T.C.

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

TRAKYA BÖLGESİNDEKİ ENDEMİK BİTKİLERİN İHA GÖRÜNTÜLERİNDEN TESPİTİNİ YAPABİLEN CNN ALGORİTMASININ GELİŞTİRİLMESİ

SELÇUK KAYA

DOKTORA TEZİ

MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI

Tez Danışmanı: Prof. Dr. Hilmi KUŞÇU

EDİRNE-2025

SELÇUK KAYA'nın hazırladığı **"TRAKYA BÖLGESİNDEKİ ENDEMİK BİTKİLERİN İHA GÖRÜNTÜLERİNDEN TESPİTİNİ YAPABİLEN CNN ALGORİTMASININ GELİŞTİRİLMESİ"** başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından **Makina Mühendisliği** Anabilim Dalında bir **Doktora tezi** olarak kabul edilmiştir.

Jüri Üyeleri	İmza
Prof. Dr. Hilmi KUŞÇU	……
Prof. Dr. Semiha ÖZTUNA	……
Dr. Öğr. Üyesi Sergun DAYAN	……
Doç. Dr. İbrahim Savaş DALMIŞ	……
Doç. Dr. Ümit HÜNER	……

Tez Savunma Tarihi: 24/06/2025

Bu tezin Doktora tezi olarak gerekli şartları sağladığını onaylarım.

İmza

Prof. Dr. Hilmi KUŞÇU

Tez Danışmanı ……

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

……

Doç. Dr. Filiz UMAROĞULLARI

Fen Bilimleri Enstitüsü Müdürü

T. Ü. FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI DOKTORA PROGRAMI

DOĞRULUK BEYANI

Trakya Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında, tüm verilerin bilimsel ve akademik kurallar çerçevesinde elde edildiğini, kullanılan verilerde tahrifat yapılmadığını, tezin akademik ve etik kurallara uygun olarak yazıldığını, kullanılan tüm literatür bilgilerinin bilimsel normlara uygun bir şekilde kaynak gösterilerek ilgili tezde yer aldığını ve bu tezin tamamı ya da herhangi bir bölümünün daha önceden Trakya Üniversitesi ya da farklı bir üniversitede tez çalışması olarak sunulmadığını beyan ederim.

24/06/2025

Selçuk KAYA

İmza

Doktora Tezi

Trakya Bölgesindeki Endemik Bitkilerin İHA Görüntülerinden Tespitini Yapabilen CNN Algoritmasının Geliştirilmesi

T.Ü. Fen Bilimleri Enstitüsü

Makina Mühendisliği Anabilim Dalı

ÖZET

Bu tez çalışması, Trakya bölgesindeki bazı endemik bitkilerin takibini, tespitini veya istatistiğini tutmak isteyen kişi ve kuruluşlara hızlı, erişilebilir ve yüksek doğruluk bir çözüm hedeflenen evrişimli sinir ağları algoritması olan You Only Look Once (YOLO) algoritması temelli bir bitki tespit modeli geliştirerek sunmaktır. Bu kapsamda, seçilen endemik bitkiler *Dianthus ingoldbyi*, *Verbascum degenii ve Centaurea kilaea* olmak üzere bitkilere ait 2 örnek alanda 2 farklı insansız hava aracı kullanılarak farklı çözünürlüklerde 75 görsel veri elde edilmiştir. Belirli veri çoğaltma teknikleri uygulanarak görsel veriler 240'a yükseltilmiştir. YOLO v11 nano modelinden doğal veri ve yapay veri kullanılarak belirli eğitim parametreleri ile 2 farklı model oluşturulmuş ve karşılaştırılmış, veri çoğaltma yöntemlerinin sınıf dengesini sağlamak ile kalmayıp aynı zamanda modelin yapısal öğrenmesini ve tespit yeteneğini olumlu yönde etkilediği deneysel olarak doğrulanmıştır. Seçili endemik bitkiler arasında en yüksek performans gösteren *Verbascum degenii* endemik bitkisinin olduğu görülmüştür. En iyi performans gösteren modele arayüz kazandırılarak kullanılması kolaylaştırılmıştır.

Yıl : 2025

Sayfa Sayısı : 80

Anahtar Kelimeler : *Dianthus ingoldbyi*, *Verbascum degenii*, *Centaurea kilaea,* YOLO algoritması, Bitki tespiti, Veri çoğaltma

PhD Thesis

Development of CNN Algorithm for Detection of Endemic Plants in Thrace Region from UAV Images

Trakya University Institute of Natural and Applied Sciences

Department of Mechanical Engineering

ABSTRACT

The aim of this thesis is to develop and present a plant detection model based on You Only Look Once (YOLO) algorithm, which is a convolutional neural networks algorithm targeting a fast, accessible and high accuracy solution for individuals and organisations who want to keep tracking, detection or statistics of some endemic plants in the Thrace region. In this context, 75 visual data at different resolutions were obtained by using 2 different unmanned aerial vehicles in 2 sample areas of selected endemic plants *Dianthus ingoldbyi*, *Verbascum degenii* and *Centaurea kilaea*. The visual data was increased to 240 by applying certain data augmentation techniques. Two different models were created and compared using natural data and augmented data from the YOLO v11 nano model with certain training parameters, and it was experimentally verified that data augmentation methods not only provide class balance but also positively affect the structural learning and detection ability of the model. Among the selected endemic plants, *Verbascum degenii* endemic plant was found to be the highest performing endemic plant. The best performing model was facilitated to be used by providing an interface.

Year 2025

Number of Pages : 80

Keywords : *Dianthus ingoldbyi*, *Verbascum degenii*, *Centaurea kilaea,* YOLO algorithm, Plant detection, Data augmentation

TEŞEKKÜR

Trakya bölgesindeki endemik bitkilerin İHA görüntülerinden tespitini yapabilen CNN algoritmasının nasıl geliştirildiğini açıklamaya çalıştığım bu tez çalışmasında fikirleri, zamanları ve psikolojik destekleri ile eşlik eden birçok kişi bulunmaktadır.

Tez süresince bana değerli bilgileri ve tecrübesi ile yardımcı olan, yol gösteren ve vermiş olduğu fikirler ile bu çalışmanın daha iyi hale gelmesinde büyük pay sahibi olan değerli tez danışmanım Prof. Dr. Hilmi KUŞÇU'ya,

Tezin konusunu belirlememde, ilk örnekleri almamda hem fiziki hem de psikolojik olarak bana yardımcı olan babam Prof. Dr. Yalçın KAYA'ya,

İlk örnekleri alırken arazi çalışmalarında bana eşlik eden, endemik bitki türlerinin teşhisinde, seçilmesinde ve fotoğraflanmasında yardımcı olan Doç. Dr. Necmettin GÜLER'e,

Gerçekleştirilen tez izleme komitelerinde bulunan ve tezin gelişmesine katkı da bulunan, yorum ve önerileri ile katkı sunan Prof. Dr. Semiha ÖZTUNA'ya ve çalışmamı her daim desteklediğini ifade eden ve endemik bitkiler konusundaki tecrübeleri ve bilgisi ile beni yönlendiren Dr. Öğretim Üyesi Sergun DAYAN'a,

Her çalışma öncesi ve sonrası beni motive eden, desteğini her daim hissettiğim annem Nilgün KAYA'ya,

Akademik yolculuğumda ve tez süresince beni yalnız bırakmayan her zaman desteğini hissettiğim, çalışmalarımda bana yardımcı olan ve bulunan değerli eşim ve hayat arkadaşım Hande Sena IŞIK KAYA'ya,

Teşekkür eder, saygılarımı sunarım.

İÇİNDEKİLER

ÖZET iv
ABSTRACT v
TEŞEKKÜR vi
İÇİNDEKİLER vii
SİMGELER VE KISALTMALAR DİZİNİ x
ŞEKİLLER DİZİNİ xii
ÇİZELGELER DİZİNİ xiv
EKLER DİZİNİ xv
BÖLÜM 1 1
GİRİŞ 1
1.1. Tezin Amacı 2
1.2. Tezin Kapsamı 2
1.3. Literatür Taraması 3
BÖLÜM 2 8
GENEL BİLGİLER 8
2.1. Trakya Bölgesindeki Endemik Bitkiler 8
2.1.1. *Dianthus ingoldbyi* 8
2.1.2. *Centaurea kilaea* 10
2.1.3. *Verbascum Degenii* 12
2.2. İHA ile Uzaktan Algılama Yöntemleri 15
2.3. Evrişimli Sinir Ağları ve Mimarisi 16
2.3.1. Giriş Katmanı 17

2.3.2. Evrişim Katmanı 17
2.3.3. Havuzlama Katmanı 18
2.3.4. Düzleştirme Katmanı 19
2.3.5. Tam Bağlantı Katmanı 19
2.3.6. Çıktı Katmanı 20
2.4. Evrişimli Sinir Ağı Algoritmaları 21
2.4.1. YOLO Algoritması 21
2.5. Veri Çoğaltma Yöntemleri 23
2.5.1. Geometrik Dönüşümler 23
2.5.2. Fotometrik Dönüşümler 24
BÖLÜM 3 26
MATERYAL VE YÖNTEM 26
3.1. Kullanılan Materyal 26
3.2. Kullanılan Yöntem 27
3.2.1. Görsel Veri Toplanması 28
3.2.2. Görsel Verilerin Çoğaltılması 30
3.2.3. Görsel Verilerin Etiketlenmesi 32
3.2.4. Görsel Verilerin YOLO Formatına Dönüştürülmesi 32
3.2.5. Veri Setlerinin Ayrılması 33
3.2.6. YOLO Modellerinin Eğitilmesi 34
3.2.7. Değerlendirmede Kullanılacak Performans Metrikleri 36
3.3. Trakya Endemik Bitki Tespit Programı 38
3.3.1. Program Mimarisi 38
3.3.2. Programın Çalıştırılabilir Dosyaya Dönüştürülmesi 40
BÖLÜM 4 42

SONUÇLAR VE TARTIŞMA 42
4.1. Birinci Veri Seti ile Eğitilmiş YOLO v11n Modelinin Tespit Sonuçları 42
4.2. İkinci Veri Seti ile Eğitilmiş YOLO v11n Modelinin Tespit Sonuçları 44
4.3. Modellerin Karşılaştırılması 45
4.3.1. Kesinlik Yönünden Karşılaştırılması 45
4.3.2. Geri Çağırma Yönünden Karşılaştırılması 46
4.3.3. mAP50 Değerleri Yönünden Karşılaştırılması 47
4.3.4. mAP50-95 Değerleri Yönünden Karşılaştırılması 48
4.3.5. F1/Güven Puanı Yönünden Karşılaştırılması 50
4.4. Tartışma 51
4.5. Programın Kullanımı 52
4.6. Öneriler 54
KAYNAKLAR 55
EKLER 61
ÖZGEÇMİŞ 64
TEZ İLE İLGİLİ BİLİMSEL FAALİYETLER 65

SİMGELER VE KISALTMALAR DİZİNİ

1D	1 Boyutlu
CNN	Convolutional Neural Networks
CR	Critically Endangered
DJI	Da-Jiang Innovations
F	Odak Uzunluğu
FN	Yanlış Negatif
FP	Yanlış Pozitif
GSD	Ground Sampling Distance
GPS	Global Positioning System
H	Yerden Yükseklik
ImgW	Görüntü Genişliği
IoU	Intersection over Union
IUCN	International Union for the Conservation of Nature
İHA	İnsansız Hava Aracı
mAP	mean Average Percision
MP	Mega Piksel
NMS	Non-Maximum Suppression
RCNN	Region Based Convolutional Neural Networks
RGB	Red Green Blue
SGD	Stochastic Gradient Descent
SSD	Single Shot Detector
Sw	Sensör Genişliği

TN	Doğru Negatif
TP	Doğru Pozitif
URL	Uniform Resource Locator
YAML	Yet Another Markup Language
YOLO	You Only Look Once

ŞEKİLLER DİZİNİ

Şekil 2.1. *Dianthus ingoldbyi* bitkisi 9

Şekil 2.2. *Dianthus ingoldbyi* bitkisinin çiçeği 10

Şekil 2.3. *Centaurea kilaea* bitkisi 11

Şekil 2.4. *Centaurea kilaea* bitkisinin çiçeği 12

Şekil 2.5. *Verbascum degenii* bitkisi 13

Şekil 2.6. *Verbascum degenii* bitkisinin çiçeği 14

Şekil 2.7. GSD oranının görüntü kalitesi üzerindeki etkisi 15

Şekil 2.8. Temel bir CNN mimarisi örneği 16

Şekil 2.9. Evrişim katmanında filtrenin uygulanması ve özellik haritasının oluşturulması işlemi 17

Şekil 2.10. Havuzlama işlemi 18

Şekil 2.11. Düzleştirme işlemi 19

Şekil 2.12. Tam bağlantı katmanı 20

Şekil 2.13. SoftMax aktivasyon fonksiyonun kullanımı ve sınıflandırma olasılıklarının oluşturulması 21

Şekil 2.14. YOLO mimarisi 23

Şekil 2.15. Geometrik dönüşüm örneği 24

Şekil 2.16. Fotometrik dönüşüm örnekleri 25

Şekil 3.1. DJI Phantom 3 Advanced 26

Şekil 3.2. DJI Mini 4 Pro 27

Şekil 3.3. Yöntemin akış diyagramı 28

Şekil 3.4. Havadan çekilmiş *Verbascum degenii* endemik bitkisi 29

Şekil 3.5. Havadan çekilmiş *Dianthus ingoldbyi* endemik bitkisi 30

Şekil 3.6. Kodda yer alan veri çoğaltma işlemleri ve olasılıkları 31

Şekil 3.7. Roboflow aracı ile etiketleme işlemi 32

Şekil 3.8. YOLO formatlı veri 33

Şekil 3.9. YAML konfigürasyonu kodunun içeriği 34

Şekil 3.10. Eğitim sırasındaki değeleri 35

Şekil 3.11. Başlangıç penceresine ait kod 38

Şekil 3.12. Programın akış diyagramı 39

Şekil 3.13. Sonuçlar penceresine ait kod 40

Şekil 3.14. Programa ait dosyanın içeriği 41

Şekil 4.1. Birinci veri seti ile eğitilmiş modelin F1-Güven grafiği 43

Şekil 4.2. İkinci veri seti ile eğitilmiş modelin F1-Güven grafiği 44

Şekil 4.3. Modellerin kesinlik değerlerinin karşılaştırılması 46

Şekil 4.4. Modellerin geri çağırma değerlerinin karşılaştırılması 46

Şekil 4.5. Modellerin genel mAP50 değerlerinin karşılaştırılması 47

Şekil 4.6. Modellerin üç endemik bitkiye göre mAP50 değerlerinin oransal olarak karşılaştırılması 48

Şekil 4.7. Modellerin genel mAP50-95 değerlerinin karşılaştırılması 49

Şekil 4.8. Modellerin üç endemik bitkiye göre mAP50-95 değerlerinin oransal olarak karşılaştırılması 49

Şekil 4.9. Program açılış penceresi 52

Şekil 4.10. Programa veri yükleme işlemi 53

Şekil 4.11. Tespit sonuçları penceresi 53

Şekil 4.12. Sonuçlar Penceresi (GPS verisiz) 55

ÇİZELGELER DİZİNİ

Çizelge 3.1. Endemik bitkiler için hesaplanan GSD oranları ve maksimum uçuş yükseklikleri 29

Çizelge 3.2. Oluşturulan veri setlerinin özellikleri 31

Çizelge 3.3. Eğitim ve doğrulama veri sayıları 33

Çizelge 3.4. İki modelde kullanılan eğitim parametreleri 35

Çizelge 4.1. Birinci veri seti ile eğitilmiş modelin eğitim sırasında elde ettiği en iyi metrikler 42

Çizelge 4.2. İkinci veri seti ile eğitilmiş modelin eğitim sırasında elde ettiği en iyi metrikler 44

Çizelge 4.3. Modellerin F1/Güven puanı grafiklerinden elde edilen sonuçların karşılaştırılması 50

Çizelge 4.4. *Centaurea kilaea* endemik bitkisine göre modellerin F1 ve güven puanları 50

Çizelge 4.5. *Dianthus ingoldbyi* endemik bitkisine göre modellerin F1 ve güven puanları 51

Çizelge 4.6. *Verbascum degenii* endemik bitkisine göre modellerin F1 ve güven puanları 51

EKLER DİZİNİ

EK 1. Trakya Endemik Bitki Tespit Programı Kodu……61

BÖLÜM 1

GİRİŞ

Endemik bitkiler, ekolojik şartlardan dolayı sadece belirli bölgelerde yetişebilen ve yaşayan bitkilerdir. Bu sebeple büyük oranda nadirlik özelliğine sahiptir ve korunmaya ihtiyaç duymaktadır. Nadirlik özelliği dışında endemik bitkiler tıp alanında da alternatif ilaç olarak kullanılmaktadır. Bazı endemik bitkiler özellikle turizm ve madencilik gibi sebeplerden dolayı yok olma tehlikesi ile karşı karşıyadır (Kargıoğlu, Cenkci ve Dayan, 2018). Bu nedenle bitkiler hakkında lokasyon bilgisi ve istatistiki veri oldukça önemli hale gelmektedir.

Günümüzde endemik bitki tespiti göz ile tespit ve uzaktan algılama yöntemleri olmak üzere iki farklı metot ile yapılmaktadır. İki yöntem karşılaştırıldığında göz ile tespit yöntemi arazi şartlarına bağlı olarak oldukça fiziksel anlamda yorucu olabilmekte ve uzun sürebilmektedir fakat bitki türünün teşhisi neredeyse mükemmel seviyede olabilmektedir. Uzaktan algılama yöntemlerinde uydu görüntüleri ve insansız hava aracı (İHA) görüntüleri kullanılmaktadır. Uydu görüntüleri yüksek kapsama alanı sunarken düşük detay sunmakta olup, İHA görüntüleri bunun tam tersidir. Geleneksel uydu tabanlı sistemlerde çözünürlük 10-30m aralığında iken, İHA'larla yapılan görüntüleme çalışmaları santimetre altı düzeyde çözünürlük sunabilmektedir (Hassan, Pourghasemi ve Panahi, 2023). Bu sebeple uydu görüntüleri büyük hacimli endemik bitkiler için uygun fakat küçük hacimli ve detayın önemli olduğu endemik bitkiler için uygun değildir.

Güvenlik, sağlık ve tarım gibi alanlarda obje tespit algoritmaları kullanılmaya başlanmış olup çok verimli ve hızlı sonuçlar alınmaktadır. Bu tespit algoritmalarının endemik bitki tespitinde kullanımı, elde edilen görüntüler üzerinden tanımlama işlemleri çok kısa bir sürede yaparak tespit işlemlerini hızlandırabilir.

Bu çalışmada Trakya Bölgesinde bulunan bazı endemik bitkilerin tespitini yapabilen evrişimli sinir ağları (CNN) algoritması olan YOLO (You Only Look Once) algoritması temelli obje tespit modelinin geliştirilmesi süreci, modelin eğitimi için dron kullanılarak görsel verinin toplanması, veri çoğaltma yöntemleri kullanılarak görsel verinin artırılması ve sınıfsal dengenin sağlanması, performans metrikleri üzerinden karşılaştırılması ve en iyi performans gösteren modelin arayüz kazandırılarak çalıştırılabilir programa haline getirebilmesi araştırılmıştır.

1.1. Tezin Amacı

Tezin amacı Trakya Bölgesindeki endemik bitkilerin yüksek oranda tespitini yapabilecek ve bu bitkiler ile ilgili olarak veri elde etmek isteyen kişilere yardımcı olabilecek bir tespit modelinin oluşturulması ve geliştirilmesidir. Çalışmada seçilen tehdit altındaki endemik bitkilere ait elde edilecek veriler sayesinde koruma alanları artırılabilir, bitkilerin yıllık bazlı istatistik bilgileri çıkartılabilir, bitki yoğunluğu ve adedi gibi veriler oluşturulabilir ve son olarak yeni türlerin bulunması için altyapı oluşturabilir.

Bu çalışma, Trakya bölgesinde bulunan endemik bitkiler üzerinde çalışmalar yapan kurum ve kuruluşların arayüz kazandırılmış çalıştırılabilir bir program şeklindeki bu algoritmayı kullanarak, kendi işlerini çok daha hızlı yapabilmeleri ve endemik bitkiler hakkında önemli istatistiki veri alarak korunmasına yönelik farkındalık oluşturmak için kullanılabilir. İHA kullanılması endemik bitkilerde bulunan hastalıkların tespitini ve bitkiye zarar verebilecek böceklerin oluşturulan hava akımı sayesinde uzaklaştırılmasını da sağlayabilir.

1.2. Tezin Kapsamı

Tez çalışması 4 bölümden oluşmaktadır. Giriş bölümü olan birinci bölümde tezin amacı ve tez ile alakalı konulara ilişkin literatür taraması yer almaktadır. İkinci bölümde çalışmada seçilen endemik bitkiler, İHA ile görsel veri toplama yöntemleri, nesne tespit algoritmaları, veri çoğaltma yöntemleri ile ilgili genel bilgiler verilmiştir. Elde edilen veri seti, veri setinin işlenmesi, kullanılan algoritma ve model, ekipman ve programlar, uygulanılan yöntemler ve aşamaları, arayüz ekleme ve program haline getirme işlemleri üçüncü bölüm olan materyal ve yöntem bölümünde yer almaktadır.

Son olarak dördüncü bölümde çalışma sonucu elde edilen veriler ve bulgular açıklanmış olup elde edilen sonuçlar karşılaştırılmış ve yorumlama yapılmıştır. Programın kullanımı ve sonucunda ulaşılan bilgiler ışığında daha sonra yapılacak araştırmalara yönelik öneriler dördüncü bölümün son kısmını oluşturmaktadır.

1.3. Literatür Taraması

Kargıoğlu vd. (2018), sanayileşme, kentleşme, turizm, aşırı otlatma, tarımsal faaliyetler ve kirliliğin nadir bitkilerin geleceğini ciddi anlamda tehdit ettiğini ifade etmiştir.

Dayan, Güler, Arda, Çolak ve Aytaç (2013), botanikçilerin en önemli hedeflerinin nadir bitkileri korumak olduğunu belirtmiştir.

Uluslararası Doğa Koruma Birliği (IUCN) 2001 listesine göre *Dianthus ingoldbyi* endemik bitkisinin tehlike kategorisini kritik tehlikede (CR) olarak belirlenmiş ve bunun antropojenik kaynaklı olduğu ifade edilmiştir.

Ekim vd. (2000), Türkiye Bitkileri Kırmızı Kitabı'na göre *Dianthus ingoldbyi*'nin koruma statüsünün kritik tehlike altında olduğu ifade edilmiştir.

Sekerler, Sen, Bitis ve Sener (2018), Trakya Bölgesi endemiği olan *Centaurea kilaea* endemik bitkisinin HepG2 kanser hücre hatlarında önemli derecede antikanser aktivitesine sahip olduğuna ulaşmışlardır.

Şekerler vd. (2020), *Centaurea kilaea* endemik bitkisinin karaciğer kanserinin öncülü hücrelerinin büyümesini durdurduğu ve mevcut yollarla hücrelerin öldürülmesini sağladığını ifade etmiştir.

Sen, Ozbas, Akbuga ve Bitis (2015), rahim ağzı kanseri, prostat kanseri ve meme kanseri hücre hatlarının ilerlemesini engelleyen ekstrelerinin *Centaurea kilaea* endemik bitkisinde olduğunu bildirmişlerdir.

Şen vd. (2016), *C. Kilaea*'nın kloroform özütünden izole edilen cnicin ve cirsimaritinin, kanser karşıtı ilaçlar olma yönünde umut veren adaylar olduğunu ifade etmişlerdir.

Avşar, Keskin ve Berber (2016) *V. Degenii*'nin metanol ve etanol ekstraktlarının yüksek antimikrobiyal aktivitesi gösterdiğini, diğer *Verbascum* türlerine göre daha etkili olduğunu ifade etmişlerdir.

Zhun, Jiewei, Maoguo, Honghui ve Goodman (2018), tütün bitkisi tespitinde mevcut yöntemlerin, yorucu ve zaman alıcı olan saha incelemesine dayandığını belirtmiştir. İHA ile uzaktan algılama yöntemi ile elde edilen yüksek çözünürlüğe sahip ve yüksek düzeyde ayrıntı görseller tespit işleminin otomatikleştirilmesine olanak sağladığını ifade etmiştir.

Comba, Biglia, Aimonino ve Gay (2018), İHA multispektral görüntülerinden üretilmiş 3 boyutlu nokta bulutu haritalarını kullanarak bağlardaki asma sıralarının yönelimini ve sıralar arası boşlukları tespit eden algoritmayı geliştirmişlerdir.

Albetis vd. (2017), üzüm bağlarında hızlıca yayılabilen ve ağır hasar bırakabilen *Flavescence dorée* hastalığının tespitinin İHA multispektral görüntülerini kullanarak geliştirmiş oldukları model ile mümkün olduğunu ifade etmişlerdir.

Görlich vd. (2021), şeker pancarında *Cercospora* yaprak lekesi hastalığının tespitinde İHA görüntülerinin kullanıldığını ifade etmişlerdir. RGB (Kırmızı Yeşil Mavi) kamera görüntülerin, kullanmış oldukları metot ile birlikte multispektral ya da hiperspektral görüntülere göre daha güvenilir ve yüksek hassasiyete sahip olduğunu belirtmişlerdir.

Wang, Thomasson, Isakeit, Yang ve Nichols (2020), İHA'ların bitki tespitine dahil olması ile birlikte önemli ölçüde çözünürlük sunduğunu belirtmiş ve geliştirmiş oldukları algoritma ile pamuk bitkisindeki kök küfünü ortalama %95.94 doğruluk oranı ile tespit edebildiklerini ifade etmişlerdir.

Şin ve Kadıoğlu (2019), yapmış oldukları derleme çalışmada yabancı ot tespitinde klasik yöntemlere göre İHA kullanılması, zaman, ekonomik ve çevreci avantajlar sunacağını ifade etmişlerdir.

Mohidem vd. (2021), yabancı ot tespitinin İHA ile yapılması tespit işlemlerinin daha verimli, sürdürülebilir ve çevre dostu olduğunu ifade etmişlerdir. Kullanılan RGB kameraların diğer kamera sensörlerine göre daha erişilebilir ve ekonomik olduğunu, çok yüksek çözünürlüklü görseller oluşturabildiğini belirtmişlerdir.

Che'Ya, Dunwoody ve Gupta (2021), sorgum tarlasında bulunan farklı yabancı otları farklı bantlarda çekilmiş İHA görselleri kullanarak tespitini ve ayrımını yapmışlardır.

Primicerio vd. (2017), yüksek çözünürlüklü İHA görüntülerini bağlardaki bitkilerin tespiti için kullanmışlardır. Bitkilerin kapladığı alan ve şekil bilgisini İHA görüntülerinden elde ederek, kullandıkları metot ile bağ sırasındaki eksik bitkileri bulabildiklerini ifade etmişlerdir.

Wu, Shen, L. Cao, Wang ve Cao (2019), kullanmış oldukları metot ile İHA görüntülerinden yararlanılarak 3 farklı yoğunluktaki 892 adet mabet ağacının tespitini ve ayrımını yapabilmişlerdir. Esnekliği, rahatlığı ve yüksek nokta yoğunluğu avantajları nedeniyle İHA kullandıklarını ifade etmişlerdir.

Song ve Park (2020), su bitkilerinin tespitinde multispektral İHA görüntüleri kullanmanın oldukça etkili olduğunu ortaya çıkarmışlardır. Klasik yöntemler ile su bitkilerinin tespitinin oldukça maliyetli olduğunu fakat İHA kullanmanın düşük maliyetli ve yüksek etkiye sahip olduğunu ifade etmişlerdir.

Aeberli, Johansen, Robson, Lamb ve Phinn (2021), İHA tabanlı algılama teknolojilerinin yüksek çözünürlükte veri sağlama yeteneğine sahip olduğunu, bireysel bitkilerin izlenmesini kolaylaştırdığını, sağlık, verim ve büyüme hakkında zamanında ve ölçülebilir temel bilgiler sağlayabildiğini ifade etmişlerdir.

Atitallah vd. (2021), kaktüs bitkisini tanımak için geliştirmiş oldukları evrişimli sinir ağları (CNN) algoritmasından yüksek doğruluk, hassasiyet ve performans elde ettiklerini ifade etmiştir. CNN algoritmalarının korunan doğal alanlar için otomatik gözetim için kullanılabileceğini belirtmiştir.

Liu vd. (2020), İHA kullanılarak elde edilen kapsamlı RGB görüntülerinin ve derin öğrenmenin, mısır püsküllerinin tespitinin doğruluğunun artırılmasına olanak sağladığını ifade etmiştir.

Osco vd. (2021), İHA kullanılarak elde edilen görüntülerin görsel incelemesinin zorlu ve önyargılı bir görev olduğunu ifade etmiş, bu nedenle bitkileri kolayca tespit edebilen CNN algoritması geliştirmişlerdir.

Machefer, Lemarchand, Bonnefond, Hitchins ve Sidiropoulos (2020), uzaktan algılama ve yapay zekanın birlikte kullanılması sayesinden bitki analizlerinin doğru, güvenilir ve hesaplama açısından verimli olduğunu ifade etmiştir.

Camargo, Schirrmann, Landwehr, Dammer ve Pflanz (2021), yapay zekanın kurulan sinir ağlarıyla çok yüksek çözünürlüklü uzaktan algılama verilerinden bilgi çıkarabildiğini, nesne tanıma ve sınıflandırmayı eskisinden çok daha yüksek ayrıntı ve doğrulukla mümkün kıldığını ve İHA elde edilen görüntülerle birleştirildiğinde, arazilerin çok daha akıllı bir şekilde izlenebileceğini ifade etmiştir.

Bao vd. (2023), çay yaprağı küfünün tespiti için kullandıkları YOLO algoritması hakkında diğer nesne algılama yöntemleri ile karşılaştırıldığında, hesaplama süresinin daha kısa, hızının daha yüksek, maliyeti daha düşük olduğunu ifade etmiştir.

Chen vd. (2023), dağlık alandaki bayberry (Çin yemişi) ağaçlarını tespit etmenin zor olduğunu belirtmiş ve bu sebeple üstün nesne tespit becerisi ve bellek dostu olarak ifade ettikleri YOLOv4 algoritmasını İHA görüntülerinde kullanarak ağaçları tespit etmiş ve karmaşık ortamlarda tek nesne algılama görevleri için uygun olduğunu ifade etmiştir.

Pu vd. (2023), mısır püskül tespitinde mevcut yöntemlerin düşük doğruluğa ve hıza sahip olduğunu ifade etmiş, YOLOv7 modelini geliştirerek üretmiş oldukları algoritma sayesinde %97.55 oranında mısır püskülünü tespit ettiklerini ve yüksek tespit hızı sayesinde gerçek zamanlı tespitte kullanabileceğini belirtmiştir.

Zhang vd. (2024), çam solgunluğu hastalığının tespitinde geliştirilmiş oldukları YOLOv4 modelinin SSD (Single Shot Detector), Faster RCNN (Bölge Tabanlı Evrişimli Sinir Ağları), YOLOv3 ve YOLOv5 ile karşılaştırılması sonucunda, geliştirilmiş YOLOv4 modelinin mAP değerinin diğer dört modelden önemli ölçüde daha yüksek olduğunu ifade etmiştir.

Wang, H. Zhang, Liu, Zhang ve Zheng (2024), karmaşık arka plana sahip orman arazilerinde tek tek ağaç tespitinin zor olduğunu ifade etmiş, YOLOv5 modelinden geliştirilmiş oldukları YOLO algoritması sayesinde 978 görüntüden oluşan kapsamlı bir veri seti içerisinde Çin köknarı örneklerinin tespiti için etkileyici bir performansa ulaştığını belirtmiş ve model değerlendirme ölçütleri sırasıyla %96.1 oranında doğruluk, %93.0 oranında duyarlılık ve %94.5 oranında F1 puanına ulaştığını tespit etmişlerdir.

Xu, Zhao ve Zhai (2024), YOLOv8n modelinde yapmış oldukları iyileştirmeler ile insansız hava araçları için yüksek hassasiyetli, hızlı çıkarıma sahip küçük nesne tespit modeli oluşturmuş, bu iyileştirmelerin doğruluk, duyarlılık ve mAP@0.5 değerlerinde performans artışına neden olduğunu ifade etmiştir.

BÖLÜM 2

GENEL BİLGİLER

2.1. Trakya Bölgesindeki Endemik Bitkiler

Endemik bitki çeşitliliği açısından dünyanın en zengin ülkeleri arasında Türkiye yer almaktır ve endemik bitki taksonlarının sayısı 2651'dir (Davis, 1988); bu rakam, Türkiye florasının yaklaşık %30,9'unu oluşturmaktadır. (Akman vd., 2005).

Güler (2013) tarafından yapılan çalışmada, Türkiye florasında 167 familya, 1320 cins ve 9996 tür olmak üzere toplamda 11.707 takson bulunduğu, Trakya bölgesinde ise 2573 takson ile 62 endemik türe rastlandığı belirtilmiştir. Uluslararası Doğa Koruma Birliği'nin (IUCN) 1997 yılında gerçekleştirdiği küresel bir araştırmaya göre, dünya genelinde var olan yaklaşık 240.000 bitki taksonunun %15'i yok olma riskiyle karşı karşıyadır. Endemik taksonlar, tehlike altındaki taksonların %90'dan fazlasını oluşturmaktadır. (IUCN, 1997; Çepel, 2003).

2.1.1. *Dianthus ingoldbyi*

Dianthus L. cinsi, çoğunlukla tek veya çok yıllık otsu bitkilerden, nadiren ise çalı formundaki türlerden oluşmakta olup, *Caryophyllaceae* (Karanfilgiller) familyasına aittir. Türkiye florasında bu cinse ait toplam 74 takson kayıt altına alınmıştır (İlçim vd., 2013). Kozmopolit dağılıma sahip olan *Caryophyllaceae* familyası, özellikle Akdeniz Bölgesi gibi sıcak ve ılıman iklim kuşaklarında yaygın olarak görülmektedir. Familya, dünya genelinde yaklaşık 86 cins ve 2100 civarında takson içermektedir.

Bu familya içerisinde yer alan *Dianthus* cinsi, Akdeniz coğrafyasında yaklaşık 300 takson ile temsil edilmekte, Türkiye'de ise 86 takson ile doğal yayılış göstermektedir. Ülkemizdeki bu taksonların 38'i endemiktir ve bu durum yaklaşık %44 oranında bir endemizm düzeyine karşılık gelmektedir (Davis, 1965–1988; Güner vd., 2000; Güner vd., 2012).

Dianthus ingoldbyi, yalnızca Balkan Yarımadası'nın belirli bölgelerinde doğal olarak yetişen endemik bir türdür. Türkiye'de Çanakkale (Bozcaada-Sulubahçe ve Eceabat-Arıburnu) ile Edirne (Keşan-Mecidiye) yörelerinde; Yunanistan'ın kuzeydoğusunda ise sınırlı alanlarda yayılış göstermektedir (Uysal vd., 1992; Başak ve Güler, 2000; Trigas vd., 2007). Şekil 2.1'de Keşan Mecidiye'de birinci arazi çalışması sırasında elde edilen Dianthus ingoldbyi bitkisinin fotoğrafı görülmektedir.



Şekil 2.1. *Dianthus ingoldbyi* bitkisi

Bu tür, 30 cm'ye kadar boylanabilen, odunsu tabanlı, salkım şeklinde (kaespitöz) büyüyen çok yıllık bir bitkidir. Gövdeleri alt kısımlarda kısa tüylerle kaplıdır. Yapraklar yaklaşık 2 mm genişliğinde, şerit biçiminde, sivri uçlu ve derimsi (koriyasal) yapıdadır. Çiçekler 2 ila 5'li gruplar halinde, neredeyse sapsız şekilde dizilmiştir.

Epikalyks (ikincil çanak yaprak) sayısı 10–12 olup, yumurtamsı biçimli ve giderek sivrileşen yapıdadır. Kalyks (çanak yaprak) 15–17 mm uzunluğunda ve 2 mm genişliğinde olup, orta kısmın yukarısından itibaren daralmaktadır. Taç yaprak uzantıları (petal-limb) 2–4 mm uzunluğunda, kenarları dişçikli, rengi ise beyazımsı ya da yeşilimsi sarıdır (Tutin ve Walters, 1993). Şekil 2.2'de Keşan Mecidiye 'de birinci arazi çalışması sırasında elde edilen *Dianthus ingoldbyi* bitkisinin çiçeğinin fotoğrafı görülmektedir.



Şekil 2.2. *Dianthus ingoldbyi* bitkisinin çiçeği

2.1.2. *Centaurea kilaea*

Bir yıllık, iki yıllık veya çok yıllık otsu bitkilerden oluşan *Centaurea* cinsi, *Asteraceae* familyasına aittir. Nadir olarak dikenli, dallanmış küçük çalı formunda ya da yeşil yapraklara sahip yarı çalı formunda türler de bu cins içerisinde yer alır. *Asteraceae* (Compositae) familyası, çiçekli bitkiler arasında taksonomik çeşitlilik açısından en zengin familyalardan biridir. Dünya genelinde yaklaşık 1100 cins ve 25.000 türle temsil edilmektedir. Türkiye florasında ise bu familyaya ait 133 cins ve 1156 tür bulunmaktadır. (Davis, 1975; Heywood, 1978). Genetik çeşitliliği ve morfolojik zenginliğiyle dikkat çeken *Centaurea* cinsinin Türkiye'deki endemizm oranı % 62 gibi yüksek bir düzeydedir. (Davis, 1988; Güner vd., 2000).

Centaurea kilaea, toprak altında stolon oluşturan, sürünücü ya da dik gelişen gövdelere sahip çok yıllık bir türdür. Genellikle kıyı kumullarında yayılmış olarak rozet formunda büyür. Gövde yüksekliği 25 ile 140 cm arasında değişirken genellikle 50 ile 90 cm arasında olabilir, genellikle köşeli yapıda olup üst kısmından yoğun şekilde dallanır. Yapraklar yoğun beyaz veya gri tonlarda tomentoz tüylüdür. Verimsiz rozet yaprakları lirattan pinnatisekte kadar değişken formlarda olabilir; nadiren parçalı olmayan bireylerde yapraklar lanselat ya da ovattır. Gövde ortasında yer alan yapraklar, genellikle 1–2 derecede pinnatisektdır ve genişliği 2–4 mm arasında değişir. Şekil 2.3'te Kırklareli İğneada'da birinci arazi çalışması sırasında elde edilen *Centaurea kilaea* bitkisinin fotoğrafı görülmektedir.



Şekil 2.3. *Centaurea kilaea* bitkisi

İnvolukrum (10–) 12–15 × (5–) 6–8 mm boyutlarında ve ovoid formdadır. İnvolukrum brakteleri hafif boyuna çizgili ve seyrek şekilde örümceğimsi (araknoid) tüylüdür. Uç kısmındaki uzantılar (appendage) küçük, kahverengi, üçgen biçiminde olup her iki yanında (3–) 4–6 (–7) silli yapı taşır; sillerin uzunluğu 0.5–1 mm, uçları ise 0.3–0.8 mm'lik küçük bir diken (mukro) ile sonlanır. Çiçekler pembe-mor renkte olup, kenarda yer alanlar hafifçe radyant görünümlü ve staminodsuzdur. Taç (korolla) 5 parçalıdır; dişi organ (stigma) 2 lopludur, erkek organ tüpü (anter tübü) ise 5 parçadan oluşur. Meyve tipi aken olup koyu kahverengidir ve boyu 3.5–4.5 mm arasında değişir.

Papus (tüylü yapı) 3–4.5 mm uzunluğunda ve kaba yüzeylidir (skabroz). En içteki papus kılları genellikle daha kısa (1.5 mm) olabilir ya da diğerleriyle aynı boyda bulunabilir (Davis, 1975). Şekil 2.4'te Kırklareli İğneada'da birinci arazi çalışması sırasında elde edilen *Centaurea kilaea* bitkisinin çiçeğinin fotoğrafı görülmektedir.



Şekil 2.4. *Centaurea kilaea* bitkisinin çiçeği

2.1.3. *Verbascum Degenii*

200'ün üzerinde cins ve yaklaşık 2500 tür içeren *Scrophulariaceae* familyası, oldukça büyük bir bitki ailesidir. Bu familyaya ait bitkiler genellikle ılıman ve subtropikal bölgelerde yayılış gösterir. Estetik görünümleriyle süs bitkisi olarak bahçelerde yetiştirilebildiği gibi, yol kenarlarında yabani ot formunda da bulunabilir. Bir yıllık ya da çok yıllık bitkiler, otsu, nadiren çalı veya küçük ağaç şeklindedirler. Bu türlerin çoğu ototrof olup, bazıları yarı ya da nadiren tamamen parazitik yaşam formlarına sahiptir.

Verbascum cinsi, *Scrophulariaceae* familyasının en büyük cinsi olarak öne çıkmaktadır (Grieve, 1995; Özcan vd., 2011). Bu cins, Türkiye florasında en fazla türe sahip olan cinslerden biridir. Kuzey Yarımküre genelinde yaklaşık 360 tür ile temsil edilirken, Türkiye'de toplam 341 türü doğal olarak yetişmektedir. Bunlardan 165'i endemik, 105'i ise hibrit türdür (Güner, 2012).

Türkiye Florası'na göre *Verbascum*, en fazla tür içeren ikinci cinstir ve yaklaşık %84'lük yüksek bir endemizm oranına sahiptir (Kaynak vd., 2006). Şekil 2.5'te Kırklareli İğneada'da birinci arazi çalışması sırasında elde edilen Scrophulariaceae familyasına ait *Verbascum degenii* bitkisinin fotoğrafı görülmektedir.



Şekil 2.5. *Verbascum degenii* bitkisi

Verbascum L. türleri, genellikle tek, iki ya da çok yıllık otsu bitkilerden oluşur; nadiren küçük çalı formunda türleri de mevcuttur. Gövde yaprakları çoğunlukla almaşık, nadiren karşılıklı dizilimde olup basit veya parçalı yapıdadır. Taban yaprakları rozet formunda düzenlenir. Türler, salgılı ya da salgısız tüylerle kaplı olabilir ya da tamamen tüysüz olabilir.

Verbascum degenii, çiçeklenmesi çok sayıda dikey olarak yükselen (fastijiat) dallanma gösterir, taban yaprakları doğrusal-mızrak şeklinde olup, 10–20 × 1–4 cm boyutlarındadır. Bu özellikler ile diğer *Verbascum* türlerinden ayrılır. İki yıllık bir bitki olup 70 ile 150 cm arasında bir boya ulaşabilir. Gövdesi ince, yünlü tomentoz tüylerle kaplıdır; yaş ilerledikçe kısmen çıplaklaşır. Taban yaprakları doğrusal-mızrak şeklinde, 10–20 × 1–4 cm boyutlarında, kenarları dişli ve uca doğru sivrileşir. Yaprak sapları 2 ile 5 cm arasında bir uzunluğa sahiptir. Gövde yaprakları benzer özellik gösterse de daha küçüktür. Çiçeklenme dönemi, çok sayıda ince dallı ve dikdörtgenimsi birleşik salkım şeklinde bir yapı oluşturur. Brakteler doğrusal ya da mızrak şeklindedir; çiçek sapları 4 mm'ye kadar ulaşabilir. Brakteoller oldukça küçüktür. Kalyks (çanak yaprak) 3 ile 5 mm uzunluğunda, beyaz tomentoz tüylerle kaplı olup zamanla kısmen çıplaklaşır. Taç yaprak (korolla) sarı renkte olup 15 ile 20 mm arasında bir çapa sahiptir. Meyve, 5–6 × 2–4 mm boyutlarında, tomentoz yapılı, silindirik-eliptikten eliptik-oval forma kadar değişen kapsül şeklindedir (Davis, 1967). Şekil 2.6'da Kırklareli İğneada'da birinci arazi çalışması sırasında elde edilen *Verbascum degenii* bitkisinin çiçeğinin fotoğrafı görülmektedir.

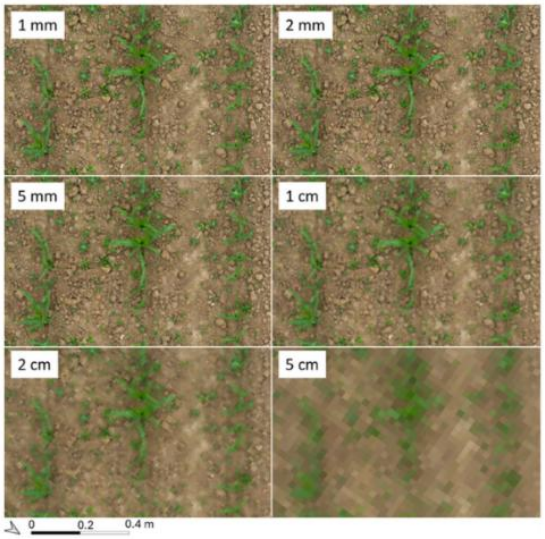


Şekil 2.6. *Verbascum degenii* bitkisinin çiçeği

2.2. İHA ile Uzaktan Algılama Yöntemleri

Doğal görüntülerden farklı olarak, uzaktan algılama görüntüleri, piksellerin standartlaştırılmış bir uzamsal çözünürlükle temsil edildiği belirgin bir özelliğe sahiptir. Bu çözünürlük, yer örnekleme mesafesi (GSD) olarak bilinir ve uzaktan algılama alanında, bir görüntüdeki bir nesne veya özelliğin ayırt edilebilecek minimum boyutunu tanımlayan temel bir kavramdır. GSD, dijital fotoğraflarla elde edilen yer yüzeyi görüntülerinde, piksel merkezleri arasındaki fiziksel mesafeyi tam olarak nitelendirir. Bu görüntüler, hava veya uzay tabanlı platformlardan elde edilebilir. Uydu görüntüleri uzay tabanlı platformlara, İHA görüntüleri ise hava tabanlı platformlara en genel örneklerdendir. Bir görüntünün GSD'si, sensörün yüksekliği ve yönü, kullanılan elektromanyetik radyasyonun dalga boyu ve sensörün boyutu ile kalitesi gibi birkaç faktörden etkilenir.

Bir uzaktan algılama görüntüsünün yer örnekleme mesafesi, görüntüde ayırt edilebilen detay seviyesini doğrudan etkiler. GSD değeri daha küçük olduğunda, piksel merkezleri arasındaki mesafe azalır ve görüntüde daha yüksek detayların yakalanabilmesi sağlanır. Tersine, daha yüksek bir GSD, daha düşük çözünürlüklü bir görüntüye yol açar. Örneğin, bir kameranın belirli bir irtifada sahip olduğu minimum GSD değeri 0.8 cm/pikselse, bu irtifada çekilen bir görüntüden elde edilebilecek en küçük detay, doğrusal olarak 0.8 cm olacaktır. Şekil 2.7'de GSD oranı arttıkça en küçük detayın düştüğü görülmektedir.



Şekil 2.7. GSD oranının görüntü kalitesi üzerindeki etkisi (Maes, 2025)

GSD, uçuş irtifasına ve üç kamera parametresine bağlıdır: sensör genişliği, odak uzaklığı ve görüntü genişliği. Denklem 2.1'de GSD oranının hesaplanması verilmiştir.

$$GSD = \frac{H \times Sw}{F \times ImgW} \quad (2.1)$$

Denklemde ifade edilen semboller;

F: Odak uzunluğu (mm)

Sw: Sensör genişliği (mm)

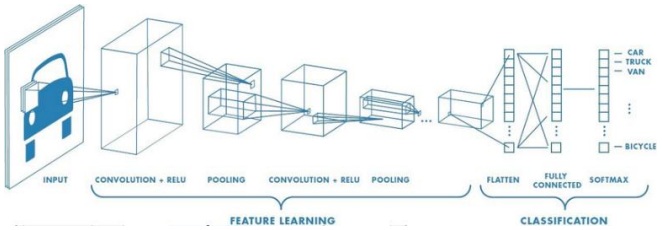
ImgW: Görüntü genişliği (piksel)

H: Yerden yükseklik (m)

2.3. Evrişimli Sinir Ağları ve Mimarisi

Evrişimsel sinir ağları (CNN), derin öğrenme alanının bir alt dalı olup, özellikle görsel verilerin işlenmesi ve analizinde yaygın olarak kullanılmaktadır. Bu ağlar, sinir ağlarının bir matematiksel işlem olan konvolüsyon (evrişim) işlemine dayalı olarak çalışır. Evrişim, doğrusal (lineer) bir işlem olup, verinin üzerinde kaydırılarak filtreleme yapar ve bu sayede görüntüdeki özellikleri öğrenir. Evrişimsel sinir ağları, katmanlarından en az birinde geleneksel matris çarpımını kullanmak yerine, evrişimsel işlemleri uygulayan ağlardır.

Temel bir CNN mimarisinde genel olarak giriş (input) katmanı, evrişim (convolution) katmanı, havuzlama (pooling) katmanı, düzleştirme (flatten) katmanı, tam bağlantı (fully connected) katmanı ve çıktı (output) katmanı olmak üzere 6 katman bulunur. Düzleştirme katmanı, tam bağlantı katmanı ve çıktı katmanı, CNN mimarisinin sınıflandırma kısmını oluşturur. Şekil 2.8'de temel bir CNN mimarisindeki katmanlar gösterilmektedir.



Şekil 2.8. Temel bir CNN mimarisi örneği (Abo Zanona, Elaiwat, Younis, Innab ve Kamruzzaman, 2022)

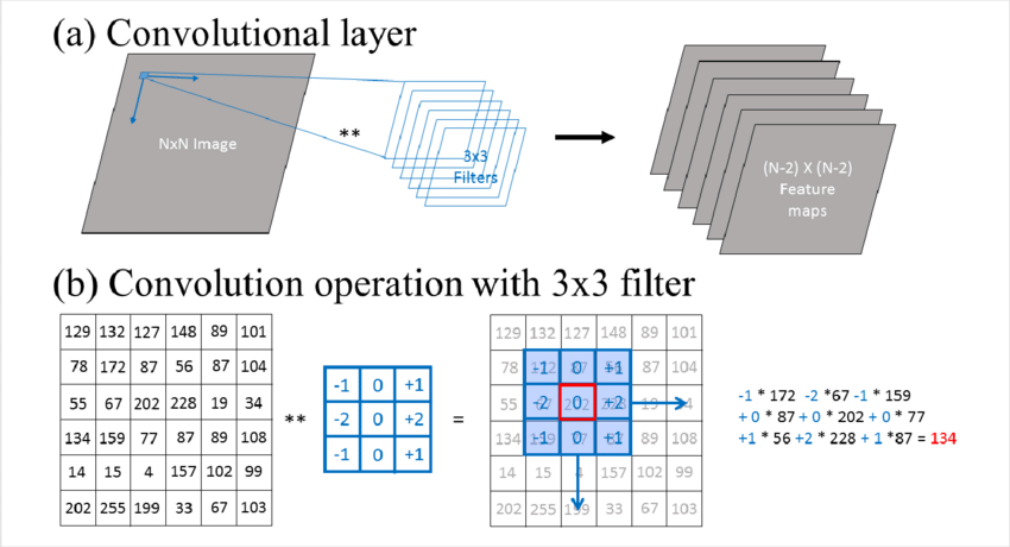
2.3.1. Giriş Katmanı

Modele veri girişinin olduğu katmandır. Genellikle bu veri bir resim veya bir dizi resmi içerir. Bu katman, genişliği 32, yüksekliği 32 ve derinliği 3 olan resmin ham girdisini tutar.

2.3.2. Evrişim Katmanı

Evrişim katmanının temel işleyişi, belirli bir filtrenin (çekirdek) görüntü üzerinde kaydırılarak her bir piksel ile çarpılması işlemine dayanır. Orijinal görüntü boyutlarından daha küçük olan bu filtre, giriş görüntüsü veya önceki katmandan gelen görüntü üzerinde hareket eder ve her piksel değeriyle çarpılarak bir çıktı değeri üretilir. Bu çıktı, ilgili piksel alanına yazılır. Çekirdek, matrisin kenarına geldiğinde, belirli bir adımda (stride) aşağıya kaydırılır ve işlem tekrarlanır. Görüntü tamamen işlendiğinde, her filtre için özgün özelliklerin bulunduğu özellik haritası (feature map) oluşturulur.

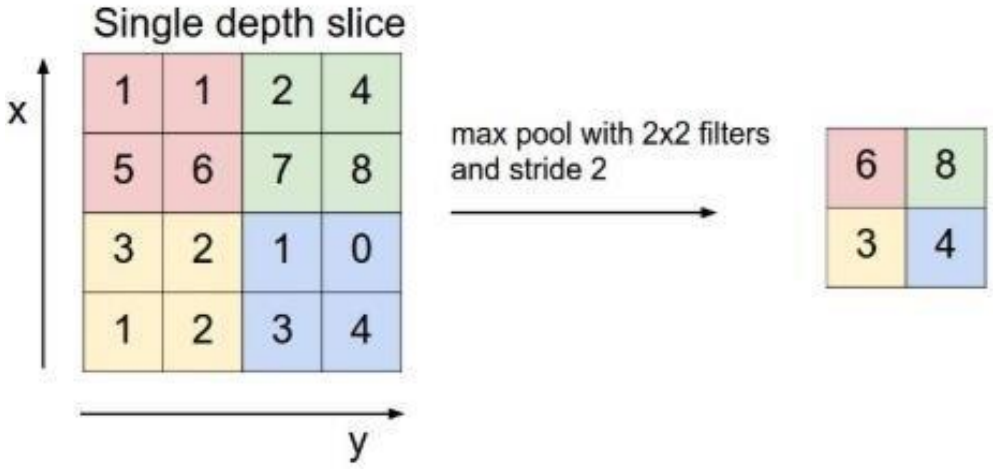
Evrişim katmanındaki filtre genişliği, filtre sayısı, adım (stride) ve dolgu (padding) parametreleri, ağın tasarımında önemli rol oynar ve bu parametreler tasarımcılar tarafından belirlenir (Krizhevsky vd., 2012). Şekil 2.9'da evrişim katmanında uygulanılan işlem gösterilmektedir.



Şekil 2.9. Evrişim katmanında filtrenin uygulanması ve özellik haritasının oluşturulması işlemi (Azuri, Goldian, Regev-Rudzki, Fantner ve Cohen, 2021)

2.3.3. Havuzlama Katmanı

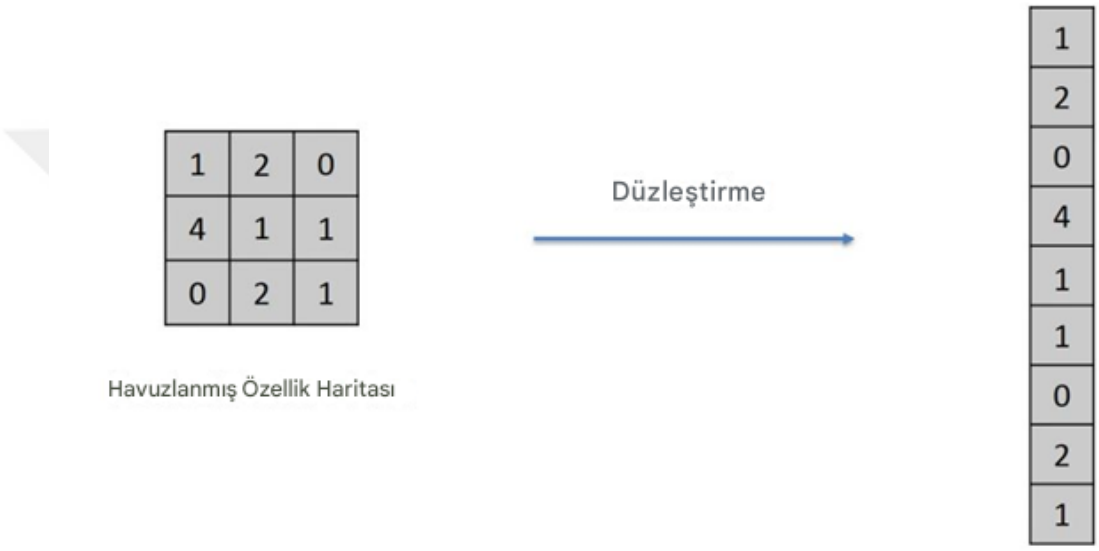
Havuzlama katmanının temel amacı, önceki katmandan elde edilen özelliklerin boyutunu azaltmaktır. Bu sayede işlem yükü azalır ve aynı zamanda gereksiz özellikler göz ardı edilerek, yalnızca önemli özelliklere odaklanılır. Bu sayede ağdaki hesaplanacak parametre sayısını azaltarak, hesaplama karmaşıklığını düşürmesi ve ağın daha hızlı bir şekilde eğitim yapmasına olanak tanır (Pacal vd., 2020). Havuzlama katmanında, evrişim katmanındaki gibi bir filtre kullanılarak, belirli adımlarla (stride) görüntü matrisi üzerinde gezinti yapılır. Ancak burada, filtre sayısal değerlere sahip değildir ve yalnızca boş bir yapıdan oluşur. Filtre, üzerinde bulunduğu görüntü değerlerini matrise kaydeder ve bu görüntüden alt kümeler elde edilmesine olanak tanır. Sonrasında, bu alt kümelerden yeni değerler türetilir. Sıklıkla kullanılan iki ana havuzlama yöntemi vardır: Maksimum (Max) havuzlama ve Ortalama (Average) havuzlama (Guo vd., 2016). Maksimum havuzlama işleminde, filtredeki en büyük değer, çıktı matrisinin ilgili alanına kaydedilir. Bu yöntem, özellikleri daha iyi koruduğu için genellikle daha sık tercih edilir. Ortalama havuzlama işleminde ise, filtredeki tüm değerlerin ortalaması alınır ve bu ortalama, çıktı matrisine kaydedilir. (İnik ve Ülker, 2017). Şekil 2.10'da havuzlama katmanındaki havuzlama işlemi gösterilmektedir.



Şekil 2.10. Havuzlama işlemi (Lakkavaram, Raghuveer, Kumar, Sri ve Habeeb, 2019)

2.3.4. Düzleştirme Katmanı

Evrişim veya havuzlama katmanına ait çıktı özellik haritalarını (feature maps), genellikle düzleştirilerek (flattening) tek boyutlu (1D) bir sayı dizisine, yani bir vektöre dönüştürür. Bu katmanın temel işlevi, sinir ağındaki en önemli katman olan tam bağlantı katmanı (fully connected layer) için giriş verilerini hazırlamaktır. Şekil 2.11'de düzleştirme katmanındaki düzleştirme işlemi gösterilmektedir.

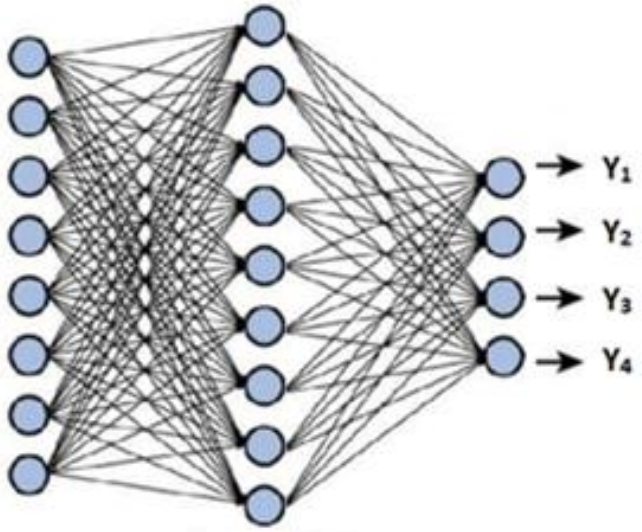


Şekil 2.11. Düzleştirme işlemi

2.3.5. Tam Bağlantı Katmanı

Bu katman, evrişimli sinir ağlarının en kritik katmanıdır ve sinir ağının yüksek seviyeli akıl yürütme işlevini yerine getirir. Düzleştirme katmanında oluşturulan vektördeki veriler, her bir girdinin her bir çıktıya öğrenilebilir ağırlıklarla bağlandığı bir veya daha fazla tam bağlantılı ağın içerisine iletilir. Tam bağlantılı ağ içerisinde, her katmandaki tüm düğümler (nöronlar), bir sonraki katmandaki tüm düğümlerle bağlantılıdır; bu özelliğinden dolayı "tam bağlantılı" olarak adlandırılır. Bu yapı sayesinde, çıkarılan tüm özellikler her bir düğüme katkı sağlar ve ağ, bu özellikler arasındaki ilişkileri daha da derinleştirerek küresel bağlamı ve desenleri yakalayabilir.

Vektörde yer alan özellikler, tam bağlantılı katmanlar aracılığıyla ağın nihai çıktısına dönüştürülür. Bu çıktıdaki nöron sayısı, genellikle tespit edilmeye çalışılan sınıf sayısıyla aynıdır. Şekil 2.12'de tam bağlantı katmanın yapısı görülmektedir.



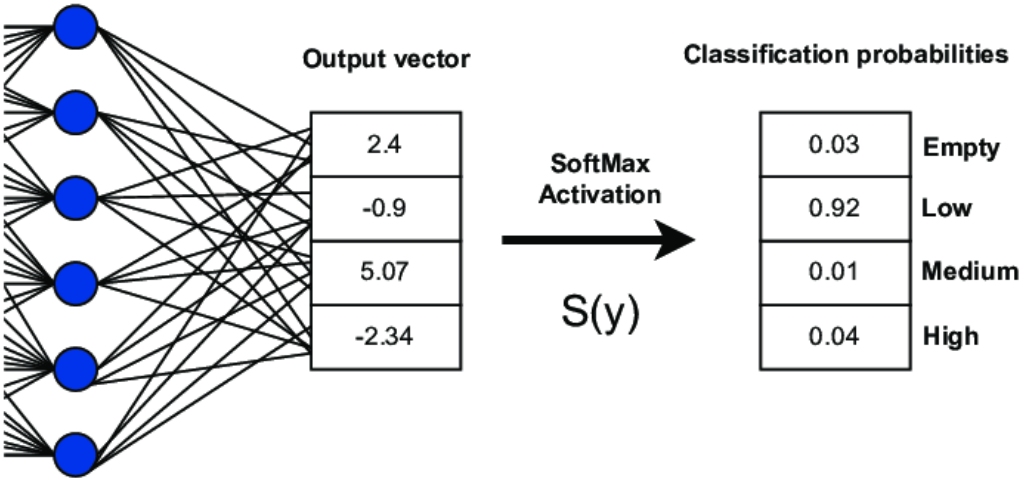
Şekil 2.12. Tam bağlantı katmanı (Maeda-Gutiérrez vd., 2020)

Genellikle bu katmanın çıktıları çıktı katmanını oluşturur ve aktivasyon fonksiyonları kullanılarak olası sınıflara karşılık gelen bir olasılık dağılımı elde edilir. Bu da ağın tahmin ettiği sınıfı belirlemesini sağlar.

2.3.6. Çıktı Katmanı

Bu katman, tam bağlantı katmanının ardından gelir ve derin öğrenme mimarilerinde ağın tahminlerini veya sınıflandırmalarını üretmekten sorumludur. Çıktı katmanının çıkış değeri, sınıflandırılacak nesne sayısına eşittir. Çıktı katmanında sigmoid ve SoftMax aktivasyon fonksiyonları tercih edilmektedir. Genellikle, SoftMax sınıflandırıcı tercih edilir, çünkü bu sınıflandırıcı başarılı sonuçlar elde etmeye olanak tanır. Sınıflandırma işlemi sırasında, her bir nesne için 0 ile 1 arasında bir çıkış değeri üretilir. Çıkış değeri 1'e yakın olan nesne, ağın tahmin ettiği nesne olarak kabul edilir (İnik ve Ülker, 2017).

Şekil 2.13'te çıktı katmanına SoftMax aktivasyon fonksiyonunun uygulanması gösterilmektedir.



Şekil 2.13. SoftMax aktivasyon fonksiyonun kullanımı ve sınıflandırma olasılıklarının oluşturulması (Cretu, Stamatescu ve Stamatescu, 2024)

2.4. Evrişimli Sinir Ağı Algoritmaları

YOLO, LeNet-5, AlexNet, VGGNet, GoogleNet, İnceptionNet, ResNet, DarkNet, ZFNet, MobileNet ve DenseNet gibi ağlar, özellikle görüntü sınıflandırma görevlerinde sıklıkla tercih edilen evrişimli sinir ağı mimarisine sahip algoritma örnekleridir. Bu algoritmalar, 1000 nesne kategorisi içeren ve yaygın olarak bilinen ImageNet veri seti üzerinde eğitilmiştir (Russakovsky vd., 2015). ImageNet'in eğitim setinde bir milyondan fazla görüntü, doğrulama setinde elli bin görüntü ve test setinde ise yüz bin görüntü yer almaktadır. Bu modeller, yalnızca eğitim süresini kısaltmakla kalmaz, aynı zamanda genelleme hatalarını da azaltarak daha iyi performans sağlar (Salehi vd., 2023).

2.4.1. YOLO Algoritması

YOLO algoritmaları evrişimli sinir ağları mimarisini kullanmaktadır. Görüntüyü bölgelere ayırarak işlem yapar. Görüntüyü tek seferde nöral ağlardan geçirir bu sebeple diğer nesne takip algoritmalarına göre daha hızlı çalışmaktadır. Diğer algoritmaların yavaş olmasının sebebi, nesne olması muhtemel alanları belirleyip hepsini ayrı ayrı nöral ağlardan geçirmeleridir. Görüntü üzerindeki işlem sayısı arttıkça hız performansı düşmektedir.

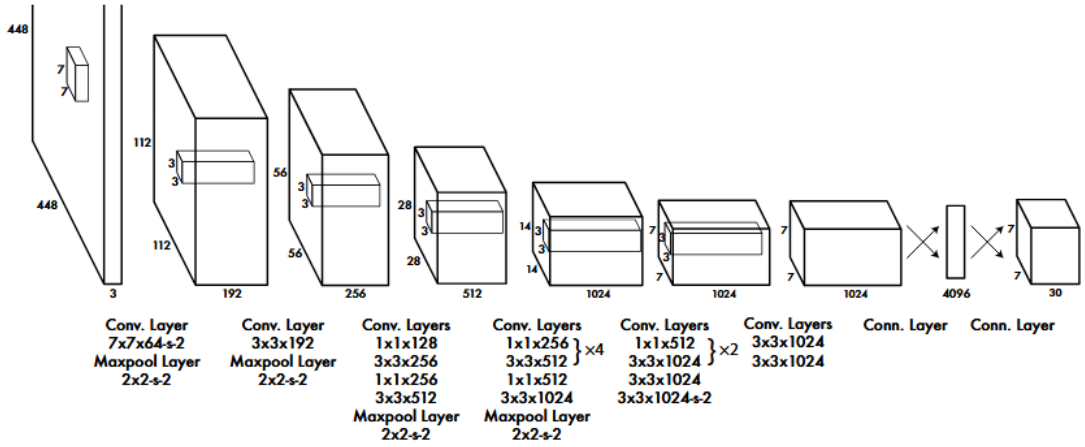
YOLO algoritması, nesne tespiti sırasında sınırlayıcı kutular (bounding boxes) kullanır. Bu kutular, görüntüde potansiyel nesnelerin yer aldığı alanları ifade eder. Her bir sınırlayıcı kutunun içinde nesne olup olmadığı, kutunun orta noktası, boyutu, konumu (koordinatları) ve güven skoru yer almaktadır (Aktaş, Demir ve Doğan, 2020). Bu bilgiler, vektör formatında saklanmakta olup, her sınırlayıcı kutu için ayrı ayrı tahmin vektörleri oluşturulmaktadır.

Birden fazla nesnenin aynı sınırlayıcı kutu (bounding box) içerisinde yer alması durumunda oluşabilecek belirsizlikleri önlemek amacıyla, YOLO algoritmalarında "anchor kutuları" kavramı geliştirilmiştir. Anchor kutuları, her bir nesneye özgü olacak şekilde sınırlayıcı kutular oluşturur ve her kutu için ayrı bir güven skoru hesaplar. Bu işlem sırasında, öngörülen kutu ile gerçek kutu arasındaki örtüşme oranını değerlendiren Intersection over Union (IoU) metriği kullanılmaktadır (Zhou vd., 2019). IoU, tahmin edilen bölge ile gerçek bölgenin ne kadar örtüştüğünü sayısal olarak ifade eder ve bu örtüşme oranı genellikle yüzde cinsinden değerlendirilir. Ayrıca, çok sayıda sınırlayıcı kutu üretildiğinde ve bu kutular arasında örtüşme oranı yüksek olanlar bulunduğunda, en güvenilir sonuçların elde edilebilmesi için Non-Maximum Suppression (NMS) algoritması devreye girer. NMS, düşük güven skoruna sahip kutuları eleyerek yalnızca en yüksek güven skoruna sahip olan kutuyu çıktı olarak sunar. Böylece, aynı nesneye ait birden fazla tahminin oluşturduğu gereksiz tekrarların önüne geçilmiş olur.

2.4.1.1. YOLO Mimarisi

YOLO mimarisi, görüntü sınıflandırması için kullanılan GoogLeNet modelinden esinlenmiştir. Algılama (detection) ağı, 24 evrişim katmanının ardından gelen 2 tam bağlantılı (fully connected) katmandan oluşmaktadır. Ara katmanlarda yer alan 1×1 boyutundaki evrişim katmanları, önceki katmanlardan gelen özellik uzayını daraltmak amacıyla kullanılmaktadır.

Bu modelin evrişim katmanları, öncelikle ImageNet sınıflandırma görevinde 224 × 224 çözünürlüğündeki giriş görüntüleriyle ön eğitimden geçirilmiştir. Daha sonra, nesne algılama işlemi için giriş çözünürlüğü iki katına çıkarılmıştır (Redmon, Divalla, Girshick ve Farhadi, 2016). Şekil 2.14'te YOLO mimarisi gösterilmektedir.



Şekil 2.14. YOLO mimarisi (Redmon vd., 2016)

2.5. Veri Çoğaltma Yöntemleri

Yaygın olarak kullanılan veri artırma (data augmentation) teknikleri, geometrik dönüşümler ve renk dönüşümlerine dayalı tekniklerdir.

2.5.1. Geometrik Dönüşümler

Geometrik dönüşümler, eğitim verisindeki görüntülerin piksel konumlarını değiştirmeyi amaçlayan işlemlerdir. Bu dönüşümler arasında yatay ve dikey yansıtma, rastgele döndürme ve ölçekleme işlemler yer almaktadır.

Yatay yansıma (horizontal flip) işlemi görselin yatay eksende simetrik olarak çevrilmesini sağlar. Bu yöntem, nesnelerin sağ-sol yönelimine karşı modelin esnekliğini artırır. Özellikle simetrik yapıya sahip objelerde, sınıflandırma ve tespit başarımını artırabilmektedir. Dikey yansıma (vertical flip) işlemi görselin dikey eksende çevrilmesi ile elde edilir. Bitkiler gibi bazı nesnelerde dikey varyasyonlar doğal olarak gözlenebilir. Bu işlem, modelin görselin konumsal farklılıklarına karşı daha dayanıklı olmasına katkı sunar.

Rastgele dönme (rotate) işleminde görsel, belirli bir açı aralığında rastgele döndürülür. Bitkilerin veya doğa görüntülerinin farklı açılardan çekilmiş versiyonlarına karşı modelin duyarlılığını azaltır ve konumsal bağımlılığı düşürür.

Ölçekleme (random scale) işleminde görsel, belirli oranlarda büyütülerek veya küçültülerek yeniden boyutlandırılır. Bu teknik, farklı uzaklıklardan çekilmiş nesnelerin varyasyonlarını modellemede etkin bir rol oynar. Şekil 2.15'te bir geometrik dönüşüm işlemi olan yansıtma işleminin örneği gösterilmiştir.



Şekil 2.15. Geometrik dönüşüm örneği

2.5.2. Fotometrik Dönüşümler

Fotometrik dönüşüm (photometric augmentation) yöntemleri, piksel konumlarını değiştirmek yerine doğrudan piksel veya yoğunluk (parlaklık) değerleri üzerinde değişiklik yapmayı amaçlamaktadır. Renk temelli artırmalar; parlaklık, kontrast, doygunluk ve renk tonu değişimi, gölge ve gürültü ekleme, hareket bulanıklığı ve gamma dönüşümü gibi işlemleri içermektedir.

Parlaklık ve kontrast değişimi (random brightness and contrast) işleminde görselin genel parlaklığı ve kontrastı rastgele oranlarda değiştirilir. Bu yöntem, değişken ışık koşullarında çekilmiş görsellerle modelin başa çıkabilmesini amaçlar ve ışıklandırmaya bağlı overfitting riskini azaltır.

Renk doygunluğu ve ton ayarı (Hue, Saturation, Value Adjustment) işleminde görselin renk tonları, doygunluğu ve parlaklık değeri belirli sınırlar dahilinde değiştirilir. Bu yöntem, özellikle dış ortam koşullarının neden olduğu renk varyasyonlarına karşı modelin toleransını artırır.

Gölge eklenmesi (random shadow) işleminde görsel üzerine rastgele gölge desenleri eklenir. Bu işlem, doğal ortamda oluşabilecek gölgelere karşı modelin daha gerçekçi senaryolarda da başarıyla çalışmasını sağlar.

Hareket bulanıklığı (motion blur) görselin belirli bir yönde ve şiddette bulanıklaştırılması işlemidir. Hareket halinde ya da titreşimli kamera ile elde edilen görüntülerin simülasyonu yapılır. Bu sayede bulanık görsellerdeki performans artışı hedeflenir.

Gamma dönüşümü (random gamma) işleminde görselin gama değeri değiştirilerek parlaklık ve renk kontrastı modifiye edilir. Bu işlem, özellikle kamera veya sensör kaynaklı parlaklık farklarının etkisini azaltmak için kullanılır.

Gauss gürültüsü ekleme (Gaussian noise) işleminde görsele istatistiksel olarak belirli bir ortalama ve varyansa sahip Gauss dağılımlı gürültü eklenir. Bu yöntem, görüntülerin düşük kaliteli ya da sensör kaynaklı bozulmalar içermesi durumunu simüle ederek modelin dayanıklılığını artırır. Şekil 2.16'da fotometrik dönüşüm örnekleri gösterilmektedir.



Şekil 2.16. Fotometrik dönüşüm örnekleri

BÖLÜM 3

MATERYAL VE YÖNTEM

3.1. Kullanılan Materyal

Tez için Trakya bölgesi endemik türleri olan *Dianthus ingoldbyi, Centaurea kilaea* ve *Verbascum degenii* bitkileri, uzman görüşler ve literatür taraması doğrultusunda çevresindeki bitkilerden ayırt edilebilme özelliklerinin yüksek olması, kritik tehlike altında olmaları ve alternatif ilaç olma potansiyellerinin yüksek olması nedenleri ile seçilmiştir.

Endemik bitkilerin havadan fotoğraflanması için Da-Jiang Innovations (DJI) Phantom 3 Advanced ve DJI Mini 4 Pro insansız hava araçlarının kameraları kullanılmıştır. Şekil 3.1'de ve Şekil 3.2'de kullanılan insansız hava araçlarına ait görseller yer almaktadır.



Şekil 3.1. DJI Phantom 3 Advanced



Şekil 3.2. DJI Mini 4 Pro

Görsel verilerin çoğaltılması için Albumentations isimli veri çoğaltma kütüphanesi, görsel veri setlerinin etiketlenmesi için Roboflow aracı kullanılmıştır.

Python altyapısına sahip PyCharm programında, YOLO nesne tespit algoritmasının v11 nano modeli eğitimde kullanılmıştır. YOLO algoritması, sunmuş olduğu hızlı ve yüksek oranlı doğruluk özelliğine sahip olmasından ve literatürde nesne tespit uygulamalarında sıkça kullanılmasından dolayı tercih edilmiştir.

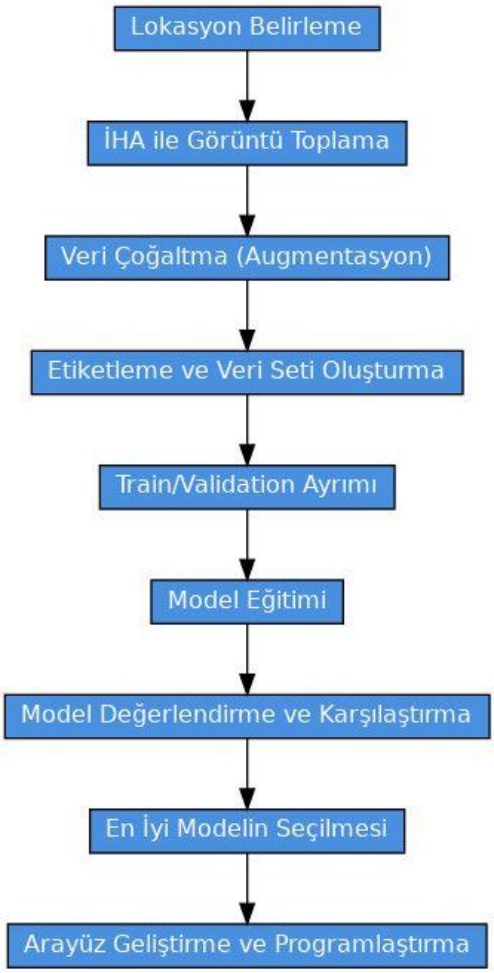
Testler ve algoritmanın eğitimi Intel Core i5 1235U 1.30-4,40 GHz işlemciye sahip Windows 11 Home işletim sistemi kullanan bir bilgisayar ile yapılmıştır.

Algoritmaya görsel arayüz kazandırarak program haline getirmek için PyCharm programında, Tkinter grafiksel arayüz aracı ve executable (çalıştırılabilir) dosya haline dönüştürmek için PyInstaller paketi kullanılmıştır.

3.2. Kullanılan Yöntem

Yapılan çalışma sırasıyla lokasyon seçimi ve görsel verinin toplanması, veri çoğaltma teknikleri ile görsel verilerin çoğaltılması, verilerin etiketlenmesi ve veri setlerinin oluşturulması, YOLO formatına uygun haline getirilmesi, veri setlerinin belirli ayrım oranına göre eğitim (train) ve doğrulama (validation) olarak ayrılması, YOLO v11 nano modeli kullanılarak modellerin eğitilmesi işlemleri ile başlamaktadır.

Son kısımda iki modelin performans metriklerine göre değerlendirilmesi, karşılaştırılma sonucu en iyi performans gösteren modelin seçilmesi ve arayüz eklenerek exe. uzantılı çalıştırılabilir program haline dönüştürme yöntemleri yer almaktadır. Bu süreç, Şekil 3.3'teki akış şemasında görselleştirilmiştir.



Şekil 3.3. Yöntemin akış diyagramı

3.2.1. Görsel Veri Toplanması

Seçilen bitkilerden *Centaurea kilaea* ve *Verbascum degenii*, İğneada lokasyonunda bulunmuş, *Dianthus ingoldbyi* ise Keşan'da İbrice Limanı lokasyonunda bulunmuştur. Endemik bitkilerin havadan fotoğrafları, yer örnekleme aralığı (Ground sampling distance) oranına göre hesaplanan uçuş yükseklerine bağlı kalınarak çekilmiştir. Hesaplamalar denklem 2.1 kullanılarak yapılmıştır.

GSD oranları, endemik bitkiler ile ilgili yapılan literatür çalışmasında elde edilen morfolojik bilgilerden yararlanılarak en küçük parçası bir pikselin içine sığacak şekilde belirlenmiştir. Çizelge 3.1'de kullanılan 2 farklı IHA için GSD oranları ve maksimum uçuş yükseklikleri görülmektedir.

Çizelge 3.1. Endemik bitkiler için hesaplanan GSD oranları ve maksimum uçuş yükseklikleri (Kullanılan 2 İHA'ya göre sınıflandırılmış)

DJI Phantom 3 Advanced		
Bitki Adı	GSD Oranları	Maksimum Uçuş Yükseklikleri
Centaurea kilaea	0,3 cm/px	38 m
Verbascum degenii	0,3 cm/px	38 m
Dianthus ingoldbyi	0,2 cm/px	25 m
DJI Mini 4 Pro		
Bitki Adı	GSD Oranları	Maksimum Uçuş Yükseklikleri
Centaurea kilaea	0,3 cm/px	54 m
Verbascum degenii	0,3 cm/px	54 m
Dianthus ingoldbyi	0,2 cm/px	36 m

Birinci arazi çalışmasında birinci veri setini oluşturan 12 mega piksel (MP) çözünürlüğe sahip 8 adet *Centaurea kilaea*, 17 adet *Dianthus ingoldbyi*, 20 adet *Verbascum degenii* fotoğrafları DJI Phantom 3 Advanced kullanılarak ortalama 7 metre yüksekliğinden çekilmiştir. Şekil 3.4'te çekilmiş olan *Verbascum degenii* görseli verisi örneği gösterilmektedir.



Şekil 3.4. Havadan çekilmiş *Verbascum degenii* endemik bitkisi (kırmızı çember ile içeri alınmış)

İkinci arazi çalışmasında 48 MP çözünürlüğe sahip 19 adet *Dianthus ingoldbyi*, 11 adet *Verbascum degenii* fotoğrafları, DJI Mini 4 Pro kullanılarak daha fazla 5,10 ve 15 metrelik farklı yüksekliklerden çekilerek elde edilmiştir. DJI Mini 4 Pro insansız hava aracının kamerasının sağladığı yüksek çözünürlüğü kullanmak adına ikinci arazi çalışmasında daha yüksek irtifalardan fotoğraflar çekilmiştir. Şekil 3.5'te çekilmiş olan *Dianthus ingoldbyi* görseli verisi örneği gösterilmektedir.



Şekil 3.5. Havadan çekilmiş *Dianthus ingoldbyi* endemik bitkisi (kırmızı çember ile içeri alınmış)

Birinci veri seti iki arazi çalışmasında da elde edilen toplamda 75 görüntüden oluşmaktadır.

3.2.2. Görsel Verilerin Çoğaltılması

Sınırlı sayıda doğal görsele sahip olan birinci veri seti bu çalışmada, modelin aşırı ezberlemeden korunması ve genelleme yeteneğinin artırılması için çeşitli veri çoğaltma yöntemleri uygulanmıştır. Kapsamlı bir literatür incelemesi, yatay ve dikey yansıtma, parlaklık–kontrast–doygunluk, rastgele döndürme, Gauss gürültü ekleme gibi basit fakat etkili veri çoğaltma tekniklerinin, özellikle küçük veri setlerinde model performansını anlamlı şekilde artırdığını göstermiştir (Shorten ve Khoshgoftaar, 2019)

Bu sebeple görsel çoğaltma tekniklerinden, yatay ve dikey yansıtma, rastgele döndürme ve ölçekleme, parlaklık, kontrast, doygunluk ve renk tonu değişimi, gölge ve gürültü ekleme, hareket bulanıklığı ve gamma dönüşümü teknikler Albumentations kütüphanesi kullanılarak uygulanmıştır. Şekil 3.6'da kullanılan kod görülmektedir.

```
transform = A.Compose([
    A.HorizontalFlip(p=0.5),
    A.VerticalFlip(p=0.3),
    A.RandomBrightnessContrast(p=0.5),
    A.Rotate(limit=25, p=0.6),
    A.HueSaturationValue(p=0.5),
    A.RandomShadow(p=0.2),
    A.MotionBlur(p=0.2),
    A.RandomGamma(p=0.3),
    A.RandomScale(scale_limit=0.2, p=0.4),
    A.GaussNoise(p=0.2),
])
```

Şekil 3.6. Kodda yer alan veri çoğaltma işlemleri ve olasılıkları

Veri çoğaltma işlemlerin sonucu birinci veri setinden eğitim için ayrılan 63 adet görüntü belirtilen veri çoğaltma teknikleri kullanılarak toplamda 240 adet görüntüye çıkartılmıştır. 6 adet *Centaurea kilaea* görüntüsünden 74 adet yapay görüntü, 31 adet *Dianthus ingoldbyi* görüntüsünden 49 adet yapay görüntü ve 26 adet *Verbascum degenii* görüntüsünden 54 adet yapay görüntü oluşturarak, üç endemik bitkininde toplamda 80 adet görsele sahip olması ile sınıf dengesi sağlanmıştır.

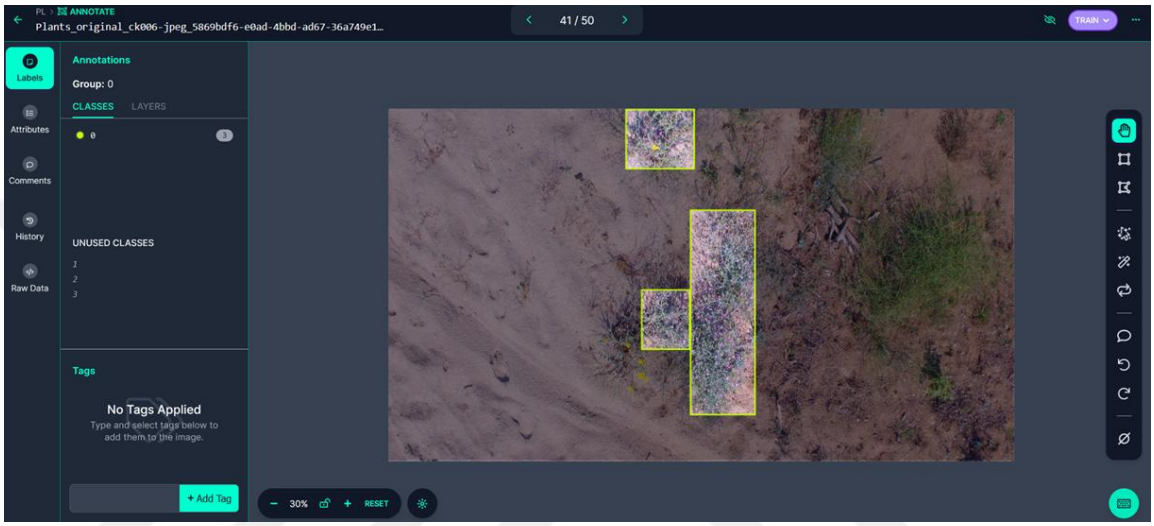
Veri çoğaltma işlemlerinin uygulanması ile birlikte toplamda 2 adet veri seti oluşturulmuştur. Çizelge 3.2'de doğal görsel verilerden oluşan birinci veri seti ve çoğaltılmış ve doğal görsel verilerden oluşan ikinci veri seti ile ilgili özellikler gösterilmiştir.

Çizelge 3.2. Oluşturulan veri setlerinin özellikleri

Veri Seti Adı	Veri Tipi	Toplam Görsel Veri Sayısı
Birinci veri seti	Doğal	75
İkinci veri seti	Doğal ve Çoğaltılmış	262

3.2.3. Görsel Verilerin Etiketlenmesi

Etiketleme işlemi, bir görüntüdeki belirli nesneleri veya özellikleri tanımlamaya yarayan bir işlemdir ve eğitilecek olan modelin objenin ne olduğunu anlamasına yardımcı olur. Bu sebeple doğru etiketleme yöntemi kullanılması gerekir. İki veri setinin de etiketlenmesinde Roboflow aracı kullanılmıştır. Şekil 3.7'de Roboflow aracı ile yapılan etiketleme işlemi görülmektedir.



Şekil 3.7. Roboflow aracı ile etiketleme işlemi

Endemik bitkilerin bulunduğu görsel veriler bahsedilen etiketleme programları kullanılarak, sınırlayıcı kutu (bounding box) etiket yöntemi ile etiketlenmiştir. Görsel verideki her bir bitkinin çiçek ve yapraklarını içeren alanı bir kutu içerisine alınarak sınırlayıcı kutu etiket yöntemi kullanılmıştır. Kutu ile oluşturulan sınırlayıcı alana bitkinin isim bilgisi atanmış ve sınıf kodu verilmiştir.

3.2.4. Görsel Verilerin YOLO Formatına Dönüştürülmesi

Etiketli görsel verilerin YOLO modelleri tarafından tanınabilmesi için görsel veriler YOLO formatında verilere dönüştürülmüştür. Veriler, görsel veriler aynı isme sahip fakat .txt uzantısında sahiptir. YOLO formatlı verilerin içeriğinde, sınırlayıcı kutunun görseldeki konumunu belirten bilgiler bulunur. 1. sütunda sınıfın (endemik bitkinin) kodu, 2. ve 3. sütundaki veri, orta noktasını (x ve y koordinatını), 4. sütundaki veri genişliğini, 5. sütundaki veri, yüksekliğini verir.

Orijin noktası olarak görüntünün sol üst köşesidir ve bu noktaya göre referans alınır. Şekil 3.8'de YOLO formatlı verinin içeriği gösterilmiştir.



Şekil 3.8. YOLO formatlı veri

3.2.5. Veri Setlerinin Ayrılması

Modelin genelleme yeteneğini ölçebilmek için, eğitim sürecinde görmediği bağımsız bir doğrulama (validation) veri setine ihtiyaç vardır. Doğrulama verilerinin, eğitim verisiyle görsel veya sahne örtüşmesi bulunmaması, her sınıf temsil eden ve doğal görsellerden oluşması gerekmektedir.

Bu çalışmada birinci veri setinde yaklaşık %80 eğitim – %20 doğrulama ayrımı uygulanmış olup, doğrulama veri setindeki 12 adet görsel 2 adet *Centaurea kilaea* görüntüsünden, 5 adet *Dianthus ingoldbyi* görüntüsünden ve 5 adet *Verbascum degenii* görüntüsünden oluşmaktadır. Bu oran, derin öğrenme literatüründe düşük ve orta büyüklükteki veri setleri için önerilen en yaygın yaklaşımdır (Zhang, Bengio, Hardt, Recht ve Vinyals, 2017). Böylelikle model hem yeterli sayıda örnekle öğrenme sürecini sürdürebilmesi hem de doğrulama seti sayesinde genel performans güvenilir bir şekilde izlenebilmesi sağlanmıştır. İkinci veri setinde de aynı görseller doğrulama setinde karşılaştırma işleminin doğru yapılabilmesi adına kullanılmıştır. Çizelge 3.3'te iki veri setinin veri ayırma işlemi sonrası eğitim ve doğrulama veri sayılar gösterilmiştir.

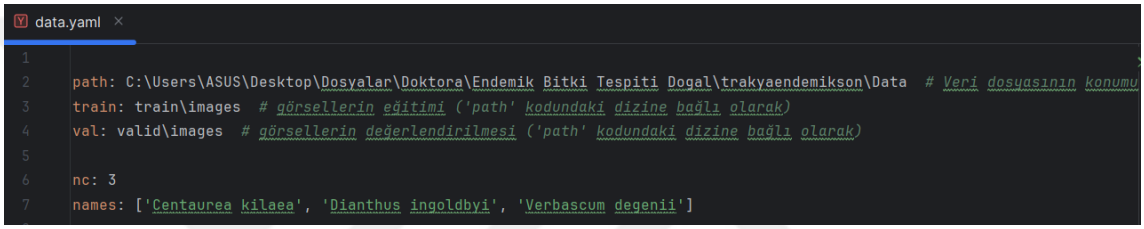
Çizelge 3.3. Eğitim ve doğrulama veri sayıları

Veri Seti Adı	Eğitim Verisi Sayısı	Doğrulama Verisi Sayısı
Birinci veri seti	63	12
İkinci veri seti	240	12

3.2.6. YOLO Modellerinin Eğitilmesi

Modellerin eğitilmesi için YOLO, Yet Another Markup Language (YAML) konfigürasyon dosyalarını kullanır. Bu dosyaların içerisinde veri setlerin yolu, sınıf kodu gibi önemli bilgiler bulunması gerekir.

Kullanılan YAML konfigürasyon dosyasında, veri dosyasının konumu, algoritmanın eğitiminde kullanılacak olan veri setinin dosya konumu, algoritmanın değerlendirilmesinde kullanılacak olan veri setinin dosya konumu ve endemik bitkilerin sınıf kodları yer almaktadır. Şekil 3.9'da YAML konfigürasyonuna ait kod yer almaktadır.



Şekil 3.9. YAML konfigürasyonu kodunun içeriği

Bu çalışmada modelin eğitimi için Stochastic Gradient Descent (SGD) optimizasyon algoritması tercih edilmiştir. SGD, özellikle sınırlı ya da augment edilmiş veri kümeleri üzerinde, adaptif optimizasyon algoritmalarına kıyasla daha kontrollü bir öğrenme süreci sunar ve genelleme başarımını artırma eğilimindedir (Wilson, Roelofs, Stern, Srebro ve Recht, 2017).

Model eğitimi sırasında kullanılan diğer hiperparametreler de veri setinin yapısı, donanım kısıtları ve overfitting riskleri göz önünde bulundurularak sistematik biçimde belirlenmiştir. Eğitim süresinin çok kısa tutulması modelin yeterince öğrenememesine, çok uzun tutulması ise overfitting'e neden olabileceğinden, literatürde önerilen aralıklara uygun şekilde 100 tekrar (epoch) bir sınır belirlenmiştir (He, Zhang, Ren ve Sun, 2016). 8 ve 16 olarak seçilen yığın boyutu (batch size), hem GPU bellek yükünü dengelemiş hem de gradyan hesaplamasında yeterli stabilite sağlamıştır. Orta ölçekli veri setlerinde 16–32 arası batch değerleri önerilmektedir.

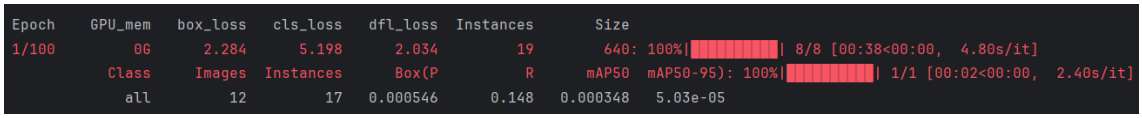
Başlangıç öğrenme oranı olarak 0.01 ve 0.005 değerleri kullanılmıştır. SGD ile yapılan eğitimlerde, küçük veri setlerinde çok yüksek olmayan, ancak öğrenmenin yeterince hızlı başlayabilmesini sağlayacak bir lr0 tercih edilmesi önerilmektedir. Erken durdurma (early stopping) mekanizması, validation performansında belirli bir iyileşme gözlenmediği takdirde eğitim sürecini sonlandırmak amacıyla devreye alınmıştır. 20 epoch'luk patience süresi, modelin geç öğrenen sınıflar üzerinde fırsat bulabilmesi amacıyla esnek bırakılmıştır. Bu değer, küçük-orta büyüklükteki veri setleri için önerilen aralıktadır (Prechelt, 1998).

Bu parametrelerin bir arada kullanımı, modelin hem öğrenme kapasitesini yeterli düzeyde kullanmasını hem de aşırı öğrenmeden kaçınmasını hedeflemektedir. Birinci modelin eğitiminde birinci veri seti kullanılmış ve ikinci modelin eğitiminde ikinci veri seti kullanılmıştır. Eğitimde kullanılan parametreler Çizelge 3.4'te gösterilmiştir.

Çizelge 3.4. İki modelde kullanılan eğitim parametreleri

Eğitim Parametresi	Birinci Model	İkinci Model
Optimizasyon Algoritması	SGD	SGD
Epoch	100	100
Lr0	0.005	0.01
Patience	20	20
Batch size	8	16

Eğitim sırasında box_loss, cls_loss ve dfl_loss değerleri incelenir bu değerler Şekil 3.10'da görülmektedir. Box_loss değeri, tespit edilen objeyi kutu içerisine alırken sınırlarını doğru şekilde çizilip çizilmediğini belirten değerdir. Cls_loss değeri, objenin ne olduğunu doğru bir şekilde tanımlanıp tanımlanmadığını belirten değerdir. Dfl_loss değeri, algılanın nesnenin özelliklerini iyi kavrayıp kavramadığını belirtir ve birbirine çok benzeyen objelerin veya ayırt edilmesi zor nesnelerin ayrımını yapabilme yeteneğini ifade eder.



Şekil 3.10. Eğitim sırasındaki değeler

3.2.7. Değerlendirmede Kullanılacak Performans Metrikleri

Değerlendirme sırasında, doğruluk (accuracy), kesinlik (precision), geri çağırma (recall), F1 puanı, mAP50 ve mAP50-95 performans metriklerine bakılacaktır.

Doğruluk, pozitif veya negatif olsun, tüm sınıflandırmaların doğru olma oranıdır. Kesinlik, pozitif olarak tahmin edilen değerlerin gerçekten kaç tanesinin pozitif olduğunu ifade eder. Geri çağırma, pozitif olarak tahmin edilmesi gereken işlemlerin ne kadarının pozitif olarak tahmin edildiğini gösteren bir değerdir. Bu metriklerin hesaplanmasında 4 değer kullanılır, bunlar;

- Doğru Pozitif (TP): Gerçek değerin 1 ve tahmin edilen değerin de 1 olduğu örneklerdir.
- Doğru Negatif (TN): Gerçek değerin 0 ve tahmin edilen değerin de 0 olduğu örneklerdir.
- Yanlış Pozitif (FP): Gerçek değerin 0 ancak tahmin edilen değerin 1 olduğu örneklerdir.
- Yanlış Negatif (FN): Gerçek değerin 1 ancak tahmin edilen değerin 0 olduğu örneklerdir.

Denklem 3.1'de doğruluk metriğinin hesaplanması verilmiştir.

$$Doğruluk = \frac{Doğru\ Sınıflandırmalar}{Toplam\ Sınıflandırmalar} = \frac{TP+TN}{TP+TN+FP+FN} \tag{3.1}$$

Denklem 3.2'de kesinlik performans metriğinin hesaplanması verilmiştir.

$$Precision = \frac{TP}{TP+FP} \tag{3.2}$$

Denklem 3.3'te geri çağırma performans metriğinin hesaplanması verilmiştir.

$$Recall = \frac{TP}{TP+FN} \tag{3.3}$$

AP (Average precision) değeri ortalama precision değerini ifade eder. Mean Average Precision (mAP) birden fazla nesne sınıfına ait ortalama AP değerlerinin hesaplanması ile bulunur. Denklem 3.4'te bu değerin hesaplanması ifade edilmiştir.

$$mAP = \frac{1}{n}\sum_{k=1}^{k=n} AP_k \tag{3.4}$$

Denklemde bulunan “k” parametresi ise her bir sınıf için hesaplanan ortalama precision değerini temsil ederken, “n” parametresi ise veri setindeki toplam sınıf sayısını belirtir. mAP değeri, mAP50 ve mAP50-95 olmak üzere iki şekilde ifade edilir. Birleşim üzerinde kesişim (Intersection over Union) adı verilen IoU metriği, tahmin edilen sınırlayıcı kutu ile temel gerçek sınırlayıcı kutu arasındaki örtüşmeyi niceliksel olarak belirleyen bir ölçüdür. mAP50, 0,50’lik eşiğe sahip IoU değerlerinin ortalama mAP değerlerini ifade eder ve modelin kolay algılamadaki doğruluk performansını ölçücüsüdür. mAP50-95, 0,50 ile 0.95 arasında değişen IoU değerlerinin ortalama mAP değerlerini ifade eder ve modelin yüksek zorluk seviyesindeki algılama performansını gösterir.

F1 puanı makine öğrenmesi alanında sınıflandırma modellerinin performansını değerlendirmek amacıyla kullanılan önemli bir ölçüttür. Özellikle sınıf dengesizliğinin söz konusu olduğu durumlarda, modelin başarı düzeyini daha doğru bir şekilde yansıtmak için tercih edilir. F1 puanı, hassasiyet ve geri çağırmanın harmonik ortalamasıdır. Denklem 3.5’te F1 puanının hesaplanması verilmiştir.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{3.5}$$

Bu metrik, hassasiyet ve geri çağırma değerlerinin önemini dengeler ve sınıf dengesi bozuk veri kümeleri için doğruluk yerine tercih edilir. Hassasiyet ve geri çağırma değerleri 1,0 değerinde olduğunda F1 değeri de 1,0 değerinde olur. Daha genel olarak, hassasiyet ve geri çağırma değerleri birbirine yakın olduğunda F1 de bu değerlerin yakınında olur. Hassasiyet ve geri çağırma birbirinden uzak olduğunda F1, daha kötü olan metriğe benzer.

F1 puanı genellikle güven (confidence) skoru ile birlikte değerlendirilir. Güven skoru 0,7'nin üzerinde olduğunda tahmin kullanıcının sorgusunu yanıtlamak için güçlü bir aday olduğunu, 0,3 ile 0,7 arasında olduğunda tahminin kullanıcının isteği kısmen yanıtlayabildiğini ve 0,3'ün altında ise tahminin kullanıcı için muhtemelen iyi bir seçim olmadığını ifade eder (Ren, He, Girshick ve Sun, 2015).

3.3. Trakya Endemik Bitki Tespit Programı

Modelin kullanımını kolaylaştırmak adına görsel arayüz kazandırma ve executable (çalıştırılabilir) dosya haline getirme işlemleri uygulanmıştır.

Kullanılan materyal kısmında bahsedildiği üzere görsel arayüz kazandırmak için Tkinter modülü, Python ile kullanılabilen, birçok işletim sisteminde çalışabilen ve basit yapıya sahip olması nedeni ile tercih edilmiştir. PyInstaller paketi sayesinde arayüz kazandırılmış algoritma programı .exe uzantılı dosya haline getirilmiş ve programa erişim kolaylaştırılmıştır. Programın mimarisi görsel verinin yüklenmesi, tespitinin yapılması ve sonuçların aktarılması aşamalarından oluşmaktadır.

3.3.1. Program Mimarisi

Program açıldığında açılan pencerede, tespiti yapılabilen endemik bitkilerin isimlerine ait bilgi notu ve veri yükleme, tespit ve sonuç aktarma işlemlerini başlatan başlat butonu bulunmaktadır. Açılış penceresine ait içerik ve geometrik özellikler Label fonksiyonu ile sağlanır. Pencere boyutu olarak 600 x 350, buton boyutu olarak 40 x 20 ölçüleri verilmiştir. Şekil 3.11'de başlangıç penceresine ait özelliklerin yer aldığı kod gösterilmektedir.

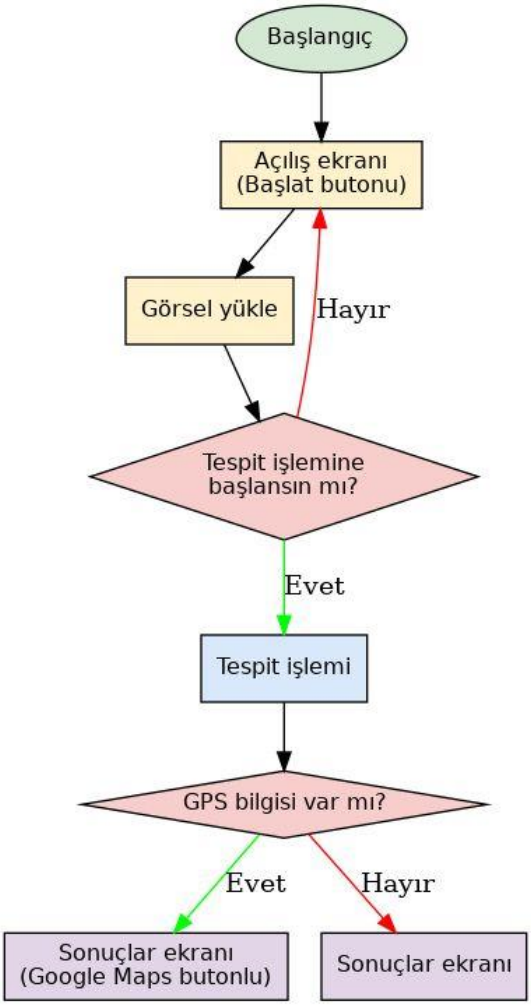
```
9   form=tk.Tk()
10  form.title("Trakya Endemik Bitki Tespiti")
11  form.geometry('600x350')
12  form.state('normal')
13  label=tk.Label(form,text='Programa Hoş Geldiniz', font='consoles 14 bold')
14  label.pack()
15  label2=tk.Label(form,text='Tespiti Yapılabilen Endemik Bitkiler;',font='consoles 12')
16  label2.pack()
17  label3=tk.Label(form,text='Centaurea kilaea, Dianthus ingoldybi, Verbascum degenii',font='consoles 11 italic')
18  label3.pack()
```

Şekil 3.11. Başlangıç penceresine ait kod

Başlat butonuna tıklandığında kullanıcıya tespit işleminin yapılmasını istediği görseli seçmesi gerektiğini ifade eden bir mesaj gönderilir. Bu mesaj Tkinter'in messagebox modülü kullanılarak oluşturulmuştur.

Bir sonraki mesaj görsel verinin içerisinde küresel konumlama sistemi (GPS) verisi olması gerektiği ile alakalıdır. Sonuç kısmında Google Maps linkini verebilmesi için görselde GPS verisi bulunmalıdır. Görsel veri yükleme işlemi Tkinter'in filedialog modülünden yararlanılarak gerçekleştirmektedir.

Veri yükleme işleminden sonra kullanıcıya tespit işleminin yapılması ile ilgili soru sorulur. Evet butonuna basıldığında tespit işlemine başlanır, hayır butonuna basıldığında işlem iptal edilir. Tespit işlemi, kod tarafından verinin algoritmaya aktarılması, algoritmanın tespit işlemini uygulanması ve eğer tespit işlemi başarılı ise üzerinde yüzdesi ve sınıfı bulunan kutulama işlemi görsel verideki bitkinin üzerine uygulanması ile sonlanır. Tespit işlemi uygulanmış görsel veriye 1 adı ve .jpg uzantısı verilerek results (sonuçlar) klasörüne kaydedilir. Program tespit işleminin başarılı olduğunu ve sonuçların yüklendiğini ifade eden mesajı kullanıcıya bildirir. Eğer görselde GPS verisi bulunmuyorsa "Görselde GPS verisi bulunamamıştır, Google Maps linki verilemeyecektir" şeklinde bir uyarı gönderilir ve sadece bitki tespit sonucunun olduğu görsel gösterilir. Programın akışının özetlendiği akış diyagramı Şekil 3.12'de gösterilmektedir.



Şekil 3.12. Programın akış diyagramı

Sonuçlar kısmı, 1200 x 700 boyutlarına sahip tespit işlem uygulanmış görselin fotoğrafının ve Google Maps linkini açan butonun oluştuğu pencereden oluşmaktadır. Şekil 3.13'te sonuçlar penceresinin özelliklerin yer aldığı kod görüntülenmektedir.

```
messagebox.showinfo(title='Sonuçlar', message='Tespit işlemi başarılı, sonuçlar yüklenmiştir')
sonuclar = tk.Toplevel()
sonuclar.title('Tespit Sonuçları')
sonuclar.geometry('1200x700')
baslik_label=tk.Label(sonuclar,text='Tespit edilen endemik bitki ve Google Maps linki aşağıda listelenmiştir.')
baslik_label.pack()
myimg= Image.open('results/' + str(image_no) + '.jpg')
resized = myimg.resize( size: (1100,619), Image.LANCZOS)
phz= ImageTk.PhotoImage(resized)
mylabel =tk.Label(sonuclar, image=phz)
mylabel.image = phz
mylabel.pack(expand=1)
buton2 = (tk.Button(sonuclar, text='Google Maps Linki', font='consoles 10 bold', command=openlink).pack(side=tk.BOTTOM,ipady=40))
```

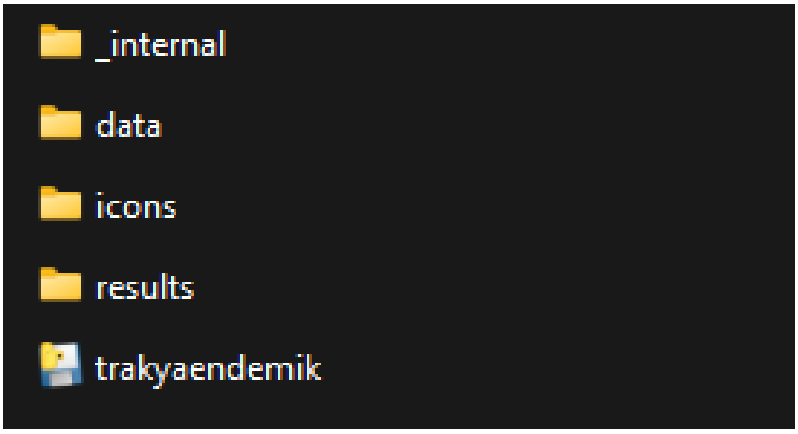
Şekil 3.13. Sonuçlar penceresine ait kod

Program, PIL.ExifTags paketindeki GPSTAGS ve TAGS modüllerini kullanarak görsel verinin içerisindeki enlem ve boylam verilerini alır ve ondalık değerlere fonksiyonlar ile dönüştürülür.

Bu veriler Google Maps tekdüzen kaynak bulucusuna (url) eklenir ve görsel veriye ulaşmak için tıklanabilen bir link haline, webbrowser paketi kullanılarak dönüştürülür. Sonuçlar penceresindeki görsel, çok yüksek çözünürlüklere sahip olabileceğinden PIL paketinin resize fonksiyonu kullanılarak 1100 x 619 boyutlarına yeniden boyutlandırılarak gösterilir. Programın tüm mimarisini içeren kod *Ek 1* kısmında yer almaktadır.

3.3.2. Programın Çalıştırılabilir Dosyaya Dönüştürülmesi

Algoritma programını .exe uzantılı çalıştırılabilir dosya haline getirmek için ifade edildiği üzere PyInstaller paketi kullanılmıştır. Terminal üzerinden pyinstaller --noconsole trakyaendemik.py komutu kullanılarak işlem gerçekleştirilmiştir. Dosyaya tıklanıldığında konsol penceresinin açılmaması için --noconsole ifadesi kullanılmıştır. Şekil 3.14'te program ait dosya içeriği görülmektedir.



Şekil 3.14. Program ait dosyanın içeriği

Dosyada 4 adet veri klasörü ve 1 adet programı açan trakyaendemik.exe dosyası bulunmaktadır. Data klasörü kullanılan algoritmanın verisini, _internal klasörü programın koduna ait verileri, icons klasörü başlangıç sayfasındaki bitkilerin ikon şeklindeki görselleri ve results klasörü ise tespit yapılan görsel veriyi içerir.

BÖLÜM 4

SONUÇLAR VE TARTIŞMA

4.1. Birinci Veri Seti ile Eğitilmiş YOLO v11n Modelinin Tespit Sonuçları

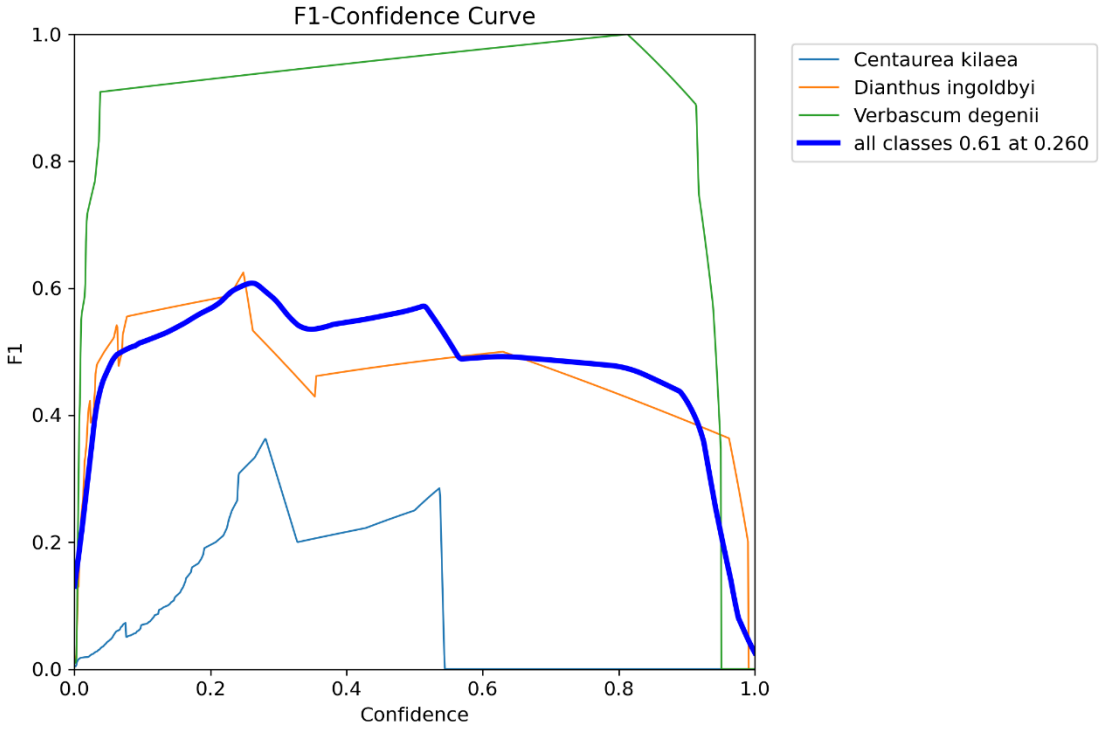
Tespit sonuçları olarak Bölüm 3'ün sonunda belirtilen performans metrikleri olan kesinlik (precision), geri çağırma (recall), mAP50, mAP50-95 ve F1 puanı gösterilmiş ve değerlendirilmiştir. Modelin tespit özelliğinin değerlendirilebilmesi için validate (doğrulama) işlemi uygulanmıştır. Çizelge 4.1'de 100 döngü ile eğitilen modelin eğitim sırasında elde edilen en iyi metrikleri gösterilmiştir.

Çizelge 4.1. Birinci veri seti ile eğitilmiş modelin eğitim sırasında elde ettiği en iyi metrikler

Precision	Recall	mAP50	mAP50-95
0,721	0,593	0,606	0,384

100 döngü ile eğitim sonrası doğrulama işlemi ile ulaşılan tespit doğruluk oranları kolay tespitte *Centaurea kilaea* bitkisi için %18.9, *Dianthus ingoldbyi* bitkisi için %63.6, *Verbascum degenii* bitkisi için %99.5 olarak bulunmuştur. Zor tespitte model, zor tespitte ise *Centaurea kilaea* bitkisi için %7.5, *Dianthus ingoldbyi* bitkisi için %38.4 doğruluk ve *Verbascum degenii* bitkisi için %69.2 doğruluk ile tespit edebilme özelliğine sahiptir. Modelin genel özelliklerine bakıldığında kolay tespitte %60.6 oranında ve zor tespitte %38.4 oranında doğruluk tespit edebilme özelliğinin olduğu görülmüştür.

Şekil 4.1'deki F1 puanı/güven skoru grafiği incelendiğinde genel anlamda 0,260 güven skorunda F1 puanının 0,61 olduğu görülmektedir.



Şekil 4.1. Birinci veri seti ile eğitilmiş modelin F1-Güven grafiği

Centaurea kilaea bitkisinde modelin 0,36 olan en yüksek F1 puanına 0,28 güven skorunda ulaştığı, *Dianthus ingoldbyi* bitkisinde modelin en yüksek olduğu 0,63 olan F1 puanına 0,25 güven skorunda ulaştığı ve *Verbascum degenii* bitkisinde modelin en yüksek olduğu 1 olan F1 puanına 0,81 güven skorunda ulaştığı görülmektedir.

Centaurea kilaea bitkisinde modelin istenilen F1 performansı gösteremediği ve yetersiz kaldığını, *Dianthus ingoldbyi* bitkisinde modelin *Centaurea kilaea* bitkisine göre daha iyi olduğunu ve tüm güven skorlarında yeterli görülebilecek bir F1 performansı sergilediğini, *Verbascum degenii* endemik bitkisinde modelin ise bu bitkiler içerisinde en iyi değerlere sahip olduğunu ve yüksek güven skorlarında oldukça iyi bir F1 performansı sergilediğini ifade edebiliriz.

4.2. İkinci Veri Seti ile Eğitilmiş YOLO v11n Modelinin Tespit Sonuçları

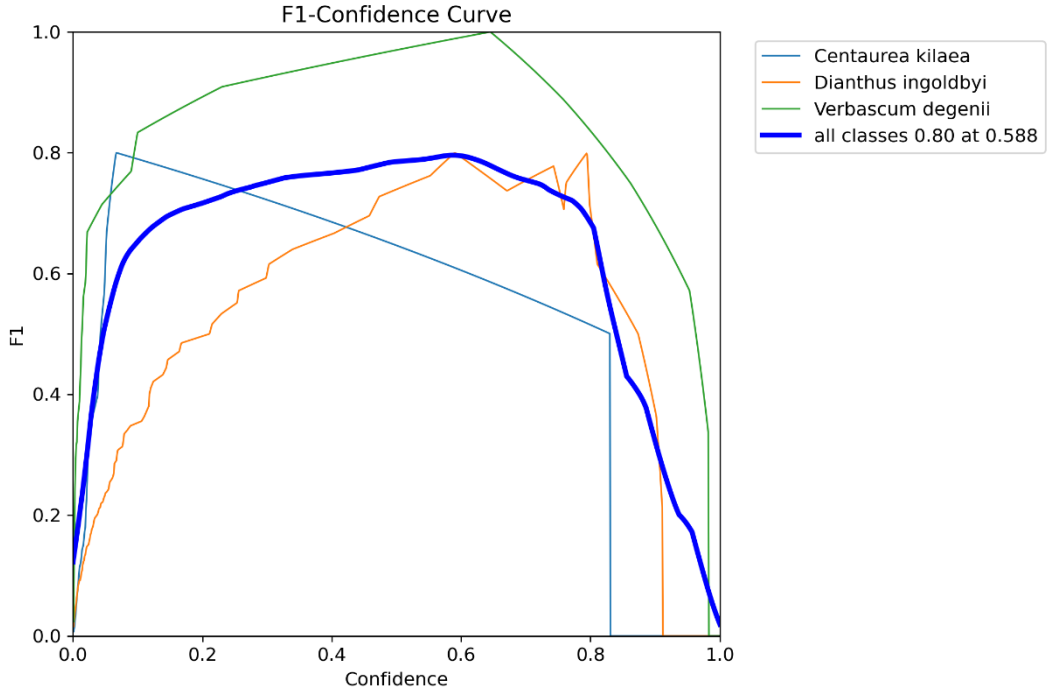
Çizelge 4.2'de 100 döngü ile eğitilen modelin eğitim sırasında elde edilen en iyi metrikleri gösterilmiştir.

Çizelge 4.2. Birinci veri seti ile eğitilmiş modelin eğitim sırasında elde ettiği en iyi metrikler

Precision	Recall	mAP50	mAP50-95
0,893	0,778	0,833	0,549

100 döngü ile eğitim sonrası doğrulama işlemi ile ulaşılan tespit doğruluk oranları kolay tespitte *Centaurea kilaea* bitkisi için %66.9, *Dianthus ingoldbyi* bitkisi için %83.6, *Verbascum degenii* bitkisi için %99.5 olarak bulunmuştur. Zor tespitte model, zor tespitte ise *Centaurea kilaea* bitkisi için %36.7, *Dianthus ingoldbyi* bitkisi için %45.5 doğruluk ve *Verbascum degenii* bitkisi için %82.5 doğruluk ile tespit edebilme özelliğine sahiptir.

Şekil 4.2'deki F1 puanı/güven skoru grafiği incelendiğinde genel anlamda 0,588 güven skorunda F1 puanının 0,80 olduğu görülmektedir.



Şekil 4.2. İkinci veri seti ile eğitilmiş modelin F1-Güven grafiği

Centaurea kilaea bitkisinde modelin 0,8 olan en yüksek F1 puanına 0,07 güven skorunda ulaştığı, *Dianthus ingoldbyi* bitkisinde modelin en yüksek olduğu 0,8 olan F1 puanına 0,8 güven skorunda ulaştığı ve *Verbascum degenii* bitkisinde modelin en yüksek olduğu 1 olan F1 puanına 0,64 güven skorunda ulaştığı görülmektedir.

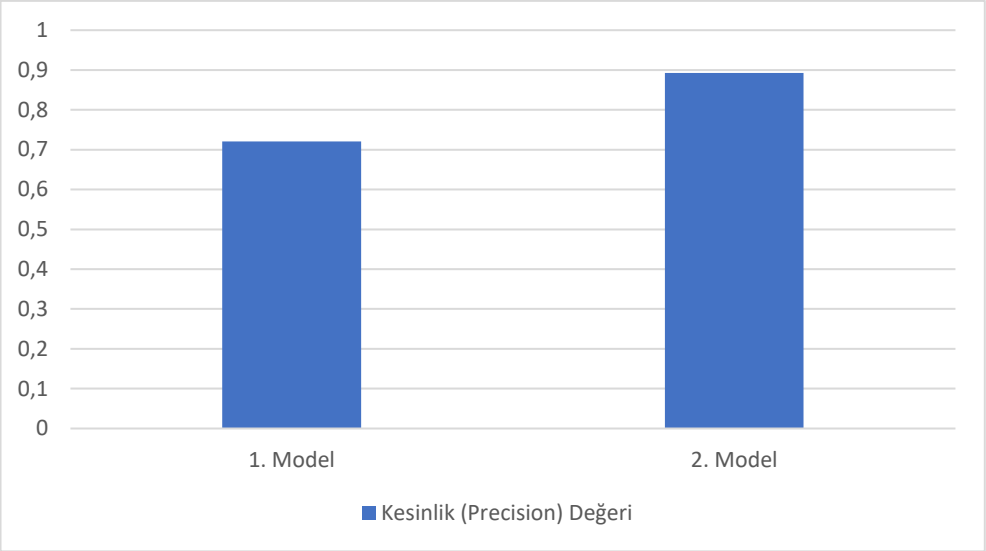
Centaurea kilaea bitkisinde modelin 0.8 güven skoruna kadar yeterli bir F1 performansı gösterdiği ve özellikle düşük güven aralığında iyi performans gösterdiğini, *Dianthus ingoldbyi* bitkisinde modelin *Centaurea kilaea* bitkisine göre daha iyi olduğunu ve tüm güven skorlarında yeterli görülebilecek bir F1 performansı sergilediğini, *Verbascum degenii* endemik bitkisinde modelin ise bu bitkiler içerisinde en iyi değerlere sahip olduğunu ve tüm güven skorlarında oldukça iyi bir F1 performansı sergilediğini ifade edebiliriz.

4.3. Modellerin Karşılaştırılması

Karşılaştırma işleminde birinci veri seti ile eğitilen model, birinci model olarak ifade edilmiş ve ikinci veri seti ile eğitilen model, ikinci model olarak belirtilmiştir. İki model, performans metrikleri yönünden karşılaştırılmış ve değerlendirilmiştir. Karşılaştırma işlemi kesinlik, geri çağırma, mAP50, mAP50-95 ve F1/Güven performans metrikleri üzerinden yapılmıştır.

4.3.1. Kesinlik Yönünden Karşılaştırılması

Birinci karşılaştırmada modellerin doğrulama (validation) işlemi sonrası elde edilen kesinlik (precision) değerleri karşılaştırılmıştır. Şekil 4.3'te geliştirilen iki modelin kesinlik değerlerinin karşılaştırıldığı grafik verilmiştir.

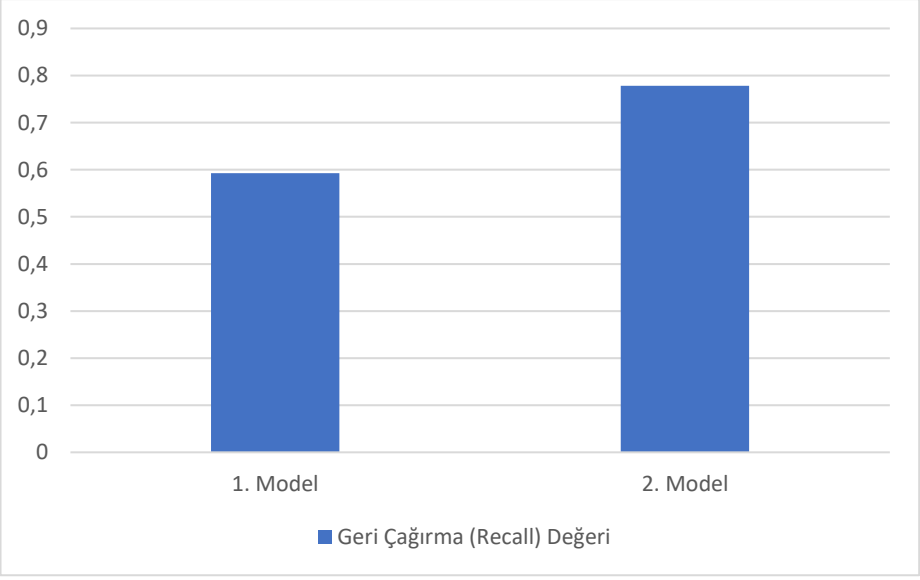


Şekil 4.3. Modellerin kesinlik değerlerinin karşılaştırılması

Karşılaştırılmaya bakıldığında içerisinde doğal ve çoğaltılmış veriler bulunan ikinci veri seti ile eğitilmiş YOLO v11n modelinin en yüksek kesinlik değerine sahip olduğu görülmüştür.

4.3.2. Geri Çağırma Yönünden Karşılaştırılması

İkinci karşılaştırmada modellerin doğrulama (validation) işlemi sonrası elde edilen geri çağırma (recall) değerleri karşılaştırılmıştır. Şekil 4.4'te geliştirilen iki modelin geri çağırma değerlerinin karşılaştırıldığı grafik verilmiştir.

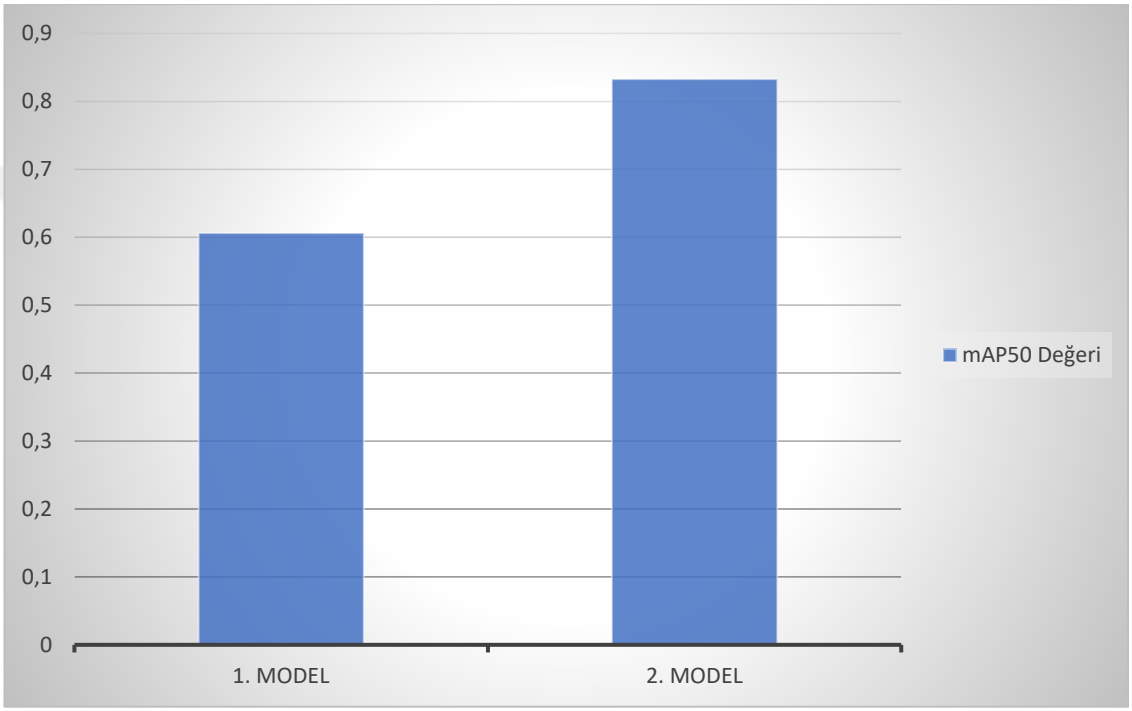


Şekil 4.4. Modellerin geri çağırma değerlerinin karşılaştırılması

Karşılaştırılmaya bakıldığında 2. modelin yüksek geri çağırma değerine sahip olduğu görülmüştür.

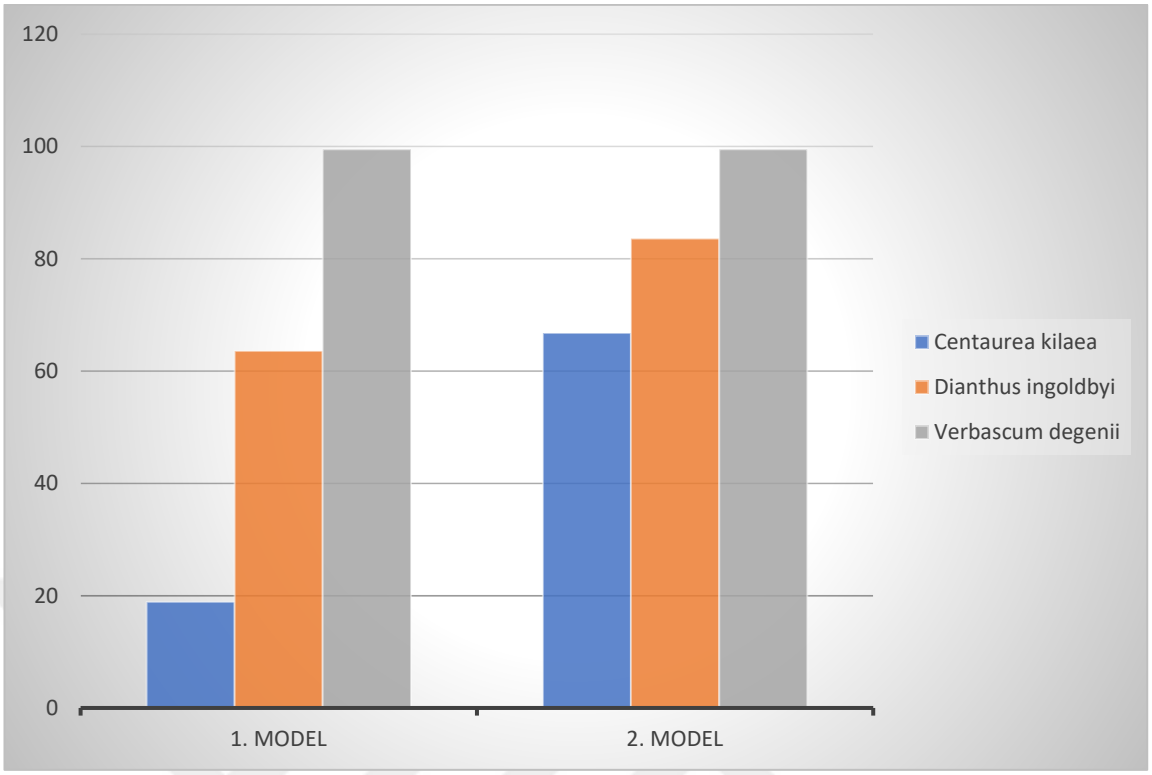
4.3.3. mAP50 Değerleri Yönünden Karşılaştırılması

Üçüncü karşılaştırmada modellerin doğrulama (validation) işlemi sonrası elde edilen genel ve üç endemik bitki üzerinden mAP50 değerleri karşılaştırılmıştır. Şekil 4.5'te modellerin genel mAP50 değerlerinin karşılaştırıldığı grafik gösterilmiştir.



Şekil 4.5. Modellerin genel mAP50 değerlerinin karşılaştırılması

Karşılaştırılmaya bakıldığında veri çoğaltma teknikleri ile oluşturulan 2. veri seti ile eğitilmiş olan YOLO v11n modeli diğer modelden üstün olduğu görülmektedir. Şekil 4.6'da mAP50 değerlerinden yola çıkılarak modellerin üç endemik bitki üzerine tespit oranları karşılaştırılmıştır.

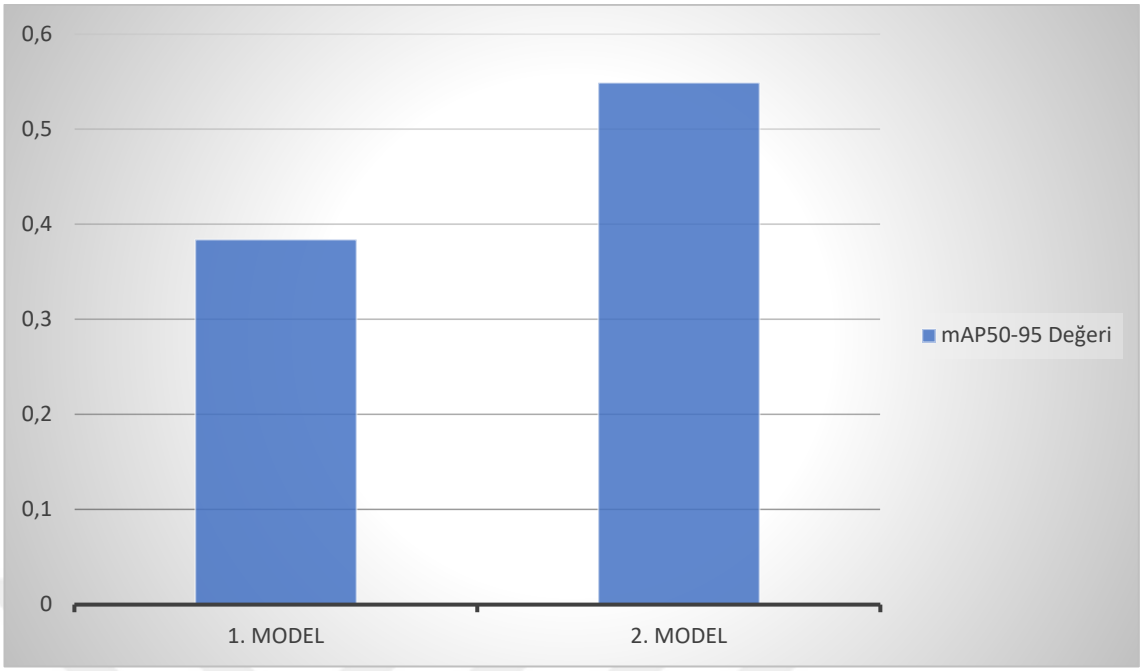


Şekil 4.6. Modellerin üç endemik bitkiye göre mAP50 değerlerinin oransal olarak karşılaştırılması

Karşılaştırılmaya bakıldığında *Verbascum degenii* bitkisi için 1 ve 2 numaralı modellerde eşit yüzde ile en yüksek mAP50 değerlerine sahip olduğu, *Dianthus ingoldbyi* bitkisi için 2 numaralı modelin diğer modele üstün mAP50 değerlerine sahip olduğu ve *Centaurea kilaea* bitkisi için 2 numaralı model ile 1 numaralı model arasında ciddi bir fark oluştuğu gözlemlenmiştir.

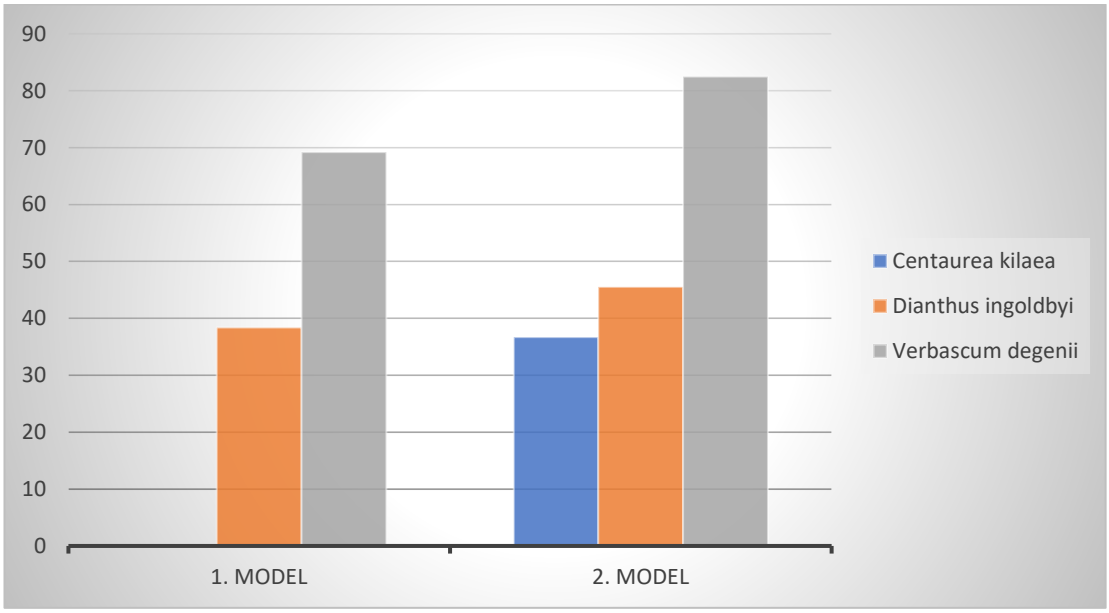
4.3.4. mAP50-95 Değerleri Yönünden Karşılaştırılması

Dördüncü karşılaştırmada modellerin doğrulama (validation) işlemi sonrası elde edilen genel ve üç endemik bitki üzerinden mAP50-95 değerleri karşılaştırılmıştır. Şekil 4.7'de genel mAP50-95 değerlerinin karşılaştırıldığı grafik gösterilmiştir.



Şekil 4.7. Modellerin genel mAP50-95 değerlerinin karşılaştırılması

Karşılaştırılmaya bakıldığında 2. veri seti ile eğitilmiş olan YOLO v11n modelinin yine üstün olan taraf olduğu belirlenmiştir. Şekil 4.8'de mAP50-95 değerlerinden yola çıkılarak modellerin üç endemik bitki üzerine tespit oranları karşılaştırılmıştır.



Şekil 4.8. Modellerin üç endemik bitkiye göre mAP50-95 değerlerinin oransal olarak karşılaştırılması

Karşılaştırılmaya bakıldığında *Verbascum degenii* bitkisi için 2 numaralı modelin en yüksek mAP50-95 değerine sahip olduğu, *Dianthus ingoldbyi* bitkisi için yine 2 numaralı modelin en yüksek mAP50-95 değerine sahip olduğu ve *Centaurea kilaea* bitkisi için 2 numaralı algoritmanın ciddi bir fark ile en yüksek mAP50-95 değerine sahip olduğu belirlenmiştir. 1. Modelin *Centaurea kilaea* mAP50-95 değerinin grafikte gözükmeme sebebi %0.07 gibi çok düşük bir orana sahip olmasıdır.

4.3.5. F1/Güven Puanı Yönünden Karşılaştırılması

Beşinci karşılaştırmada modellerin doğrulama (validation) işlemi sonrası elde edilen genel ve üç endemik bitki bazlı F1/Güven puanları karşılaştırılmıştır. Çizelge 4.3'te modellerin F1/Güven puanı grafiklerinden elde edilen sonuçlar ve değerlendirmeler yer almaktadır.

Çizelge 4.3. Modellerin F1/Güven puanı grafiklerinden elde edilen sonuçların karşılaştırılması

Özellik / Model	1. Model	2. Model
Maksimum F1 (Tüm sınıflar)	0,61	0,80
Confidence (Maks. F1 noktası)	0,260	0,588
Eğri kararlılığı	Düşük ve Dengesiz	Dengeli ve Kararlı

Karşılaştırılmaya bakıldığında 2. Modelin en iyi genel performansı verdiği ifade edilebilir. Çizelge 4.4'te modellerin, *Centaurea kilaea* endemik bitkisine göre F1/Güven puanlarının karşılaştırılması yer almaktadır.

Çizelge 4.4. *Centaurea kilaea* endemik bitkisine göre modellerin F1 ve güven puanları

Model / Özellik	F1 puanı	Güven puanı
1. Model	0,36	0,28
2. Model	0,8	0,07

Karşılaştırılmaya bakıldığında *Centaurea kilaea* bitkisi için en iyi performansı 2. model göstermiştir. Çizelge 4.5'te modellerin, *Dianthus ingoldbyi* endemik bitkisine göre F1/Güven puanlarının karşılaştırılması yer almaktadır.

Çizelge 4.5. *Dianthus ingoldbyi* endemik bitkisine göre modellerin F1 ve güven puanları

Model / Özellik	F1 puanı	Güven puanı
1. Model	0,63	0,25
2. Model	0,8	0,8

Karşılaştırılmaya bakıldığında *Dianthus ingoldbyi* bitkisi için en iyi performansı 2. model göstermiştir. Çizelge 4.6'da modellerin, *Verbascum degenii* endemik bitkisine göre F1/Güven puanlarının karşılaştırılması yer almaktadır.

Çizelge 4.6. *Verbascum degenii* endemik bitkisine göre modellerin F1 ve güven puanları

Model / Özellik	F1 puanı	Güven puanı
1. Model	1	0,81
2. Model	1	0,64

Karşılaştırılmaya bakıldığında *Verbascum degenii* bitkisi için tüm algoritmaların tam F1 puanına ulaştığı, bu sebeple sadece güven puanları üzerinde karşılaştırılması gerektiği ifade edilebilir. Bu sebeple 1. model en iyi performansı göstermiştir.

4.4. Tartışma

Karşılaştırmalara bakıldığında neredeyse tüm performans metriklerinde çoğaltılmış veri ile eğitilmiş olan 2. modelin üstün olduğu görülmüş, F1 skoru ve mAP gibi metriklerde %20-30 arası artış sağlandığı belirlenmiştir. Sınırlı veri sayısında ve sınıf dengesizliğinde veri çoğaltma işlemenin düzgün olarak uygulanması halinde endemik bitki tespitinde etkili olabileceği varsayılabilir. Öz ve Özcan tarafından 2023 yılında gerçekleştirilen derin öğrenme ağı algoritması kullanılarak endemik bitki tespiti çalışmasında test F1-skoru ortalama 0.6486 olarak raporlanmıştır. Bu çalışma ile kıyaslandığında 0.80 F1-skoruna sahip olan eğitilmiş YOLO v11n'nin endemik bitki tespitinde daha iyi bir algoritma olduğu ifade edilebilir. (Öz ve Özcan, 2023)

Tezde uygulanan veri çoğaltma stratejileri ve YOLOv11n modelini kullanarak mAP@0.5 değerinde %13'lük bir artış sağlanmıştır. YOLOv8 mimarisi kullanan ve veri çoğaltma işlemi uygulayan Miao, Meng ve Zhou'nun 2025 yılında yapmış olduğu çalışmada mAP@0.5 değerinde yaklaşık olarak %3.3 artış sağlayabilmiştir.

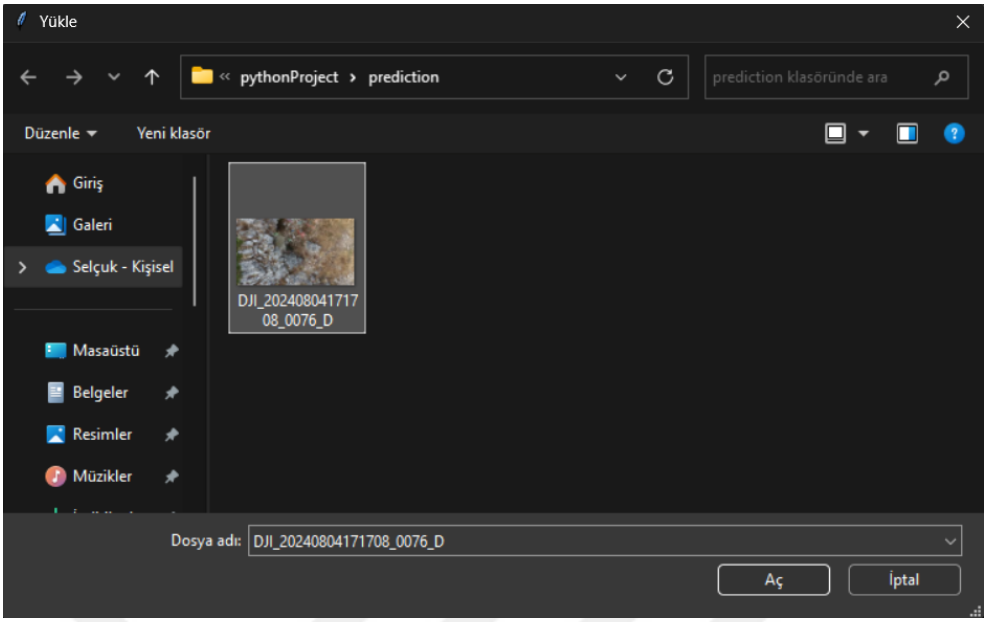
4.5. Programın Kullanımı

Program, en iyi performans gösteren ikinci model olarak isimlendirilen ikinci veri seti ile eğitilmiş olan YOLO v11 nano modelini kullanmaktadır. Programı çalıştırmak için trakyaendemik.exe dosyasına tıklanır. Tespit edilebilen bitki sınıflarının bilgisinin yer aldığı ve tespit işleminin başlamasını sağlayan başlat butonu giriş ekranında kullanıcıyı karşılar. Şekil 4.9'da program açıldığında karşılaşılan pencere görülmektedir.



Şekil 4.9. Program açılış penceresi

Başlat butonuna tıklandığında tespit edilmesi istenen görsel verinin seçilmesi istenir. Şekil 4.10'da görsel veri yükleme işlemi gösterilmektedir. Görsel seçiminin ardından tespit işlemine başlanması yönünde kullanıcı tarafından onay alınır ve model yüklenen görsel üzerinde özellik çıkarma ve sınıflandırma işlemini uygular.



Şekil 4.10. Programa veri yükleme işlemi

Görsel veri üzerinde tespit işlemi uygulandıktan sonra sonuçlar penceresi açılır ve tespit işlemi uygulanmış görsel veri gösterilir. Şekil 4.11'de tespit sonuçları penceresinin görüntüsü yer almaktadır.



Şekil 4.11. Tespit sonuçları penceresi

Görsel verinin Google Maps linkine ulaşmak için butona basılır. Varsayılan tarayıcı üzerinden link açılır ve bir anlamda tespit edilen bitkinin koordinat noktası verilmiş olur.

Eğer görsel verinin içerisinde GPS bilgisi bulunmuyor ise Şekil 4.12'de gösterilen tespit sonuçları penceresi kullanıcının karşısına çıkar.



Şekil 4.12. Sonuçlar Penceresi (GPS verisiz)

4.6. Öneriler

Bu çalışmayı tekrarlayacak ya da geliştirecek olan araştırmacılar, çalışmayı daha iyi materyal kullanarak yaptıklarında çok daha iyi sonuçlar elde edebilirler. Örnek olarak RGB kamera yerine multispektral ya da hiperspektral kamera kullanma sonucu elde edilecek olan görsel verilerin endemik bitkilerin ayırt edici özelliklerinin daha iyi sergilenmesini sağlayabilir. Bu, modelin eğitimi sırasında bitkiye ait özellikleri daha iyi tanımasına sebep olabilir.

İkinci olarak arayüzün daha da geliştirilmesi kullanıcının programı daha verimli ve hızlı kullanmasını sağlayabilir. Özellikle kodun sadeleştirmesi, programın açılış hızının artmasına, tespit işlemini, sonuçların aktarılmasını ve yükleme işlemini daha hızlı yapılmasını sağlayabilir. Bunların yanında yapılan işlemler sırasında ekstra mesaj kutularının veya butonların kullanılması yapılan işlemi sıfırlamak yerine kaldıkları yerden müdahale edebilmelerini sağlayabilir. Programa ayarlar kısmı eklenerek, tespit parametrelerinin değiştirilebilmesi gibi özellikler kazandırarak programın kişiselleştirilebilmesi sağlanabilir.

KAYNAKLAR

Abo Zanona, M., Elaiwat, S., Younis, S., Innab, N., & Kamruzzaman, M. M. (2022). Classification of palm trees diseases using convolutional neural network. International Journal of Advanced Computer Science and Applications, 13.

Aeberli, A., Johansen, K., Robson, A., Lamb, D. W., & Phinn, S. (2021). Detection of banana plants using multi-temporal multispectral UAV imagery. Remote Sensing, 13(11), 2123.

Akman, Y., Düzenli, A., & Güney, K. (2005). Biyocoğrafya. Palme Yayıncılık.

Aktaş, A., Demir, Ö., & Doğan, B. (2020). Derin öğrenme yöntemleri ile dokunsal parke yüzeyi tespiti. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 35(3), 1685–1700.

Atitallah, B. S., Maha, D., Boulila, W., Koubaa, A., Atitallah, N., & Ghezala, H. B. (2021). An enhanced randomly initialized convolutional neural network for columnar cactus recognition in unmanned aerial vehicle imagery. Applied Sciences, 192, 573–581.

Avşar, C., Keskin, H., & Berber, İ. (2016). Hastane infeksiyonlarından izole edilen mikroorganizmalara karşı bazı bitki ekstraktlarının antimikrobiyal aktivitesi. International Journal of Pure and Applied Sciences, 2(1), 22–29.

Basak, N., & Güler, N. (2000). Karyological investigation and distribution of some rare and endemic plants of European Turkey. In N. Özhatay (Ed.), Proceedings of 2nd Balkan Botany Congress (Vol. 1, pp. 435–438). Marmara University.

Bao, W., Zhu, Z., Hu, G., Zhou, X., Zhang, D., & Yang, X. (2023). UAV remote sensing detection of tea leaf blight based on DDMA-YOLO. Computers and Electronics in Agriculture, 205, 107637.

Camargo, T., Schirrmann, M., Landwehr, N., Dammer, K. H., & Pflanz, M. (2021). Optimized deep learning model as a basis for fast UAV mapping of weed species in winter wheat crops. Remote Sensing, 13(9), 1704.

Che'Ya, N. N., Dunwoody, E., & Gupta, M. (2021). Assessment of weed classification using hyperspectral reflectance and optimal multispectral UAV imagery. Agronomy, 11(7), 1435.

Comba, L., Biglia, A., Ricauda Aimonino, D., & Gay, P. (2018). Unsupervised detection of vineyards by 3D point-cloud UAV photogrammetry for precision agriculture. Computers and Electronics in Agriculture, 155, 84–95.

Cretu, G., Stamatescu, I., & Stamatescu, G. (2024). Modeling and prediction of occupancy in buildings based on sensor data using deep learning methods. IEEE Access, PP, 1–1.

Davis, P. H. (1965). Flora of Turkey and East Aegean Islands (Vol. 1). Edinburgh University Press.

Davis, P. H. (1975). Flora of Turkey and the East Aegean Islands (Vol. 5). Edinburgh University Press.

Davis, P. H. (1978). Flora of Turkey Volume 6. Edinburgh University Press.

Davis, P. H. (1988). Flora of Turkey and the East Aegean Islands (Vol. 10). Edinburgh University Press.

Dayan, S., Güler, N., Arda, H., Çolak, A., & Aytaç, A. (2013). The current distribution and conservation status of the endangered endemic Bellevalia edirnensis Özhatay & Mathew (Asparagaceae). Trakya University Journal of Natural Sciences, 14(2), 87–91.

Duran, A., & Duman, H. (2002). Two new species of Centaurea (Asteraceae) from Turkey. Annales Botanici Fennici, 39, 43–48.

Elgendi, M., Nasir, M., Tang, Q., Smith, D., Grenier, J.-P., Batte, C., Spieler, B., Leslie, W., Menon, C., Fletcher, R., Howard, N., Parker, W., & Nicolaou, S. (2021). The effectiveness of image augmentation in deep learning networks for detecting COVID-19: A geometric transformation perspective. Frontiers in Medicine, 8, 629134.

Fan, Z., Lu, J., Gong, M., Xie, H., & Goodman, E. D. (2018). IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 11(3).

Grieve, M. A. (1995). Modern Herbal. Barnes and Noble Books.

Görlich, F., Marks, E., Mahlein, A.-K., König, K., Lottes, P., & Stachniss, C. (2021). UAV-based classification of Cercospora leaf spot using RGB images. Drones, 5(2), 34.

Güler, N. (2013). Kırklareli ili (Merkez, Babaeski, Kofçaz, Lüleburgaz, Pehlivanköy ve Pınarhisar) flora ve vejetasyonu. Çevre ve Orman Bakanlığı, Kırklareli Orman İşletme Müdürlüğü.

Güner, A. (2012). Türkiye Bitkileri Listesi (Damarlı Bitkiler). Nezahat Gökyiğit Botanik Bahçesi Yayınları.

Güner, A., Özhatay, N., Ekim, T., & Başer, K. H. C. (2000). Flora of Turkey and the East Aegean Islands (Vol. 11, Supplement 2). Edinburgh University Press.

Hassan, Q. K., Pourghasemi, H. R., & Panahi, M. (2023). Applications of UAV-based remote sensing in natural resource management: A comprehensive review. Sensors, 23(4), 1655.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 770–778)

İlçim, A., Behçet, L., & Mükemre, M. (2013). Dianthus vanensis (Caryophyllaceae), a new species from Turkey. Turkish Journal of Botany, 37, 219–224.

İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85–104.

International Union for Conservation of Nature (IUCN). (2001). IUCN Red List categories and criteria: Version 3.1. IUCN Species Survival Commission. IUCN.

Kaynak, G., Daşkın, R., Yılmaz, Ö., & Erdoğan, E. (2006). Verbascum yurtkuraianum, a new species from northwest Anatolia, Turkey. Annales Botanici Fennici, 43, 456–459.

Kargıoğlu, M., Cenkci, S., & Dayan, S. (2008). Endemic plant species and their endangered categories vegetated in the boundary of Afyonkarahisar province in Turkey. Pakistan Journal of Botany, 40(4), 1785–1796.

Kaya, B., & Duman, H. (2012). Contribution to the taxonomy of Centaurea L. sect. Pseudoseridia Wagenitz (Asteraceae) in Turkey. Turkish Journal of Botany, 36(3), 291–304.

Kaya, B., & Ülker, E. (2018). A new species of Centaurea L. (Asteraceae) from the central Anatolia region of Turkey. Turkish Journal of Botany, 42(6), 512–517.

Kaya, B., & Yıldız, M. (2020). Centaurea henricii (Asteraceae), a new species from Turkey. Turkish Journal of Botany, 44, 1–6.

Kılıç, G., Kaya, B., & Duman, H. (2022). Two new species from Centaurea L. sect. Pseudoseridia Wagenitz (Asteraceae) from Central Anatolia, Turkey. Turkish Journal of Botany, 46(4), 351–359.

Kiranyaz, S., Ince, T., & Gabbouj, M. (2021). Real-time UAV detection of unknown objects based on incremental learning. Pattern Recognition, 114, 107878.

Koc, M. (2012). The flora of Seben (Bolu, Turkey). Turkish Journal of Botany, 36(1), 101–113.

Köksal, F., & Erdoğan, N. (2016). A new species of Centaurea (Asteraceae) from western Turkey. Phytotaxa, 248(1), 87–93.

Kültür, Ş. (2022). A contribution to the flora of Gümüşhane, Turkey. Turkish Journal of Botany, 46, 417–429.

MacKinlay, A. (2017). Gelişen teknolojiler ve yapay zeka. Nobel Akademik Yayıncılık.

Meena, K. S., & Kavya, B. (2023). Applications of machine learning algorithms in plant disease detection: A review. International Journal of Research and Analytical Reviews, 10(1), 120–128.

Miao, Y., Meng, W., & Zhou, X. (2025). SerpensGate-YOLOv8: An enhanced YOLOv8 model for accurate plant disease detection. Frontiers in Plant Science, 15, Article 1514832.

Öz, M., & Özcan, A. (2023). Endemic plant classification using deep neural networks. Orclever Proceedings of Research and Development, 2(1), 59–67

Özhatay, N., & Kültür, Ş. (2019). New taxa and new records from Turkish flora. Turkish Journal of Botany, 43(4), 413–426.

Prechelt, L. (1998). Early stopping — But when? In G. B. Orr & K.-R. Müller (Eds.), Neural networks: Tricks of the trade (pp. 55–69).

Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. Advances in Neural Information Processing Systems, 28, 91–99.

Ryder, P., & Ostendorf, B. (2017). Estimating cover and structure of shrub vegetation with UAV-based multispectral imagery. Remote Sensing, 9(7), 706.

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. Journal of Big Data, 6(1), 60.

Şekerler, T., Şen, A., Bitiş, L., & Şener, A. (2018). Anticancer, antioxidant and anti-inflammatory activities of chloroform extracts from some Centaurea species. Proceedings, 2(25), 1542.

Şekerler, T., Şen, A., Bitiş, L., & Şener, A. (2020). In vitro antihepatocellular carcinoma activity of secondary metabolites of Centaurea kilaea Boiss. Journal of Research in Pharmacy, 24(4), 479–486.

Şen, A., Özbaş, S. T., Akbuğa, J., & Bitiş, L. (2015). In vitro antiproliferative activity of endemic Centaurea kilaea Boiss. against human tumor cell lines. Clinical and Experimental Health Sciences, 5(3), 149–153.

Şen, A., Özbaş Turan, S., & Bitiş, L. (2016). Bioactivity-guided isolation of anti-proliferative compounds from endemic Centaurea kilaea. Pharmaceutical Biology, 55(1), 541–546.

Şen, A., Şekerler, T., & Bitiş, L. (2017). Centaurea kalanlarensis, a new species from Turkey. Turkish Journal of Botany, 41(3), 457–463.

Şenol, O., Arslan, E., & Kuru, A. (2016). Morphological and anatomical studies on the genus Centaurea L. (Asteraceae) in Western Anatolia. Turkish Journal of Botany, 40(1), 28–39.

Tolunay, A., & Keleş, H. (2020). A new species of Centaurea L. sect. Phalolepis Wagenitz (Asteraceae) from Turkey. Phytotaxa, 447(2), 98–104.

Türkan, Ö. (2019). Türkiye Bitkileri. TDK Basım Yayın.

Ülker, E., & Kaya, B. (2021). Centaurea L. sect. Phalolepis Wagenitz (Asteraceae) in Turkey: New records and taxonomic remarks. Turkish Journal of Botany, 45, 193–203.

Yılmaz, N., & Kaya, B. (2017). A new species of Centaurea (Asteraceae) from the Mediterranean region of Turkey. Turkish Journal of Botany, 41, 350–355.

Wilson, A. C., Roelofs, R., Stern, M., Srebro, N., & Recht, B. (2017). The marginal value of adaptive gradient methods in machine learning. Advances in Neural Information Processing Systems, 30.

Zhang, Y., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2017). Understanding deep learning requires rethinking generalization. arXiv preprint arXiv:1611.03530

Zhang, X., & Zhou, H. (2022). An improved YOLOv5 algorithm for real-time weed detection in UAV images. Computers and Electronics in Agriculture, 193, 106616.

EKLER

EK 1 Trakya Endemik Bitki Tespit Programı Kodu

```
import tkinter as tk
import webbrowser
from PIL import Image, ImageTk
from tkinter import messagebox
from tkinter import filedialog
from ultralytics import YOLO
from PIL.ExifTags import GPSTAGS, TAGS

form=tk.Tk()
form.title("Trakya Endemik Bitki Tespiti")
form.geometry('600x350')
form.state('normal')
label=tk.Label(form,text='Programa Hoş Geldiniz', font='consoles 14
bold')
label.pack()
label2=tk.Label(form,text='Tespiti Yapılabilen Endemik
Bitkiler;',font='consoles 12')
label2.pack()
label3=tk.Label(form,text='Centaurea kilaea, Dianthus ingoldbyi,
Verbascum degenii',font='consoles 11 italic')
label3.pack()

bitki1 = Image.open('icons/centaurea.png')
bitki1im = ImageTk.PhotoImage(bitki1)
bitki2 = Image.open('icons/ingoldbyi.png')
bitki2im = ImageTk.PhotoImage(bitki2)
bitki3 = Image.open('icons/verbascum.png')
bitki3im = ImageTk.PhotoImage(bitki3)

label4=tk.Label(image = bitki1im)
label4.place(anchor = 'w', relx = 0.25, rely = 0.5)
label5=tk.Label(image = bitki2im)
label5.place(anchor = 'center', relx = 0.5, rely = 0.5)
label6=tk.Label(image = bitki3im)
label6.place(anchor = 'e', relx = 0.75, rely = 0.5)
def mesaj():
    messagebox.showinfo(title='Veri Yükleme', message='Lütfen tespit
etmek istediğiniz endemik bitkinin görselini seçiniz')
    messagebox.showinfo(title='Uyarı', message='Google Maps linki için
görselde GPS verisinin olduğuna emin olunuz.')
    veri =
filedialog.askopenfilenames(initialdir='prediction',title="Yükle",
filetypes= [("Görsel Veriler","*.png"),("Görsel
Veriler","*.jpg"),("Görsel Veriler","*.jpeg")])
    model = YOLO('data/best2.pt')
    res = messagebox.askquestion(title='Bitki Tespiti',
message='Tespit işlemine başlamak istiyor musun?')
    if res == 'yes':
        source = veri
```

```
        results = model(source, stream=True)
        image_no = 1

        for r in results:
            im_array = r.plot()
            im = Image.fromarray(im_array[..., ::-1])
            im.save('results/' + str(image_no) + '.jpg', 'JPEG')


        for file in veri:
            try:
                image = Image.open(file)
                gps_coords = {}

                for tag, value in image._getexif().items():

                    tag_name = TAGS.get(tag)
                    if tag_name == "GPSInfo":
                        for key, val in value.items():

                            if GPSTAGS.get(key) == "GPSLatitude":
                                gps_coords["lat"] = val

                            elif GPSTAGS.get(key) == "GPSLongitude":
                                gps_coords["lon"] = val

                            elif GPSTAGS.get(key) == "GPSLatitudeRef":
                                gps_coords["lat_ref"] = val

                            elif GPSTAGS.get(key) ==
"GPSLongitudeRef":
                                gps_coords["lon_ref"] = val


                def convert_decimal_degrees(degree, minutes, seconds,
direction):
                    decimal_degrees = degree + minutes / 60 + seconds
/ 3600
                    if direction == "S" or direction == "W":
                        decimal_degrees *= -1
                    return decimal_degrees

                dec_deg_lat =
convert_decimal_degrees(float(gps_coords["lat"][0]),
float(gps_coords["lat"][1]),

float(gps_coords["lat"][2]), gps_coords["lat_ref"])

                dec_deg_lon =
convert_decimal_degrees(float(gps_coords["lon"][0]),
float(gps_coords["lon"][1]),

float(gps_coords["lon"][2]), gps_coords["lon_ref"])

                url =
f"https://maps.google.com/?q={dec_deg_lat},{dec_deg_lon}"

                def openlink():
                    webbrowser.open(url)
```

```
            except:
                messagebox.showinfo(title='Sonuçlar',
message='Görselde GPS verisi bulunamamıştır, Google Maps linki
verilemeyecektir.')

        messagebox.showinfo(title='Sonuçlar', message='Tespit işlemi
başarılı, sonuçlar yüklenmiştir')
        sonuclar = tk.Toplevel()
        sonuclar.title('Tespit Sonuçları')
        sonuclar.geometry('1200x700')
        baslik_label=tk.Label(sonuclar,text='Tespit edilen endemik
bitki ve Google Maps linki aşağıda listelenmiştir.')
        baslik_label.pack()
        myimg= Image.open('results/' + str(image_no) + '.jpg')
        resized = myimg.resize ((1100,619), Image.LANCZOS)
        phz= ImageTk.PhotoImage(resized)
        mylabel =tk.Label(sonuclar, image=phz)
        mylabel.image = phz
        mylabel.pack(expand=1)
        buton2 = (tk.Button(sonuclar, text='Google Maps Linki',
font='consoles 10 bold',
command=openlink).pack(side=tk.BOTTOM,ipady=40))

    else:
        messagebox.showinfo(title='Bitki Tespiti', message='İşlem
iptal edildi')

buton1=tk.Button(form,text='Başlat',font='consoles 10
bold',command=mesaj).pack(side=tk.BOTTOM, ipadx=40,ipady=20)
form.mainloop()
```

ÖZGEÇMİŞ

2016 yılında Trakya Üniversitesi Mühendislik Fakültesi Makina Mühendisliği bölümünden mezun oldu. 2018 yılında Varşova Teknoloji Üniversitesinde Enerji, Makina ve Havacılık Fakültesinde Havacılık ve Uzay Mühendisliği Programında yüksek lisans eğitimine başladı. 2020 yılında yüksek lisans eğitimini tamamladı ve 2021 yılında Trakya Üniversitesi Teknik Bilimler Meslek Yüksekokulu Uçak Teknolojisi programında öğretim görevlisi olarak çalışmaya başladı. 2020 yılında başladığı Trakya Üniversitesi Fen Bilimleri Enstitüsü Makina Mühendisliği bölümünde doktora eğitimine devam etmektedir.

TEZ İLE İLGİLİ BİLİMSEL FAALİYETLER

Kaya, S., & Kuşçu, H. (2023) Some Endangered Endemıc Plants In Thrace Regıon: A Remote Sensıng Approach Wıth UAV Imagery. *V.Internatıonal Agrıcultural, Bıologıcal, Lıfe Scıence Conference AGBIOL 2023*., 1156-1163

Kaya, S., & Kuşçu, H. (2024) Flight Altitude and Camera Resolution Characteristics of UAV Images in Endemic Plant Detection. *V.Internatıonal Agrıcultural, Bıologıcal, Lıfe Scıence Conference AGBIOL 2024*., 1892-1895

Kaya, S., & Kuşçu, H. (2024) Applicability of Data Augmentation Technique in Endemic Plant Identification Algorithms. *V.Internatıonal Agrıcultural, Bıologıcal, Lıfe Scıence Conference AGBIOL 2024*., 1896-1899