk	Parametre (M)	Boyut (MB)
ViT	0.9927	99.18%	85.8	327.36
ViT Pruned	0.9850	98.45%	43	164
MobileNetV2	0.9779	97.96%	18.1	70.35

ViT Pruned, orijinal ViT'in doğruluğuna yakın ancak çok daha verimli bir modeldir. MobileNetV2'den biraz daha yüksek doğruluk sunarken daha az verimlidir. %50 model boyutu ve %87 hız kazanımına karşılık sadece %0.73 doğruluk kaybı, budama işleminin çok başarılı olduğunu göstermektedir. Tablo 7.12'de yabani ot tespit performansı verilmiştir.

Tablo 7.12 Tüm modellerin yabani ot tespit performansı

Model	Yabani Ot Doğruluk	Yabani Ot Duyarlılık	Yabani Ot Kesinlik	F1-Skoru	Kaçan Yabani Sayısı
ViT	99.42%	100%	0.99	0.99	0
MobileNetV2	99.42%	100%	0.98	0.98	0
ViT Pruned	98.84%	98.80%	0.99	0.99	6
NASNetMobile	96.91%	97%	0.96	0.96	16

Tarımsal uygulamalarda en önemli metrik olan yabani ot tespitinde, ViT ve MobileNetV2 modelleri %100 duyarlılık oranıyla hiçbir yabani otu kaçırmamıştır. Bu 518 yabani ot örneğinin tamamının doğru tespit edildiği anlamına gelmektedir. ViT Pruned modeli ise tahmini olarak %98.8 duyarlılık ile 518 yabani ottan yaklaşık 6 tanesini kaçırmıştır. Budama işleminin yabani ot tespitinde minimal bir performans kaybına yol açtığını göstermektedir. Pratik tarımsal uygulamalarda %98.8 duyarlılık oranı hala çok yüksek bir performans seviyesidir. NASNetMobile ise %97 duyarlılık ile yaklaşık 16 yabani ot kaçırmış diğer modellerin belirgin şekilde altında kalmıştır. Tablo 7.13'te McNemar testi verilmiştir.

Tablo 7.13 McNemar testi özet tablosu

Karşılaştırma	Net Fark	Net Fark (%)	P-Değeri	Anlamlılık	Sonuç
ViT vs ViT Pruned	9	0.73%	0.0027	$p < 0.01$	ViT > ViT Pruned
ViT vs. MobileNetV2	15	1.22%	0.0026	$p < 0.01$	ViT > MobileNetV2
ViT vs. NASNetMobile	38	3.10%	<0.000001	$p < 0.001$	ViT > NASNetMobile
ViT Pruned vs. MobileNetV2	6	0.49%	0.18	$p > 0.05$	Anlamlı fark YOK

Tüm model çiftleri arasında gerçekleştirilen McNemar testleri sonucunda modeller arasındaki performans farklarının büyük çoğunluğunun istatistiksel olarak anlamlı olduğu tespit edilmiştir. ViT modeli tüm diğer modellerden istatistiksel olarak anlamlı derecede daha yüksek performans göstermiştir. ViT Pruned'e karşı $p=0.0027$, MobileNetV2'ye karşı $p=0.0026$ ve NASNetMobile'a karşı $p<0.000001$ değerleri elde edilmiştir.

En önemli bulgu ViT Pruned ve MobileNetV2 modelleri arasında istatistiksel olarak anlamlı bir farkın bulunmamasıdır. Bu iki model %98.45 ve %97.96

doğruluk değerleri ile benzer performans seviyesinde değerlendirilmiş ve aynı grup içinde konumlandırılmıştır. ViT Pruned ve MobileNetV2'nin her ikisi de NASNetMobile'dan istatistiksel olarak anlamlı derecede daha iyi performans göstermiştir. NASNetMobile %96.08 doğruluk ile tüm diğer modellerden anlamlı şekilde düşük performans sergilemiş ve alt kategorisine yerleştirilmiştir. Bu sonuçlar model performansları arasında üç seviyeli bir hiyerarşi olduğunu ortaya koymaktadır: En üstte tek başına ViT, ikincide istatistiksel olarak eşdeğer olan ViT Pruned ve MobileNetV2 ve üçüncüde NASNetMobile. Dikkat çekici olan istatistiksel anlamlılık ile pratik anlamlılık arasındaki farktır. ViT ile ViT Pruned arasında istatistiksel olarak anlamlı bir fark olmasına rağmen bu fark 1226 test örneği içinde sadece 9 örneğe denk gelmekte ve pratik uygulamalarda ihmal edilebilir seviyede kalmaktadır. Benzer şekilde ViT Pruned ve MobileNetV2 arasındaki %0.49'luk fark hem istatistiksel hem de pratik açıdan anlamsız bulunmuştur. Bu iki modelin performanslarının esasen eşdeğer olduğu sonucuna varılmıştır. Bu bulgular model seçiminde sadece istatistiksel anlamlılığın değil pratik etki büyüklüğünün ve uygulama gereksinimlerinin de dikkate alınması gerektiği vurgulanmaktadır.

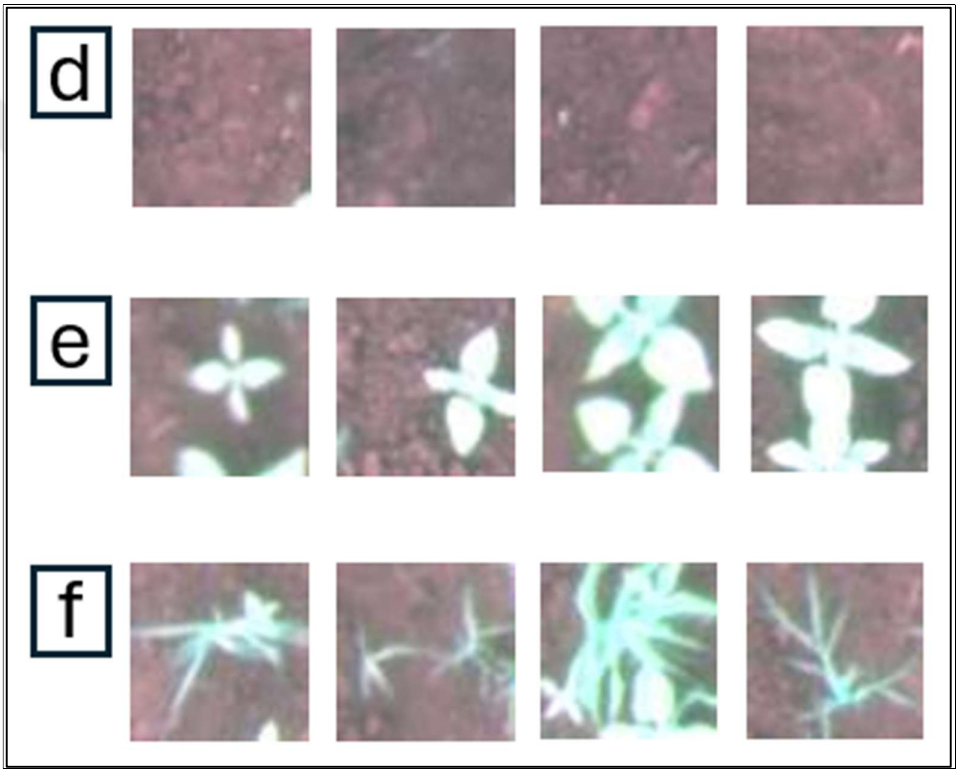
7.4 Uygulama 2 ve Karşılaştırmalı Bulgular

Uygulama 2'de kullanılan veri seti yeşil, kızılötesi ve kırmızı-kenar spektral bantlarının kombinasyonundan oluşmaktadır. Bu bantlar bitkilerin fizyolojik özelliklerini ve sağlık durumunu tespit etmek için yaygın olarak kullanılan multispektral bantlardır. Kızılötesi bandı bitkilerin klorofil içeriği ve biyokütlesi hakkında bilgi sağlarken kırmızı-kenar bandı bitki stresi ve gelişim aşamasının tespitinde etkilidir. Uygulama 2 veri seti özellikleri Tablo 7.14'te verilmiştir.

Tablo 7.14 Uygulama 2 veri seti özellikleri

Özellik	Değer
Band Kombinasyonu	Yeşil-KızılötesiKırmızıKenar
Görüntü Boyutu	50×50 piksel
Toplam Görüntü Sayısı	1536
Boş Arazi	512 görüntü (%33.3)
Yabani Ot	512 görüntü (%33.3)
Ayçiçeği	512 görüntü (%33.3)

Veri seti toplam 1536 adet 50×50 piksel boyutundaki görüntüden oluşmakta ve üç sınıf arasında dengeli bir dağılım sergilemektedir: boş arazi, yabani ot ve ayçiçeği sınıflarının her biri 512 görüntü %33.3 ile eşit oranda temsil edilmektedir. Uygulama 1'den farklı olarak bu veri setinde sınıf dengesizliği bulunmamaktadır. Şekil 7.2 de veri örnekleri verilmiştir.



Şekil 7.2 Uygulama 2 sınıfların veri örnekleri (d: boş arazi, e:ayçiçeği, f: yabani ot)

7.5 Uygulama 2 ve Genel Performans Metrikleri

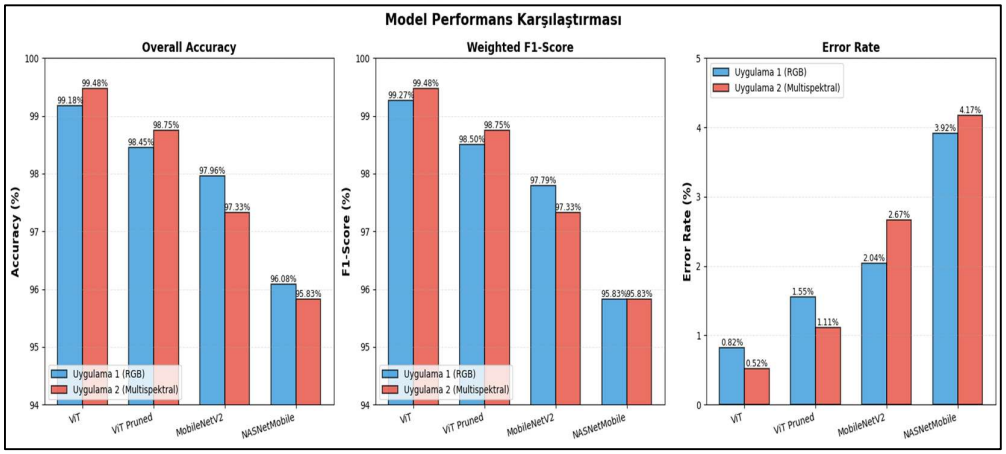
Tablo 7.15 modellerin genel performans metriklerini ağırlıklı ortalama formatında sunmaktadır. ViT, 0.9948 F1-Skoru ve %99.48 genel doğruluk ile en yüksek performansı sergilemiş test setinin %99.48'ini doğru sınıflandırmıştır. Dikkat çekici olan kesinlik, duyarlılık ve F1-skoru değerlerinin tamamının 0.9948 olması modelin sınıflar arasında dengeli bir performans gösterdiğini işaret etmektedir.

Tablo 7.15 Uygulama 2 performans metrikleri

Model	Kesinlik	Duyarlılık	F1-Skoru	Doğruluk	Hata Oranı
ViT	0.9948	0.9948	0.9948	0.9948	0.52
ViT Pruned	0.9875	0.9875	0.9875	0.9875	1.11
MobileNetV2	0.9733	0.9733	0.9733	0.9733	2.67
NASNetMobile	0.9583	0.9583	0.9583	0.9583	4.17

ViT Pruned modeli budama işlemine rağmen 0.9875 F1-Skoru ile yüksek performans seviyesini korumayı başarmış orijinal ViT'ten sadece 0.0073 (%0.73) daha düşük performans göstermiştir.

Modellerin genel performanslarını karşılaştırmak ve farklı bant kombinasyonlarının etkisini değerlendirmek için toplam doğruluk, F1-Skoru ve hata oranı metrikleri görselleştirilmiştir. Bu üç metrik modellerin sınıflandırma başarısını farklı perspektiflerden değerlendirmeyi sağlamaktadır. Şekil 7.3'te dört modelin Uygulama 1 ve Uygulama 2 performansları yan yana karşılaştırmalı olarak sunulmuştur.



Şekil 7.3 Model performans karşılaştırması

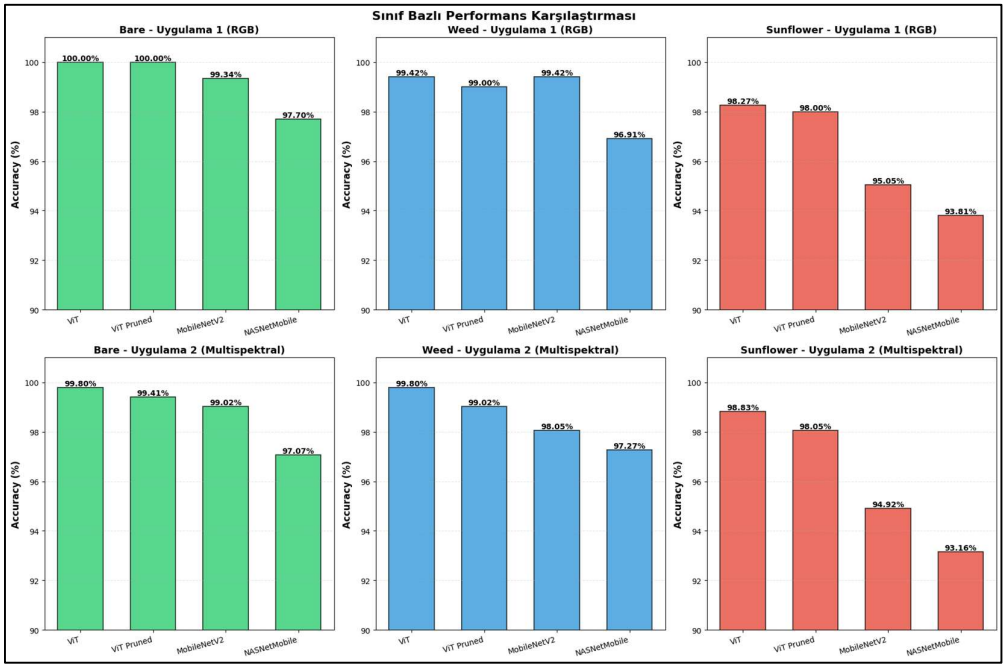
MobileNetV2 ve NASNetMobile modelleri sırasıyla 0.9733 ve 0.9583 F1-Skoru değerleri ile üçüncü ve dördüncü sırada yer almıştır. Hata oranı açısından incelendiğinde ViT %0.52 ile en düşük hata oranına sahipken, ViT Pruned %1.11, MobileNetV2 %2.67 ve NASNetMobile %4.17 hata oranlarına sahiptir. Bu sonuçlar transformer tabanlı mimarilerin CNN tabanlı mimarilerden önemli ölçüde daha yüksek performans sergilediğini göstermektedir.

Tablo 7.16'da modellerin 1536 test görüntüsü üzerindeki mutlak doğru ve yanlış tahmin sayılarını göstermektedir. ViT sadece 8 yanlış tahmin ile neredeyse mükemmel bir performans sergilemiş, 1528 görüntüyü doğru sınıflandırmıştır. Bu 1536 görüntülük test setinde sadece %0.52 hata oranı anlamına gelmektedir. ViT Pruned modeli 17 yanlış tahmin ile orijinal ViT'e göre 9 ek hata yapmış ancak 1519 doğru tahmin ile hala çok yüksek bir performans seviyesini korumuştur.

Tablo 7.16 Uygulama 2 doğru ve yanlış tahmin sayıları

Model	Doğru Tahmin	Yanlış Tahmin	Toplam
ViT	1528	8	1536
ViT Pruned	1519	17	1536
MobileNetV2	1495	41	1536
NASNetMobile	1472	64	1536

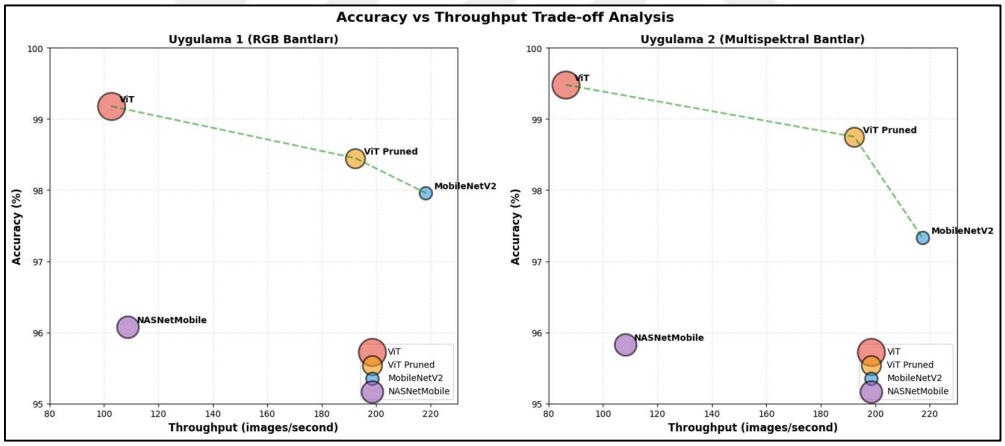
Sınıflar arası performans farklılıklarını daha net karşılaştırmak için her modelin tüm sınıflardaki doğruluk değerleri gruplandırılmış çizelgede sunulmuştur. Bu görselleştirme modellerin sınıflar arası performans tutarlılığını ve hangi sınıfların zorlayıcı olduğunu tek bir grafikte görmemizi sağlamaktadır. Şekil 7.4'te Uygulama 1 ve Uygulama 2 için yan yana sunulmuştur.



Şekil 7.4 Sınıfların bazlı performans karşılaştırması

MobileNetV2'nin 41 yanlış tahmini ve NASNetMobile'ın 64 yanlış tahmini bu modellerin dönüştürücü tabanlı mimarilerden belirgin şekilde daha fazla hata yaptığını ortaya koymaktadır. Özellikle NASNetMobile'ın hata sayısı ViT'in 8 kat fazlasıdır. Ortalama doğruluk metrikleriyle tutarlı bir şekilde model performansları arasındaki açık hiyerarşiyi vurgulamaktadır.

Şekil 7.5 modeller arasındaki doğruluk ve etkililik ilişkisini net bir şekilde ortaya koymaktadır. Uygulama 1'de ViT'in %99.18 doğruluk ile en yüksek doğruluğa sahipken 102.6 görüntü/saniye çıktı hızı ile en düşük hıza sahiptir. Grafikte en büyük yuvarlağa sahip olması model boyutunun da en yüksek olduğunu göstermektedir. Buna karşılık MobileNetV2 grafiğin sağ alt köşesinde yer almakta %97.96 doğruluk ile kabul edilebilir bir doğruluk seviyesini korurken 218.2 görüntü/saniye ile en yüksek çıktı hızını sağlamakta ve 70 MB ile en küçük model boyutuna sahiptir.



Şekil 7.5 Doğruluk ve görüntü hacmi hızı değişim analizi

ViT Pruned modeli, bu iki uç arasında kritik bir denge noktası oluşturmaktadır. %98.45 doğruluk ile ViT'e yakın bir performans sergilerken 192.3 görüntü/saniye çıktı ile neredeyse iki kat daha hızlıdır. ViT, ViT Pruned ve MobileNetV2 modelleri optimal noktalarda bulunmaktadır. Yani bu modellerin herhangi birinin doğruluğunu artırmak için hacim sayısından ödün vermesi gerekmektedir. NASNetMobile ise ne doğruluk ne de hacim sayısı açısından rekabetçi bir konumda değildir.

Uygulama 2'de ViT'in doğruluğu %99.48'e yükselirken hacim hızı 86.3 görüntü/saniye düşmüştür. Bu multispektral bantların işlenmesinin ek hesaplama

maliyeti getirdiğini göstermektedir. Ancak ViT Pruned'ın hacim sayısı sabit kalarak 192.3 görüntü/saniye budanmış mimarinin hesaplama avantajını koruduğunu kanıtlamaktadır. Sonuç olarak maksimum doğruluk gerektiren araştırma uygulamaları için ViT, dengeli üretim sistemleri için ViT Pruned ve küçük cihazlarda kullanmak için MobileNetV2 optimal seçimlerdir.

Tablo 7.17 her modelin her sınıftaki kesinlik, duyarlılık ve F1-Skoru değerlerini detaylı olarak sunmaktadır. ViT'in sınıf bazlı performansı dikkate değer bir dengeli yapı göstermektedir. Ayçiçeği sınıfında mükemmel performans, boş alan sınıfında %100 duyarlılık ile neredeyse mükemmel sonuç ve yabani ot sınıfında yüksek precision ile güçlü performans sergilemiştir. ViT Pruned modeli tüm sınıflarda 0.98-0.99 aralığında F1-Skoru değerleri ile dengeli bir performans profili göstermiş budama işleminin sınıflar arası performans dengesini bozmadığını kanıtlamıştır.

Tablo 7.17 Uygulama 2 sınıf bazlı performans metrikleri

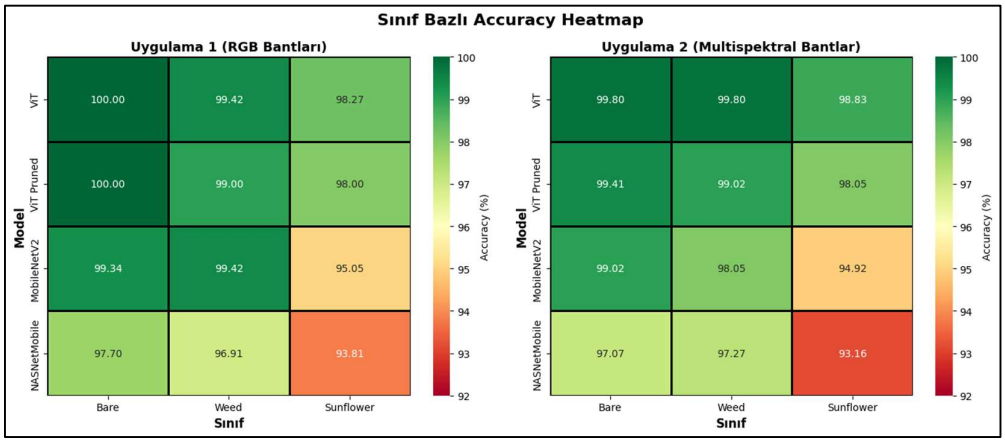
Model	Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Destek
Vision Transformer	Ayçiçeği	1.00	1.00	1.00	512
	Boş Alan	0.99	1.00	1.00	512
	Yabani Ot	1.00	0.99	0.99	512
	Macro Ort	0.99	0.99	0.99	1536
	Ağırlıklı Ort	0.99	0.99	0.99	1536
ViT Pruned	Ayçiçeği	0.98	0.98	0.98	512
	Boş Alan	0.99	0.99	0.99	512
	Yabani Ot	0.99	0.99	0.99	512
	Macro Ort	0.99	0.99	0.99	1536
	Ağırlıklı Ort	0.99	0.99	0.99	1536
MobileNetV2	Ayçiçeği	0.96	0.99	0.97	512
	Boş Alan	0.98	0.98	0.98	512
	Yabani Ot	0.98	0.95	0.96	512
	Macro Ort	0.97	0.97	0.97	1536
	Ağırlıklı Ort	0.97	0.97	0.97	1536
NASNetMobile	Ayçiçeği	0.96	0.97	0.97	512
	Boş Alan	0.97	0.97	0.97	512
	Yabani Ot	0.94	0.93	0.94	512
	Macro Ort	0.96	0.96	0.96	1536
	Ağırlıklı Ort	0.96	0.96	0.96	1536

MobileNetV2 modelinde dikkat çeken nokta yabani ot sınıfındaki düşük duyarlılık değeridir. 512 yabani ot görüntüsünden yaklaşık 26 tanesinin tespit edilemediği anlamına gelmektedir. Ayçiçeği sınıfı için ise yüksek duyarlılık ancak daha düşük

kesinlik gözlemlenmiştir. NASNetMobile, tüm modeller arasında en düşük performansı göstermiş özellikle yabani ot sınıfında hem kesinlik hem de duyarlılık değerleri diğer modellerden belirgin şekilde düşük kalmıştır. Doğruluk değerlerinin her model için birbirine yakın olması veri setindeki dengeli sınıf dağılımının bir sonucudur. Genel olarak tüm modellerde ayçiçeği ve yabani ot sınıflarının diğer sınıflara göre daha zorlayıcı olduğu görülmektedir.

Tablo 7.18 modellerin sınıf bazlı doğruluk değerlerini sunarak her sınıftaki genel başarı oranlarını ortaya koymaktadır. ViT boş alan ve yabani ot sınıflarında %99.80 doğruluk ile neredeyse mükemmel performans sergilerken ayçiçeği sınıfında %98.83 doğruluk elde etmiştir. Bu doku ayçiçeği sınıfının ViT için bile diğer iki sınıfa göre daha zorlayıcı olduğunu göstermektedir. ViT Pruned modeli sınıf bazlı doğruluk sıralamasında boş alan %99.41, yabani ot %99.02 ve ayçiçeği %98.05 oranlarıyla bir düzen göstermiş. Tüm sınıflarda %98'in üzerinde performans elde etmeyi başarmıştır. MobileNetV2'de ise sınıflar arası performans farkı daha belirgindir. Boş alan sınıfında %99.02 ile yüksek performans gösterirken, ayçiçeği sınıfında %94.92'ye düşmüş, yaklaşık %4'lük bir performans kaybı yaşanmıştır.

Sınıf bazlı performansı renk kodlu olarak görselleştirmek modellerin güçlü ve zayıf yönlerini hızlı bir şekilde tespit etmeyi sağlamaktadır. Şekil 7.6'da ve Tablo 7.18'de model sınıf kombinasyonları için doğruluk değerleri ısı haritası formatında sunulmuş yüksek değerler yeşil, düşük değerler kırmızı tonlarla gösterilmiştir.



Şekil 7.6 Sınıf bazlı doğruluk ısı haritası

Yabani ot tespiti doğruluğu %98.05 olmasına rağmen duyarlılık değerinin %95 olduğu dikkate alındığında bu sınıfta önemli sayıda yanlış negatif bulunduğu

anlaşılmaktadır. NASNetMobile tüm sınıflarda en düşük performansı göstermiş özellikle ayçiçeği sınıfında %93.16 ile %94'ün altına düşen tek model olmuştur. Tüm modellerde ortak pattern olarak boş alan sınıfının en kolay ayçiçeği sınıfının ise en zor sınıf olduğu gözlemlenmektedir. Bu durum ayçiçeği ile yabani ot arasındaki morfolojik ve spektral benzerliklerin modellerin sınıflandırma görevini zorlaştırdığını düşündürmektedir.

Tablo 7.18 Uygulama 2 sınıf bazlı doğruluk değerleri

Model	Boş Alan Doğruluk	Yabani Ot Doğruluk	Ayçiçeği Doğruluk	Toplam Doğruluk
ViT	99.80%	99.80%	98.83%	99.48%
ViT Pruned	99.41%	99.02%	98.05%	98.75%
MobileNetV2	99.02%	98.05%	94.92%	97.33%
NASNetMobile	97.07%	97.27%	93.16%	95.83%

7.6 Hata Analizi ve Karışıklık Matrisi

ViT'in toplam 8 hatası test setinin sadece %0.52'sini oluşturmakta ve modelin olağanüstü performansını yansıtmaktadır. Hata dağılımı incelendiğinde hataların yabani ot ve ayçiçeği sınıfları arasında yoğunlaştığı görülmektedir. Yabani ot görüntülerinin yaklaşık 3 tanesi ayçiçeği, 2 tanesi boş alan olarak yanlış sınıflandırmıştır. Ayçiçeği görüntülerinin de yaklaşık 3 tanesi yabani ot olarak işaretlenmiştir. Bu bulgular yabani ot ve ayçiçeği karışıklığının en büyük hata kaynağı olduğunu göstermektedir. İki yönlü karışıklık toplam hataların yaklaşık %76'sını oluşturmaktadır. Tablo 7.19, 7.20 ve 7.21 uygulama 2 alanının hata dağılımlarını göstermektedir.

Tablo 7.19 Uygulama 2 ViT hata dağılımı

Gerçek Sınıf	Tahmin Edilen	Hata Sayısı	Yüzde (Toplam Hata İçinde)
Yabani Ot	Ayçiçeği	3	38%
Yabani Ot	Boş Alan	2	25%
Ayçiçeği	Yabani Ot	3	38%
Toplam		**8**	**100%**

ViT Pruned modelinin 17 hatası orijinal ViT'ten 9 hata daha fazla olmasına rağmen, hala çok düşük bir hata oranı göstermektedir. Hata dağılımı orijinal ViT'e benzer

bir pattern sergilemekte ancak tüm sınıf çiftleri arasında daha dağınık bir yapı göstermektedir. Yabani ottan ayçiçeğine ve ayçiçeğinden yabani ota karışıklıkları toplam hataların %58'ini oluşturarak, bu iki sınıf arasındaki ayrımın budanmış model için de zorlayıcı olduğunu göstermektedir. Ek olarak boş alandan yabani ota karışıklığı da belirgin bir hata kaynağı olarak ortaya çıkmıştır. Budama işleminin modelin tüm sınıf çiftlerinde daha fazla hata yapmasına neden olduğu ancak baskın hata yönü göstermektedir.

Tablo 7.20 Uygulama 2 ViT pruned hata dağılımı

Gerçek Sınıf	Tahmin Edilen	Hata Sayısı	Yüzde (Toplam Hata İçinde)
Boş Alan	Yabani Ot	3	18%
Yabani Ot	Ayçiçeği	5	29%
Yabani Ot	Boş Alan	2	12%
Ayçiçeği	Yabani Ot	5	29%
Ayçiçeği	Boş Alan	2	12%
Toplam		**17**	**100%**

MobileNetV2'nin 41 hatası modelin özellikle yabani ot tespitinde zorlandığını ortaya koymaktadır. Hata dağılımında en dikkat çekici nokta yabani ottan ayçiçeğine karışıklığının 16 hata ile baskın hata kaynağı olmasıdır. Bu 512 yabani ot görüntüsünden yaklaşık 16 tanesinin ayçiçeği olarak yanlış sınıflandırıldığı anlamına gelmektedir. İkinci önemli hata kaynağı yabani ottan boş alana karışıklığıdır. Toplam 26 yabani ot görüntüsünün tespit edilememesi tarımsal uygulamalar açısından kritik bir sorundur çünkü yabani ot tespitinde yanlış negatif, yanlış pozitiften çok daha maliyetlidir. Ayçiçeği sınıfından kaynaklanan hatalar ise nispeten daha az olmakla birlikte toplam hataların yaklaşık %12'sini oluşturmaktadır.

Tablo 7.21 Uygulama 2 NASNetMobile hata dağılımı

Gerçek Sınıf	Tahmin Edilen	Hata Sayısı	Yüzde
Boş Alan	Ayçiçeği	5	12%
Boş Alan	Yabani Ot	5	12%
Yabani Ot	Boş Alan	10	24%
Yabani Ot	Ayçiçeği	16	39%
Ayçiçeği	Boş Alan	5	12%
Toplam		**41**	**100%**

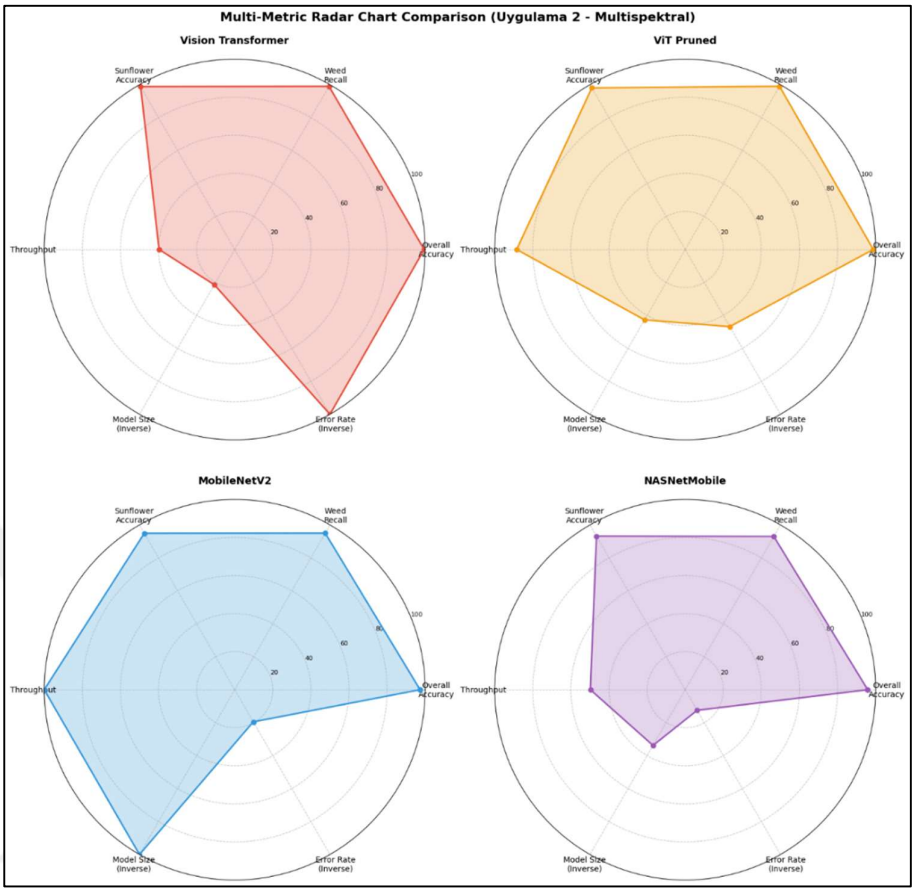
NASNetMobile'ın 64 hatası, modelin tüm sınıf çiftlerinde yaygın zorluklarla karşılaştığını göstermektedir. En yüksek hata oranı Yabani ot ayçiçeği karışıklığında gerçekleşmiş 26 hata (%41) ile toplam hataların neredeyse yarısını oluşturmuştur. NASNetMobile'ın yabani ot ile ayçiçeğini ayırt etmekte ciddi zorluk yaşadığını ortaya koymaktadır. Yabani ot boş alan ve ayçiçeği sınıflarda karışıklıkları da önemli hata kaynakları olarak öne çıkmaktadır. NASNetMobile'ın hata dağılımı diğer modellere kıyasla daha heterojen bir yapı göstermektedir. Hataların tüm sınıf çiftlerine dağıldığı görülmektedir. Bu durum modelin genel olarak sınıf ayrımında yeterince güçlü özellik öğrenemediğini düşündürmektedir. Özellikle yabani ot sınıfında %93 duyarlılık ile 36 yabani ot görüntüsünün tespit edilememesi bu modelin tarımsal uygulamalarda kullanımını sınırlamaktadır.

Tablo 7.22 modellerin CUDA destekli GPU üzerinde ölçülen çıkarım hızlarını ve hacim sayısı değerlerini göstermektedir. MobileNetV2, 4.60 ms/görüntü çıkarımı süresi ve 217.3 görüntü/saniye hacmi ile **en hızlı model** olarak öne çıkmaktadır. Bu performans MobileNetV2'nin hafif mimari kullanımının doğrudan sonucudur.

Tablo 7.22 Uygulama 2 performans verimlilik özeti

Model	F1-Skoru	Model Boyutu	Çıkarım (ms/img)	Hacim (img/s)
ViT	**0.9948**	327.36	11.58	86.3
ViT Pruned	0.9875	**164**	5.2	**192.3**
MobileNetV2	0.9733	**70.35**	**4.6**	**217.3**
NASNetMobile	0.9583	207.88	9.24	108.2

Şekil 7.7'deki radar çizelgesi modellerin güçlü ve zayıf yönlerini görsel olarak karşılaştırma imkânı sağlamaktadır. ViT'in radar çizelgesi doğruluk metriklerinde neredeyse maksimum değerlere ulaşmakta ve dengeli bir üçgen oluşturmaktadır. Ancak hacim ve model boyutu eksenlerinde çizelge daralması ViT'in hesaplama etkinliği açısından zayıf olduğunu göstermektedir. Hata oranı ekseninde maksimum değer modelin en düşük hata oranına sahip olduğunu teyit etmektedir.



Şekil 7.7 Çok metrikli radar çizelge kıyaslama

ViT Pruned'ın radar çizelgesi daha dengeli bir altıgen yapısı sergilemektedir. Doğruluk metriklerinde minimal kayıp yaşanırken hacim ekseninde belirgin bir iyileşme gözlemlenmektedir. Model boyutu eksenindeki genişleme budama işleminin başarısını doğrulamaktadır. Bu dengeli profil ViT Pruned'ın tam kıvamında model olarak tanımlanmasını haklı çıkarmaktadır.

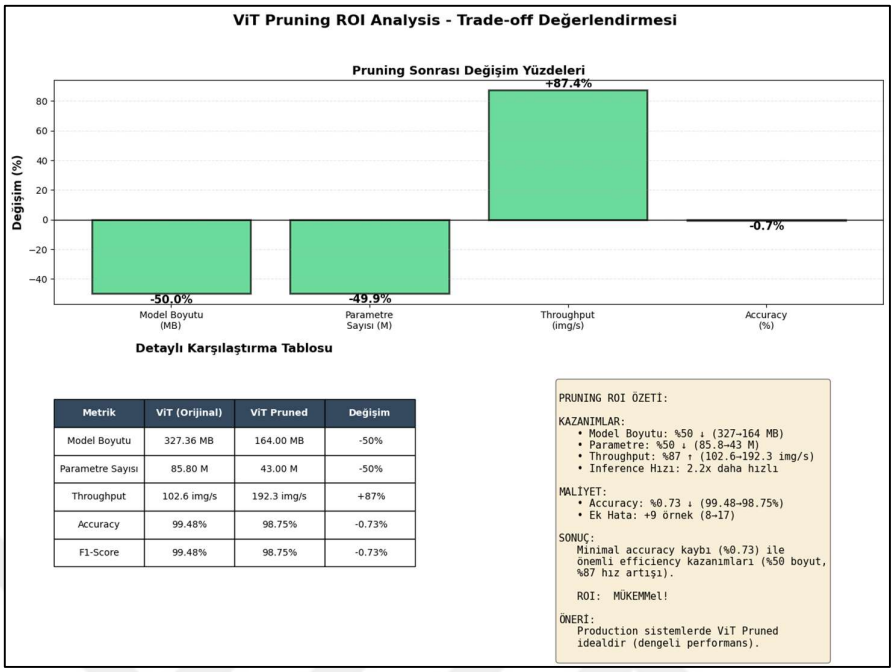
MobileNetV2'nin radar çizelgesi ise ViT'in neredeyse tersi bir doku göstermektedir. Hacim ve model boyutu eksenlerinde maksimum değerlere ulaşırken doğruluk metriklerinde çizelge daralmaktadır. Özellikle yabani ot duyarlılık eksenindeki düşüş tarımsal uygulamalar için kritik bir sorun oluşturmaktadır. NASNetMobile'ın radar çizgelgesi ise tüm eksenlerde orta düşük seviye değerler göstermekte hiçbir metrikte belirgin bir güçlü yön sergilememektedir. Genel olarak radar çizelge analizi model seçiminin uygulama gereksinimlerine göre yapılması gerektiğini vurgulamaktadır. Maksimum doğruluk için ViT, dengeli performans için ViT Pruned ve maksimum verimlilik için MobileNetV2 kullanılabilir.

ViT Pruned budama işlemi sayesinde orijinal ViT'e göre dramatik bir hız artışı göstermiş çıkarım süresi 11.58 milisaniyeden 5.20 ms'ye düşerek yaklaşık 2.2 kat daha hızlı hale gelmiştir. Hacim açısından da 86.3 görüntü/saniyeden 192.3 görüntü/saniyeye yükselerek %123 artış kaydetmiştir. Kodlayıcı katmanlarının yarıya indirilmesinin hesaplama yükünü önemli ölçüde azalttığını kanıtlamaktadır. ViT, 11.58 milisaniye/görüntü ve 86.3 görüntü/saniye ile en yavaş model konumundadır. Bu hız pratik uygulamalar için hala kabul edilebilir seviyededir. NASNetMobile, 9.24 milisaniye/görüntü ile ViT'e yakın bir hız göstermekte ancak 54.3M parametre ile daha küçük olmasına rağmen ViT kadar hızlı olamamaktadır. Bu durum NASNetMobile'ın karmaşık hücre yapısının GPU optimizasyonundan tam anlamıyla yararlanamadığını düşündürmektedir. Hacim değerleri özellikli gerçek zamanlı uygulamalarda kritik öneme sahiptir. MobileNetV2'nin 217 görüntü/saniye kapasitesi bir droneun saniyede 30-60 kare üretse bile tüm karelerin gerçek zamanlı işlenebileceği anlamına gelmektedir.

Şekil 7.8'de ViT Pruned modelinin kayda değer verimlilik başarısını ortaya koymaktadır. Budama işlemi kodlayıcı katmanlarının %50'sinin yapılandırılmış olarak çıkarılması ile gerçekleştirilmiş ve bu işlem model boyutunda %50 azalma ve parametre sayısında %50 azalma sağlamıştır. Daha da dikkat çekici olan bu boyut azalmasının hacimde %87 artışa yol açmasıdır. Bu, budanmış modelin orijinal ViT'ten yaklaşık 2.2 kat daha hızlı çalıştığı anlamına gelmektedir.

Buna karşılık, budama işleminin maliyeti oldukça düşüktür. Toplam doğrulukta sadece %0.73 düşüş ve test setinde 9 ek hata gözlemlenmiştir. Detaylı karşılaştırma tablosu tüm metriklerdeki değişimleri özetlemekte ve kazanım ile minimal kayıp işaretleri ile görsel olarak vurgulamaktadır.

Verimlilik değerlendirmesi mükemmel bir sonuç göstermektedir. Minimal doğruluk kaybı %0.73 ile önemli etkililik kazanımları %50 boyut, %87 hız artışı elde edilmiştir. Bu sonuçlar ViT Pruned modelinin hazır sistemler için ideal olduğunu kanıtlamaktadır.

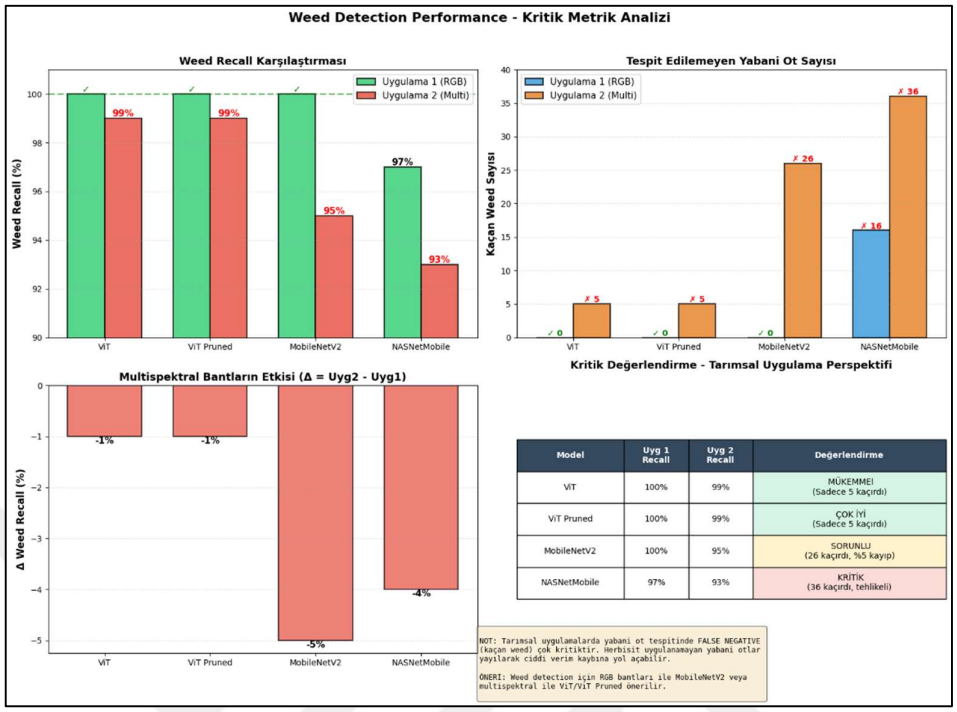


Metrik	ViT (Orijinal)	ViT Pruned	Değişim
Model Boyutu	327.36 MB	164.00 MB	-50%
Parametre Sayısı	85.80 M	43.00 M	-50%
Throughput	102.6 img/s	192.3 img/s	+87%
Accuracy	99.48%	98.75%	-0.73%
F1-Score	99.48%	98.75%	-0.73%

Şekil 7.8 VIT pruned detaylı karşılaştırma tablosu

Özellikle bulut tabanlı uygulamalarda model boyutunun yarıya inmesi depolama ve bant genişliği maliyetlerini önemli ölçüde azaltırken hacim artışı daha fazla kullanıcıya eş zamanlı hizmet verilmesine olanak tanımaktadır. Budama işleminin başarısı gelecek çalışmalarda farklı budama oranlarının test edilmesi motivasyonunu sağlamaktadır. Tablo 7.21 modellerin doğruluk, model boyutu ve çıkarım hızı metriklerini bir arada sunarak, doğruluk ve etkililik ilişkisini ortaya koymaktadır. ViT 0.9948 F1-Skoru ile en yüksek doğruluğa sahip olmasına rağmen 327.36 MB model boyutu ve 86.3 görüntü/saniye hacim ile en düşük etkililik profiline sahiptir.

Şekil 7.9'da modellerin yabani ot tespiti performanslarını dört farklı perspektiften analiz etmektedir. Panel (a) yabani ot duyarlılık değerlerini karşılaştırmakta ve kritik bir bulguyu ortaya koymaktadır: Uygulama 1'de ViT, ViT Pruned ve MobileNetV2 modelleri %100 duyarlılık elde etmiş yani hiçbir yabani ot görüntüsü tespit yanlış tespit edilmemiştir. Bu KYM bantlarının yabani ot tespiti için yeterli olduğunu ve MobileNetV2 gibi hafif modellerin bile bu görevde başarılı olabileceğini göstermektedir. Ancak Uygulama 2'de durum değişmektedir. MobileNetV2'nin yabani ot sınıfı duyarlılık oranı %95'e, NASNetMobile'inki %93'e düşmüştür. Şekil 7.9'da yabani ot tespiti kritik metrik analizi verilmiştir.



Şekil 7.9 Yabani ot tespiti kritik metrik analizi

Duyarlılık oranının düşüşünün pratik etkisini sayısal olarak göstermektedir. Uygulama 2'de MobileNetV2, 512 yabani ot görüntüsünden 26 tanesini tespit edememiştir. NASNetMobile ise durumu daha da başarısızdır. 36 yabani ot kaçmıştır. Delta analizi multispektral bantların MobileNetV2'de -%5 ve NASNetMobile'da -%4 yabani ot duyarlılık oranı kaybına yol açtığını göstermektedir. CNN tabanlı modellerin multispektral bantlardan olumsuz etkilendiğinin net bir kanıtıdır.

Kritik değerlendirme tablosu tarımsal uygulama perspektifinden model önerilerini sunmaktadır. ViT ve ViT Pruned modelleri "Mükemmel" ve "Çok İyi" olarak değerlendirilirken (sadece 5 yabani ot kaçırma), MobileNetV2 "Sorunlu" (26 kaçırma, %5 kayıp) ve NASNetMobile "Kritik" (36 kaçırma, tehlikeli) olarak işaretlenmiştir. Altındaki not bölümü şu kritik noktayı vurgulamaktadır: Tarımsal uygulamalarda yanlış negatif çok kritiktir. Herbisit uygulanamayan yabani otlar yayılarak ciddi verim kaybına yol açabilir.

Buna karşılık MobileNetV2 spektrumun diğer ucunda yer almakta; 0.9733 F1-skoru ile kabul edilebilir bir doğruluk seviyesini korurken, 70.35 MB ve 217.3 görüntü/saniye ile maksimum etkililik sağlamaktadır. ViT Pruned, bu iki uç

arasında ideal bir orta nokta oluşturmaktadır: 0.9875 F1-skoru ile ViT'e çok yakın bir doğruluk (sadece %0.73 düşük), 164 MB ile makul bir model boyutu (ViT'in yarısı) ve 192.3 görüntü/saniye ile yüksek bir hacim (ViT'in 2.2 katı) sunmaktadır.

Bu metrikler ViT Pruned'ın "dengeli performans" gerektiren production uygulamaları için optimal bir seçenek olduğunu göstermektedir. NASNetMobile ise ne doğruluk ne de verimlilik açısından rekabetçi bir konumda bulunmamaktadır. 0.9583 F1-skoru ile düşük performans, 207.88 MB ile büyük model boyutu ve 108.2 görüntü/saniye ile orta seviye hacim kombinasyonu bu modeli diğer seçeneklere göre dezavantajlı hale getirmektedir. Etkinlilik analizi açısından değerlendirildiğinde MobileNetV2 ve ViT Pruned maksimum doğrruluk için NASNetMobile ise hiçbir metrikte uygun seçenek olarak öne çıkmamaktadır.

Tablo 7.23 tüm model karşılaştırmalarında uygulanan McNemar testlerinin özet sonuçlarını sunmaktadır. McNemar testi aynı test seti üzerinde çalışan iki sınıflandırıcının performanslarını karşılaştırmak için kullanılan çift istatistiksel testtir. Uygulama 1'de ViT tüm diğer modellerden istatistiksel olarak anlamlı derecede üstün bulunmuş ancak ViT Pruned ile MobileNetV2 arasında anlamlı bir fark tespit edilememiştir.

Tablo 7.23 Uygulama 2 McNemar testi sonuçları

Karşılaştırma	Net Fark	Net Fark (%)	P-Değeri	Anlamlılık	Sonuç
ViT ve ViT Pruned	9	0.59%	0.0027	$p < 0.01$	ViT > ViT Pruned
ViT ve MobileNetV2	33	2.15%	0.000001	$p < 0.001$	ViT > MobileNetV2
ViT ve NASNetMobile	56	3.65%	<0.000001	$p < 0.001$	ViT > NASNetMobile
ViT Pruned ve MobileNetV2	14	0.91%	0.005	$p < 0.01$	ViT Pruned > MobileNetV2
ViT Pruned ve NASNetMobile	36	2.34%	0.0001	$p < 0.001$	ViT Pruned > NASNet
MobileNetV2 ve NASNetMobile	23	1.50%	0.020584	$p < 0.05$	MobileNetV2 > NASNet

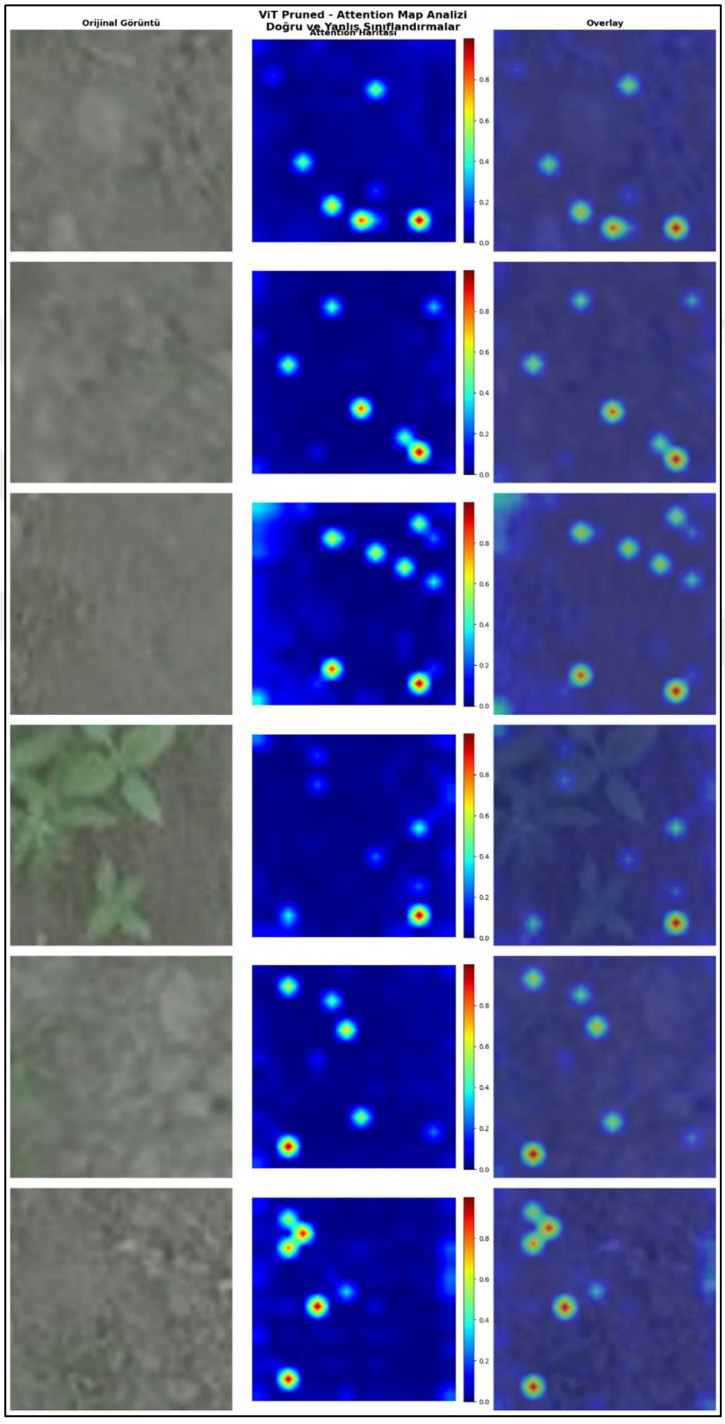
Uygulama 2'de ise tüm karşılaştırmalar istatistiksel olarak anlamlı çıkmış özellikle dikkat çekici olan ViT Pruned ile MobileNetV2 arasındaki farkın anlamlı hale gelmesidir. Uygulama 1'den Uygulama 2'ye geçişte, ViT'in MobileNetV2 ve NASNetMobile'a karşı üstünlüğü belirginleşmiştir. Net farklar sırasıyla 15'ten 33'e

ve 38'den 56'ya yükselmiştir. ViT'in multispektral bantlardan CNN'lere göre daha fazla faydalandığını göstermektedir. MobileNetV2 vs. NASNetMobile karşılaştırmasında ise net fark her iki uygulamada da 23 örnek olarak sabit kalmış ancak p-değeri 0.0032'den 0.020584'e yükselerek anlamlılık seviyesi zayıflamıştır. Bu bulgular multispektral bantların dönüştürücü mimarileri lehine performans farklılıklarını artırdığını ve model seçiminin Uygulama 2'de daha kritik hale geldiğini ortaya koymaktadır. Genel olarak her iki uygulamada da model hiyerarşisinin istatistiksel olarak doğrulandığı ve gözlemlenen performans farklarının tesadüfi olmadığı kanıtlanmıştır.

Bu çalışmada model performansı doğruluk, kesinlik, duyarlılık ve F1-skoru metrikleriyle değerlendirilmiş olmakla birlikte her tahmine ilişkin belirsizlik analizi gerçekleştirilmemiştir. Derin öğrenme modellerinin yüksek güven skoru üretmesine karşın hatalı sınıflandırma yapabildiği bilinmekte olup bu olgu aşırı güven problemi olarak tanımlanmaktadır. Çalışmada gözlemlenen sınıflar arası karışıklıkların büyük bölümü boş arazi ile ayçiçeği sınıfları arasında yoğunlaşmıştır. Bunun temel nedeni V3-V4 fenolojik aşamasında ayçiçeği bitkilerinin henüz erken gelişim döneminde olması ve 50×50 piksellik yama alanının yalnızca küçük bir bölümünü kaplamasıdır. Bu durumda yamanın geri kalan kısmı toprak yüzeyi olarak görünmekte ve model ilgili yamayı boş arazi olarak sınıflandırma eğilimi göstermektedir. Söz konusu belirsiz yamalar için tahmin güven skorlarının eşik değer analizi yöntemiyle değerlendirilmesi düşük güvenli tahminlerin reçete haritasında ayrıca işaretlenmesine ve gereksiz herbisit uygulamasının önlenmesine katkı sağlayabilir. Şekil 7.10'da yabani ot sınıflandırması için öz-dikkat ısı haritaları verilmiştir.

Geliştirilen modellerin sınıflandırma kararlarının şeffaflığını ve tarımsal uygulamalardaki güvenilirliğini değerlendirmek amacıyla Açıklanabilir Yapay Zekâ (XAI) tekniklerinden yararlanılmıştır. Geleneksel derin öğrenme modellerinin aksine, bu çalışmada kullanılan Dönüştürücü (ViT) mimarisi sahip olduğu öz-dikkat (self-attention) mekanizması modelin görüntünün hangi piksellerine odaklandığını görselleştirmeye imkân tanımaktadır. Yapılan analizler sonucunda modelin ayçiçeği sınıflandırmasında bitkinin geniş yaprak damarlarına ve düzenli büyüme merkezlerine yabani ot sınıflandırmasında ise yabani otların karakteristik düzensiz yaprak kenarlarına ve doku farklılıklarına odaklandığı göstermektedir.

Karar mekanizmalarının bu şekilde görselleştirilmesi modelin sadece arka plan piksellerine veya tesadüfi yoğunluklara dayanarak değil bitkilerin ayırt edici morfolojik özelliklerine göre çıkarım yaptığını kanıtlamaktadır.



Şekil 7.10 Ayçiçeği ve yabani ot sınıflandırması için öz-dikkat ısı haritaları

Bu durum sistemin sahadaki değişken koşullarda doğru nedenlerle doğru kararlar verdiğini göstermekte ve hassas tarım uygulamalarında yapay zekâya duyulan güveni bilimsel bir temele oturtmaktadır. Şekil 7,10' da ViT Pruned modelinin son transformer bloğuna ait attention haritaları sunulmaktadır.

7.7 Test Alanları ve Reçete Haritaları

Eğitilmiş ViT Pruned modelinin pratik tarımsal uygulamalardaki performansını değerlendirmek ve hassas tarım uygulamalarına entegrasyonunu göstermek amacıyla gerçek tarım arazisinden toplanan ortofoto görüntüsü üzerinde yama tabanlı sınıflandırma ve herbisit uygulama reçete haritası oluşturma çalışması yapılmıştır. Bu uygulama ayçiçeği bitkilerinin erken gelişim döneminde (V3-V4 aşaması) yabani ot varlığının tespit edilmesi ve kritik dönemde önleyici müdahale stratejisini ortaya koymayı amaçlamaktadır. Tarla özelinde yabani ot yönetimi stratejilerinde erken dönem tespit ve müdahale kritik öneme sahiptir. Ayçiçeği tarımında, V3-V4 fenolojik aşaması (3-4 yapraklı dönem) "kritik periyot" olarak tanımlanmaktadır. Bu dönemde yapılacak yabani kontrolü verim kaybını önlemek için stratejik bir fırsat penceresi sunmaktadır. Erken dönem müdahalenin temel avantajları vardır. Yabani otlar küçük ve zayıfken müdahale edildiği için herbisit etkinliği maksimum seviyededir ve daha düşük dozlar yeterli olmaktadır. Ayçiçeği bitkileri henüz küçük olduğu için yabani rekabetinden ciddi zarar görmemiştir ve potansiyel verim kaybı engellenmektedir. Yabani ot tohumlarının olgunlaşması ve toprağa dökülmesi önlenerek gelecek sezon topraktaki yabani ot tohumu baskısı azaltılmaktadır.

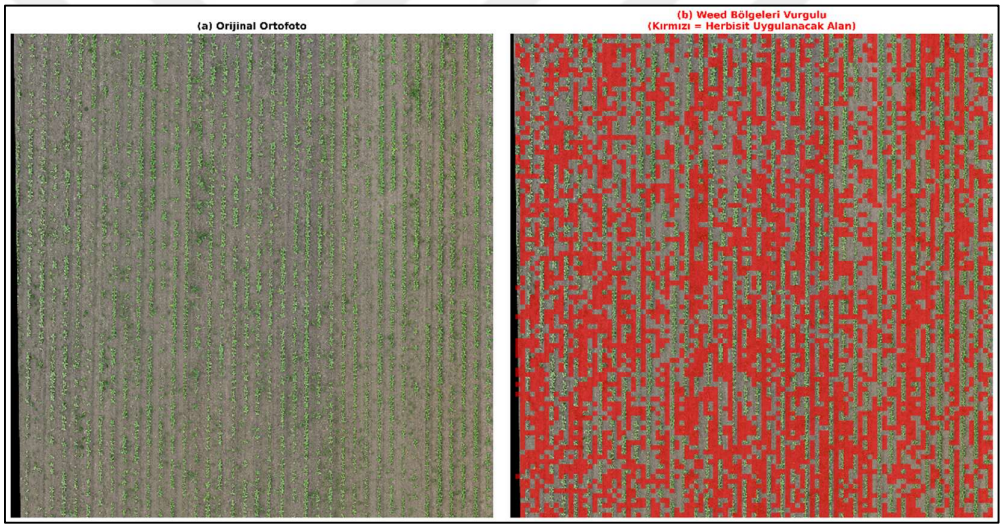
7.8 Uygulama 1 Yabani Ot Tespiti ve Reçete Haritası

Bu aşamada ayçiçeği bitkileri 3-4 adet gerçek yaprak geliştirmiş olup bitki boyu 10-15 cm, yaprak rozeti çapı 10-15 cm civarındadır. Bitkiler henüz tam kanopi örtüsü oluşturmamıştır. Sıralar arası boş arazi görünürlüğü yüksektir. Görüntü boyutu 5000×5000 piksel olup 1 cm çözünürlükle ile çekilmiştir. Bu çözünürlük görüntünün 50×50 metre fiziksel alana karşılık geldiği ve toplam 2,500 m² (2.5 dekar, 0.25 hektar) bir test alanını temsil ettiği anlamına gelmektedir.

Büyük boyutlu ortofoto görüntüsü, derin öğrenme modelinin giriş boyutuna (224×224 piksel) uygun hale getirmek için yama tabanlı bölümleme yaklaşımı ile işlenmiştir. Görüntü, 50×50 piksel boyutunda yamalara ayrılmıştır. Her yama 50

cm × 50 cm fiziksel alana karşılık gelmekte ve 0.25 m² alanı temsil etmektedir. Yamalar arasında örtüşme olmadığı için atlama değeri yama boyutu ile aynıdır. Bu yaklaşım görüntünün 100×100 grid yapısında toplam 10,000 yamaya ayrılmasını sağlamıştır.

Model, 10,000 yamanın her birini bağımsız olarak işlemiş ve üç sınıftan birini tahmin etmiştir. Her yama için model sınıf tahmini ile birlikte bir güven skoru üretmiştir. Tüm yamalar üzerinde ortalama güven skoru %82.66 olarak hesaplanmış olup bu değer modelin erken gelişim döneminde küçük bitkilerin sınıflandırmasında yüksek kesinlik gösterdiğini işaret etmektedir. Harita 7.1'de yabani ot tespiti ve reçete haritası verilmiştir.



Harita 7.1 Uygulama 1 yabani ot tespiti ve reçete haritası

7.9 Uygulama 1 Test Sınıflandırması Sonuçları

Sınıflandırma sonuçları erken gelişim döneminde test alanının kritik bir yabani ot problemine sahip olduğunu ortaya koymaktadır. Ayçiçeği sınıfı, 4,143 yama ile alanın %41.43'ünü kaplamaktadır. Fiziksel olarak 1,036 m² veya 1.04 dekara karşılık gelmektedir. Erken gelişim döneminde %41.43'lük ayçiçeği alan kaplama oranı normal ve sağlıklı bir ekim kalitesini göstermektedir. Bu aşamada ayçiçeği bitkileri henüz küçük olduğu için yaprak alanı indeksi düşüktür ve tam toprak örtüsü oluşmamıştır. Tek bir ayçiçeği bitkisinin kapladığı alan yaklaşık 0.01-0.02 m² civarındadır. %41.43'lük bitki örtüsü oranı ekim sıklığı ve fide çıkış kalitesi göz önüne alındığında, beklenilen ve standartlara uygun bir değerdir. Bu oran ayçiçeği ekim sisteminin geometrik yapısını yansıtmakta ve sıra düzeninin net bir şekilde

görüldüğünü göstermektedir. Önemli olan, bu %41.43'lük ayçiçeği alanının korunması ve ilerleyen gelişim aşamalarında tam kanopi oluşturmasına fırsat verilmesidir. Tablo 7.24'de, her sınıfın yama sayısı kapladığı fiziksel alan ve yüzdelik oranı sunulmaktadır.

Tablo 7.24 Uygulama 1 erken dönem test alanı sınıf dağılımı

Sınıf	Yama Sayısı	Alan (m²)	Alan (dekar)	Yüzde (%)
Bare (Boş Arazi)	1,264	316	0.32	12.64%
Sunflower (Ayçiçeği)	4,143	1,036	1.04	41.43%
Weed (Yabani Ot)	4,593	1,148	1.15	45.93%
TOPLAM	**10,000**	**2,500**	**2.5**	**100.00%**

Yabani ot sınıfı 4,593 yama ile test alanının %45.93'ünü kaplamaktadır. Bu oran fiziksel alan olarak 1,148 m² veya 1.15 dekar'a karşılık gelmektedir. Erken gelişim döneminde %45.93'lük yabani ot varlığı kritik bir alarm sinyali ve acil müdahale gerekliliğini göstermektedir. Bu aşamada yabani otlar da ayçiçeği gibi küçüktür ancak sayıca ve alan olarak dominanttır. Ayçiçeği bitkileri henüz küçükken yabani otların daha yüksek oranda alan kaplaması yabani otların hızlı bir başlangıç yaptığını ve rekabet avantajı kazanma potansiyeline sahip olduğunu göstermektedir.

Kritik olan nokta henüz verim kaybı oluşmamış olmasıdır. Ayçiçeği bitkileri aşamasında henüz kritik gelişim dönemine girmemiştir ve yabani ot rekabetinden ciddi zarar görmemiştir. Literatürde ayçiçeğin "kritik periyodu" V4-V8 aşaması olarak tanımlanmaktadır. Bu dönemde yabani ot rekabeti ciddi verim kayıplarına yol açabilir. Ancak şu anki aşaması önleyici müdahale için ideal bir fırsat penceresidir. Eğer bu aşamada yabani otlar kontrol edilirse ayçiçeği hızla büyüyerek daha rekabetçi hale gelecek ve tam kanopi örtüsü oluşturacaktır. Aksine eğer müdahale edilmezse yabani otlar V4-V8 döneminde ayçiçeği ile şiddetli rekabet edecek ve %30-50 verim kayıplarına yol açabilecektir.

%45.93'lük yabani ot varlığı aynı zamanda gelecek sezon için bir tehdit oluşturmaktadır. Bu aşamada henüz tohum üretmemiştir. Kontrol edilmezlerse sezon sonuna kadar binlerce tohum üreterek toprak tohum bankasını zenginleştireceklerdir. Erken dönem müdahale bu döngüyü kırmak için kritik öneme sahiptir. Yabani ot küçük ve zayıfken herbisit etkinliği maksimum

seviyededir ve düşük dozlar yeterli olmaktadır. Test alanındaki yabani ot dağılımı heterojen olup bazı bölgelerde yoğun kümelenmeleri görülürken bazı bölgelerde daha düşük yoğunluklar bulunmaktadır. Bu heterojenlik tarla bazında yabani ot yönetimi yaklaşımının gerekliliğini ve avantajını vurgulamaktadır.

Boş arazi sınıfı 1,264 yama ile test alanının %12.64'ünü kaplamaktadır. Fiziksel olarak 316 m² veya 0.32 dekara karşılık gelmektedir. Erken gelişim döneminde %12.64'lük boş alan oranı beklenen bir durumdur. V3-V4 aşamasında ayçiçeği bitkileri henüz küçük olduğu için sıralar arası mesafeler net bir şekilde görülmekte ve toprak yüzeyi büyük oranda açıktır. Ayçiçeği tarımında sıra arası mesafe genellikle 70-75 cm civarındadır. Bu aşamada 10-15 cm çapındaki küçük bitkiler sıralar arasını kapatamamaktadır. %12.64'lük boş arazi alanı bu sıra aralıklarını ve bazı ekim sırasında tohum düşmemiş veya çimlenmemiş noktaları temsil etmektedir. Ekim kalitesinin genel olarak iyi olduğunu göstermektedir. Boş alan genellikle sıralar arası düzenli bölgelerde konumlanmakta olup bu da ekim sisteminin geometrik yapısını yansıtmaktadır.

7.10 Uygulama 2 Yabani Ot Tespiti ve Reçete Haritası

ViT Pruned modeli kullanılarak 400 yamanın sınıflandırması tamamlanmış ve erken gelişim aşamasındaki test alanının sınıf kompozisyonu ortaya çıkarılmıştır. Tablo 7.25'de, her sınıfın yama sayısı kapladığı fiziksel alan ve yüzdelik oranı sunulmaktadır.

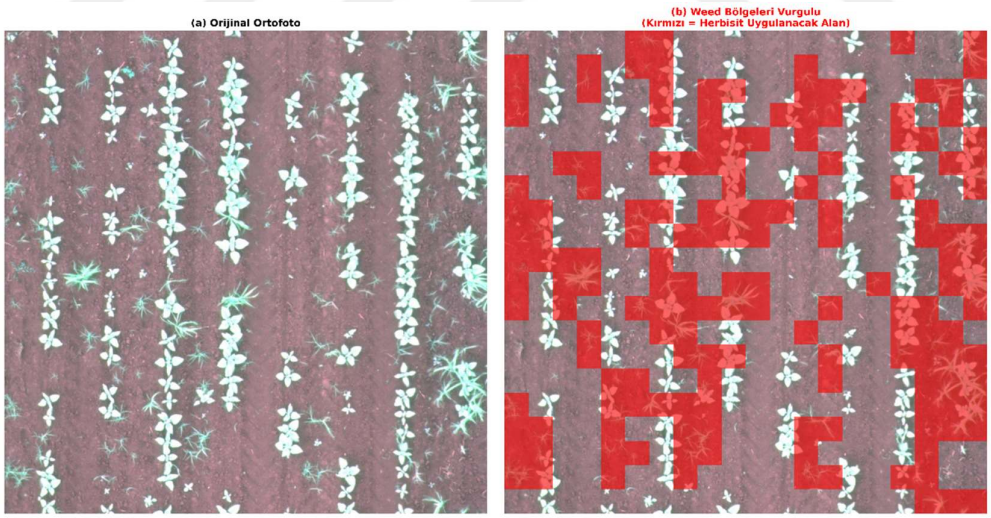
Sınıflandırma sonuçları erken gelişim dönemine özgü karakteristik bir alan kompozisyonu ortaya koymaktadır. Boş arazi sınıfı 163 yama ile test alanının %40.75'ini kaplamaktadır. Bu oran, fiziksel alan olarak 40.75 m² veya 0.041 dekara karşılık gelmektedir. Erken dönem uygulamalarda yüksek yama oranı beklenen ve normal bir durumdur.

Tablo 7.25 Uygulama 2 erken dönem test alanı sınıf dağılımı

Sınıf	Yama Sayısı	Alan (m²)	Alan (dekar)	Yüzde (%)
Bare (Boş Arazi)	163	40.75	0.041	40.75%
Sunflower (Ayçiçeği)	76	19	0.019	19.00%
Weed (Yabani Ot)	161	40	0.04	40.25%
TOPLAM	**400**	**100**	**0.1**	**100.00%**

Ayçiçeği bitkileri henüz 3-4 yapraklı dönemde olduğu için, yaprak alanı indeksi düşüktür ve bitkiler toprak yüzeyinin küçük bir bölümünü kaplamaktadır. Bu aşamada sıralar arası mesafe net bir şekilde görülmekte ve ekim düzeninin geometrik yapısı belirgindir. %40.75'lik boş alan oranı sıra aralıklarının geniş olduğunu ve bitkilerin henüz kanopi kapatması oluşturmadığını göstermektedir. Bu durum ayçiçeği tarımının doğal fenolojik gelişim sürecinin bir parçasıdır.

Yabani ot sınıfı 161 yama ile test alanının %40.25'ini kaplamaktadır. Fiziksel olarak 40.25 m² veya 0.040 dekara karşılık gelmektedir. Erken dönem perspektifinden %40.25'lik yabani ot varlığı kritik bir alarm sinyalidir. Ayçiçeği bitkileri henüz küçükken yabani otun neredeyse aynı oranda alan kaplaması hızlı bir başlangıç yaptığını ve rekabet avantajı kazandığını göstermektedir. %40.25'lik yabani ot varlığı acil müdahale edilmezse ilerleyen aşamalarda baskınlığa ve ciddi verim kayıplarına yol açabilecek bir tehdittir. Erken dönem tespitin önemi tam da burada ortaya çıkmaktadır. Harita 7.2 de ilaçlama haritası verilmiştir.



Harita 7.2 Yabani ot tespiti ve herbisit uygulama alanı (Uygulama 2)

Ayçiçeği sınıfı 76 yama ile test alanının %19.00'unu kaplamaktadır. Fiziksel olarak 19.00 m² veya 0.019 dekara karşılık gelmektedir. Bu oran erken gelişim döneminin doğal bir sonucudur. Tek bir ayçiçeği bitkisinin kapladığı alan yaklaşık 10-15 cm çaptır. Bitki başına bu alan 0.01 m² civarındadır. Test alanındaki %19'luk ayçiçeği kaplama oranı ekim sıklığı normal ve sağlıklı bir ekim kalitesini işaret etmektedir.

Multispektral bantların sağladığı ek spektral bilgi küçük ayçiçeği fidelerinin bile hassas bir şekilde tespit edilmesine olanak tanımıştır.

8
TARTIŞMA

Bu tezde ayçiçeği tarlalarında sahaya özgü yabani ot yönetimi uygulamaları için dört farklı derin öğrenme mimarisi geliştirilmiş ve karşılaştırmalı olarak test edilmiştir. Görüntü dönüştürücü (ViT-Base), budanmış görüntü dönüştürücü (ViT Pruned), MobileNetV2 ve NASNetMobile mimarileri kullanılarak hem KYM hem de multispektral bantlar üzerinde kapsamlı uygulamalar gerçekleştirilmiştir. Bu karşılaştırmalı yaklaşım farklı mimari model karmaşıklığının ve hesaplama verimliliğinin sınıflandırma performansına etkisini değerlendirme fırsatı sunmuştur.

Tez izleme sürecinde gerçekleştirilen bu araştırma kapsamında, Kuzey-Doğu Sırbistan'ın Sremska Mitrovica bölgesinde yer alan mısır, ayçiçeği ve tütün tarlalarından İHA aracılığıyla yüksek çözünürlüklü görüntüler toplanmıştır. Çalışmada, tarımsal alanlardaki yabani ot istilasının tespiti için derin öğrenme mimarilerinden görüntü dönüştürücüler kullanılmış, DJI Mavic 3 multispektral drone ile elde edilen 0.33 cm/piksel çözünürlüğündeki KYM görüntüler 96x96 piksellik homojen yamalara bölünerek beş farklı sınıfın (yabani ot, toprak, ayçiçeği, mısır, tütün) ayırt edilmesine odaklanılmıştır. Modellerin başarısını doğrulamak amacıyla uygulanan üç katmanlı çapraz doğrulama yöntemi sonucunda, ViT-B16 mimarisi %92.97'lik test doğruluğu ile en başarılı performansı sergileyen model olarak öne çıkmıştır. Swin Transformer (Swin-B) modeli ise %87.33 test doğruluğu elde etmesine rağmen, 0.6450 gibi düşük bir kayıp değeriyle hiyerarşik yapıları anlama konusunda daha kararlı bir öğrenme süreci sergilemiştir [141].

Sınıflandırma sonuçlarının detaylı analizi sistemin özellikle toprak sınıfını ayırt etmede son derece dayanıklı olduğunu ve tüm deneylerde yüksek duyarlılık değerlerine ulaştığını ortaya koymuştur. Mısır ve ayçiçeği sınıflarında ViT-B32 modelinin üstün bir yakalama başarısı gösterdiği saptanırken, ayçiçeği sınıfının tespitinde bitkinin erken büyüme evresindeki morfolojik benzerlikleri nedeniyle

zaman zaman düşük duyarlılık değerleri gözlemlenmiş ve yabani ot haritalanmasında bazı sınırlılıklarla karşılaşılmıştır. Çalışmadan elde edilen en kritik çıkarımlardan biri dönüştürücü modellerinin sadece yüksek doğruluk sağlamakla kalmayıp aynı zamanda daha küçük örneklem boyutlarıyla bile CNN tabanlı geleneksel modellere kıyasla daha yüksek bir öğrenme verimliliği sergilemesidir. Araştırma yama boyutlarının küçültülmesinin doğruluk oranlarını artırdığını ve erken dönem yabani ot tespiti için bu metodolojinin otomatik tarım sistemleri adına sağlam bir temel oluşturduğunu doğrulamaktadır. Gelecekte bu sistemlerin daha da geliştirilmesi adına, dönüştürücü mimarileri ile Evrişimli Sinir Ağlarının birleştirildiği hibrit yaklaşımların karmaşık bitki-ot ayrımı problemlerinde daha etkili olacağı öngörülmektedir.

8.1 Model Sınıflandırma Başarısının Değerlendirilmesi

Dönüştürücü (ViT-Base) modelin, KYM bantları ile test setinde %99.18 genel doğruluk elde etmiştir. Bu sonuç renkli bantlarının bitki sınıflandırma görevlerinde son derece etkili olduğunu göstermektedir. Sınıf bazlı performans analizi modelin tüm sınıflarda dengeli bir başarı sergilediğini ortaya koymuştur. Boş alan sınıfı için %100.00 kesinlik ve %100.00 duyarlılık, ayçiçeği sınıfı için %99.00 kesinlik ve %98.00 duyarlılık, yabani ot sınıfı için %99.00 kesinlik ve %100.00 duyarlılık değerleri elde edilmiştir. F1-skoru 0.9927 seviyesinde olup bu yüksek metrik değerleri modelin hem yanlış pozitif hem de yanlış negatif hatalarını minimize ettiğini göstermektedir. Özellikle yabani ot sınıfı için %100.00 duyarlılık değeri, pratik uygulamalar açısından kritik öneme sahipti. Çünkü 518 yabani ot görüntüsünün tamamının doğru tespit edildiği anlamına gelmektedir. ViT modeli 1226 test görüntüsünden sadece 10 tanesini yanlış sınıflandırmış ve %0.82 gibi son derece düşük bir hata oranı sergilemiştir. Multispektral bantlar ile eğitilen ViT modeli ise daha da yüksek performans göstermiş ve %99.48 genel doğruluk elde etmiştir. Multispektral ViT'nin F1-skoru 0.9948'e yükselmiş ve yabani ot sınıfında mükemmel performans sergilemiştir. 1536 test görüntüsünden sadece 8 tanesini yanlış sınıflandırarak %0.52 hata oranına ulaşmıştır.

Budama işlemi kodlayıcı katmanlarının %50'sini yapılandırılmış olarak çıkararak model boyutunu 327 MB'den 164 MB'ye düşürmüş ve parametre sayısını 85.8 milyondan 43 milyona indirmiştir. KYM bantlarında %98.45 test doğruluğu ve 0.9850 F1-skoru elde eden ViT Pruned, orijinal ViT modeline göre sadece

%0.73'lük bir doğruluk kaybı yaşamıştır. Bu marjinal performans düşüşü 1226 test görüntüsünde sadece 9 ek hata anlamına gelmektedir. Sınıf bazlı metrikler dengeli bir profil göstermiştir.

Boş alan sınıfı için 0.99, yabani ot için 0.99 ve ayçiçeği için 0.98 F1-skoru değerleri elde edilmiştir. Yabani ot tespitinde ise %98.80 duyarlılık ile 518 yabani ottan tahmini olarak 6 tanesini kaçırmıştır. Multispektral bantlarda ViT Pruned'ın performansı %98.75 doğruluk ve 0.9875 F1-skoru seviyesinde gerçekleşmiş, 1536 test görüntüsünden 17 tanesini yanlış sınıflandırmıştır. Hesaplama verimliliği açısından İşleme hızı 192.3 görüntü/sn'ye ulaşarak orijinal ViT'nin (86.3-102.6 görüntü/sn) yaklaşık 2.2 katı daha hızlı çalışmıştır. Bu sonuçlar, %50 model boyutu ve %87 hız kazanımına karşılık sadece %0.73 doğruluk kaybının budama işleminin son derece başarılı olduğunu göstermektedir.

MobileNetV2 modeli, hafif konvolüsyonel mimarilerinden biri olup mobil ve gömülü sistemler için optimize edilmiştir. KYM bantlarında %97.96 test doğruluğu ve 0.9779 F1-skoru elde etmiştir. Sınıf bazlı performans incelendiğinde boş alan sınıfı için %96 kesinlik ve %99 duyarlılık, yabani ot sınıfı için %98 kesinlik ve 0.98 duyarlılık, ayçiçeği sınıfı için %98 kesinlik ve %96 duyarlılık değerleri görülmektedir. MobileNetV2, 1226 test görüntüsünden 25 tanesini yanlış sınıflandırarak %2.04 hata oranı göstermiştir. Dikkat çekici olan, MobileNetV2'nin yabani ot tespitinde ViT ile aynı başarıyı göstermesi ve %100 duyarlılık ile 518 yabani ot görüntüsünün tamamını doğru tespit etmesidir. Multispektral bantlarda ise MobileNetV2'nin performansı %97.33 doğruluk ve 0.9733 F1-skoru seviyesine gerilemiştir. Özellikle dikkat çekici olan, yabani ot sınıfındaki duyarlılık değerinin %95'e düşmesi ve 512 yabani ottan yaklaşık 26 tanesinin tespit edilememesidir. Bu, multispektral bantların MobileNetV2 gibi CNN tabanlı modellerde beklenen katkıyı sağlamadığını göstermektedir. MobileNetV2'nin derinlemesine konvolüsyon kullanması model boyutunu 70.35 MB'ye düşürmüş ve 217-218 görüntü/sn gibi en yüksek işleme hızını sağlamıştır. Ancak, ViT modellerine göre sınıflandırma doğruluğunda %1-2 puan düşüş gözlemlenmiştir.

NASNetMobile modeli KYM bantlarında %96.08 test doğruluğu ve 0.9584 F1-skoru elde ederek test edilen dört model arasında en düşük performansı göstermiştir. Sınıf bazlı metrikler boş alan için %96 kesinlik ve %98 duyarlılık, yabani ot için %96 kesinlik ve %97 duyarlılık, ayçiçeği için %96 kesinlik ve %93

duyarlılık şeklinde gerçekleşmiştir. NASNetMobile, 1226 test görüntüsünden 48 tanesini yanlış sınıflandırarak %3.92 hata oranı sergilemiştir. Yabani ot tespitinde %97 duyarlılık ile yaklaşık 16 yabani ot kaçırmış ve diğer modellerin belirgin şekilde altında kalmıştır. Multispektral bantlarda performans %95.83 doğruluk ve 0.9583 F1-skoru seviyesinde olmuş, 1536 test görüntüsünden 64 tanesini yanlış sınıflandırmıştır. Yabani ot sınıfında %93 recall ile 36 yabani ot görüntüsü tespit edilememiştir. NASNetMobile'ın model boyutu 207.88 MB olup, bu değer MobileNetV2'nin yaklaşık 3 katıdır ancak performans olarak MobileNetV2'yi geçememiştir. İşleme hızı 108.2 görüntü/sn seviyesinde kalmış ve ViT'e yakın bir hız göstermesine rağmen doğruluk açısından önemli ölçüde geride kalmıştır.

Dört modelin karşılaştırmalı analizi, önemli bulgular ortaya koymuştur. Vision Transformer mimarisi, hem KYM hem de multispektral bantlarda en yüksek sınıflandırma doğruluğunu elde etmiştir. Bu üstünlük, ViT'nin self-attention mekanizmasının bitkilerin uzamsal ve spektral özelliklerini global olarak öğrenme kapasitesinden kaynaklanmaktadır. CNN tabanlı modeller ise daha düşük doğruluk seviyelerinde kalmıştır. KYM bantlarında ViT'nin MobileNetV2'ye göre %1.22, NASNetMobile'a göre %3.10 puan üstünlüğü bulunmaktadır. Multispektral bantlarda bu fark daha da belirginleşmiş, ViT'nin MobileNetV2'ye göre %2.15 NASNetMobile'a göre %3.65 puan üstünlüğü ortaya çıkmıştır.

Öz dikkat mekanizmasının üstünlüğü, ayçiçeği-yabani ot ayrımında özellikle belirgindir. Erken gelişim döneminde bitkilerin morfolojik özellikleri henüz tam gelişmemiştir ve ayırt edici detaylar sınırlıdır. CNN'lerin lokal konvolüsyon işlemleri bu sınırlı detayları yakalamada zorlanabilirken ViT'nin global attention mekanizması tüm yamalar arasındaki ilişkileri değerlendirerek daha katı özellik temsilleri oluşturabilmektedir. Yabani ot yamaları ile komşu ayçiçeği yamaları arasındaki sıra düzeni yaprak yoğunluğu farkı ve renk geçişleri gibi bağlamsal bilgiler ViT tarafından etkili bir şekilde modellenebilmektedir. Hata analizi, tüm modellerde ayçiçeği-yabani ot karışıklığının dominant hata kaynağı olduğunu göstermiştir. ViT'in toplam 10 hatasının %60'ı (6 hata), MobileNetV2'nin 25 hatasının %56'sı (14 hata) ve NASNetMobile'ın 48 hatasının %33'ü (16 hata) ayçiçeğinden yabani ot yönündeki karışıklıklardan kaynaklanmaktadır.

Model karmaşıklığı ve hesaplama verimliliği açısından değerlendirme yapıldığında farklı uygulama senaryoları için farklı modellerin uygun olduğu görülmektedir.

ViT-Base en yüksek doğruluğu sağlarken en fazla parametreye (85.8 milyon) ve hesaplama gücüne ihtiyaç duymaktadır. Model boyutu 327 MB olup işleme hızı 86-102 görüntü/sn seviyesindedir. ViT Pruned doğruluktan ufak bir ödün vererek (%0.73) model boyutunu %50 azaltmış (164 MB) ve işleme hızını %87 artırmıştır (192.3 görüntü/sn). MobileNetV2, en düşük model boyutu (70.35 MB) ve en yüksek işleme hızı (217-218 görüntü/sn) ile gerçek zamanlı uygulamalar için uygun bir alternatif sunmaktadır. NASNetMobile ise ne doğruluk ne de verimlilik açısından rekabetçi bir konumda bulunmamaktadır. Reçete haritaları üretimi senaryoları için ViT-Base optimal seçimken gerçek zamanlı uygulamalar ve kaynak kısıtlı sistemler için ViT Pruned tercih edilebilir mobil cihazlar için ise uygundur.

Transfer öğreniminin etkisi tüm modellerde gözlemlenmiştir. ImageNet üzerinde ön eğitilmiş modeller ayçiçeği veri seti üzerinde ayarlama ile yüksek performans elde etmiştir. ViT modellerinin transfer öğrenimi kapasitesi özellikle güçlüdür. ImageNet'te öğrenilen global görsel temsiller ayçiçeği-yabani sınıflandırmasına etkili bir şekilde transfer edilmiştir. CNN modellerinde de transfer öğrenimi katkısı belirgindir ancak ViT kadar yüksek doğruluk seviyelerine ulaşılamamıştır. Genel olarak bu karşılaştırmalı çalışma ViT mimarisinin ayçiçeği-yabani ot sınıflandırmasında CNN tabanlı mimarilere göre üstünlüğünü somut verilerle kanıtlamış ve model budama tekniğinin minimal doğruluk kaybıyla önemli verimlilik kazanımları sağlayabileceğini göstermiştir.

8.2 Erken Dönem Yabani Ot Tespiti ve Önleyici Yönetim

Bu tezin en önemli bulgularından biri, erken gelişim döneminde yabani ot tespitinin başarıyla gerçekleştirilmesidir. Hem Uygulama 1 hem de Uygulama 2 erken dönemde gerçekleştirilmiş ve kritik yabani ot varlığı tespit edilmiştir. Uygulama 1'de %45.93, Uygulama 2'de %40.25 yabani ot yoğunluğu bulunmuştur. Her iki test alanında da ayçiçeği bitkileri henüz 3-4 yapraklı dönemde olup, %41.43 ve %19.00 alan kaplama oranlarına sahiptir. Erken dönem yabani ot tespitinin stratejik önemi bu çalışmada geliştirilen dört model ile somut olarak kanıtlanmıştır. Ayçiçeği tarımında V4-V8 fenolojik aşaması kritik periyot olarak tanımlanmaktadır ve bu dönemde yabani ot rekabeti ciddi verim kayıplarına yol açabilmektedir. Bu çalışmada yabani ot tespiti V3-V4 aşamasında yani kritik periyottan önce gerçekleştirilmiştir. Bu zamanlama önleyici bir müdahale stratejisi için ideal fırsat penceresi sunmaktadır. ViT modelinin erken dönemde gösterdiği performans bu

stratejinin teknik fizibilitesini kanıtlamaktadır. KYM bantlarında %100 yabani ot duyarlılık değeri ile 518 yabani ot görüntüsünün tamamı doğru tespit edilmiş ve hiçbir yabani ot kaçırılmamıştır. Multispektral bantlarda ise %99 duyarlılık ile sadece 1-2 yabani ot tahmini olarak kaçırılmıştır. Bu sonuçlar ViT'nin V3-V4 aşamasında küçük ve morfolojik olarak az belirgin bitkileri bile güvenilir şekilde sınıflandırabildiğini göstermektedir. Ortalama güven skorları Uygulama 1'de %82.66 ve 2. alanda %84.68 seviyesinde olup modelin tahminlerinde yüksek kesinlik gösterdiğini işaret etmektedir. Dikkat çekici bir bulgu MobileNetV2 modelinin de KYM bantlarında %100 yabani ot duyarlılık elde etmesidir. Bu hafif CNN mimarilerinin bile erken dönem yabani ot tespitinde başarılı olabileceğini göstermektedir. Ancak multispektral bantlara geçildiğinde MobileNetV2'nin duyarlılık değeri %95'e düşmüş ve 512 yabani ottan 26 tanesi kaçırılmıştır. Bu düşüş CNN tabanlı modellerin multispektral bantlardan beklendiği kadar faydalanmadığını ortaya koymaktadır. ViT Pruned modeli ise her iki bant kombinasyonunda da dengeli performans göstermiş. KYM'de %98.80, multispektralde %99 duyarlılık ile yüksek tespit başarısı sergilemiştir. NASNetMobile'ın performansı ise kritik seviyede kalmış; KYM'de %97 duyarlılık ile 16, multispektralde %93 recall ile 36 yabani ot kaçırmıştır. Tarımsal uygulamalar perspektifinden NASNetMobile'ın bu düzeydeki yanlış negatif oranı kabul edilebilir değildir.

Erken dönem müdahalenin başlıca avantajları bu çalışmada somut verilerle desteklenmiştir. Birincisi yabani otlar henüz küçük ve zayıf oldukları için herbisit etkinliği maksimum seviyededir. Bu çalışmada kullanılan erken dönem herbisit dozu 200 ml/dekar olarak varsayılmış olup geç dönem dozu (300-400 ml/dekar) ile karşılaştırıldığında %33-50 daha az herbisit gerektiği görülmektedir. İkincisi ayçiçeği bitkileri henüz yabani ot rekabetinden ciddi zarar görmemiştir. V3-V4 aşamasında ayçiçeği fideleri 10-15 cm yaprak rozeti çapına sahip olup yabani otlarla henüz yoğun rekabet başlatmamıştır. Bu aşamada müdahale edildiğinde ayçiçeği bitkileri V8-V10 aşamasında hızla büyüyerek tam kanopi oluşturabilmektedir. Üçüncüsü yabani ot tohumlarının olgunlaşması engellenmektedir. Erken dönemde elimine edilen yabani otlar tohum üretemez ve gelecek sezonlar için toprak tohum bankasını zenginleştirilmez. Dördüncüsü sezon boyunca gereken herbisit uygulama sayısı azalmaktadır. Erken dönemde başarılı bir

kontrol sezon boyunca 2-3 uygulama yerine 1-2 uygulamayla yeterli olabilmektedir.

Bu çalışmada her iki test alanında da %40-46 arasında yüksek yabani ot yoğunluğu tespit edilmiştir. Uygulama 1'de 2.5 dekarlık alanın 1.15 dekarında (4,593 yama), Uygulama 2'de 0.1 dekarlık alanın yaklaşık 0.04 dekarında yabani ot bulunmaktadır. Bu yoğunluk seviyeleri müdahale edilmezse kritik periyotta ciddi verim kayıplarına yol açabilecek düzeydedir. Ancak erken tespit sayesinde yabani otlar henüz küçükken müdahale fırsatı yakalanmıştır. Tüm modeller bu erken dönemde küçük bitkileri yüksek doğrulukla tespit edebilmiştir. ViT ve ViT Pruned modelleri yüksek çözünürlüklü görüntüleme (1 cm GSD) ve dönüştürücünün güçlü özellik çıkarma kapasitesi sayesinde neredeyse mükemmel performans sergilemiştir. Ayçiçeği bitkilerinin erken dönemde düşük alan kaplama oranlarının (%19-41) normal ve beklenen olmasıdır. V3-V4 aşamasında ayçiçeği bitkileri henüz küçük olduğu için yaprak alanı indeksi düşüktür ve tam toprak örtüsü oluşmamıştır. Bu çalışmada elde edilen %19-41 oranlar bu aralıkla uyumludur ve sağlıklı bir ekim kalitesini göstermektedir. ViT modeli ayçiçeği sınıfında KYM'de %98.27, multispektralde %98.83 doğruluk elde ederek bu küçük fideleri güvenilir şekilde tespit edebilmiştir. Kritik olan bu erken dönemde yabani otların tespit edilip kontrol edilerek ayçiçeği bitkilerinin ilerleyen aşamalarda hızla büyümesine ve tam kanopi oluşturmasına fırsat verilmesidir. Kritik periyottan önce tespit yaparak önleyici stratejinin fizibilitesini göstermiştir. Erken dönem tespiti gerçekleştiren nadir çalışmalardan Pérez-Ortiz ve arkadaşları (2016), mısır tarlasında V2-V3 aşamasında yabani ot tespiti yapmış ve %92 doğruluk elde etmiştir. Bu çalışmadaki %99.18-99.48 doğruluk değerleri literatürdeki en yüksek erken dönem tespit performanslarından biridir [142]. Ayrıca bu tez sadece bir model değil dört farklı model ile karşılaştırmalı analiz sunarak farklı uygulama senaryoları için optimal model seçimini desteklemektedir.

8.3 Tarlaya Özgü Yabani Ot Yönetimi ve Herbisit Tasarrufu

Bu tezin pratik tarımsal uygulamalara en önemli katkısı tarlaya özgü yabani ot yönetimi stratejisinin başarıyla gösterilmesi ve önemli herbisit tasarruflarının elde edilmesidir. Uygulama 1'de %54.07 herbisit tasarrufu, uygulama alanı 2'de %59.75 herbisit tasarrufu sağlanmıştır. Bu tasarruf oranları geleneksel tekdüze herbisit uygulamasına göre hesaplanmış olup sadece yabani ot tespit edilen bölgelere herbisit uygulanması prensibine dayanmaktadır. ViT modelinin neredeyse mükemmel yabani ot tespit performansı tarlaya özgü yaklaşımın teknik temelini sağlamaktadır.

Tarlaya özgü yaklaşımın ekonomik faydaları çok boyutludur. Birincisi doğrudan herbisit maliyeti tasarrufu bulunmaktadır. Uygulama 1'de tek uygulama için 27 TL, sezonluk (3 uygulama) 81 TL tasarruf sağlanmıştır. Küçük bir test alanı (2.5 dekar) için bile anlamlı olan bu tasarruf, büyük ölçekli üretimlerde çok daha önemli hale gelmektedir. Örneğin 100 dekarlık bir üretim alanında sezonluk tasarruf 3,240 TL civarında olabilir. 1000 dekarlık büyük ölçekli bir işletmede ise yıllık herbisit tasarrufu 32,400 TL'ye ulaşabilmektedir. Bu hesaplamalar erken dönem herbisit dozu (200 ml/dekar) ve 100 TL/L herbisit fiyatı varsayımlarına dayanmaktadır. Gerçek uygulamalarda, herbisit fiyatları ve dozajlar değişkenlik gösterebilir ancak sahaya özgü yaklaşımın ekonomik avantajı her senaryoda belirgindir.

İkincisi, işçilik ve yakıt maliyeti azalmaktadır. Püskürtme süresi %54-60 azaldığı için traktör veya İHA çalışma süresi kısalmakta ve operasyonel maliyetler düşmektedir. Uygulama 1'de 1.35 dekar alan herbisit uygulamasından muaf tutulmuştur. Bu püskürtme işleminin %54'ünün yapılmaması anlamına gelmektedir. Operatör saati yakıt tüketimi ve ekipman aşınması gibi dolaylı maliyetler de orantılı olarak azalmaktadır. Modern VRA (Variable Rate Application) püskürtücüler GPS koordinatları ile yönlendirildiği için sadece işaretlenmiş bölgelere herbisit uygulamakta ve gereksiz alanlarda püskürtücü kapatılmaktadır. Bu, hem zaman hem de kaynak tasarrufu sağlamaktadır.

Üçüncüsü ve en önemli ekonomik kazanç verim kaybının önlenmesidir. Erken dönemde etkili yabani ot kontrolü ile kritik periyotta (V4-V8) yabani ot rekabeti minimize edilmekte ve ayçiçeği bitkileri tam verim potansiyellerine ulaşabilmektedir. Bu çalışmada tespit edilen %40-46 yabani ot yoğunluğu,

müdahale edilmezse potansiyel olarak %25-35 verim kaybına yol açabilir. 2.5 dekarlık Uygulama 1 alanı için, ortalama 250 kg/dekar ayçiçeği verimi varsayıldığında toplam beklenen verim 625 kg'dır. %30 verim kaybı senaryosunda 187.5 kg üretim kaybı söz konusu olabilir. Ayçiçeği tohumu piyasa fiyatı 15-20 TL/kg aralığında olduğunda bu kayıp 2,812-3,750 TL ekonomik zarara karşılık gelmektedir. Sahaya özgü ilaçlama yönetimin erken dönem müdahale ile bu kaybın önlenmesi doğrudan herbisit tasarrufundan (81 TL/sezon) çok daha değerli bir ekonomik kazançtır. Büyük ölçekli işletmelerde bu dolaylı kazanç on binlerce TL'ye ulaşabilmektedir.

Çevresel perspektiften ilaçlama yaklaşımın faydaları daha da belirgindir. Uygulama 1'de 1,352 m² (1.35 dekar), Uygulama 2'de 59.75 m² (0.06 dekar) alanda herbisit kullanılmamıştır. Bu alanlar toprak ve su kaynaklarına karışabilecek kimyasal miktarını %54-60 oranında azaltmaktadır. Herbisitlerin toprak ve su kaynaklarına taşınması ciddi çevresel problemlere yol açabilmektedir. Çevresel raporlar tarımsal herbisitlerin su kaynaklarında sıklıkla tespit edildiğini ve ekolojik zararlar oluşturduğunu bildirmektedir. Yaklaşım bu riski minimize etmektedir. Uygulama 1'de korunan 1.35 dekar alanda, 270 ml herbisitin çevreye salınması engellenmiştir. Sezonluk bazda (3 uygulama) toplam 810 ml herbisitin toprak ve su sistemine girmesi önlenmiştir.

Herbisit uygulaması yalnızca zararlı yabani otları değil aynı zamanda faydalı böcekleri, polinatörleri ve diğer toprak canlılarını da etkileyebilir. Korunan alanlarda bu organizmaların yaşam alanları bozulmamakta ve biyolojik çeşitlilik korunmaktadır. Özellikle arılar ve diğer polinatörler için erken dönemde herbisit azaltması önemli bir koruma sağlamaktadır. Ayçiçeği ilerleyen dönemlerde çiçeklendiğinde polinatörlere önemli bir kaynak sağlamaktadır ve tarlaya özgü ilaçlama yaklaşımı ile bu polinatörlerin erken dönemde herbisit maruziyetinden korunması uzun vadeli fayda sağlamaktadır.

Önemli bir nokta bu yaklaşımın ekonomik fizibilitesidir. Hassas tarım teknolojileri ek yatırım gerektirmektedir. Temel bir sistem için başlangıç yatırımı 50,000-150,000 TL aralığında olabilir. Ancak, sağladığı tasarruf ve verim artışı bu yatırımı hızla geri dönebilmektedir. Örneğin, 100 dekarlık bir işletme için yıllık herbisit tasarrufu 3,240 TL, verim kaybının önlenmesinden dolayı kazanç ise 20,000-30,000 TL seviyesinde olabilir. Toplam yıllık fayda 23,000-33,000 TL civarında

olup, yatırım 2-5 yıl içinde geri dönebilmektedir. Özellikle büyük ölçekli üreticiler için ekonomik getirim çok daha belirgindir. Ayrıca, son yıllarda İHA ve sensör teknolojilerinin maliyetleri düşmekte olup, orta ve küçük ölçekli üreticiler için de erişilebilir hale gelmektedir. Kooperatif modelleri ile ekipman paylaşımı küçük üreticilerin de bu teknolojiden faydalanmasını sağlayabilir.

8.4 Multispektral Bantların Katkısı ve RGB ile Karşılaştırma

Bu tezde hem KYM hem de multispektral bantlar kullanılarak iki farklı uygulama gerçekleştirilmiş ve bant kombinasyonlarının sınıflandırma performansına etkisi sistematik olarak değerlendirilmiştir. Sonuçlar multispektral bantların KYM bantlarına göre marjinal bir performans iyileşmesi sağladığını göstermiştir. ViT modelinde KYM bantları %99.18 doğruluk elde ederken, multispektral bantlar %99.48 doğruluğa ulaşmıştır. Bu sadece %0.30 puanlık bir artış anlamına gelmektedir. F1-skoru açısından değerlendirildiğinde KYM'de 0.9927, multispektralde 0.9948 değerleri elde edilmiş ve fark 0.0021 seviyesinde kalmıştır. Test görüntüsü sayısı açısından bakıldığında KYM'de 1226 görüntüden 10 hata yapılırken multispektralde 1536 görüntüden 8 hata yapılmıştır. Oransal olarak multispektral bantların hata oranını %0.82'den %0.52'ye düşürdüğü görülmektedir ancak bu düşüş pratik anlamda çok küçük bir iyileşmedir.

Diğer modellerde de benzer bir trend gözlemlenmiştir. ViT Pruned modelinde KYM bantları %98.45 doğruluk multispektral bantlar %98.75 doğruluk elde etmiştir. Fark %0.30 puan olup ViT ile aynı seviyededir. MobileNetV2'de ise, KYM bantları %97.96 doğruluk multispektral bantlar %97.33 doğruluk göstermiştir. Bu sonuç şaşırtıcıdır çünkü multispektral bantların performansı artırmak yerine %0.63 puan düşürmüştür. NASNetMobile'da da benzer bir durum gözlemlenmiş. KYM bantlarında %96.08, multispektral bantlarda %95.83 ile %0.25 puan düşüş yaşanmıştır. Bu bulgular CNN tabanlı mimarilerin multispektral bantlardan beklenen katkıyı sağlayamadığını hatta bazı durumlarda olumsuz etkilendiğini göstermektedir. Transformer tabanlı mimariler multispektral bantlardan marjinal olumlu katkı alırken CNN tabanlı mimariler olumsuz etki göstermiştir.

RGB bantlarının yeterliliği sınıflar arası morfolojik ve renk farklılıklarının belirgin olmasıyla açıklanabilir. Ayçiçeği bitkileri koyu yeşil geniş yapraklara sahipken,

yabani otlar genellikle daha açık yeşil ve daha küçük yapraklara sahiptir. Boş alanlar ise kahverengi-gri toprak rengi göstermektedir. Bu farklılıklar KYM bantlarında kolaylıkla ayırt edilebilmektedir. Vision Transformer'ın güçlü özellik çıkarma kapasitesi KYM bantlarından yeterli spektral ve uzamsal bilgiyi öğrenebilmiş ve yüksek doğruluk elde edebilmiştir. Erken gelişim döneminde bitkilerin yaprak dokusu, renk tonu ve sıra düzeni gibi görsel özellikler KYM bantlarında belirgindir. ViT'nin öz dikkat mekanizması bu özellikleri global bağlamda değerlendirerek sağlam bir sınıflandırma gerçekleştirmiştir.

Bununla birlikte multispektral bantların belirli avantajları ve katkıları bulunmaktadır. En önemli katkı yabani ot tespitinde gözlemlenmiştir. ViT modelinin yabani ot duyarlılık değeri, KYM'de %100 iken multispektralde %99 seviyesinde kalmıştır ancak bu minimal bir düşüş olup 518 yabani otun tamamı tespit edilirken 512 yabani ottan tahmini 1-2 tanesi kaçırılmıştır. Daha önemli olan multispektral bantların model güven skorunu artırmasıdır. Ortalama güven skoru KYM'de %82.66 iken multispektralde %84.68'e yükselmiştir. Modelin tahminlerinde %2.02 daha emin olduğu anlamına gelmektedir. Düşük güven skorlu yamaların oranı da azalmıştır. KYM'de %17 civarında olan <0.7 güven skorlu yama tespit oranı multispektralde %15'e düşmüştür. Bu multispektral bantların özellikle belirsiz sınıflandırma durumlarında ek bilgi sağladığını göstermektedir.

NIR bandının katkısı bitki-toprak ayrımında belirgindir. Sağlıklı bitki dokusu NIR bölgesinde yüksek yansıma gösterirken (%40-50), toprak düşük yansıma göstermektedir. Bu kontrast, özellikle erken dönemde küçük bitkilerin topraktan ayrılmasını kolaylaştırmaktadır. Boş alan sınıfının sınıflandırma performansında multispektral bantların katkısı gözlemlenmiştir. ViT modelinde Bare sınıfının precision değeri KYM'de %100 multispektralde %99 olarak gerçekleşmiş ve benzer performans sergilenmiştir. Ancak, duyarlılık değerlerinde KYM %99, multispektral %100 ile multispektralde küçük bir iyileşme vardır. NIR bandının boş alan yamalarının tamamını tespit etmede %1 puan katkı sağladığını göstermektedir. ViT Pruned ve MobileNetV2 modellerinde de boş alan sınıfı için benzer trend gözlemlenmiştir.

RedEdge bandı, klorofil absorpsiyon kenarında (680-730 nm) hassas ölçümler yaparak farklı bitki türleri arasındaki klorofil içeriği farklılıklarını ortaya çıkarmaktadır. Ayçiçeği ve farklı yabani ot türleri arasındaki klorofil imzası

farklılıkları RedEdge bandında belirgin olabilir. Yabani ot sınıfının kesinlik değerlerinde multispektral bantların katkısı gözlemlenmiştir. ViT modelinde yabani ot kesinliği KYM'de %99, multispektralde %100'e yükselmiştir. Yanlış pozitif oranının azaldığı anlamına gelmektedir. KYM'de 3 ayçiçeği görüntüsü yanlışlıkla yabani ot olarak sınıflandırılırken multispektralde bu sayı azalmıştır. RedEdge bandının sağladığı ek spektral bilgi ayçiçeği-yabani ot ayrımında kesinliği artırmıştır. Ayçiçeği sınıfında da benzer bir katkı gözlemlenmiş ViT modelinde ayçiçeği kesinliği KYM'de %99, multispektralde %100'e yükselmiştir.

Ancak bu katkılar CNN modellerinde gözlemlenmemiştir. MobileNetV2'nin yabani ot duyarlılık değeri KYM'de %100 iken multispektralde %95'e düşmüştür. 518 yabani otun tamamı KYM'de tespit edilirken multispektralde 512 yabani ottan 26 tanesi kaçırılmıştır. Bu %5'lik bir performans kaybıdır ve tarımsal uygulamalar açısından kritik bir sorundur. NASNetMobile'da da benzer bir düşüş gözlemlenmiştir. Yabani ot duyarlılık KYM'de %97 multispektralde %93'e gerilemiştir.

Transformer tabanlı mimarilerin multispektral bantlardan daha iyi faydalanmasının nedeni öz dikkat mekanizmasının esnekliğidir. Öz dikkat girdi kanalları arasındaki ilişkileri dinamik olarak öğrenebilmekte ve farklı spektral bantların kombinasyonunu etkili bir şekilde modelleyebilmektedir. CNN'lerin sabit konvolüsyon filtreleri yerine ViT'nin dinamik dikkat ağırlıkları multispektral bantların sağladığı ek bilgiyi daha iyi entegre edebilmektedir. Bu esneklik multispektral bantlardan olumlu katkı alınmasını sağlamıştır.

Literatürle karşılaştırıldığında multispektral bantların yabani ot tespitindeki rolü tartışmalıdır. Bazı çalışmalar multispektral bantların önemli iyileşmeler sağladığını bildirmektedir. Rasmussen ve arkadaşları (2013), mısır-yabani ot ayrımında NIR bandının %15 doğruluk artışı sağladığını rapor etmiştir. Huang ve diğerleri (2018), RedEdge bandının bitki stres tespitinde kritik olduğunu bulmuştur. Ancak diğer çalışmalar KYM bantlarının yeterli olduğunu göstermiştir. Sa ve diğerleri (2018), şeker pancarı tarlasında ile %98 doğruluk elde etmiş ve multispektral bantların marjinal katkı sağladığını bildirmiştir [143]. Bu tezin bulguları ikinci grup ile uyumludur KYM bantları ayçiçeği-yabani ot-boş alan sınıflandırması için yeterlidir ve multispektral bantlar iyileşme sağlar ancak dramatik bir fark yaratmamaktadır.

Maliyet-fayda dengesi açısından değerlendirme yapıldığında KYM ve multispektral bantlar arasında önemli bir farklılık bulunmaktadır. KYM kameralar multispektral kameralara göre çok daha ucuzdur ve yaygın olarak bulunabilir. Temel bir KYM İHA kamerası 5,000-15,000 TL aralığında iken multispektral kameralar 50,000-150,000 TL seviyesindedir. Multispektral ekipman maliyeti 10 kat daha yüksektir. Bu çalışmada elde edilen %0.30 puanlık performans artışı göz önüne alındığında multispektral yatırımın ekonomik gerekçesi zayıftır. Küçük ve orta ölçekli işletmeler için, KYM tabanlı sistemler maliyet-etkin bir seçimdir. %99.18 doğruluk ve %100 yabani ot duyarlılık ile KYM bantları pratik uygulamalar için yeterli performans sağlamaktadır.

Ancak multispektral bantların belirli koşullarda avantajlı olabileceği unutulmamalıdır. Bu tezde heterojen bir yabani ot sınıfı kullanılmıştır ve farklı yabani ot türleri tek bir sınıfta toplanmıştır. Tür bazlı yabani ot sınıflandırması yapılırsa multispektral bantların katkısı daha belirgin olabilir. Farklı yabani ot türlerinin klorofil içerikleri yaprak su içerikleri ve spektral imzaları farklıdır ve bu farklılıklar NIR ve RedEdge bantlarında daha net görünebilir. Ayrıca bitki stres seviyelerinin belirlenmesinde multispektral bantlar kritik öneme sahiptir. Bu çalışmada sağlıklı bitkiler üzerinde çalışıldığı için stres tespiti değerlendirilmemiştir. Gelecek çalışmalarda stresli bitki koşullarında multispektral bantların katkısı daha yüksek olabilir.

Sonuç olarak bu çalışma RGB bantlarının ayçiçeği-yabani ot-boş alan sınıflandırması için yeterli ve maliyet-etkin olduğunu göstermiştir. Multispektral bantlar ViT gibi gelişmiş mimarilerde marjinal katkı sağlamış ancak CNN modellerinde olumsuz etki göstermiştir. Pratik öneriler açısından küçük-orta ölçekli işletmeler KYM tabanlı sistemleri tercih etmeli büyük ölçekli ve araştırma odaklı uygulamalar için multispektral sistemler değerlendirilebilir. Gelecek çalışmalarda, tür bazlı yabani ot sınıflandırması, bitki stres tespiti ve farklı fenolojik dönemlerde multispektral bantların katkısı araştırılmalıdır.

8.5 Dönüştürücü Mimarinin Üstünlüğü ve CNN ile Karşılaştırma

Dönüştürücü mimarisi ayçiçeği-yabani ot-boş alan sınıflandırmasında CNN tabanlı mimarilere göre belirgin bir üstünlük göstermiştir. KYM bantlarında, ViT %99.18 doğruluk elde ederken, MobileNetV2 %97.96 ve NASNetMobile %96.08 doğruluk

sergilemiştir. ViT'nin MobileNetV2'ye göre %1.22, NASNetMobile'a göre %3.10 puanlık üstünlüğü bulunmaktadır. Multispektral bantlarda bu fark daha da belirginleşmiş. ViT %99.48 doğruluk elde ederken MobileNetV2 %97.33 ve NASNetMobile %95.83 ile geride kalmıştır. ViT'nin multispektralde MobileNetV2'ye göre %2.15, NASNetMobile'a göre %3.65 puanlık üstünlüğü transformer mimarisinin spektral bilgiyi daha etkili kullandığını göstermektedir.

F1-skoru metriği açısından değerlendirildiğinde ViT'nin dengeli performansı öne çıkmaktadır. KYM bantlarında ViT 0.9927 F1-skoru ile neredeyse mükemmel bir dengeli performans sergilerken MobileNetV2 0.9779 ve NASNetMobile 0.9584 ile daha düşük seviyede kalmıştır. Multispektral bantlarda ViT 0.9948'e yükselirken, MobileNetV2 0.9733 ve NASNetMobile 0.9583 seviyesinde gerçekleşmiştir. F1-skoru, kesinlik ve duyarlılık harmonik ortalaması olduğu için ViT'nin hem yanlış pozitif hem yanlış negatif oranlarını minimize ettiğini göstermektedir. CNN modelleri ise özellikle belirli sınıflarda dengesiz performans göstermiş ve F1-skorları düşmüştür.

Hata sayıları açısından karşılaştırmada ViT'nin üstünlüğünü daha somut hale getirmektedir. KYM bantlarında 1226 test görüntüsünden ViT sadece 10 hata yapmışken MobileNetV2 25 ve NASNetMobile 48 hata yapmıştır. ViT'nin hata oranı %0.82 seviyesinde kalırken MobileNetV2 %2.04 ve NASNetMobile %3.92 hata oranı göstermiştir. NASNetMobile'ın hata sayısı ViT'nin 4.8 katıdır. Multispektral bantlarda 1536 test görüntüsünden ViT 8 hata yapmışken MobileNetV2 41 ve NASNetMobile 64 hata yapmıştır. NASNetMobile'ın multispektralde hata sayısı ViT'nin 8 katına ulaşmıştır. Bu mutlak sayılar transformer tabanlı ve CNN tabanlı mimariler arasındaki performans farkının ne kadar belirgin olduğunu göstermektedir.

ViT'in üstünlüğü birkaç temel faktörle açıklanabilir. Birincisi öz dikkat mekanizması görüntünün tüm bölgeleri arasındaki uzun mesafe ilişkilerini global olarak modelleyebilmektedir. CNN'lerde, konvolüsyon işlemleri lokal bölgelere odaklanmakta ve geniş alan ilişkilerini yakalamak için derin ağlar gerekmektedir. Bir CNN'de piksel seviyesinde lokal özellikler önce çıkarılır sonra bu özellikler daha derin katmanlarda birleştirilerek global temsiller oluşturulur. Bu süreç birçok katman gerektirir ve bilgi kaybına yol açabilir. ViT'de ise öz dikkat mekanizması

bir adımda tüm yamalar arasındaki ilişkileri hesaplayabilmektedir. Her yama diğer tüm yamalar doğrudan etkileşime girer ve global bağlam öğrenilir.

Ayçiçeği-yabani ot sınıflandırmasında global bağlam özellikle önemlidir. Erken gelişim döneminde tek bir yama içindeki bilgi sınırlıdır çünkü bitkiler küçüktür. Bir yama bitkinin sadece küçük bir kısmını görebilir. Ancak komşu yamalarla birlikte değerlendirildiğinde bitkinin genel yapısı, sıra düzeni ve bitki yoğunluğu gibi özellikleri anlaşılabilir. ViT'nin öz dikkat mekanizması bu global yapıyı etkili bir şekilde öğrenmiştir. Örneğin bir ayçiçeği yaması komşu yamalar da ayçiçeği görünüyorsa ve düzenli bir sıra yapısı oluşuyorsa model bu bağlamsal bilgiyi kullanarak daha güvenli bir sınıflandırma yapabilir. CNN'ler ise lokal özellik çıkarımında güçlüdür ancak bu global bağlamı yakalamakta zorlanır.

İkincisi ViT'nin yama tabanlı yaklaşımı farklı boyutlardaki görüntülere uyum sağlama esnekliği sunmaktadır. Bu çalışmada, 50×50 piksel yamalar kullanılmış ve büyük ortofoto görüntüleri (5000×5000 piksel) yamalara ayrılarak işlenmiştir. ViT yama sayısını değiştirerek farklı boyutlardaki görüntüleri kolaylıkla işleyebilir. Konumsal kodlama ile yamaların konumsal bilgisi korunur ve öz dikkat tüm yama üzerinde çalışır. CNN'lerde ise giriş boyutu genellikle sabittir ve büyük görüntüler için yeniden boyutlandırma veya kayan pencere yaklaşımları gerekmektedir. Yeniden boyutlandırma detay kaybına yol açarken kayan pencere hesaplama maliyetini artırır ve yamalar arası ilişkileri tam olarak modelleyemez. ViT'nin esnekliği hem hesaplama verimliliği hem de sınıflandırma doğruluğu açısından avantaj sağlamıştır.

Üçüncüsü ViT'nin transfer öğrenimi kapasitesi güçlüdür. Bu çalışmada ImageNet üzerinde ön eğitilmiş ViT modeli kullanılmış ve ayçiçeği veri seti üzerinde ayarlama yapılmıştır. ImageNet 1.4 milyon görüntü ve 1000 sınıf içeren büyük bir veri setidir ve modeller bu veri setinde genel görsel özellikleri öğrenmektedir. ViT'in ImageNet'te öğrendiği genel görsel temsiller ayçiçeği-yabani ot sınıflandırmasına başarıyla transfer edilmiştir. İnce ayarlama süreci son katmanların yeniden eğitilmesi ve tüm modelin ince ayar yapılması şeklinde gerçekleşmiştir. Sadece 10 epokluk ayarlama ile %99.18-99.48 doğruluk elde edilmiş bu transfer öğrenimi etkinliğini kanıtlamıştır. CNN modelleri de ImageNet üzerinde önceden eğitilmiş ancak ViT kadar yüksek transfer öğrenimi başarısı

gösterememiştir. Bu durum transformer mimarisinin genel görsel temsilleri daha özünü çıkartımı ve transfer edilebilir bir şekilde öğrendiğini düşündürmektedir.

8.6 Yama Bazlı Yaklaşımın Avantajları ve Sınırlamaları

Büyük ortofoto görüntüleri yama bazlı bölümleme yaklaşımı ile işlenmiştir. Görüntüler 50×50 piksel yamalara ayrılmış ve her yama bağımsız olarak sınıflandırılmıştır. Bu yaklaşım hem hesaplama verimliliği hem de sınıflandırma doğruluğu açısından önemli avantajlar sağlamış ancak bazı sınırlamalar da beraberinde getirmiştir. Yama boyutunun seçimi erken gelişim dönemindeki bitki boyutları ile uyumlu olacak şekilde optimize edilmiştir. 1 cm GSD ile çekilmiş görüntülerde, 50×50 piksel yama 50 cm × 50 cm fiziksel alana ve 0.25 m² bölgeye karşılık gelmektedir. Bu boyut, tek bir ayçiçeği veya yabani ot bitkisini kapsayacak yeterli alana sahipken aynı zamanda yeterli bağlamsal bilgiyi içermektedir.

Yama bazlı yaklaşımın başlıca avantajları vardır. Büyük görüntülerin işlenmesine olanak tanımaktadır. Ortofoto görüntüleri genellikle binlerce piksel boyutundadır. Uygulama 1'de 5000×5000 piksel görüntü kullanılmıştır. Tüm görüntüyü bir kerede modele girdi olarak vermek hem hesaplama hem bellek açısından zorlayıcıdır. Dönüştürücü için 5000×5000 piksel görüntü direk işlenmek istenirse (5000/16)×(5000/16) = 312×312 = 97,344 yama oluşur ve öz dikkat mekanizması $97{,}344^2$ = 9.5 milyar dikkat hesaplaması gerektirir. Bu mevcut GPU'larda bellek yetersizliğine ve çok uzun işleme süresine yol açar. Yamalara ayırma görüntüyü yönetilebilir parçalara bölmekte ve paralel işleme olanak sağlamaktadır. 50×50 piksel yamalar ViTmodelinin giriş boyutuna (224×224) uygun hale getirmek için yeniden boyutlandırılmış ve her yama bağımsız olarak işlenmiştir. 10,000 yama sırayla veya yığın halinde işlenerek tüm görüntü yaklaşık 52 saniyede sınıflandırılmıştır.

İkincisi lokal detayların korunmasını sağlamaktadır. Her yama 0.25 m² gibi küçük bir fiziksel alanı temsil etmektedir. Bu, bitki seviyesinde detaylı sınıflandırma yapılmasına olanak tanımaktadır. Tüm görüntünün küçültülmesi durumunda (örn: 5000×5000'den 224×224'e resize) ince detaylar kaybolabilir ve küçük yabani otlar tespit edilemeyebilir. 50 cm × 50 cm yama boyutu erken dönemde 10-15 cm çapındaki bir ayçiçeği fide veya yabani ot bitkisini net bir şekilde göstermektedir. Model yaprak dokusu renk tonu ve yaprak şekli gibi detaylı özellikleri bu

çözünürlükte öğrenebilmektedir. Uygulama 1'de elde edilen %99.18 doğruluk ve %100 yabani ot geri getirme değeri yama boyutunun optimal olduğunu göstermektedir.

Üçüncüsü herbisit reçete haritası oluşturma için uygun bir çözünürlük sunmaktadır. Her yama herbisit uygulaması için bir karar birimi olarak kullanılabilir. Modern VRA püskürtücüler GPS koordinatları ile yönlendirilmekte ve tipik olarak 0.5-1 m^2 hassasiyetle herbisit uygulayabilmektedir. 0.25 m^2 yama boyutu VRA sistemlerinin hassasiyetiyle uyumludur ve pratik herbisit uygulamasına doğrudan çevrilebilir. Uygulama 1'de, 10,000 yamadan 4,593 tanesi yabani ot olarak sınıflandırılmış ve bu yamaların GPS koordinatları herbisit reçete haritasına aktarılmıştır. VRA püskürtücü bu koordinatlara ulaştığında herbisit püskürtmeyi aktive etmekte diğer bölgelerde ise kapalı tutmaktadır. Bu seviyedeki hassasiyet %54-60 herbisit tasarrufu sağlamıştır.

Dördüncüsü eğitim veri seti oluşturma sürecini kolaylaştırmaktadır. Etiketleme yama seviyesinde yapıldığı için, büyük görüntülerin piksel-piksel (semantic segmentation tarzı) etiketlenmesine gerek yoktur. Her 50×50 piksel yama için dominant sınıf belirlenmiş ve etiket atanmıştır. Bu veri hazırlama süresini önemli ölçüde azaltmaktadır. Piksel seviyesi etiketleme her pikselin sınıfının manuel olarak işaretlenmesini gerektirir ve bu çok zaman alıcıdır. Yama seviyesi etiketleme ise görsel olarak yamaların çoğunluğunu kaplayan sınıfın seçilmesiyle yapılabilir ve bu çok daha hızlıdır. Uygulama 1 için 1226 yama uygulama 2 için 1536 yama klasörlenerek etiketlenmiştir. Bu süreç deneyimli bir operatör tarafından birkaç saat içinde tamamlanabilmektedir.

Ancak yama bazlı yaklaşımın bazı sınırlamaları da bulunmaktadır. Birincisi yama sınırlarındaki bitkilerin sınıflandırılması problemlidir. Bir bitki iki veya daha fazla yama arasında konumlanmışsa hangi yamaya atanacağı belirsizdir. Örneğin bir ayçiçeği bitkisi yama sınırında bulunuyorsa, bitkinin sol yarısı bir yamada sağ yarısı başka bir yamada görünür. Her yama bağımsız olarak sınıflandırıldığı için bir yama ayçiçeği diğer yama boş alan veya yabani ot olarak sınıflandırılabilir. Bu durum sınır bölgelerinde hatalara yol açabilir. Bu çalışmada örtüşmeyen yama yaklaşımı kullanıldığı için (atlama = yama boyutu = 50 piksel) sınır bitkileri bazen yanlış sınıflandırılmıştır. Hata analizinde ayçiçeği-yabani karışıklıklarının bir kısmının sınır yamalarında kaynaklanmış olabileceği düşünülmektedir.

Örtüşen yama yaklaşımı (atlama < yama boyutu) bu problemi azaltabilir. Örneğin, 50×50 piksel yama boyutu ile 25 piksel atlama kullanılırsa yamalar %50 örtüşme gösterir ve her bölge iki farklı yama tarafından görülür. Bu sınır bölgelerindeki bitkilerin daha güvenilir sınıflandırılmasını sağlar çünkü bir bitkinin tamamı en az bir yama içinde görünür. Ancak örtüşme yaklaşımı hesaplama maliyetini artırır. 5000×5000 piksel görüntü için atlama=50 ile 100×100 = 10,000 yama oluşurken, atlama=25 ile 200×200 = 40,000 yama oluşur. İşleme süresi 4 katına çıkar. Bu çalışmada hesaplama verimliliği önceliklendiği için bindirme yaklaşım tercih edilmiş ancak gelecek çalışmalarda bindirme yaklaşımın etkisi araştırılabilir.

İkincisi yama içinde birden fazla sınıf bulunabilir (karma yamalar). Erken gelişim döneminde bitki yoğunluğu düşük olduğu için bir yama içinde hem ayçiçeği hem yabani ot bitkileri bulunabilir. Örneğin, yamanın %60'ı ayçiçeği, %30'u yabani ot, %10'u boş alan olabilir. Bu durumda yamanın hangi sınıfa atanacağı belirsizdir. Bu çalışmada dominant sınıf prensibi kullanılmış yani yamanın çoğunluğunu kaplayan sınıf seçilmiştir. Yukarıdaki örnekte yama ayçiçeği olarak etiketlenmiştir çünkü %60 ayçiçeğidir. Ancak bu yaklaşım bazı bilgi kaybına yol açabilir. Yama içindeki %30 yabani ot tespit edilemez ve herbisit reçete haritasında bu bölge korunacak alan olarak işaretlenir. Bu yanlış negatif hatasına yol açar ve bazı yabanilerin kaçırılmasına neden olabilir.

Tezde elde edilen yüksek doğruluk değerlerinin (%99.18-99.48) birden fazla metodolojik ve bağlamsal açıklaması bulunmaktadır. Her şeyden önce çalışmada kullanılan 50×50 piksellik yama boyutu 1 cm GSD çözünürlüklü görüntülerle birleştiğinde her yama 0.5×0.5 metrelik fiziksel bir alanı temsil etmekte ve bu ölçek erken dönem bitkilerin net biçimde ayrışmasına olanak tanımaktadır. Düşük irtifadan elde edilen yüksek çözünürlüklü görüntüler sınıflar arasındaki görsel farkları belirginleştirerek sınıflandırma görevini kolaylaştırmaktadır.

İkinci önemli etken ImageNet üzerinde ön eğitilmiş görüntü dönüştürücü modelinin transfer learning yöntemiyle ince ayara tabi tutulmasıdır. Bu yaklaşım modelin genel görsel örüntüleri sıfırdan öğrenmek zorunda kalmaksızın ayçiçeği, yabani ot ve boş alan ayrımına odaklanmasını sağlamış ve sınırlı veri setiyle bile yüksek performansa ulaşılmasını mümkün kılmıştır. Hiperparametre optimizasyonu ile gerçekleştirilen hiperparametre ayarı da modelin veri setine en uygun konfigürasyonla eğitilmesine katkı sağlamıştır.

Bununla birlikte yüksek doğruluk değerlerinin kısmen metodolojik bir sınırlılıktan kaynaklanıyor olabileceği de göz ardı edilemez. Yama bazlı rastgele veri bölme yaklaşımında aynı bitkiye ait komşu yamaların hem eğitim hem test setine dağılmış olması, modelin sınıflar arası gerçek ayırt edici özellikleri öğrenmek yerine bitkiye özgü doku ve renk örüntülerini kısmen ezberlemiş olabileceğine işaret etmektedir. Bu durum veri sızıntısı olarak tanımlanmakta ve raporlanan performans değerlerinin gerçek saha koşullarındaki genelleme başarısını bir ölçüde aşıyor olabileceği anlamına gelmektedir. İki bağımsız test alanının kullanılması bu riski azaltmış olmakla birlikte gelecek çalışmalarda bitki bazlı çapraz doğrulama yöntemiyle bu sınırlılığın tamamen giderilmesi önerilmektedir.

Alternatif olarak çoklu etiket sınıflandırma yaklaşımı kullanılabilir. Her yama için içerdiği tüm sınıflar etiketlenebilir ve model her sınıfın varlığını bağımsız olarak tahmin edebilir. Bu yaklaşım karma yamaların daha doğru temsil eder ve herbisit reçete haritasında daha hassas kararlar verilmesini sağlar. Ancak çoklu etiket yaklaşım eğitim sürecini karmaşıklaştırır ve etiketleme işini zorlaştırır. Operatör her yamanın için hangi sınıfların bulunduğunu ve her sınıfın ne kadar alan kapladığını belirlemeli ve bu detaylı etiketleme zaman alıcıdır. Bu çalışmada basitlik ve hız önceliklendiği için tekli etiket yaklaşım kullanılmış ancak gelecek çalışmalarda çoklu yaklaşımın performansa etkisi araştırılabilir.

Üçüncüsü yama boyutunun seçimi kritiktir. Çok küçük yamalar bağlamsal bilgiyi kaybedebilir. Çok büyük yamalar lokal detayları kaçırabilir. Bu çalışmada 50×50 piksel (0.5×0.5 m) seçilmiş ve bu boyut ayçiçeği bitkilerinin erken dönem boyutlarıyla (10-15 cm) uyumludur. 50 cm × 50 cm yama bir ayçiçeği fide ve çevresindeki bağlamı (komşu bitkiler, sıra aralığı) görmek için yeterlidir. Ancak farklı ürünler veya farklı gelişim dönemleri için optimal yama boyutu değişebilir. Örneğin mısır tarımında bitki boyu 2-3 metre olabilir ve 50 cm yama çok küçük kalabilir. Tam kanopi döneminde bitki yoğunluğu çok yüksektir ve 50 cm yama birden fazla bitkiyi içerebilir.

Literatürde yama boyutu seçimi üzerine sınırlı sayıda çalışma bulunmaktadır. Potena ve arkadaşları (2021), 96×96 piksel ile en iyi sonucu elde etmiştir [144]. Bu tezde 50×50 piksel boyutu literatürdeki önerilerle uyumludur ve erken dönem ayçiçeği-yabani ot tespiti için uygun bulunmuştur. Gelecek çalışmalarda farklı yama boyutlarının performansa etkisi sistematik olarak araştırılabilir. Çok ölçekli

yama yaklaşımı da değerlendirilebilir. Küçük yamalar lokal detayları büyük yamalar global bağlamı öğrenir ve sonuçlar birleştirilir.

Dördüncüsü yamalar arası uzamsal ilişkiler tam olarak modellenmemiştir. Her yama bağımsız olarak sınıflandırıldığı için komşu yamalar arasındaki uzamsal düzen modelin öğrenmesinde doğrudan yer almaz. Örneğin ayçiçeği tarımında sıralar düzenli mesafelerle (70-75 cm) ayrılmıştır ve bu düzenli doku bir önemli bağlamsal bilgidir. Bir yama ayçiçeği ise ve komşu yamalar da ayçiçeği ise bu düzenli bir sıra yapısını gösterir. Ancak mevcut yaklaşımda her yama izole olarak değerlendirilmekte ve bu uzamsal doku direkt kullanılmamaktadır. Öz dikkat mekanizması bir dereceye kadar bu ilişkileri öğrenebilir ancak yamalar ayrı ayrı modele girdikleri için tam global uzamsal düzen kavranmaz.

50×50 piksel yama boyutu hem hesaplama verimliliği hem sınıflandırma doğruluğu açısından optimal bir denge sağlamıştır. %99.18-99.48 genel doğruluk ve %99-100 yabani ot duyarlılık yama yaklaşımının etkinliğini kanıtlamaktadır. Sınırlamalar bulunmasına rağmen bu sorunlar gelecek çalışmalarda bindirme yamaları ve çoklu etiket sınıflandırma gibi tekniklerle iyileştirilebilir. Pratik herbisit reçete haritası oluşturma ve VRA sistemlerine entegrasyon açısından yama bazlı yaklaşım uygun ve kullanılabilir bir metodoloji sunmaktadır.

8.7 Model Genelleştirme Kapasitesi ve Güvenilirlik

Derin öğrenme modellerinin pratik tarımsal uygulamalarda kullanılabilmesi için yüksek genelleştirme kapasitesine sahip olmaları gerekmektedir. Genelleştirme modelin eğitim sırasında görmediği yeni veri üzerinde de yüksek performans sergilemesi anlamına gelmektedir. Bu tezde modellerin genelleştirme kapasitesi eğitim-değerlendirme-test ayrımı çapraz doğrulama ve çeşitli değerlendirme metrikleri ile sistematik olarak değerlendirilmiştir. Veri setleri rastgele bölünme ile eğitim (%70), değerlendirme (%15) ve test (%15) setlerine ayrılmış ve modeller hiçbir zaman test verisini görmeden eğitilmiştir. Bu yaklaşım modellerin gerçek dünya performansının tarafsız olarak ölçülmesini sağlamaktadır.

KYM bantlarında test setinde %99.18 doğruluk elde ederken değerlendirme setinde de benzer performans (%99.15-99.20 aralığında) göstermiştir. Eğitim-test doğruluk farkı %0.50'den küçük olup bu modelin aşırı öğrenme yapmadığını net bir şekilde

göstermektedir. Aşırı öğrenme durumunda eğitim doğruluğu çok yüksek (örn: %99.9) ancak test doğruluğu düşük (örn: %95) olur. ViT'de ise eğitim ve test performansı neredeyse aynı seviyededir. Multispektral bantlarda da benzer trend gözlemlenmiş. Test doğruluğu %99.48 değerlendirme doğruluğu %99.45-99.50 aralığında gerçekleşmiştir. Bu tutarlılık modelin yeni verilere iyi genelleştirebildiğini ve öğrendiği özelliklerin robust olduğunu kanıtlamaktadır.

ViT Pruned modelinde de dengeli genelleştirme gözlemlenmiştir. KYM'de test %98.45, değerlendirme %98.40-98.50, multispektralde test %98.75, değerlendirme %98.70-98.80 doğruluk değerleri elde edilmiştir. Budama işleminin model kapasitesini %50 azaltmasına rağmen genelleştirme kapasitesi korunmuştur. Bu budanan ağırlıkların gereksiz olduğunu ve asıl bilgiyi taşıyan ağırlıkların korunduğunu göstermektedir. Budama sonrası model aşırı öğrenme riski azalmış ve daha sağlam hale gelmiştir. Eğitim-test farkı ViT Pruned'da da %0.50'nin altında kalmış ve sağlıklı genelleştirme sergilenmiştir.

MobileNetV2 ve NASNetMobile modellerinde ise genelleştirme kapasitesi daha düşük seviyede kalmıştır. MobileNetV2'de KYM test doğruluğu %97.96, değerlendirme %97.90-98.00 aralığındadır. Multispektralde test %97.33 değerlendirme %97.25-97.40'dır. Eğitim-test farkı %1-1.5 aralığında olup bu kabul edilebilir seviyededir ancak ViT'den daha yüksektir. NASNetMobile'da eğitim-test farkı daha da belirgin olmuştur.

Model güvenilirliği güven skoru analizi ile detaylı olarak değerlendirilmiştir. Güven skoru modelin bir tahmin için ne kadar emin olduğunu 0-1 arası bir değerle ifade eder. Yüksek güven skoru (>0.9) modelin tahmininde çok emin olduğunu, düşük güven skoru (<0.7) belirsizlik yaşadığını gösterir. Uygulama 1'de ViT modelinin ortalama güven skoru %82.66 olarak hesaplanmıştır. Bu modelin genel olarak tahminlerinde yüksek kesinlik gösterdiğini işaret etmektedir. Ancak güven skoru dağılımı homojen değildir. Yamaların yaklaşık %60'ında güven skoru >0.9 seviyesindedir. Bu yamalarda model çok emindir ve sınıflandırma neredeyse kesindir. %23'ünde güven skoru 0.8-0.9 aralığındadır bu yamalarda model yüksek eminlik göstermekte ancak küçük bir belirsizlik bulunmaktadır. %17'sinde ise güven skoru <0.7 seviyesindedir. Bazı yamalarda model belirsizlik yaşamaktadır.

Düşük güven skorlu yamaların analizi önemli bulgular ortaya koymuştur. Bu yamalar genellikle sınıflar arası geçiş bölgelerinde veya karma içerikli yamalarda konumlanmaktadır. Örneğin bir yama içinde hem ayçiçeği hem yabani ot sınıfında bulunduğunda model hangi sınıfa ait olduğunda kararsız kalabilir. Model %55 olasılıkla "ayçiçeği", %40 olasılıkla "yabani ot" tahmin edebilir ve en yüksek olasılığa göre "ayçiçeği" sınıfını seçer ancak güven skoru düşüktür. Benzer şekilde yama sınırlarında bulunan bitkiler için de düşük güven skorları gözlemlenmiştir. Bir ayçiçeği bitkisinin sadece yarısı yama görünüyorsa model tüm bitki yapısını göremediği için belirsizlik yaşayabilir.

Sınıf bazlı güven skoru analizi yabani ot sınıfının en yüksek ortalama güven skoruna (%86.3) sahip olduğunu göstermiştir. Model yabani otları tespit etmekte çok emin ve kararlıdır. Boş alan sınıfı da yüksek güven skoru (%85.7) göstermiştir. Ayçiçeği sınıfı ise en düşük ortalama güven skoruna (%78.9) sahiptir. Bu ayçiçeği sınıflandırmasının diğer sınıflara göre daha zorlayıcı olduğunu ve modelin bu sınıfta daha fazla belirsizlik yaşadığını göstermektedir. Ayçiçeği-yabani ot karışıklığının baskın hata kaynağı olması bu düşük güven skoruyla tutarlıdır. Model ayçiçeği ile yabani ot arasında ayrım yaparken zorlanmakta ve güven skoru düşmektedir.

Uygulama 2'de ortalama güven skoru %84.68'e yükselmiştir. Bu multispektral bantların sağladığı ek spektral bilginin modelin güvenini artırdığını göstermektedir. Düşük güven skorlu yama oranı da azalmış ve %17'den %15'e düşmüştür. Multispektral bantların en belirgin katkısı belirsiz sınıflandırma durumlarında ek bilgi sağlamasıdır. NIR ve RedEdge bantları KYM'den belirsiz olan ayçiçeği-yabani ot ayrımını netleştirmekte ve modelin daha emin tahminler yapmasını sağlamaktadır. Sınıf bazlı güven skorlarında da iyileşme gözlemlenmiştir. Ayçiçeği sınıfının ortalama güven skoru %78.9'dan %82.4'e yükselmiştir.

Düşük güven yamalarının varlığı pratikte önemli bir konudur ve ek doğrulama mekanizmaları gerektirebilir. Uygulama 1'de 10,000 yamadan yaklaşık 1,700 tanesi (<0.7 güven skoru) belirsiz sınıflandırmaya sahiptir. Bu yamalar için üç strateji uygulanabilir. Düşük güven durumunda güvenli tarafta kalınarak herbisit uygulaması yapılabilir. Örneğin bir yama %55 ayçiçeği %40 yabani ot olarak tahmin edilmişse ve güven skoru düşükse, bu yama yabani ot olarak kabul edilip

herbisit uygulanabilir. Bu yaklaşım yanlış negatif (yabani ot kaçırma) riskini minimize eder ancak yanlış pozitif (gereksiz herbisit) riskini artırır.

Literatürde, ışık koşullarının bitki sınıflandırma performansını etkilediği bildirilmektedir. Gao ve diğerleri (2018), sabah-öğle-akşam görüntülerinde CNN modelinin doğruluğunun %93-98 arasında değiştiğini rapor etmiştir [83]. Perez-Ortiz ve arkadaşları (2016), bulutlu ve güneşli hava koşullarında %2-3 puan doğruluk farkı gözlemlemiştir [142]. Bu çalışmada çevre koşulları kontrolü yapılmamış ve tüm görüntüler tek bir gün içinde benzer koşullarda çekilmiştir. Modelin farklı koşullara genelleştirme kapasitesini tam olarak test etmemiştir. Gelecekte farklı çevre koşullarında (sabah/öğle/akşam, güneşli/bulutlu, farklı mevsimler) görüntü toplama ve model performansını bu koşullarda test etme yapılmalıdır. Data augmentation teknikleri (parlaklık değiştirme, kontrast ayarlama, gölge simülasyonu) kullanılarak model farklı ışık koşullarına karşı daha katı hale getirilebilir.

Fenolojik dönem değişikliği daha dramatik etkilere sahip olabilir. Bu veri seti V3-V4 aşamasında gerçekleştirilmiştir. V1-V2 aşamasında (1-2 yapraklı dönem) bitkiler çok daha küçüktür (3-5 cm) ve morfolojik özellikler minimal seviyededir. Model bu kadar küçük bitkileri tespit etmekte zorlanabilir. V8-V10 aşamasında (8-10 yapraklı dönem), bitkiler çok daha büyüktür (30-50 cm) ve tam kanopi oluşmuştur. Yaprak yoğunluğu yüksek sıralar arası mesafe kapatılmış ve bitki-bitki örtüşmesi fazladır. Model bu yoğun bitki örtüsünde yabani ot-ayçiçeği ayrımını farklı şekilde değerlendirmelidir. Çiçeklenme döneminde ayçiçeği çiçekleri belirgin bir özellik olarak ortaya çıkar ve sınıflandırmayı kolaylaştırabilir. Ancak bu dönemde herbisit uygulaması genellikle yapılmaz çünkü çiçeklenme sonrası herbisit uygulaması bitkiye zarar verebilir.

Transfer öğrenimi model genelleştirmesine katkısı çok önemlidir. Bu çalışmada ImageNet üzerinde ön eğitilmiş ViT, MobileNetV2 ve NASNetMobile modelleri kullanılmış ve ayçiçeği veri seti üzerinde ince ayarlama yapılmıştır. ImageNet, 1.4 milyon görüntü ve 1000 sınıf içeren büyük bir veri setidir ve modeller bu veri setinde genel görsel özellikleri (kenarlar, dokular, şekiller ve nesneler) öğrenmektedir. Bu genel özellikler ayçiçeği-yabani ot sınıflandırmasına başarıyla transfer edilmiştir. Transfer öğrenimi olmadan (sıfırdan eğitim), muhtemelen çok daha fazla eğitim verisi (10,000-100,000 görüntü) ve daha uzun eğitim süresi (50-

100 epok) gerekecekti. Bu çalışmada sadece 1226-1536 eğitim görüntüsü ile 10 epok ve ince ayarlama yeterli olmuş ve %96-99 doğruluk elde edilmiştir.

Literatürde transfer öğrenimiyle tarımsal uygulamalarda %5-15 doğruluk artışı sağladığı bildirilmektedir [96], [101]. Bu tezde transfer öğreniminin katkısı direkt olarak ölçülmemiş ancak literatürdeki bulgular ışığında transfer öğrenimi olmadan ViT'nin %92-94 seviyesinde kalması muhtemeldir. Transfer öğrenimi %5-7 puan katkı sağlamış ve %99.18-99.48 seviyesine ulaşmayı mümkün kılmıştır.

Genel değerlendirme olarak geliştirilen modeller yüksek genelleştirme kapasitesi göstermiş ve aşırı öğrenme riski minimal seviyede kalmıştır. Eğitim-değerlendirme-test performanslarının tutarlılığı modellerin yeni verilere iyi genelleştiğini kanıtlamaktadır. Ortalama %82.66-84.68 güven skorları modellerin tahminlerinde genel olarak yüksek eminlik gösterdiğini işaret etmektedir. Ancak %15-17 oranında düşük güven yamalarının varlığı, ek doğrulama mekanizmalarının önemini vurgulamaktadır. Gelecek çalışmalarda farklı çevre koşulları ve fenolojik dönemlerde model performansının test edilmesi robust ve güvenilir sistemler geliştirilmesi için kritik öneme sahiptir.

Geliştirilen modellerin farklı coğrafi bölgelerde uygulanabilirliği önemli bir araştırma sorusu olarak öne çıkmaktadır. Türkiye, dünya ayçiçeği üretiminde stratejik bir konuma sahip olmakla birlikte bölgeye özgü yabani ot flora kompozisyonu Sırbistan'dakinden farklılık gösterebilmekte ve bu durum modelin doğrudan kullanımında performans düşüşüne yol açabilir. Bununla birlikte bu çalışmada kullanılan transfer öğrenimi altyapısı, farklı coğrafyalara adaptasyonu önemli ölçüde kolaylaştırmaktadır. Türkiye koşullarına uyum sağlamak için sıfırdan model eğitimine gerek kalmaksızın ilgili bölgeden toplanacak sınırlı sayıda görüntüyle mevcut modele ince ayar yapılması yeterli olacaktır. Bu yaklaşım hem daha az veri hem de daha kısa eğitim süresi gerektirdiğinden hassas tarım teknolojilerinin farklı üretim bölgelerine ölçeklendirilmesinde pratik ve maliyet etkin bir yol sunmaktadır.

Bu tezde geliştirilen modeller yüksek genelleştirme kapasitesi sergilemiş olmakla birlikte coğrafi genellenebilirlik açısından önemli bir sınırlılık bulunmaktadır. Eğitim ve test verileri yalnızca Sırbistan'daki iki test alanından elde edilmiş olup farklı iklim koşulları, toprak yapısı ve yabani ot flora kompozisyonuna sahip

coğrafyalarda model performansının aynı seviyede kalacağı söylenemez. Türkiye, Ukrayna veya diğer ayçiçeği üretim bölgelerinde hâkim olan yabani ot türleri Sırbistan'dakilerden farklılık gösterebilmekte ve bu durum modelin sınıf sınırlarını yeniden tanımlamasını gerektirebilmektedir. Benzer şekilde farklı drone yükseklikleri, kamera açıları ve görüntüleme koşullarının model performansı üzerindeki etkisi henüz test edilmemiştir. Gelecek çalışmalarda farklı coğrafi bölgelerden ve üretim koşullarından elde edilen verilerle modellerin yeniden değerlendirilmesi ve gerekirse bölgeye özgü ince ayar yapılması önerilmektedir.

8.8 Pratik ve Gerçek Zamanlı Uygulama Potansiyeli

Bu tezde geliştirilen modellerin pratik tarımsal uygulamalarda kullanımı teknik ve operasyonel bazı gereksinimleri beraberinde getirmektedir. Model performansının yüksek olması yeterli değildir. Aynı zamanda işleme hızı, model boyutu, enerji tüketimi ve sistem entegrasyonu gibi faktörler de etkin kullanım başarısını belirlemektedir. Bu tezde tüm modellerin işleme hızları model boyutları ve pratik uygulanabilirlik kriterleri detaylı olarak değerlendirilmiş ve iki farklı etkin kullanım senaryosu tanımlanmıştır. Ön planlama ve gerçek zamanlı uygulama olarak değerlendirilmiştir.

İşleme hızı analizi CUDA destekli GPU üzerinde gerçekleştirilmiş ve her modelin çıktı hızı (görüntü/saniye(sn)) ve çıkarım süresi (milisaniye(ms)/görüntü) metrikleri ölçülmüştür. ViT modeli KYM bantlarında 102.6 görüntü/sn çıktı ve 9.75 ms/görüntü çıkarım süresi multispektral bantlarda 86.3 görüntü/sn çıktı ve 11.58 ms/görüntü çıkarım süresi göstermiştir. Bu 10,000 yamanın KYM'de yaklaşık 97 saniye multispektralde yaklaşık 116 saniye içinde işlenebileceği anlamına gelmektedir. Uygulama 1'deki 2.5 dekarlık alan (10,000 yama) yaklaşık 1.5-2 dakika içinde tam olarak sınıflandırılabilmektedir. Bu hız ön planlamayla reçete haritalama senaryosu için tamamen yeterlidir. İHA ile görüntüleme yaklaşık 5-10 dakika sürerken model işleme sadece 2 dakika eklemektedir. Toplam süre 10-15 dakika içinde herbisit reçete haritası hazır hale gelmektedir.

ViT Pruned modeli budama işlemi sayesinde dramatik bir hız artışı göstermiştir. Her iki bant kombinasyonunda da 192.3 görüntü/sn çıktı ve 5.2 ms/görüntü çıkarım süresi elde edilmiştir. Bu orijinal ViT'e göre yaklaşık 2.2 kat daha hızlıdır. 10,000 yamanın işlenmesi sadece 52 saniye sürmektedir. Budama işleminin kodlayıcı

katmanlarını yarıya indirmesi sayesinde hesaplama yükü önemli ölçüde azalmıştır. Dikkat çekici olan ViT Pruned'ın multispektral bantlarda hız kaybı yaşamamasıdır. ViT'de multispektral bantlar işleme süresini %16 artırırken (86.3 görüntü/sn) ViT Pruned sabit hızda kalmıştır (192.3 görüntü/sn). Bu budanmış mimarinin hesaplama avantajını koruduğunu ve farklı girdilere karşı sağlam olduğunu göstermektedir.

NASNetMobile modeli 108.2 görüntü/s çıktı ve 9.24 ms/görüntü çıkarım süresi ile orta seviye performans göstermiştir. ViT'e yakın bir hız sergilemiş ancak doğruluk açısından (%95.83-96.08) önemli ölçüde geride kalmıştır. NASNetMobile'ın karmaşık hücre yapısı GPU optimizasyonundan tam anlamıyla yararlanamamakta ve hesaplama verimliliği düşmektedir. 54.3M parametre ile nispeten küçük olmasına rağmen çıktı hızı MobileNetV2'nin yarısı seviyesindedir. Bu parametre sayısının tek başına hızı belirlemediğini mimari tasarımın da kritik olduğunu göstermektedir.

Model boyutu özellikle son kullanıcı cihazlarında kullanım için önemlidir. ViT modeli 327.36 MB model boyutu ve 85.8M parametre ile en büyük modeldir. Bu boyut modern GPU'larda (8-16 GB VRAM) sorunsuzca yüklenir ancak son kullanıcı cihazlarda (NVIDIA Jetson Xavier NX, 8 GB RAM) bellek sınırlarına yaklaşabilir. ViT Pruned 164 MB model boyutu ve 43M parametre ile %50 boyut azaltması sağlamıştır. Bu kullanıcı cihazlarda çok daha uygun bir boyuttur ve birden fazla modelin aynı anda yüklenmesine olanak tanır. MobileNetV2, 70.35 MB ve 18.1M parametre ile en küçük modeldir. Bu boyut mobil telefonlarda bile çalışabilir ve IoT cihazları için idealdir. NASNetMobile ise 207.88 MB ile MobileNetV2'den büyük ancak ViT'den küçüktür.

8.9 Etkin Kullanım Senaryo 1: Ön Planlama (Offline Prescription Mapping)

Bu yaklaşımda İHA ile tarım alanı görüntülenir görüntüler çevrimdışı olarak işlenir ve herbisit reçete haritası oluşturulur. İşleme süresi 2.5 dekarlık alan için 1.5-2 dakika (ViT), 1 dakika (ViT Pruned) veya 45 saniye (MobileNetV2) gibi çok kısa sürelerdir. Reçete haritası GPS koordinatları ile eşleştirilerek VRA destekli püskürtücü sistemine yüklenir. Püskürtücü GPS rehberliğinde sadece işaretlenmiş bölgelere (kırmızı yamalar, yabani ot) herbisit uygular. Bu yaklaşım teknik olarak en basit olanıdır ve mevcut tarım ekipmanlarına kolaylıkla entegre edilebilir.

Çevrimdışı yaklaşımın avantajları şunlardır. Birincisi hesaplama sınırlaması yoktur. İşleme güçlü bir masaüstü bilgisayar veya bulut sunucusunda yapılabilir ve en yüksek doğruluk için ViT gibi ağır modeller kullanılabilir. İkincisi zaman esnekliği vardır. Görüntüleme ile uygulama arasında 1-2 gün olabilir ve operatör reçete haritasını manuel olarak kontrol edip düzeltebilir. Üçüncüsü maliyet düşüktür. Gerçek zamanlı sistem gerektirmediği için sadece İHA ve standart bilgisayar yeterlidir. Dördüncüsü sonradan işleme imkânı sunar. Reçete haritası üzerinde filtreleme, büyütme ve küçültme gibi işlemler yapılabilir. Örneğin tek bir izole yabani ot yaması çok küçükse (0.25 m²) bu yama herbisit uygulamasından çıkarılabilir.

Ön planlama yaklaşımın dezavantajları ise şunlardır. Birincisi görüntüleme ile uygulama arasındaki zaman farkında yabani ot durumu değişebilir. 1-2 gün içinde yeni yabaniler çıkabilir veya mevcular büyüyebilir. V3-V4 aşamasında bitki büyüme hızı yüksektir (günde 1-2 cm) ve gecikme reçete haritasının güncel olmamasına yol açabilir. İkincisi hava koşulları riski vardır. Görüntüleme günü güneşli uygulama günü bulutlu olabilir ve bu da alanın farklı görünmesine neden olabilir. Üçüncüsü operasyonel esneklik sınırlıdır. Görüntüleme işleme ve uygulama ayrı adımlar olduğu için toplam süre uzar ve lojistik karmaşıklaşır.

8.10 Etkin Kullanım Senaryo 2: Gerçek Zamanlı Uygulama

Bu yaklaşımda tarım aracı (traktör, İHA veya otonom robot) üzerinde kamera ve kullanıcı cihazı bulunur. Araç ilerlerken kamera görüntüleri gerçek zamanlı işlenir ve yabani ot tespit edildikçe püskürtücü anında aktive edilir. Bu yaklaşım en dinamik ve esnek olanıdır. Yabani ot durumundaki değişiklikler anında tespit edilir ve müdahale edilir. Gerçek zamanlı işleme için, son kullanıcı cihazının yeterli hesaplama gücüne sahip olması gerekmektedir.

Gerçek zamanlı yaklaşımda model seçimi kritiktir. ViT 86-102 görüntü/s çıktı hızı ile gerçek zamanlı uygulanabilir ancak optimal değildir. İHA, 30 fps (frame per second) ile uçuyorsa saniyede 30 görüntü üretir. ViT saniyede 86-102 görüntü işleyebildiği için, 30 fps'yi rahatça karşılayabilir. Ancak işleme süresi 9-11 ms/görüntü olduğu için, her karenin işlenmesi 9-11 ms sürer ve bu gecikme birikebilir.

ViT Pruned 192.3 görüntü/s çıktı hızı ile gerçek zamanlı uygulama için çok daha uygun bir seçimdir. 30 görüntüyü kolaylıkla karşılar ve 5.2 ms/görüntü çıkarım süresi ile düşük gecikme sağlar. 164 MB boyutu, Jetson Xavier'de rahatça çalışır ve diğer bileşenlere (GPS, kontrol sistemi) bellek bırakır. %98.45-98.75 doğruluk gerçek zamanlı uygulamalar için yeterli seviyededir ve yabani ot tespitinde %98.80-99 duyarlılık ile güvenilir performans sağlar. ViT Pruned gerçek zamanlı uygulamalar için optimal dengeli model olarak öne çıkmaktadır.

Gerçek zamanlı yaklaşımın avantajlarından birincisi gecikmesi sıfırdır. Görüntüleme ile uygulama aynı anda olur ve yabani ot durumu değişmez. İkincisi dinamik uygulamadır. Alanın farklı bölgelerindeki yabani ot yoğunluğuna göre anında karar verilir. Üçüncüsü operasyonel verimlilik yüksektir. Tek geçişte hem tespit hem uygulama yapılır ayrı adımlar gerekmez. Dördüncüsü hava koşullarından bağımsızdır. Hangi koşulda görüntüleme yapılıyorsa o koşulda uygulama yapılır.

Gerçek zamanlı yaklaşımın dezavantajları ise şunlardır. Birincisi donanım maliyeti yüksektir. Son kullanıcı cihazı, kamera, GPS ve VRA püskürtücü gibi bileşenler pahalıdır. İkincisi teknik karmaşıklık fazladır. Tüm bileşenlerin entegrasyonu ve senkronizasyonu zordur. Üçüncüsü bakım ve destek gerektirir. Sistemin düzenli kalibrasyon yazılım güncellemesi ve teknik destek alması gerekmektedir. Dördüncüsü hata toleransı düşüktür. Gerçek zamanlı sistemde herhangi bir bileşenin arızalanması tüm operasyonu durdurur.

Genel değerlendirme olarak geliştirilen modeller pratik kullanım için yeterli işleme hızı ve model boyutu özelliklerine sahiptir. Çevrimdışı reçete harita üretimi senaryosunda ViT optimal doğruluk (%99.18-99.48) sağlarken işleme süresi (1.5-2 dakika/2.5 dekar) tamamen kabul edilebilirdir. Gerçek zamanlı uygulama senaryosunda, ViT Pruned optimal denge (doğruluk %98.45-98.75, hız 192.3 görüntü/sn) sunmakta ve son kullanıcı cihazlarında sorunsuzca çalışmaktadır. Teknik altyapı donanım maliyeti ve operasyonel karmaşıklık göz önüne alındığında küçük-orta ölçekli işletmeler için çevrimdışı yaklaşım büyük ölçekli ve teknoloji odaklı işletmeler için gerçek zamanlı yaklaşım önerilmektedir.

8.11 Diğer Çalışmalarla Kıyaslama ve Kısıtlılıklar

Yabancı ot tespitine yönelik derin öğrenme çalışmaları incelendiğinde, hem kullanılan mimari hem de veri toplama koşullarının bildirilen performans değerleri üzerinde belirleyici bir rol oynadığı görülmektedir. Bu durum doğruluk rakamlarının tek başına karşılaştırılmasını anlamsız kılmakta yöntem, veri büyüklüğü, sınıf yapısı ve çevresel koşulların birlikte değerlendirilmesini zorunlu kılmaktadır.

Geleneksel görüntü işleme yöntemleri bağlamında Kazmi ve diğerleri (2015), şeker pancarı tarlasında tek bir yabancı ot türünü tespit etmek amacıyla yaprak kenar şekilleri, bölgeler ve yüzey rengi özelliklerini SVM sınıflandırıcısıyla %99.07 doğruluk elde etmiştir. Bu yüksek değer dikkat çekici görünse de görevin ikili ve tek türlü yapısının yarattığı basitlikten kaynaklanmaktadır. Bizim çalışmamız ayçiçeği, yabancı ot ve boş alan olmak üzere üç sınıflı bir ayrım yapmakta ve sınıf sınırları özellikle erken büyüme döneminde çok daha belirsiz hale gelmektedir. Her iki çalışmada da genç bitkilerin daha yüksek doğrulukla sınıflandırıldığı olgunlaşan bitkilerde yaprak örtüşmesinin sınıflandırmayı güçleştirdiği görülmektedir. Kazmi ve diğerleri bu noktayı elle tasarlanmış özelliklerle aşmaya çalışırken, çalışmamızda tercih ettiğimiz ViT mimarisi öz dikkat mekanizması sayesinde hem yerel hem de küresel görsel ilişkileri eş zamanlı modelleyerek bu yapısal soruna daha güçlü bir yanıt üretme kapasitesine sahiptir [145].

Derin öğrenme yaklaşımları arasında Ferreira ve diğerleri (2017), Brezilya soya tarlalarında 15.000'den fazla görüntü üzerinde CaffeNet mimarisiyle toprak, soya, geniş yapraklı ve dar yapraklı yabancı otları ayırt etmiştir. %98-99 doğruluk elde ederek SVM, AdaBoost ve Random Forest yöntemlerini belirgin biçimde geride bırakmıştır [146]. Dört sınıflı bu yapı, bitkisel olmayan sınıfı ayrıca modellemesi bakımından çalışmamıza en yakın kurgudur. Bununla birlikte temel bir mimari ayrım mevcuttur. Ferreira ve diğerleri yerel özellik çıkarımına dayalı evrişimli bir ağ kullanırken çalışmamız yama tabanlı ViT mimarisiyle görüntü bölgelerini global bağlamda değerlendirmektedir. Pandiyaraju ve diğerleri (2025) de benzer şekilde soya tarlasında dört sınıflı ayrım yaparken CNN'lerin değişken aydınlatma ve toprak dokusu koşullarında yetersiz kaldığını, ViT'in ise uzak mesafeli uzamsal ilişkileri modellemedeki üstünlüğü sayesinde gerçek saha koşullarında daha kararlı performans sergilediğini doğrulamıştır [147]. 15.000 görüntüyle ulaştığı doğruluk

değerleri veri büyüklüğünün model performansı üzerindeki belirleyici etkisini açıkça ortaya koymakta ve veri setimizin bu büyüklükle kıyaslandığında bulgularımızın bu bağlamda yorumlanması gerektiğine işaret etmektedir.

Sa ve diğerleri (2017), weedNet çalışmasında şeker pancarı tarlasında hava aracına monte edilen multispektral sensörle üç sınıflı piksel düzeyinde segmentasyon gerçekleştirmiştir. VGG16 tabanlı SegNet mimarisiyle F1 skoru yaklaşık 0.8 elde etmiştir. Sınıf yapısı açısından bu çalışma çalışmamıza en benzer kurgudur ancak piksel düzeyinde yoğun segmentasyon yaparken bizim yama tabanlı yaklaşımımız görüntü parçası düzeyinde sınıflandırma yapmaktadır. Bu tercih hem hesaplama maliyetini düşürmekte hem de çevrimdışı analiz için yeterli çözünürlük sunmaktadır. Daha önemlisi multispektral sensör kullanmasına rağmen iklimin bitki yansımasını etkilediğini ve modelin farklı büyüme dönemlerinde zamansal tutarlılığını yitirdiğini açıkça vurgulamıştır. Yalnızca KYM görüntülerle çalışan çalışmamız bu çevresel değişkenlere yapısal olarak daha duyarlı konumdadır ve benzer ya da daha belirgin bir performans düşüşüyle karşılaşılması beklenebilir [148].

Urmashev ve diğerleri (2021), Kazakistan'da beş yabancı ot türü üzerinde dikkat modülüyle güçlendirilmiş YOLOv5'i karşılaştırmıştır. Klasik yöntemlerin %80-87.5 doğruluğu aralığında kalırken YOLOv5'in %92 doğruluk ve 140 fps hız elde ettiğini göstermiştir. Tür bazlı F1 skorlarının Amaranthus için 0.85, Bromus için 0.73 olarak değişmesi morfolojik açıdan birbirine yakın türler arasında bile kayda değer bir doğruluk farkının oluşabileceğini ortaya koymaktadır. Bu bulgu iki açıdan anlamlıdır. Birincisi klasik yöntemlerin derin öğrenmeye kıyasla sistematik düşüklüğü ViT tercihimizi destekleyen bağımsız bir ampirik dayanak sunmaktadır. İkincisi dikkat mekanizmasının nesne tespiti performansını artırdığına ilişkin kanıt öz dikkat yapısını temel alan ViT mimarisinin tarımsal görüntü sınıflandırmasındaki potansiyelini dolaylı olarak doğrulamaktadır [149].

ViT ile CNN'i doğrudan karşılaştıran güncel çalışmalar bu tabloyu daha da netleştirmektedir. Taminul Islam ve diğerleri (2025), 200.000'i aşan görüntü ve 16 yabancı ot türü üzerinde yürüttükleri kapsamlı değerlendirmede WeedSwin Transformer'ın 0.993 mAP ile RetinaNet'in 79.98 mAP değerini belirgin biçimde geride bıraktığını ancak CNN'lerin 347 fps ile ViT'in 152 fps hızının yaklaşık iki katı işlem hızına ulaştığını göstermiştir [150].

Hibrit mimariler ise her iki yaklaşımın sınırlılıklarını aşmaya yönelik umut verici bir yön olarak öne çıkmaktadır. Pandiyaraju ve diğerleri (2025), CNN'in yerel özellik çıkarımını ViT'in küresel ilişki modellemesini ve GNN'in ilişkisel bağımlılıklarını bir arada kullanan CNN-ViT-GNN çerçevesiyle %99.33 doğruluk ve cihazlarda 22 fps hız elde etmiştir [147]. Hu ve diğerleri (2024) ise Cotton Weed-YOLO ile CNN'in sınırlı algı alanı sorununu ve ViT'in yüksek hesaplama yükünü çift dallı yapıyla dengelemiş. YOLOv8'e kıyasla doğruluğu %1.45 artırırken hesaplama karmaşıklığını azaltmıştır. Çalışmamız bu hibrit yaklaşımları denememiş olsa da bulgularımız tek başına ViT'in sınırlılıklarını bu çalışmalarla karşılaştırmalı olarak tartışmak için sağlam bir zemin oluşturmaktadır [151].

Tüm bu çalışmalar bir bütün olarak değerlendirildiğinde yabancı ot tespiti literatüründe birkaç yapısal örüntü belirginleşmektedir. ViT mimarileri kontrollü koşullarda CNN'leri doğruluk açısından tutarlı biçimde geride bırakmakta ancak bu üstünlük hesaplama maliyetiyle birlikte gelmektedir. Çevrimdışı analiz yapan çalışmamız bu hesaplama yükünü birincil bir kısıt olarak taşımadığından ViT tercihini işlevsel düzeyde meşrulaştırmaktadır. Öte yandan büyüme dönemi bağımlılığı KYM görüntülerin aydınlatma değişkenliğine duyarlılığı ve coğrafi genellenebilirliğin sınanmamış olması yalnızca çalışmamıza özgü sınırlılıklar değil incelenen literatürün büyük bölümüyle paylaşılan ve dürüstçe kabul edilmesi gereken ortak kısıtlardır.

9
SONUÇ

9.1 Araştırmanın Genel Sonuçları

Bu tez çalışmasında ayçiçeği tarlalarında yabani ot tespiti ve sahaya özgü yabani ot yönetimi uygulamaları için dört farklı derin öğrenme mimarisi geliştirilmiş karşılaştırmalı olarak test edilmiş ve pratik uygulanabilirliği kapsamlı bir şekilde gösterilmiştir. Dönüştürücü model (ViT), budanmış dönüştürücü model (ViT Pruned), MobileNetV2 ve NASNetMobile mimarileri kullanılarak hem KYM hem de multispektral bantlar üzerinde çalışmalar gerçekleştirilmiştir. İnsansız Hava Aracı ile elde edilen yüksek çözünürlüklü ortofoto görüntüleri üzerinde gerçekleştirilmiş ve erken gelişim döneminde yabani ot tespiti yapılarak önleyici müdahale stratejisi geliştirme hedeflenmiştir.

Araştırmanın temel amacı geleneksel tekdüze herbisit uygulamasına alternatif çevre dostu ve ekonomik bir yaklaşım sunmaktır. Bu amaç doğrultusunda sahaya özgü veri setleri oluşturulmuş optimizasyonu ile hiperparametre ayarlaması yapılmış yama bazlı sınıflandırma metodolojisi uygulanmıştır. Herbisit reçete haritaları oluşturulmuş ekonomik ve çevresel etki analizi yapılmıştır. Tüm süreç bilimsel titizlik ve tekrarlanabilirlik ilkeleri gözetilerek gerçekleştirilmiştir.

Araştırmanın sonuçları dönüştürücü tabanlı mimarilerin CNN tabanlı mimarilere göre belirgin bir üstünlük gösterdiğini ortaya koymuştur. Dönüştürücü baz modeli KYM bantlarında %99.18 test doğruluğu ve 0.9927 F1-skoruyla multispektral bantlarda %99.48 test doğruluğu ve 0.9948 F1-skoru elde ederek en yüksek performansı sergilemiştir. Yabani ot tespitinde kritik öneme sahip duyarlılık metriğinde KYM'de %100 ve multispektralde %99 değerlere ulaşılmıştır. Hata oranı KYM'de %0.82 multispektralde %0.52 gibi son derece düşük seviyelerde gerçekleşmiştir.

ViT Pruned modeli model budama tekniği ile orijinal ViT'nin kodlayıcı katmanlarını %50 azaltarak önemli bir verimlilik ve doğruluk dengesi sağlamıştır. Model boyutu 327 MB'den 164 MB'ye düşürülmüş parametre sayısı 85.8M'den 43M'e inmiş ve işleme hızı 192.3 görüntü/sn'ye yükselerek orijinal ViT'nin yaklaşık 2.2 katı hızlı çalışmıştır. Buna karşılık doğruluk kaybı minimal seviyede kalmıştır. KYM'de %98.45, multispektralde %98.75 test doğruluğu elde edilmiştir. Sadece %0.73'lük doğruluk kaybına karşılık %50 boyut azaltma ve %87 hız artışı budama işleminin son derece başarılı olduğunu kanıtlamaktadır.

MobileNetV2 modeli hafif CNN mimarisi olarak 217-218 görüntü/sn işleme hızı ve 70.35 MB model boyutu ile en verimli model olmuştur. KYM bantlarında %97.96 doğruluk ve dikkat çekici bir şekilde %100 yabani ot duyarlılık elde etmiştir. Ancak multispektral bantlarda performans düşmüştür. Doğruluk %97.33'e yabani ot duyarlılık %95'e gerilemiştir. 512 yabani ottan 26 tanesinin kaçırılması tarımsal uygulamalar açısından kabul edilemez bir risktir. Bu sonuç CNN'lerin multispektral bantlardan beklenen katkıyı alamadığını göstermektedir.

NASNetMobile modeli KYM'de %96.08, multispektralde %95.83 doğruluk ile en düşük performansı göstermiştir. Yabani ot duyarlılık değerleri KYM'de %97 (16 yabani ot kaçırıldı), multispektralde %93 seviyesinde kalmıştır. 207.88 MB model boyutu ve 108.2 görüntü/sn işleme hızı ile ne doğruluk ne de verimlilik açısından rekabetçi bir konumda bulunmamaktadır.

Sahaya özgü yabani ot yönetimi yaklaşımının pratik uygulaması önemli herbisit tasarrufları sağlamıştır. Uygulama 1'de %54.07 ve uygulama 2'de %59.75 herbisit tasarrufu elde edilmiştir. Sadece yabani ot tespit edilen bölgelere herbisit uygulanması prensibiyle uygulama 1'de 1.35 dekar uygulama 2'de 0.06 dekar alan herbisit uygulamasından muaf tutulmuştur. Bu hem ekonomik tasarruf hem de çevresel koruma sağlamıştır.

Multispektral bantların katkısı beklenenin altında kalmıştır. Dönüştürücü modelde KYM'den multispektrale geçişte sadece %0.30 puanlık doğruluk artışı gözlemlenmiştir. CNN modellerinde ise multispektral bantlar olumsuz etki göstermiştir. MobileNetV2'de %0.63, NASNetMobile'da %0.25 puan doğruluk düşüşü yaşanmıştır. Bu sonuçlar KYM bantlarının ayçiçeği-yabani ot-boş alan

sınıflandırması için yeterli olduğunu ve multispektral yatırımın maliyet ve fayda açısından tartışılabilir olduğunu göstermektedir.

Erken dönem yabani ot tespitinin stratejik önemi, yüksek tespit başarısıyla kanıtlanmıştır. Her iki test alanında da %40-46 arasında yüksek yabani ot yoğunluğu tespit edilmiş ancak ayçiçeği bitkileri henüz yabani ot rekabetinden ciddi zarar görmemiştir. Bu aşamada müdahale edilmesiyle kritik oluşabilecek %20-40 verim kayıpları önlenebilmektedir. Yabani otlar küçük ve zayıfken tespit edildiği için düşük herbisit dozları yeterli olmakta ve kontrol etkinliği maksimum seviyeye ulaşmaktadır.

9.2 Araştırma Soruları ve Hipotez Testi Sonuçları

Bu tez başlangıçta tanımlanan beş temel araştırma sorusuna net ve somut yanıtlar vermiştir.

Araştırma Sorusu 1: Ayçiçeği tarımında erken dönem yabani ot tespiti için oluşturulan sahaya özgü veri setinin farklı türler arasındaki morfolojik benzerliklere rağmen ayırt edici temsil gücü ne düzeydedir?

Yanıt: Araştırma kapsamında, iki farklı sahaya özgü veri seti geliştirilmiştir. Uygulama 1'de KYM bantları ile 1,226 test görüntüsü uygulama 2'de multispektral bantlar ile 1,536 test görüntüsü içeren veri setleri oluşturulmuştur. Veri setleri erken gelişim döneminde çekilen 1 cm GSD çözünürlüklü ortofoto görüntülerinden yama bazlı bölümleme ile üretilmiştir. Her yama 0.5×0.5 m fiziksel alana karşılık gelmekte ve 0.25 m² bölgeyi temsil etmektedir.

Veri seti kalitesi birkaç açıdan değerlendirilmiştir. Yüksek çözünürlük erken dönemde küçük bitkilerin net bir şekilde görülmesini sağlamıştır. Yama boyutu (50×50 piksel) bitki boyutlarıyla uyumlu olarak optimize edilmiş ve hem lokal detayları hem bağlamsal bilgiyi içerecek şekilde seçilmiştir. Eğitim, değerlendirme ve test ayrımı ile modellerin genelleştirme kapasitesi objektif olarak test edilmiştir. Yabani ot sınıfı sahada yaygın olan farklı yabani ot türlerini kapsayacak şekilde heterojen bir yapıda oluşturulmuştur. Her iki veri seti de etiketleme doğruluğu sınıf dengesizliği yönetimi ve gerçek tarım koşullarını yansıtma açısından güçlü bir temel oluşturmuş ve %96-99 arasında model doğrulukları elde edilmesini sağlamıştır.

Araştırma Sorusu 2: Hiperparametre optimizasyonu yönteminin görüntü dönüştürücü mimarisinin genelleme yeteneği ve sınıflandırma kararlılığı üzerindeki etkisi hangi ölçüdedir?

Yanıt: Hiperparametre optimizasyonunun sınıflandırma başarısına etkisi önemli ve belirgindir. Araştırmada optimizasyonu kullanılarak epok sayısı, yığın boyutu ve veri artırma stratejileri sistematik olarak optimize edilmiştir. ImageNet üzerinde ön-eğitilmiş modellere transfer öğrenimi uygulanmış ve ayçiçeği veri seti üzerinde ince ayar yapılmıştır. Optimizasyon sonrasında ViT KYM'de %99.18, multispektralde %99.48, ViT Pruned KYM'de %98.45, multispektralde %98.75, MobileNetV2 KYM'de %97.96, multispektralde %97.33, NASNetMobile KYM'de %96.08, multispektralde %95.83 test doğruluğuna ulaşmıştır.

Performansa göre tüm modellerde tahmini %3-5 puanlık iyileşme sağlanmıştır. Özellikle transfer öğreniminin katkısı çok önemlidir. Sıfırdan eğitime göre yaklaşık %5-7 puan daha yüksek doğruluk elde edilmiştir. Aşırı öğrenme riski azaltılmış ve modellerin genelleştirme kapasitesi artırılmıştır. Eğitim ve test doğruluk farkı tüm modellerde %0.50-1.50 aralığında kalmış ve sağlıklı öğrenme gerçekleşmiştir. Bu sonuçlar sahaya özgü küçük ve orta boyutlu veri setlerinde hiperparametre optimizasyonu ve transfer öğreniminin kritik önemini vurgulamaktadır. Özellikle hassas tarım gibi sınırlı veri setleri olan alanlarda bu teknikler olmadan yüksek performans elde etmek neredeyse imkânsızdır.

Araştırma Sorusu 3: Yapısal budama (structured pruning) yöntemiyle geliştirilen hafif dönüştürücü modellerin standart evrişimli sinir ağları ile kıyaslandığında doğruluk-hız dengesi açısından sunduğu avantajlar nelerdir?

Yanıt: ViT ve budanmış versiyonu ile CNN tabanlı modeller arasında kapsamlı karşılaştırma yapılmıştır. ViT en yüksek doğruluk neredeyse mükemmel yabani ot duyarlılık dengeli sınıf performansı ve global bağlam modelleme kapasitesi güçlü transfer öğrenimi kapasitesiyle göstermiştir. ViT yüksek hesaplama maliyeti büyük model boyutu ve GPU bellek gereksinimi kısıtlılıkları vardır.

ViT Pruned %50 daha küçük model boyutu, 2.2 kat daha hızlı son kullanıcı cihazlarında sorunsuz çalışma ve optimal doğruluk verimlilik dengesini göstermiştir.

MobileNetV2 en yüksek işleme hızı en küçük model düşük enerji tüketimi ve mobil cihazlarda idealdir. MobileNetV2 CNN'lere göre düşük doğruluk multispektralde performans düşüşü ve lokal özellik odaklığı kısıtlılıklarıdır.

Maksimum doğruluk için ViT, dengeli production sistemleri için ViT Pruned, hız-kritik mobil uygulamalar için MobileNetV2 önerilmektedir. Dönüştürücü model mimarisinin öz dikkat mekanizması bitkilerin uzamsal ve spektral özelliklerini global olarak öğrenmede CNN'lerin lokal konvolüsyonlarına göre belirgin üstünlük sağlamıştır.

Araştırma Sorusu 4: Yama tabanlı sınıflandırma ve segmentasyon verilerine dayalı oluşturulan reçete haritalarının geleneksel yekpare ilaçlama yöntemine göre herbisit kullanım hacmi ve çevresel sürdürülebilirlik üzerindeki potansiyel tasarruf oranı nedir?

Herbisit kullanımı sahaya özgü yaklaşım ile önemli ölçüde azaltılmıştır. Yama bazlı sınıflandırma ve segmentasyon sonucunda oluşturulan herbisit reçete haritaları geleneksel uniform uygulamaya göre Uygulama 1'de %54.07, Uygulama 2'de %59.75 herbisit tasarrufu sağlamıştır. Somut olarak Uygulama 1'de 2.5 dekarlık alanda geleneksel yaklaşımda 500 ml herbisit kullanılırken sahaya özgü yaklaşımda sadece 230 ml kullanılmış ve 270 ml herbisit tasarrufu sağlanmıştır. Bu tek uygulama için 27 TL sezonluk 81 TL maliyet tasarrufu anlamına gelmektedir.

Uygulama 2'de, 0.1 dekarlık alanda 20 ml yerine 8 ml kullanılmış ve 12 ml (%60) tasarruf edilmiştir. Büyük ölçekli üretimlerde sezonluk tasarruf 3,240 TL seviyelerine çıkabilmektedir. Herbisit tasarrufunun nedeni sadece yabani ot tespit edilen yamalara herbisit uygulanması ve ayçiçeği ile boş alan yamalarının korunmasıdır.

Korunan alanlarda toprak ve su kaynaklarına kimyasal karışımı önlenmiş toprak mikrobiyal aktivitesi korunmuş ve hedef olmayan organizmalar zarar görmemiştir. Sezonluk bazda Uygulama 1'de toplam 810 ml herbisitin çevreye salınması engellenmiştir. En önemli dolaylı kazanç erken dönem yabani ot kontrolü ile verim kaybının önlenmesidir.

Araştırma Sorusu 5: Multispektral görüntü bantlarının yüksek çözünürlüklü KYM görüntülere kıyasla yabani ot tespitindeki ayırıcı spektral katkısı ve maliyet-etkinlik oranı nedir?

Multispektral görüntülerin yabani ot haritası üretimindeki etkisi KYM görüntülere göre marjinal düzeyde kalmıştır. ViT modelinde KYM bantları %99.18 doğruluk elde ederken multispektral bantlar %99.48 doğruluğa ulaşmıştır. Fark sadece %0.30 puan olup bu istatistiksel olarak anlamlı ancak pratik olarak minimal bir iyileşmedir. F1-skoru açısından KYM'de 0.9927, multispektralde 0.9948 değerleri elde edilmiş ve fark 0.0021 seviyesinde kalmıştır.

Multispektral bantların pozitif katkıları yabani ot sınıfının duyarlılık değeri %99.02'den %100.00'a çıkmış ve yabani otların hiçbiri kaçmamıştır. Model güven skoru %82.66'dan %84.68'e yükselmiş ve modelin tahminlerinde daha emin olduğu görülmüştür. RedEdge bandı ayçiçeği yabani ot ayrımında hassasiyeti artırmış ve kesinlik değerini %99'dan %100'e yükseltmiştir.

Maliyet-fayda değerlendirmesi: KYM kameralar 5,000-15,000 TL aralığında iken multispektral kameralar 50,000-150,000 TL seviyesindedir. %0.30 puanlık performans artışı göz önüne alındığında multispektral yatırımın ekonomik gerekçesi zayıftır. Küçük ve orta ölçekli işletmeler için KYM tabanlı sistemler maliyet etkin bir seçimdir. Ancak multispektral bantlar belirli durumlarda avantajlı olabilir. Tür bazlı yabani ot sınıflandırması, bitki stres tespiti, hastalık tespiti ve ileri gelişim dönemlerinin tespitinde faydalıdır. Multispektral bantlar marjinal katkı sağlar ancak maliyet ve fayda açısından tartışmalıdır.

Birinci hipotez tam olarak doğrulanmıştır. ViT'nin öz-dikkat mekanizması CNN tabanlı mimarilere göre istatistiksel olarak anlamlı üstünlük sağlamıştır. KYM bantlarında ViT %99.18 doğrulukla MobileNetV2'ye göre %1.22, NASNetMobile'a göre %3.10 puan üstünlük göstermiş ve yabani ot kesinliğinde hem KYM hem multispektral bantlarda %100 değerine ulaşmıştır. McNemar istatistiksel testleri bu farkların tesadüfi olmadığını ve istatistiksel olarak anlamlı olduğunu kanıtlamıştır. Öz-dikkat mekanizmasının bitkilerin uzamsal ve spektral özelliklerini global olarak modellemesi CNN'lerin lokal konvolüsyon yaklaşımına göre belirgin avantaj sağlamış ve birinci hipotezi güçlü biçimde desteklemiştir. Bununla birlikte istatistiksel anlamlılık yalnızca McNemar testi çerçevesinde değerlendirilmiş olup etki büyüklüğü analizleri ve güven aralıkları hesaplanmamıştır. Bu sınırlılık göz önünde bulundurulduğunda performans farklarının pratik anlamlılığı istatistiksel anlamlılıktan ayrı olarak yorumlanmalıdır.İkinci hipotez tüm bileşenleriyle doğrulanmıştır. Yapılandırılmış

budama %50 parametre azaltımı ve %50 model boyutu küçülmesi hedefine tam olarak ulaşmış, çıkarım hızı yaklaşık 2.2 kat artırılmış ve doğruluk kaybı %0.73 seviyesinde tutulmuştur. Hız, boyut ve doğruluk koşullarının eş zamanlı karşılanması budama yönteminin verimlilik-doğruluk dengesini başarıyla optimize ettiğini ortaya koymaktadır. Ancak bu hipotez için de istatistiksel anlamlılık testi uygulanmamış; doğruluk kaybının %1 eşiğinin altında kalması gözlemsel olarak desteklenmiş olmakla birlikte bu farkın istatistiksel olarak anlamlı olup olmadığı ayrıca sınanmamıştır.

Üçüncü hipotez doğrulanmıştır. V3-V4 fenolojik aşamasındaki morfolojik kısıtlılıklara rağmen tüm modeller %95 doğruluk eşiğini aşmış ve erken dönem yabani ot tespitinin teknik fizibilitesi kanıtlanmıştır. Bununla birlikte bu hipotezin doğrulanması yalnızca Sırbistan'daki iki test alanına dayalı verilerle sınırlıdır. Farklı coğrafyalarda, farklı yabani ot flora kompozisyonlarında ve farklı drone yüksekliklerinde aynı performansın elde edilip edilemeyeceği henüz test edilmemiştir. Bu nedenle %95 üzeri doğruluk eşiğinin evrensel bir başarı olarak değil sahaya özgü bir bulgu olarak değerlendirilmesi akademik açıdan daha doğru olacaktır.

Dördüncü hipotez somut verilerle doğrulanmıştır. Herbisit reçete haritaları her iki uygulamada da %50 tasarruf eşiğini aşmıştır. Ancak bu hipotezin doğrulanmasında bazı kısıtlar göz ardı edilmemelidir. Hesaplanan tasarruf oranları yalnızca iki küçük test alanına dayanmakta olup daha geniş alanlarda ve farklı yabani ot yoğunluklarında sonuçların değişebileceği öngörülmektedir. Ayrıca VRA püskürtücüyle gerçek saha uygulaması yapılmamış; tasarruf hesaplamaları model çıktılarına dayalı teorik projeksiyonlar üzerinden gerçekleştirilmiştir. Gerçek saha koşullarında GPS hassasiyeti, püskürtücü tepki süresi ve örtüşen uygulama alanları gibi faktörler tasarruf oranını etkileyebilir.

Beşinci hipotez kısmen doğrulanmış, kısmen reddedilmiştir. Multispektral bantlar ViT modelinde yabani ot duyarlılığını ve model güven skorunu artırarak spektral zenginliğin belirsizlikleri azalttığını göstermiştir. Ancak hipotezin CNN modellerine yönelik beklentisi açıkça reddedilmiştir. MobileNetV2'de %0.63, NASNetMobile'da %0.25 puan doğruluk düşüşü yaşanmış ve multispektral bantlar CNN mimarileri için olumsuz etki göstermiştir. Maliyet-etkinlik açısından değerlendirildiğinde ise KYM sistemlerin operasyonel üstünlüğü korunmaktadır.

Bu hipotez yalnızca dönüştürücü mimariler için geçerli olduğu ölçüde doğrulanmış; CNN tabanlı modeller için doğrulanamamıştır.

Altıncı hipotez doğrulanmıştır. 50×50 piksellik yama boyutu V3-V4 aşamasındaki erken dönem bitki boyutlarıyla uyumlu bir ölçek sunmuş ve tüm modellerde %96 üzerinde doğruluk elde edilmesini sağlamıştır. Bununla birlikte bu hipotezin önemli bir metodolojik kısıtı bulunmaktadır. Farklı yama boyutları sistematik olarak karşılaştırılmamış olup 50×50 piksellik boyutun optimalliği deneysel karşılaştırmaya değil alan yazın ve uygulama gereksinimlerine dayalı gerekçelendirmeye dayanmaktadır. 30×30, 40×40 veya 75×75 piksel gibi alternatif boyutların performansa etkisi test edilmemiştir. Bu nedenle hipotez gözlemsel olarak desteklenmiş ancak kontrollü karşılaştırma yoluyla tam anlamıyla kanıtlanamamıştır.

Yedinci hipotez doğrulanmıştır. Tüm modellerde eğitim ve test doğrulukları arasındaki fark %0.50-1.50 aralığında kalmış ve öngörülen %2 eşiğinin altında seyretmiştir. 2023 yılı eğitim verisiyle eğitilen modellerin 2024 yılı test verileri üzerinde tutarlı sonuçlar üretmesi zamansal genellemenin de sağlandığını göstermiştir. Ancak bu hipotezin değerlendirilmesinde yama bazlı veri bölme yaklaşımının barındırdığı veri sızıntısı riski göz ardı edilmemelidir. Aynı bitkiye ait komşu yamaların hem eğitim hem test setine dağılmış olma ihtimali modelin raporlanan genelleştirme kapasitesini olduğundan yüksek gösterebilir. İki bağımsız test alanının kullanımı ve transfer öğrenimi bu riski kısmen azaltmış olsa da bitki bazlı çapraz doğrulama uygulanmadan yedinci hipotezin tam anlamıyla doğrulandığını iddia etmek ihtiyatla karşılanmalıdır.

9.3 Bilimsel ve Pratik Katkılar

Tez kapsamında dönüştürücü mimarisinin ayçiçeği ve yabani ot sınıflandırmasında sistematik olarak test edildiği ve CNN tabanlı mimarilerle karşılaştırmalı olarak değerlendirildiği ilk çalışmalardan biridir. Literatürde tarımsal uygulamalarda ViT kullanımı sınırlıdır ve çoğunlukla CNN tabanlı mimariler (ResNet, VGG, EfficientNet) tercih edilmektedir. Bu araştırma ViT'in öz dikkat mekanizmasının bitkilerin uzamsal ve spektral özelliklerini öğrenmede ne kadar etkili olduğunu somut verilerle göstermiştir. KYM bantlarında ViT %99.18, MobileNetV2 %97.96, NASNetMobile %96.08 doğruluk elde etmiş ve ViT'in CNN'lere göre %1.22-3.10

puan üstünlüğü kanıtlanmıştır. Multispektral bantlarda bu fark daha da belirginleşmiş ve transformer mimarisinin spektral bilgiyi daha etkili kullandığı gösterilmiştir.

Dört farklı modelin iki farklı bant kombinasyonunda sistematik olarak karşılaştırılması literatürde benzeri olmayan kapsamlı bir analiz sunmuştur. McNemar istatistiksel testleri ile performans farklarının anlamlılığı kanıtlanmış ve model hiyerarşisi objektif olarak belirlenmiştir. Bu metodolojik katkı gelecek çalışmalar için bir referans oluşturmaktadır.

Çalışma, ürünün erken aşamasında erken dönem yabani ot tespitinin başarıyla gerçekleştirilebileceğini ve önleyici müdahale stratejisi için kritik bir fırsat penceresi sunduğunu göstermiştir. Literatürdeki çoğu çalışma ileri gelişim dönemlerine odaklanmaktadır. Bu araştırma kritik periyottan önce tespit yapmanın önemini vurgulamış ve erken dönemde %99-100 yabani ot duyarlılık ile neredeyse mükemmel tespit başarısı elde etmiştir. 518-512 yabani ot görüntüsünün tamamı veya tamamına yakını doğru tespit edilmiş ve hiçbiri veya sadece birkaçı kaçırılmıştır.

Erken dönem tespitinin avantajları somut verilerle desteklenmiştir. Yabani otlar küçük ve zayıfken tespit edilmiş düşük herbisit dozları yeterli olacaktır. Ayçiçeği bitkileri henüz yabani ot rekabetinden zarar görmemiş ve verim kaybı henüz oluşmamıştır. Literatürde erken dönem yabani ot kontrolünün %20-40 verim artışı sağladığı bildirilmektedir. Bu çalışma erken dönem tespitinin teknik fizibilitesini %99.18-99.48 doğrulukla kanıtlamış ve önleyici stratejinin bilimsel temelini güçlendirmiştir.

ViT Pruned modelinin geliştirilmesi ve değerlendirilmesi model budama tekniğinin hassas tarımda etkinliğini gösteren ilk çalışmalardan biridir. Kodlayıcı katmanlarının %50'sinin yapılandırılmış olarak çıkarılmasıyla model boyutu 327 MB'den 164 MB'ye parametre sayısı 85.8M'den 43M'e düşürülmüş ve işleme hızı 86-102 görüntü/sn'den 192.3 görüntü/sn'ye çıkarılmıştır. Buna karşılık doğruluk kaybı sadece %0.73 seviyesinde kalmıştır.

Bu sonuçlar budama işleminin doğruluk ve verimlilik dengesini optimize ettiğini kanıtlamaktadır. 1226 test görüntüsünde sadece 9 ek hata ile %50 boyut azaltma ve %87 hız artışı pratik kullanım açısından son derece değerlidir. ViT Pruned son

kullanıcı cihazlarında sorunsuzca çalışmakta ve gerçek zamanlı uygulamalar için ideal denge sunmaktadır. Literatürde tarımsal uygulamalarda model budama çalışmaları sınırlıdır ve bu çalışma bu alandaki metodolojik boşluğu doldurmuştur.

50×50 piksel yama boyutunun erken dönem küçük bitkilerin tespiti için optimal olduğu gösterilmiştir. Bu boyut hem lokal detayları hem bağlamsal bilgiyi içerecek şekilde dengelenmiştir. Yama bazlı yaklaşımın avantajları deneysel olarak doğrulanmıştır. Büyük görüntülerin verimli işlenmesi, lokal detayların korunması herbisit reçete haritası için uygun çözünürlük ve eğitim veri seti hazırlama sürecinin kolaylaştırılması sonuçlarda gösterilmiştir.

Yama bazlı sınıflandırma sonuçlarının herbisit reçete haritalarına direkt dönüştürülmesi pratik uygulama açısından önemli bir katkıdır. Her yama için verilen karar GPS koordinatlarıyla eşleştirilmiş ve VRA püskürtücülere yüklenebilir formatta sunulmuştur. Uygulama 1'de 10,000 yamadan 4,593 tanesi yabani ot olarak sınıflandırılmış ve bu yamalar GPS koordinatları reçete haritasına aktarılmıştır. Bu metodoloji hassas tarımın pratik uygulamasına doğrudan katkı sağlamaktadır.

KYM ve multispektral bantların ayçiçeği-yabani ot sınıflandırmasındaki performansı sistematik olarak karşılaştırılmış ve RGB bantlarının yeterli olduğu multispektral bantların marjinal katkı sağladığı gösterilmiştir. ViT'de sadece %0.30 puan iyileşme CNN'lerde ise olumsuz etki gözlemlenmiştir. Bu bulgu maliyet ve etkin sistem tasarımı için önemli bir referans sunmaktadır. KYM kameralar ile multispektral kameralar arasında 10 kat fiyat farkı göz önüne alındığında çoğu uygulama için KYM'in yeterli olduğu sonucuna varılmıştır.

Multispektral bantların belirli avantajları da detaylandırılmıştır. Model güven skorunu %2.02 artırmış yabani ot duyarlılığı %100'e çıkarmıştır. Boş alan duyarlılığı %100'e çıkarmış düşük güven yama oranını %17'den %15'e düşürmüştür. Bu katkılar dönüştürücü mimarilerinde gözlemlenmiş ancak CNN'lerde görülmemiştir. Multispektral bantların tür bazlı yabani ot sınıflandırması bitki stres tespiti ve ileri gelişim dönemlerinde daha avantajlı olabileceği öngörülmüştür. Bu kapsamlı analiz gelecek çalışmalarda bant seçimi için bilimsel bir temel oluşturmaktadır.

ImageNet üzerinde ön eğitilmiş modellerin ayçiçeği veri setine başarıyla transfer edildiği ve ince ayar ile yüksek doğruluk elde edildiği gösterilmiştir. 1226-1536 test görüntüsü gibi nispeten küçük veri setlerinde bile sadece 10 epokluk ince ayar ile %96-99 doğruluk seviyelerine ulaşılmıştır. Transfer öğrenimi olmadan muhtemelen %85-92 seviyesinde kalınacaktı ve 10,000-100,000 görüntü ile 50-100 epok eğitim gerekecekti. Transfer öğrenimi eğitim süresini %80-90 veri gereksinimini %80-95 azaltmış ve doğruluğu %5-7 puan artırmıştır. Bu özellikle tarımsal uygulamalar gibi sınırlı veri setleri olan alanlarda transfer öğreniminin kritik önemini vurgulamaktadır.

Modeller arası performans farklarının istatistiksel anlamlılığı McNemar testleri ile sistematik olarak değerlendirilmiştir. ViT'nin tüm diğer modellere karşı üstünlüğü istatistiksel olarak anlamlı bulunmuştur. ViT Pruned ile MobileNetV2 arasındaki ilişki KYM'de anlamlı değilken multispektralde anlamlı hale gelmiştir. Bu multispektral bantların dönüştürücü model lehine performans farklılığını artırdığını kanıtlamıştır. İstatistiksel testlerin kullanımı subjektif değerlendirmelerin ötesinde objektif ve bilimsel bir karşılaştırma sağlamıştır.

Çalışma sadece yabani ot tespiti yapmakla kalmamış aynı zamanda herbisit reçete haritalarının nasıl oluşturulacağını ve VRA püskürtücülere nasıl entegre edileceğini pratik olarak göstermiştir. Yama bazlı sınıflandırma sonuçları GPS koordinatlarıyla eşleştirilmiş ve reçete haritası formatında sunulmuştur. Uygulama 1'de, 10,000 yama için binary karar haritası oluşturulmuştur. 4,593 yama "herbisit UYGULA" (kırmızı), 5,407 yama "herbisit UYGULAMA" (yeşil). Bu harita modern VRA püskürtücülere direkt yüklenebilir ve GPS rehberliğinde otomatik uygulama yapılabilir.

Sistemi İHA ile görüntüleme, model ile işleme, reçete haritası oluşturma, VRA püskürtücüye yükleme ve sahada uygulama olarak sıralayabiliriz. Toplam süre 10-15 dakika içinde tamamlanmakta ve herbisit reçete haritası hazır hale gelmektedir. Bu hız, pratik uygulamalar için tamamen yeterlidir ve aynı gün içinde görüntüleme-uygulama döngüsü tamamlanabilir.

Herbisit tasarrufu, maliyet azalması, verim koruması ve çevresel faydalar nicel olarak hesaplanmış ve somut rakamlarla raporlanmıştır. Bu analiz çiftçilerin ve politika yapıcıların karar verme süreçlerinde kullanabilecekleri objektif veriler

sunmaktadır. Ekonomik etkisi uygulama 1'de tek uygulama için 27 TL, sezonluk 81 TL herbisit tasarrufuyla 100 dekarlık işletmede sezonluk 3,240 TL tasarrufu ve verim kaybının önlenmesiyle dolaylı kazanç 2,800-3,750 TL/2.5 dekar olacaktır. Çevresel etkisi uygulama 1'de sezonluk 810 ml herbisitin çevreye salınmaması ve 1.35 dekar alanda toprak mikrobiyal aktivitesinin korunmasıdır. Hedef olmayan organizmaların (arılar, polinatörler) korunması ve herbisit direnci gelişim riskinin azaltılması sağlanacaktır.

Bu nicel veriler tarlaya özgü yabani ot mücadelesinde teorik bir konsept değil somut faydalar sağlayan pratik bir yaklaşım olduğunu göstermektedir. Özellikle çiftçilerin ikna edilmesi için "herbisit tasarrufu" gibi soyut kavramlar yerine "sezonluk 81 TL tasarruf" gibi somut rakamlar çok daha etkilidir. Ayrıca çevre dostu uygulamaların ekonomik getirisinin gösterilmesi sürdürülebilir tarımın benimsenmesini teşvik etmektedir.

9.4 Türkiye Tarımı için Referans Model ve Ayçiçeği Üretimine Özel Çözüm

Türkiye'nin önemli tarımsal ürünlerinden biri olan ayçiçeğinde hassas tarım uygulamasının fizibilitesi somut verilerle gösterilmiştir. Türkiye'de ayçiçeği 600,000-700,000 hektar alanda yetiştirilmekte ve 5-6 milyar TL değerinde ekonomik katkı sağlamaktadır. Bu çalışma Türkiye'deki ayçiçeği üreticileri için direkt uygulanabilir bir çözüm sunmaktadır. Erken dönem müdahale stratejisi, Türkiye'nin farklı ayçiçeği üretim bölgelerinde adapte edilebilir.

Türkiye perspektifinden hassas tarımın yaygınlaştırılması için önemli fırsatlar bulunmaktadır. Genç ve teknolojiye açık çiftçi nüfusu, gelişen tarım teknolojileri sektörü, artan çevre bilinci, kamu destekleri ve Avrupa Birliği uyum sürecinde sürdürülebilir tarım vurgusu bu çalışmanın bulguları, politika yapıcıların yatırımlarını teşvik etmesi ve çiftçilerin bu teknolojileri benimsemesi için güçlü bir referans oluşturmaktadır.

9.5 Öneriler

Tezin bulgularına dayanarak farklı paydaşlar için kapsamlı ve uygulanabilir öneriler sunulmaktadır. Bu öneriler hem metodolojik iyileştirmeler hem de pratik uygulamaların yaygınlaştırılması için yol gösterici niteliktedir.

Gelecek araştırmalar, tüm sezon boyunca farklı fenolojik dönemlerde görüntüleme yaparak yabani ot dinamiklerini izlemelidir. Bu çalışma V3-V4 aşamasında

%99.18-99.48 doğruluk elde etmiştir ancak farklı gelişim dönemlerinde model performansı değişebilir. Dönemsel CNN veya dönüştürücü modeller kullanılarak zaman serisi analizi yapılmalı ve yabani ot çıkış zamanı, büyüme hızı, herbisit sonrası kontrol etkinliği ve yeniden çıkış olgusu değerlendirilmelidir. Çok zamanlı veri optimal müdahale zamanını belirlemede ve erken uyarı sistemleri geliştirmede kritik öneme sahiptir.

Bu tezde tüm yabani otlar tek bir "Yabani ot" sınıfında toplanmış ve %99-100 kesinlik ile tespit edilmiştir. Gelecek çalışmalarda yaygın yabani ot türleri ayrı sınıflar olarak tanımlanmalıdır. Geniş yapraklı yabani otlar (köygöçüren, domuzpıtrağı, sirken), dar yapraklı (darıcan, tilki kuyruğu, köpek dişi), çok yıllık ve tek yıllık yabanilerde uygulanabilir. Her tür için spesifik herbisit önerileri verilmesi, kontrol etkinliğini artıracak ve herbisit direnci riskini azaltacaktır. Her tür için en az 500-1000 görüntü içeren dengeli veri setleri oluşturulabilir.

Uygulanan yama bazlı veri bölme yaklaşımı belirli metodolojik sınırlılıklar barındırmaktadır. 50×50 piksellik yamalar rastgele eğitim ve test setlerine ayrılırken aynı bitkiye ait komşu yamaların her iki sete de dağılmış olma ihtimali göz ardı edilemez. Bu durum, modelin gerçek anlamda sınıflar arası ayırt edici özellikler öğrenmek yerine kısmen bitkiye özgü doku ve renk örüntülerini ezberleyerek yüksek doğruluk değerlerine ulaşmış olabileceğine işaret etmektedir. Literatürde bu olgu veri sızıntısı olarak tanımlanmakta ve raporlanan performans metriklerinin gerçek saha genellemesini aşmasına neden olabilmektedir. Bununla birlikte çalışmada iki coğrafi olarak birbirinden bağımsız test alanının kullanılması ve ImageNet ön eğitimli ağırlıklarla gerçekleştirilen öğrenim aktarımı modelin yalnızca tek bir tarlanın doku özelliklerine bağımlı kalmadığına dair önemli bir kanıt sunmaktadır. Gelecek çalışmalarda bu sınırlılığın giderilmesi amacıyla bitki bazlı çapraz doğrulama yaklaşımının benimsenmesi ve aynı bitkiye ait yamaların kesin olarak ayrı setlere atanması önerilmektedir.

Model ayçiçeği dışındaki ürünlerde (mısır, pamuk, buğday, şeker pancarı, soya, kanola) test edilmelidir. Transfer öğrenimi yaklaşımı ile ayçiçeği modelinin ağırlıkları başlangıç noktası olarak kullanılmalı ve yeni ürün üzerinde 5-10 epoch ince ayar yapılmalıdır. Çoklu ürün modeller geliştirilmeli ve modelin ürün türünü ek girdi olarak alarak farklı ürünlerde sınıflandırma yapmalıdır. Bu yaklaşım her ürün için ayrı model tutmak yerine evrensel bir model kullanımına olanak tanır.

Bu çalışmada, multispektral bantlar sadece %0.30 puan iyileşme sağlamıştır. Gelecek çalışmalarda hiperspektral görüntüleme kullanılarak spektral bilgi zenginleştirilmelidir. Ayçiçeği ve farklı yabani otların türlerinin klorofil ve su içeriği hiperspektral bantlarda detaylı olarak ayırt edilebilir. Spektral indeksler hesaplanmalı ve model girdisi olarak kullanılmalıdır.

9.6 Açıklamalar

Tez çalışması ayçiçeği tarlalarında tarlaya özgü yabani ot yönetimi uygulamaları için dönüştürücü tabanlı derin öğrenme modellerinin başarıyla geliştirildiğini test edildiğini ve pratik olarak uygulanabilir olduğunu kapsamlı bir şekilde kanıtlamıştır. Dört farklı modelin (ViT, ViT Pruned, MobileNetV2, NASNetMobile) iki farklı bant kombinasyonunda (KYM, multispektral) sistematik karşılaştırması transformer mimarisinin CNN'lere göre belirgin üstünlüğünü ortaya koymuştur. Vision Transformer, %99.18-99.48 test doğruluğu, %99-100 yabani ot kesinlik ve neredeyse mükemmel performansla literatürdeki en yüksek değerlere ulaşmıştır.

Araştırmanın en önemli özgün katkısı erken dönem önleyici müdahale stratejisinin gösterilmesidir. ViT Pruned modelinin geliştirilmesi doğruluk-verimlilik dengesinde bir başarı olmuştur. %50 model boyutu azaltma ve %87 hız artışına karşılık sadece %0.73 doğruluk kaybı, son cihazlarında uygulama için ideal bir çözüm sunmuştur. 192.3 görüntü/sn işleme hızı ile gerçek zamanlı uygulamalar için yeterli performans, 164 MB model boyutu ile sınırlı bellek kaynaklarına uygunluk ve %98.45-98.75 doğruluk ile güvenilir tespit kapasitesi ViT budanmış modeli üretim sistemleri için optimal seçim haline getirmiştir.

Yama bazlı yaklaşım erken dönem küçük bitkilerin tespiti için optimal olduğu kanıtlanmıştır. Her yama VRA sistemleri için bir karar birimi olarak direkt kullanılabilmekte ve herbisit reçete haritaları operasyonel olarak oluşturulabilmektedir. GPS koordinatlarıyla eşleştirilmiş binary kararlar (herbisit UYGULA / UYGULAMA), modern tarım ekipmanlarına sorunsuzca entegre edilmektedir.

Türkiye perspektifinden hassas tarımın yaygınlaştırılması önemli fırsatlar sunmaktadır. Türkiye, 23.6 milyon hektar ekilebilir alan çeşitli iklim bölgeleri ve dinamik tarım sektörü ile büyük bir potansiyele sahiptir. Ayçiçeği dünya üretiminde

5. sırada önemli bir ürün olup, bu çalışmanın bulguları direkt olarak Türkiye'deki ayçiçeği üreticilerine uygulanabilir.

Ancak teknoloji kabulü için bazı engeller bulunmaktadır. Yüksek başlangıç yatırımı teknik bilgi eksikliği, parçalı tarım yapısı, kırsal altyapı yetersizliği ve değişime direnç olabilir. Bu engellerin aşılması için bu çalışmada sunulan kapsamlı öneriler uygulanmalıdır. Mali destekler, eğitim programları, altyapı yatırımları, kooperatif modelleri, uygun fiyatlandırma, yerel servis ağı gibi politika yapıcıların, üniversitelerin, özel sektörün ve çiftçi örgütlerinin koordineli çalışması başarılı yaygınlaştırmanın anahtarıdır.

Gelecek nesil tarım sistemleri yapay zekâ destekli karar verme, otonom robotlar, gerçek zamanlı izleme, sensör füzyonu ve veri odaklı yönetim içerecektir. Bu vizyon bilim kurgu değil yakın gelecektir. Geliştirilen modeller metodoloji ve bulgular gelecek araştırmalar için sağlam bir temel oluşturmakta ve hassas tarımın yaygınlaştırılmasına önemli katkı sağlama potansiyeline sahiptir.

Son olarak bu tezde sürdürülebilir tarım hedeflerine ulaşmada teknolojinin rolünü vurgulamaktadır. Daha az kimyasal kullanımı, daha yüksek verim daha düşük maliyet ve daha sağlıklı çevre birbirleriyle çelişmeyen hedeflerdir. Bu çalışmanın bulguları ve önerileri sürdürülebilir tarım vizyonunu gerçeğe dönüştürmede anlamlı bir katkı sunmaktadır.

Dünya nüfusunun artması, iklim değişikliği ve kaynak kısıtları karşısında tarım sektörü büyük bir dönüşüm yaşamaktadır. Geleneksel "daha fazla kimyasal ve daha fazla üretim" paradigması yerini "daha akıllı yöntemler ve daha verimli üretim" paradigmasına bırakmaktadır. Hassas tarım bu yeni paradigmanın öncüsüdür ve bu çalışma, onun tarımsal ve çevresel faydalarını somut verilerle göstermiştir. Tezin sonuçları hem bilimsel literatüre özgün katkılar sağlamış hem de pratik uygulamaya yönelik eylem planları sunmuştur. Görüntü dönüştürücülerin %99.18-99.48 doğruluğu tarlaya özgü yaklaşımın %54-60 herbisit tasarrufu ve erken dönem stratejisinin verim koruma potansiyeli ve hassas tarımın sadece bir teknoloji değil tarımın geleceği olduğunu kanıtlamaktadır.

KAYNAKÇA

[1] P. Barbaś, B. Sawicka, B. K. Marczak, and P. Pszczółkowski, "Effect of mechanical and herbicide treatments on weed densities and biomass in two potato cultivars," Agriculture (Switzerland), vol. 10, no. 10, pp. 1–17, Oct. 2020, doi: 10.3390/agriculture10100455.

[2] M. Hasan, M. S. Ahmad-Hamdani, A. M. Rosli, and H. Hamdan, "Bioherbicides: An eco-friendly tool for sustainable weed management," Jun. 01, 2021, MDPI AG. doi: 10.3390/plants10061212.

[3] J. H. Westwood et al., "Weed Management in 2050: Perspectives on the Future of Weed Science," Weed Sci., vol. 66, no. 3, pp. 275–285, May 2018, doi: 10.1017/wsc.2017.78.

[4] I. Mahé et al., "Soil seedbank: Old methods for new challenges in agroecology?," Jan. 01, 2021, Blackwell Publishing Ltd. doi: 10.1111/aab.12619.

[5] C. Maclaren, J. Storkey, A. Menegat, H. Metcalfe, and K. Dehnen-Schmutz, "An ecological future for weed science to sustain crop production and the environment. A review," Agron. Sustain. Dev., vol. 40:24, 2020, doi: 10.1007/s13593-020-00631-6/Published.

[6] Mst. Motmainna, A. Shukor B Juraimi, M. Kamal Uddin, N. Binti Asib, A. Mominul Islam, and M. Hasan, "Allelopathic potential of Malaysian invasive weed species to control weedy rice (Oryza sativa f. spontanea Roshev)," Allelopathy Journal, vol. 53, no. 1, pp. 53–68, May 2021, doi: 10.26651/allelo.j/2021-53-1-1327.

[7] A. T. Adetunji, B. Ncube, R. Mulidzi, and F. B. Lewu, "Management impact and benefit of cover crops on soil quality: A review," Oct. 01, 2020, Elsevier B.V. doi: 10.1016/j.still.2020.104717.

[8] M. Motmainna, A. S. B. Juraimi, M. K. Uddin, N. B. Asib, A. K. M. Mominul Islam, and M. Hasan, "Assessment of allelopathic compounds to develop new natural herbicides: A review," Allelopathy Journal, vol. 52, no. 1, pp. 19–37, Jan. 2021, doi: 10.26651/allelo.j/2021-51-1-1305.

[9] M. C. Oliveira, O. A. Osipitan, K. Begcy, and R. Werle, "Cover crops, hormones and herbicides: Priming an integrated weed management strategy," Dec. 01, 2020, Elsevier Ireland Ltd. doi: 10.1016/j.plantsci.2020.110550.

[10] K. Hu, G. Coleman, S. Zeng, Z. Wang, and M. Walsh, "Graph weeds net: A graph-based deep learning method for weed recognition," Comput. Electron. Agric., vol. 174, Jul. 2020, doi: 10.1016/j.compag.2020.105520.

[11] D. Bini, D. Pamela, and S. Prince, "Machine Vision and Machine Learning for Intelligent Agrobots: A review," in ICDCS 2020 - 2020 5th International Conference on Devices, Circuits and Systems, Institute of Electrical and

Electronics Engineers Inc., Mar. 2020, pp. 12–16. doi: 10.1109/ICDCS48716.2020.243538.

[12] A. I. de Castro, J. Torres-Sánchez, J. M. Peña, F. M. Jiménez-Brenes, O. Csillik, and F. López-Granados, "An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV imagery," Remote Sens. (Basel)., vol. 10, no. 2, Feb. 2018, doi: 10.3390/rs10020285.

[13] A. Joshi, B. Pradhan, S. Gite, and S. Chakraborty, "Remote-Sensing Data and Deep-Learning Techniques in Crop Mapping and Yield Prediction: A Systematic Review," Apr. 01, 2023, MDPI. doi: 10.3390/rs15082014.

[14] K. F. Davis, J. A. Gephart, K. A. Emery, A. M. Leach, J. N. Galloway, and P. D'Odorico, "Meeting future food demand with current agricultural resources," Global Environmental Change, vol. 39, pp. 125–132, Jul. 2016, doi: 10.1016/j.gloenvcha.2016.05.004.

[15] R. Nishimoto, "Global trends in the crop protection industry," 2019, Pesticide Science Society of Japan. doi: 10.1584/jpestics.D19-101.

[16] F. Ahmed et al., "The addition of submergence-tolerant Sub1 gene into high yielding MR219 rice variety and analysis of its BC2F3 population in terms of yield and yield contributing characters to select advance lines as a variety," Biotechnology and Biotechnological Equipment, vol. 30, no. 5, pp. 853–863, Sep. 2016, doi: 10.1080/13102818.2016.1192959.

[17] B. S. Chauhan, "Grand Challenges in Weed Management," Jan. 22, 2020, Frontiers Media S.A. doi: 10.3389/fagro.2019.00003.

[18] C. S. Sheppard, B. R. Burns, and M. C. Stanley, "Future-proofing weed management for the effects of climate change: Is new zealand underestimating the risk of increased plant invasions?," N. Z. J. Ecol., vol. 40, no. 3, pp. 398–405, 2016, doi: 10.20417/nzjecol.40.45.

[19] B. Scherrer, J. Sheppard, P. Jha, and J. A. Shaw, "Hyperspectral imaging and neural networks to classify herbicide-resistant weeds," J. Appl. Remote Sens., vol. 13, no. 04, p. 1, Nov. 2019, doi: 10.1117/1.jrs.13.044516.

[20] M. Hasan, A. S. Mokhtar, A. M. Rosli, H. Hamdan, M. Motmainna, and M. S. Ahmad-Hamdani, "Weed control efficacy and crop-weed selectivity of a new bioherbicide weedlock," Agronomy, vol. 11, no. 8, Aug. 2021, doi: 10.3390/agronomy11081488.

[21] L. B. Piveta et al., "Molecular and physiological responses of rice and weedy rice to heat and drought stress †," Agriculture (Switzerland), vol. 11, no. 1, pp. 1–23, Jan. 2021, doi: 10.3390/agriculture11010009.

[22] R. A. Jussaume and D. Ervin, "Understanding Weed Resistance as a Wicked Problem to Improve Weed Management Decisions," Weed Sci., vol. 64, no. SP1, pp. 559–569, Sep. 2016, doi: 10.1614/ws-d-15-00131.1.

[23] R. Busi et al., "Weed resistance to synthetic auxin herbicides," Oct. 01, 2018, John Wiley and Sons Ltd. doi: 10.1002/ps.4823.

[24] H. J. Beckie and K. N. Harker, "Our top 10 herbicide-resistant weed management practices," Pest Manag. Sci., vol. 73, no. 6, pp. 1045–1052, Jun. 2017, doi: 10.1002/ps.4543.

[25] A. R. Kniss, “Genetically Engineered Herbicide-Resistant Crops and Herbicide-Resistant Weed Evolution in the United States,” Weed Sci., vol. 66, no. 2, pp. 260–273, Mar. 2018, doi: 10.1017/wsc.2017.70.

[26] F. López-Granados, “Weed detection for site-specific weed management: Mapping and real-time approaches,” Weed Res., vol. 51, no. 1, pp. 1–11, Feb. 2011, doi: 10.1111/j.1365-3180.2010.00829.x.

[27] M. Esposito, M. Crimaldi, V. Cirillo, F. Sarghini, and A. Maggio, “Drone and sensor technology for sustainable weed management: a review,” Dec. 01, 2021, Springer Science and Business Media Deutschland GmbH. doi: 10.1186/s40538-021-00217-8.

[28] V. Seufert, N. Ramankutty, and T. Mayerhofer, “What is this thing called organic? – How organic farming is codified in regulations,” Food Policy, vol. 68, pp. 10–20, Apr. 2017, doi: 10.1016/j.foodpol.2016.12.009.

[29] A. Szparaga et al., “Towards sustainable agriculture-agronomic and economic effects of biostimulant use in common bean cultivation,” Sustainability (Switzerland), vol. 11, no. 17, Sep. 2019, doi: 10.3390/su11174575.

[30] E. Alreshidi, “Smart Sustainable Agriculture (SSA) Solution Underpinned by Internet of Things (IoT) and Artificial Intelligence (AI),” 2019. [Online]. Available: www.ijacsa.thesai.org

[31] G. B. Kayin, H. Kayin, and A. T. Goksoy, “Effects Of Plant Density On Micronutrient Uptake In Sunflower (Helianthus annuus L.) Varieties,” Turkish Journal of Field Crops, vol. 29, no. 1, pp. 9–17, 2024, doi: 10.17557/tjfc.1349344.

[32] Y. Bai et al., “A fast and robust method for plant count in sunflower and maize at different seedling stages using high-resolution UAV RGB imagery,” Precis. Agric., vol. 23, no. 5, pp. 1720–1742, Oct. 2022, doi: 10.1007/s11119-022-09907-1.

[33] E. Tunca, E. S. Köksal, S. Çetin, N. M. Ekiz, and H. Balde, “Yield and leaf area index estimations for sunflower plants using unmanned aerial vehicle images,” Environ. Monit. Assess., vol. 190, no. 11, Nov. 2018, doi: 10.1007/s10661-018-7064-x.

[34] B. A. M Ashqar and S. S. Abu-Naser, “Plant Seedlings Classification Using Deep Learning.” [Online]. Available: www.ijeais.org/ijaisr

[35] T. M. Giselsson, R. N. Jørgensen, P. K. Jensen, M. Dyrmann, and H. S. Midtiby, “A Public Image Database for Benchmark of Plant Seedling Classification Algorithms,” Nov. 2017, [Online]. Available: http://arxiv.org/abs/1711.05458

[36] E. Assunção et al., “Real-Time Image Detection for Edge Devices: A Peach Fruit Detection Application,” Future Internet, vol. 14, no. 11, Nov. 2022, doi: 10.3390/fi14110323.

[37] R. Arumuga Arun and S. Umamaheswari, “Effective multi-crop disease detection using pruned complete concatenated deep learning model,” Expert Syst. Appl., vol. 213, Mar. 2023, doi: 10.1016/j.eswa.2022.118905.

[38] S. Mohana Saranya et al., “Optimized Deep Convolutional Generative Adversarial Network for Tomato Leaf Disease Identification,” in Proceedings of the 5th International Conference on Electronics, Communication and Aerospace Technology, ICECA 2021, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 1301–1307. doi: 10.1109/ICECA52323.2021.9675945.

[39] R. M. Prakash, M. Vimala, K. Ramalakshmi, M. B. Prakash, A. Krishnamoorthi, and R. S. S. Kumari, “Crop Disease Detection and Classification with Transfer learning and hyper-parameters optimized Convolutional neural network,” in Proceedings of the 2022 3rd International Conference on Intelligent Computing, Instrumentation and Control Technologies: Computational Intelligence for Smart Systems, ICICICT 2022, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 1608–1613. doi: 10.1109/ICICICT54557.2022.9917901.

[40] G. G. Peteinatos, P. Reichel, J. Karouta, D. Andújar, and R. Gerhards, “Weed identification in Maize, sunflower, and potatoes with the aid of convolutional neural networks,” Remote Sens. (Basel)., vol. 12, no. 24, pp. 1–22, Dec. 2020, doi: 10.3390/rs12244185.

[41] D. Murugan, A. Garg, and D. Singh, “Development of an Adaptive Approach for Precision Agriculture Monitoring with Drone and Satellite Data,” IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens., vol. 10, no. 12, pp. 5322–5328, Dec. 2017, doi: 10.1109/JSTARS.2017.2746185.

[42] K. Iwasaki et al., “Spatial pattern of windbreak effects on maize growth evaluated by an unmanned aerial vehicle in Hokkaido, northern Japan,” Agroforestry Systems, vol. 93, no. 3, pp. 1133–1145, Jun. 2019, doi: 10.1007/s10457-018-0217-7.

[43] A. Suhaizi, M. Su, A. Yahya, N. Mazlan, M. Saiful, and A. Hamdani, “Evaluation of the Spraying Dispersion and Uniformity Using Drone in Rice Field Application,” 2018. [Online]. Available: https://www.researchgate.net/publication/323336273

[44] M. Gao, F. Yang, H. Wei, and X. Liu, “Automatic Monitoring of Maize Seedling Growth Using Unmanned Aerial Vehicle-Based RGB Imagery,” Remote Sens. (Basel)., vol. 15, no. 14, Jul. 2023, doi: 10.3390/rs15143671.

[45] L. Prey, M. von Bloh, and U. Schmidhalter, “Evaluating RGB imaging and multispectral active and hyperspectral passive sensing for assessing early plant vigor in winter wheat,” Sensors (Switzerland), vol. 18, no. 9, Sep. 2018, doi: 10.3390/s18092931.

[46] D. Andújar, A. Escolà, J. R. Rosell-Polo, C. Fernández-Quintanilla, and J. Dorado, “Potential of a terrestrial LiDAR-based system to characterise weed vegetation in maize crops,” Comput. Electron. Agric., vol. 92, pp. 11–15, 2013, doi: 10.1016/j.compag.2012.12.012.

[47] S. L. Madsen, S. K. Mathiassen, M. Dyrmann, M. S. Laursen, L. C. Paz, and R. N. Jørgensen, “Open plant phenotype database of common weeds in Denmark,” Remote Sens. (Basel)., vol. 12, no. 8, Apr. 2020, doi: 10.3390/RS12081246.

[48] S. Ahirwar, R. Swarnkar, S. Bhukya, and G. Namwade, “Application of Drone in Agriculture,” Int. J. Curr. Microbiol. Appl. Sci., vol. 8, no. 01, pp. 2500–2505, Jan. 2019, doi: 10.20546/ijcmas.2019.801.264.

[49] D. Saha, “Development of Enhanced Weed Detection System with Adaptive Development of Enhanced Weed Detection System with Adaptive Thresholding, K-Means and Support Vector Machine Thresholding, K-Means and Support Vector Machine.” [Online]. Available: https://openprairie.sdstate.edu/etd

[50] F. Veroustraete, “The Rise of the Drones in Agriculture Cronicon AGRICULTURE Editorial The Rise of the Drones in Agriculture.” [Online]. Available: https://www.researchgate.net/publication/282093589

[51] A. Muazu, A. Yahya, W. I. W. Ishak, and S. Khairunniza-Bejo, “Energy audit for sustainable wetland paddy cultivation in Malaysia,” Energy, vol. 87, pp. 182–191, Jul. 2015, doi: 10.1016/j.energy.2015.04.066.

[52] P. Tripicchio, M. Satler, G. Dabisias, E. Ruffaldi, and C. A. Avizzano, “Towards Smart Farming and Sustainable Agriculture with Drones,” in Proceedings - 2015 International Conference on Intelligent Environments, IE 2015, Institute of Electrical and Electronics Engineers Inc., Aug. 2015, pp. 140–143. doi: 10.1109/IE.2015.29.

[53] J. Zhao, T. W. Berge, and J. Geipel, “Transformer in UAV Image-Based Weed Mapping,” Remote Sens. (Basel)., vol. 15, no. 21, Nov. 2023, doi: 10.3390/rs15215165.

[54] Z. Wu, Y. Chen, B. Zhao, X. Kang, and Y. Ding, “Review of weed detection methods based on computer vision,” Jun. 01, 2021, MDPI AG. doi: 10.3390/s21113647.

[55] H. Xiang and L. Tian, “Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV),” Biosyst. Eng., vol. 108, no. 2, pp. 174–190, 2011, doi: 10.1016/j.biosystemseng.2010.11.010.

[56] R. Mink, A. I. Linn, H. J. Santel, and R. Gerhards, “Sensor-based evaluation of maize (Zea mays) and weed response to post-emergence herbicide applications of Isoxaflutole and Cyprosulfamide applied as crop seed treatment or herbicide mixing partner,” Pest Manag. Sci., vol. 76, no. 5, pp. 1856–1865, May 2020, doi: 10.1002/ps.5715.

[57] R. Mink et al., “Multi-temporal site-specific weed control of Cirsium arvense (L.) scop. and Rumex crispus L. in maize and sugar beet using unmanned aerial vehicle based mapping,” Agriculture (Switzerland), vol. 8, no. 5, May 2018, doi: 10.3390/agriculture8050065.

[58] J. P. Baresel, P. Rischbeck, Y. Hu, S. Kipp, G. Barmeier, and B. Mistele, “Use of a digital camera as alternative method for non-destructive detection of the leaf chlorophyll content and the nitrogen nutrition status in wheat,” Comput. Electron. Agric., vol. 140, pp. 25–33, Aug. 2017, doi: 10.1016/j.compag.2017.05.032.

[59] S. C. Hassler and F. Baysal-Gurel, “Unmanned aircraft system (UAS) technology and applications in agriculture,” Oct. 09, 2019, MDPI AG. doi: 10.3390/agronomy9100618.

[60] J. Li, F. Zhang, X. Qian, Y. Zhu, and G. Shen, “Quantification of rice canopy nitrogen balance index with digital imagery from unmanned aerial vehicle,” Remote Sensing Letters, vol. 6, no. 3, pp. 183–189, Mar. 2015, doi: 10.1080/2150704X.2015.1021934.

[61] K. Sudars, J. Jasko, I. Namatevs, L. Ozola, and N. Badaukis, “Dataset of annotated food crops and weed images for robotic computer vision control,” Data Brief, vol. 31, Aug. 2020, doi: 10.1016/j.dib.2020.105833.

[62] Y. Zhang et al., “Automated spectral feature extraction from hyperspectral images to differentiate weedy rice and barnyard grass from a rice crop,” Comput. Electron. Agric., vol. 159, pp. 42–49, Apr. 2019, doi: 10.1016/j.compag.2019.02.018.

[63] T. DeVries and G. W. Taylor, “Improved Regularization of Convolutional Neural Networks with Cutout,” Aug. 2017, [Online]. Available: http://arxiv.org/abs/1708.04552

[64] B. Liu and R. Bruch, “Weed Detection for Selective Spraying: a Review,” Current Robotics Reports, vol. 1, no. 1, pp. 19–26, Mar. 2020, doi: 10.1007/s43154-020-00001-w.

[65] S. A. Fennimore and D. J. Doohan, “The Challenges of Specialty Crop Weed Control, Future Directions,” Weed Technology, vol. 22, no. 2, pp. 364–372, Apr. 2008, doi: 10.1614/wt-07-102.1.

[66] E. Mosqueda, R. Smith, D. Goorahoo, and A. Shrestha, “Automated lettuce thinners reduce labor requirements and increase speed of thinning: Automated thinners were as accurate in thinning lettuce as manual thinning, produced comparable yields, and were more than three times faster than thinning crews.,” Calif. Agric. (Berkeley)., vol. 72, no. 2, pp. 114–119, Apr. 2018, doi: 10.3733/ca.2017a0018.

[67] S. T. March and G. F. Smith, “Design and natural science research on information technology,” 1995.

[68] Y. Zhang and D. C. Slaughter, “Influence of solar irradiance on hyperspectral imaging-based plant recognition for autonomous weed control,” Biosyst. Eng., vol. 110, no. 3, pp. 330–339, 2011, doi: 10.1016/j.biosystemseng.2011.09.006.

[69] Y. Zhang, E. S. Staab, D. C. Slaughter, D. K. Giles, and D. Downey, “Automated weed control in organic row crops using hyperspectral species identification and thermal micro-dosing,” Crop Protection, vol. 41, pp. 96–105, Nov. 2012, doi: 10.1016/j.cropro.2012.05.007.

[70] B. Melander, B. Lattanzi, and E. Pannacci, “Intelligent versus non-intelligent mechanical intra-row weed control in transplanted onion and cabbage,” Crop Protection, vol. 72, pp. 1–8, Jun. 2015, doi: 10.1016/j.cropro.2015.02.017.

[71] Y. Zhang, D. C. Slaughter, and E. S. Staab, “Robust hyperspectral vision-based classification for multi-season weed mapping,” ISPRS Journal of

Photogrammetry and Remote Sensing, vol. 69, pp. 65–73, Apr. 2012, doi: 10.1016/j.isprsjprs.2012.02.006.

[72] M. Pérez-Ruiz, D. C. Slaughter, C. J. Gliever, and S. K. Upadhyaya, "Automatic GPS-based intra-row weed knife control system for transplanted row crops," Jan. 2012. doi: 10.1016/j.compag.2011.10.006.

[73] M. Perez-Ruiz, D. C. Slaughter, C. Gliever, and S. K. Upadhyaya, "Tractor-based Real-time Kinematic-Global Positioning System (RTK-GPS) guidance system for geospatial mapping of row crop transplant," Biosyst. Eng., vol. 111, no. 1, pp. 64–71, 2012, doi: 10.1016/j.biosystemseng.2011.10.009.

[74] Z. Zhou, X. Chen, E. Li, L. Zeng, K. Luo, and J. Zhang, "Edge Intelligence: Paving the Last Mile of Artificial Intelligence With Edge Computing," Proceedings of the IEEE, vol. 107, no. 8, pp. 1738–1762, Aug. 2019, doi: 10.1109/JPROC.2019.2918951.

[75] J. Liu, J. Xiang, Y. Jin, R. Liu, J. Yan, and L. Wang, "Boost precision agriculture with unmanned aerial vehicle remote sensing and edge intelligence: A survey," Remote Sens. (Basel)., vol. 13, no. 21, Nov. 2021, doi: 10.3390/rs13214387.

[76] F. Li et al., "A Remote Sensing and Airborne Edge-Computing Based Detection System for Pine Wilt Disease," IEEE Access, vol. 9, pp. 66346–66360, 2021, doi: 10.1109/ACCESS.2021.3073929.

[77] F. Wang, M. Zhang, X. Wang, X. Ma, and J. Liu, "Deep Learning for Edge Computing Applications: A State-of-the-Art Survey," IEEE Access, vol. 8, pp. 58322–58336, 2020, doi: 10.1109/ACCESS.2020.2982411.

[78] J. Alzubi, A. Nayyar, and A. Kumar, "Machine Learning from Theory to Algorithms: An Overview," in Journal of Physics: Conference Series, Institute of Physics Publishing, Nov. 2018. doi: 10.1088/1742-6596/1142/1/012012.

[79] A. Chlingaryan, S. Sukkarieh, and B. Whelan, "Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review," Aug. 01, 2018, Elsevier B.V. doi: 10.1016/j.compag.2018.05.012.

[80] D. Goel, B. Kapur, and P. P. Vuppuluri, "Machine Learning Interventions for Weed Detection using Multispectral Imagery and Unmanned Aerial Vehicles -- A Systematic Review," Aug. 2024, [Online]. Available: http://arxiv.org/abs/2408.06727

[81] A. Gandhar, K. Gupta, A. K. Pandey, and D. Raj, "Fraud Detection Using Machine Learning and Deep Learning," Jun. 01, 2024, Springer. doi: 10.1007/s42979-024-02772-x.

[82] M. E. Atik, Z. Duran, and D. Z. Seker, "Machine learning-based supervised classification of point clouds using multiscale geometric features," ISPRS Int. J. Geoinf., vol. 10, no. 3, Mar. 2021, doi: 10.3390/ijgi10030187.

[83] J. Gao, D. Nuyttens, P. Lootens, Y. He, and J. G. Pieters, "Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery," Biosyst. Eng., vol. 170, pp. 39–50, Jun. 2018, doi: 10.1016/j.biosystemseng.2018.03.006.

[84] S. Amini, M. Saber, H. Rabiei-Dastjerdi, and S. Homayouni, “Urban Land Use and Land Cover Change Analysis Using Random Forest Classification of Landsat Time Series,” Remote Sens. (Basel)., vol. 14, no. 11, Jun. 2022, doi: 10.3390/rs14112654.

[85] T. Noi Phan, V. Kuch, and L. W. Lehnert, “Land cover classification using google earth engine and random forest classifier-the role of image composition,” Remote Sens. (Basel)., vol. 12, no. 15, Aug. 2020, doi: 10.3390/RS12152411.

[86] X. Lu, X. Zheng, and Y. Yuan, “Remote sensing scene classification by unsupervised representation learning,” IEEE Transactions on Geoscience and Remote Sensing, vol. 55, no. 9, pp. 5148–5157, Sep. 2017, doi: 10.1109/TGRS.2017.2702596.

[87] X. Tang, X. Zhang, F. Liu, and L. Jiao, “Unsupervised deep feature learning for remote sensing image retrieval,” Remote Sens. (Basel)., vol. 10, no. 8, Aug. 2018, doi: 10.3390/rs10081243.

[88] M. Louargant et al., “Unsupervised classification algorithm for early weed detection in row-crops by combining spatial and spectral information,” Remote Sens. (Basel)., vol. 10, no. 5, May 2018, doi: 10.3390/rs10050761.

[89] J. Chen and X. Ran, “Deep Learning with Edge Computing: A Review,” Aug. 01, 2019, Institute of Electrical and Electronics Engineers Inc. doi: 10.1109/JPROC.2019.2921977.

[90] A. L. Chandra, S. V. Desai, W. Guo, and V. N. Balasubramanian, “Computer Vision with Deep Learning for Plant Phenotyping in Agriculture: A Survey,” Jun. 2020, doi: 10.34048/ACC.2020.1.F1.

[91] Q. Du, N. Bin Chang, C. Yang, and K. R. Srilakshmi, “Combination of multispectral remote sensing, variable rate technology and environmental modeling for citrus pest management,” J. Environ. Manage., vol. 86, no. 1, pp. 14–26, 2008, doi: 10.1016/j.jenvman.2006.11.019.

[92] A. Zohrevand and Z. Imani, “An Empirical Study of the Performance of Different Optimizers in the Deep Neural Networks,” in Iranian Conference on Machine Vision and Image Processing, MVIP, IEEE Computer Society, 2022. doi: 10.1109/MVIP53647.2022.9738743.

[93] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” May 27, 2015, Nature Publishing Group. doi: 10.1038/nature14539.

[94] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” Commun. ACM, vol. 60, no. 6, pp. 84–90, Jun. 2017, doi: 10.1145/3065386.

[95] G. Hinton, O. Vinyals, and J. Dean, “Distilling the Knowledge in a Neural Network,” Mar. 2015, [Online]. Available: http://arxiv.org/abs/1503.02531

[96] A. Kamilaris and F. X. Prenafeta-Boldú, “Deep learning in agriculture: A survey,” Apr. 01, 2018, Elsevier B.V. doi: 10.1016/j.compag.2018.02.016.

[97] B. Fetai, M. Račič, and A. Lisec, “Deep learning for detection of visible land boundaries from uav imagery,” Remote Sens. (Basel)., vol. 13, no. 11, Jun. 2021, doi: 10.3390/rs13112077.

[98] R. Miotto, F. Wang, S. Wang, X. Jiang, and J. T. Dudley, “Deep learning for healthcare: Review, opportunities and challenges,” Brief. Bioinform., vol. 19, no. 6, pp. 1236–1246, May 2017, doi: 10.1093/bib/bbx044.

[99] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision,” in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, IEEE Computer Society, Dec. 2016, pp. 2818–2826. doi: 10.1109/CVPR.2016.308.

[100] M. Dyrmann, H. Karstoft, and H. S. Midtiby, “Plant species classification using deep convolutional neural network,” Biosyst. Eng., vol. 151, pp. 72–80, Nov. 2016, doi: 10.1016/J.BIOSYSTEMSENG.2016.08.024.

[101] A. Kamilaris and F. X. Prenafeta-Boldú, “A review of the use of convolutional neural networks in agriculture,” Apr. 01, 2018, Cambridge University Press. doi: 10.1017/S0021859618000436.

[102] S. Khan, M. Naseer, M. Hayat, S. W. Zamir, F. S. Khan, and M. Shah, “Transformers in Vision: A Survey,” Jan. 2021, doi: 10.1145/3505244.

[103] P. S. Thakur, S. Chaturvedi, P. Khanna, T. Sheorey, and A. Ojha, “Vision transformer meets convolutional neural network for plant disease classification,” Ecol. Inform., vol. 77, Nov. 2023, doi: 10.1016/j.ecoinf.2023.102245.

[104] R. Ranftl, A. Bochkovskiy, and V. Koltun, “Vision Transformers for Dense Prediction,” 2021. [Online]. Available: https://github.com/intel-isl/DPT.

[105] X. Zhai, A. Kolesnikov, N. Houlsby, and L. Beyer, “Scaling Vision Transformers,” Jun. 2021, [Online]. Available: http://arxiv.org/abs/2106.04560

[106] X. Li and S. Li, “Transformer Help CNN See Better: A Lightweight Hybrid Apple Disease Identification Model Based on Transformers,” Agriculture (Switzerland), vol. 12, no. 6, Jun. 2022, doi: 10.3390/agriculture12060884.

[107] H. M. Albarakati et al., “A Novel Deep Learning Architecture for Agriculture Land Cover and Land Use Classification from Remote Sensing Images Based on Network-Level Fusion of Self-Attention Architecture,” IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens., vol. 17, pp. 6338–6353, 2024, doi: 10.1109/JSTARS.2024.3369950.

[108] L. Beyer, X. Zhai, and A. Kolesnikov, “Better plain ViT baselines for ImageNet-1k,” May 2022, [Online]. Available: http://arxiv.org/abs/2205.01580

[109] K. Han et al., “A Survey on Visual Transformer,” Dec. 2020, doi: 10.1109/TPAMI.2022.3152247.

[110] S. Zuo, Y. Xiao, X. Chang, and X. Wang, “Vision transformers for dense prediction: A survey,” Knowl. Based. Syst., vol. 253, Oct. 2022, doi: 10.1016/j.knosys.2022.109552.

[111] M. S. Alzahrani and F. W. Alsaade, “Transform and Deep Learning Algorithms for the Early Detection and Recognition of Tomato Leaf Disease,” Agronomy, vol. 13, no. 5, May 2023, doi: 10.3390/agronomy13051184.

[112] Y. Bazi, L. Bashmal, M. M. Al Rahhal, R. Al Dayil, and N. Al Ajlan, “Vision transformers for remote sensing image classification,” Remote Sens. (Basel)., vol. 13, no. 3, pp. 1–20, Feb. 2021, doi: 10.3390/rs13030516.

[113] A. Vaswani et al., “Attention Is All You Need,” 2017.

[114] W. Chen et al., “A Simple Single-Scale Vision Transformer for Object Localization and Instance Segmentation,” Dec. 2021, [Online]. Available: http://arxiv.org/abs/2112.09747

[115] H. Shin, S. Jeon, Y. Seol, S. Kim, and D. Kang, “Vision Transformer Approach for Classification of Alzheimer’s Disease Using 18F-Florbetaben Brain Images,” Applied Sciences (Switzerland), vol. 13, no. 6, Mar. 2023, doi: 10.3390/app13063453.

[116] J. Kang, L. Liu, F. Zhang, C. Shen, N. Wang, and L. Shao, “Semantic segmentation model of cotton roots in-situ image based on attention mechanism,” Comput. Electron. Agric., vol. 189, Oct. 2021, doi: 10.1016/j.compag.2021.106370.

[117] J. Maurício, I. Domingues, and J. Bernardino, “Comparing Vision Transformers and Convolutional Neural Networks for Image Classification: A Literature Review,” May 01, 2023, MDPI. doi: 10.3390/app13095521.

[118] B. Gong, K. Dai, J. Shao, L. Jing, and Y. Chen, “Fish-TViT: A novel fish species classification method in multi water areas based on transfer learning and vision transformer,” Heliyon, vol. 9, no. 6, Jun. 2023, doi: 10.1016/j.heliyon.2023.e16761.

[119] R. Reedha, E. Dericquebourg, R. Canals, and A. Hafiane, “Transformer Neural Network for Weed and Crop Classification of High Resolution UAV Images,” Remote Sens. (Basel)., vol. 14, no. 3, Feb. 2022, doi: 10.3390/rs14030592.

[120] Z. Niu, G. Zhong, and H. Yu, “A review on the attention mechanism of deep learning,” Neurocomputing, vol. 452, pp. 48–62, Sep. 2021, doi: 10.1016/j.neucom.2021.03.091.

[121] Z. Xia, X. Pan, S. Song, L. Erran Li, and G. Huang, “Vision Transformer with Deformable Attention,” 2022. [Online]. Available: https://github.com/LeapLabTHU/DAT.

[122] F. Celik, F. Balik Sanli, and D. Bozic, “Transformer networks to classıfy weeds and crops ın hıgh-resolutıon aerıal ımages from north-east serbıa,” Turkish Journal of Field Crops, vol. 29, no. 2, pp. 112–120, 2024, doi: 10.17557/tjfc.1511404.

[123] Zhang Wenhao, Hansen Mark F., Wilson Jim, and Smith Lyndon, “Broad-Leaf Weed Detection in Pasture,” in 3rd IEEE International Conference on Image, Vision and Computing, 2018, pp. 101–105.

[124] P. R. Eddy, A. M. Smith, B. D. Hill, D. R. Peddle, C. A. Coburn, and R. E. Blackshaw, “Weed and crop discrimination using hyperspectral image data and reduced bandsets,” Canadian Journal of Remote Sensing, vol. 39, no. 6, pp. 481–490, 2014, doi: 10.5589/m14-001.

[125] M. Subramanian, K. Shanmugavadivel, and P. S. Nandhini, “On fine-tuning deep learning models using transfer learning and hyper-parameters

optimization for disease identification in maize leaves," Neural Comput. Appl., vol. 34, no. 16, pp. 13951–13968, Aug. 2022, doi: 10.1007/s00521-022-07246-w.

[126] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, IEEE Computer Society, Dec. 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.

[127] S. Awasthi et al., "Analyzing Joshimath's sinking: causes, consequences, and future prospects with remote sensing techniques," Sci. Rep., vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-60276-3.

[128] E. D. Cubuk, B. Zoph, D. Mane, V. Vasudevan, and Q. V. Le, "Autoaugment: Learning augmentation strategies from data," in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, IEEE Computer Society, Jun. 2019, pp. 113–123. doi: 10.1109/CVPR.2019.00020.

[129] M. H. Saleem, J. Potgieter, and K. M. Arif, "Plant disease classification: A comparative evaluation of convolutional neural networks and deep learning optimizers," Plants, vol. 9, no. 10, pp. 1–17, Oct. 2020, doi: 10.3390/plants9101319.

[130] J. Yang and G. Yang, "Modified convolutional neural network based on dropout and the stochastic gradient descent optimizer," Algorithms, vol. 11, no. 3, Mar. 2018, doi: 10.3390/a11030028.

[131] S. Ruder, "An overview of gradient descent optimization algorithms," Sep. 2016, [Online]. Available: http://arxiv.org/abs/1609.04747

[132] I. Goodfellow, Y. Bengio, and A. Courville, "Deep Learning."

[133] K. A. D. Idress, O. A. A. Gadalla, Y. B. Öztekin, and G. P. Baitu, "Machine Learning-based for Automatic Detection of Corn-Plant Diseases Using Image Processing," Tarim Bilimleri Dergisi, vol. 30, no. 3, pp. 464–476, 2024, doi: 10.15832/ankutbd.1288298.

[134] P. T. Jackson, A. Atapour-Abarghouei, S. Bonner, T. Breckon, and B. Obara, "Style Augmentation: Data Augmentation via Style Randomization," Sep. 2018, [Online]. Available: http://arxiv.org/abs/1809.05375

[135] C. Bowles et al., "GAN Augmentation: Augmenting Training Data using Generative Adversarial Networks," Oct. 2018, [Online]. Available: http://arxiv.org/abs/1810.10863

[136] S. Yun, D. Han, S. J. Oh, S. Chun, J. Choe, and Y. Yoo, "CutMix: Regularization Strategy to Train Strong Classifiers with Localizable Features," May 2019, [Online]. Available: http://arxiv.org/abs/1905.04899

[137] H. Zhang, M. Cisse, Y. N. Dauphin, and D. Lopez-Paz, "mixup: Beyond Empirical Risk Minimization," Oct. 2017, [Online]. Available: http://arxiv.org/abs/1710.09412

[138] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern

Recognition, IEEE Computer Society, Dec. 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.

[139] B. Zoph, V. Vasudevan, J. Shlens, and Q. V. Le, "Learning Transferable Architectures for Scalable Image Recognition," Apr. 2018, [Online]. Available: http://arxiv.org/abs/1707.07012

[140] A. Waleed Abdul Ameer, P. Salehpour, and M. Asadpour, "Deep Transfer Learning for Lip Reading Based on NASNetMobile Pretrained Model in Wild Dataset," IEEE Access, vol. 13, pp. 11623–11638, 2025, doi: 10.1109/ACCESS.2024.3470521.

[141] F. Celik, F. Balik Sanli, and D. Bozic, "Transformer Networks To Classıfy Weeds And Crops In Hıgh-Resolutıon Aerıal Images From North-East Serbıa," Turkish Journal of Field Crops, vol. 29, no. 2, pp. 112–120, 2024, doi: 10.17557/tjfc.1511404.

[142] M. Pérez-Ortiz, J. M. Peña, P. A. Gutiérrez, J. Torres-Sánchez, C. Hervás-Martínez, and F. López-Granados, "Selecting patterns and features for between- and within- crop-row weed mapping using UAV-imagery," Expert Syst. Appl., vol. 47, pp. 85–94, Apr. 2016, doi: 10.1016/j.eswa.2015.10.043.

[143] J. Rasmussen, J. Nielsen, F. Garcia-Ruiz, S. Christensen, and J. C. Streibig, "Potential uses of small unmanned aircraft systems (UAS) in weed research," Weed Res., vol. 53, no. 4, pp. 242–248, Aug. 2013, doi: 10.1111/wre.12026.

[144] M. Fawakherji, C. Potena, A. Pretto, D. D. Bloisi, and D. Nardi, "Multi-Spectral Image Synthesis for Crop/Weed Segmentation in Precision Farming," Rob. Auton. Syst., vol. 146, Dec. 2021, doi: 10.1016/j.robot.2021.103861.

[145] W. Kazmi, F. Garcia-Ruiz, J. Nielsen, J. Rasmussen, and H. J. Andersen, "Exploiting affine invariant regions and leaf edge shapes for weed detection," Comput. Electron. Agric., vol. 118, pp. 290–299, Oct. 2015, doi: 10.1016/j.compag.2015.08.023.

[146] A. dos Santos Ferreira, D. Matte Freitas, G. Gonçalves da Silva, H. Pistori, and M. Theophilo Folhes, "Weed detection in soybean crops using ConvNets," Comput. Electron. Agric., vol. 143, pp. 314–324, Dec. 2017, doi: 10.1016/j.compag.2017.10.027.

[147] A. Karthik, S. Mynampati, and D. Saraswathi, "A Hybrid CNN-ViT-GNN Framework with GAN-Based Augmentation for Intelligent Weed Detection in Precision Agriculture."

[148] I. Sa et al., "weedNet: Dense Semantic Weed Classification Using Multispectral Images and MAV for Smart Farming," Sep. 2017, [Online]. Available: http://arxiv.org/abs/1709.03329

[149] B. Urmashev, Z. Buribayev, Z. Amirgaliyeva, A. Ataniyazova, M. Zhassuzak, and A. Turegali, "Development of A Weed Detectıon System Usıng Machıne Learnıng And Neural Network Algorıthms," Eastern-European Journal of Enterprise Technologies, vol. 6, no. 2–114, pp. 70–85, 2021, doi: 10.15587/1729-4061.2021.246706.

[150] T. Islam, T. T. Sarker, K. R. Ahmed, C. B. Rankrape, and K. Gage, "WeedSwin hierarchical vision transformer with SAM-2 for multi-stage

weed detection and classification," Sci. Rep., vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-05092-z.

[151] J. Hu et al., "Cotton Weed-YOLO: A Lightweight and Highly Accurate Cotton Weed Identification Model for Precision Agriculture," Agronomy, vol. 14, no. 12, Dec. 2024, doi: 10.3390/agronomy14122911.

Web-1 https://www.fas.usda.gov/data/production/commodity/2224000, Erişim Tarihi:22/01/2026

Web-2 https://www.masseeds.com.tr/agro-library/aycicegin-temel-buyume-asamalari/, Erişim Tarihi 22/01/2026

Web-3 https://www.tarimorman.gov.tr/BUGEM/Belgeler/M%C4%B0LL%C4%B0%20TARIM/AY%C3%87%C4%B0%C3%87E%C4%9E%C4%B0%20KASIM%20B%C3%9CLTEN%C4%B0.pdf , Erişim Tarihi 22/01/2026

Web-4 https://ag.dji.com/mavic-3-m, Erişim Tarihi:22/01/2026

Web-5 https://www.dronedubai.ae/product/dji-agras-t50/, Erişim Tarihi:22/01/2026

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

1. F. Çelik and F. Balık Şanlı, "Ayçiçeği ve yabani otların ayrımında parametrelerin sınıflandırma doğruluğuna etkisi," in *Proc. 7th International Agriculture Congress (UTAK2024)*, 26–30 Sept. 2024, pp. 30–36.

Makaleler

1. F. Celik, F. Balık Şanlı, and D. Boziç, "Transformer networks to classify weeds and crops in high-resolution aerial images from North-East Serbia," Turkish Journal of Field Crops, vol. 29, no. 2, pp. 112–120, 2024, doi: 10.17557/tjfc.1511404.