



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



**UZAKTAN ALGILAMA VERİLERİNİ
KULLANARAK BİREYSEL AĞAÇ TAÇ
TESPİT ALGORİTMASI**

MOHAMMED ISSA MOHAMMED ALHAYANI

YÜKSEK LİSANS TEZİ

KIRŞEHİR

2023



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



**UZAKTAN ALGILAMA VERİLERİNİ
KULLANARAK BİREYSEL AĞAÇ TAÇ
TESPİT ALGORİTMASI**

MOHAMMED ISSA MOHAMMED ALHAYANI

YÜKSEK LİSANS TEZİ

DANIŞMAN

DOÇ. DR. HAKAN SEPET

KIRŞEHİR

2023

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

Kırőehir Ahi Evran Üniversitesi Bilimsel Araőtırma ve Yayın Etiđi Yönergesini okuduđumu ve anladıđımı ve Kırőehir Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladıđım bu tez çalışmasında;

- Tez içinde sunduđum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiđimi,
- Tüm bilgi, belge, deđerlendirme ve sonuçları bilimsel etik kurallarına uygun olarak sunduđumu,
- Tez çalışmasında yararlandıđım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiđimi,
- Kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir deđeriklik yapmadıđımı,
- Tez olarak sunduđum bu çalışmanın özgün olduđunu,

bildirir, aksi bir durumda bu konuda hakkımda yapılacak tüm yasal işlemleri ve aleyhime doğabilecek tüm hak kayıplarını kabullendiđimi beyan ederim./...../20...

Mohammed İssa Mohammed ALHAYANİ

İÇİNDEKİLER DİZİNİ

Sayfa No

| | |
|---|-------------|
| İÇİNDEKİLER DİZİNİ | I |
| TEŞEKKÜR | III |
| ÖZET | IV |
| ABSTRACT | V |
| TABLolar DİZİNİ | VI |
| ŞEKİLLER DİZİNİ | VII |
| SİMGELER VE KISALTMALAR DİZİNİ | VIII |
| 1. GİRİŞ | 1 |
| 1.1. Araştırma Konusu | 2 |
| 1.2. Problem Tanımı..... | 3 |
| 1.3. Amaç ve Hedefler..... | 3 |
| 1.4. Tez Organizasyonu..... | 4 |
| 2. ÖNCEKİ ÇALIŞMALAR | 5 |
| 3. MATERYAL VE METOT | 15 |
| 3.1. Görüntü Verileri | 15 |
| 3.2. Coğrafi TIFF | 15 |
| 3.3. Veri Kümesi | 17 |
| 3.4. Derin Öğrenme | 19 |
| 3.4.1. Derin öğrenme uygulamaları..... | 20 |
| 3.4.2. Evrişimsel Sinir Ağı..... | 21 |
| 3.4.3. Mask RCNN (Bölge tabanlı evrişimli sinir ağı)..... | 23 |
| 3.5. Sınıflandırma Yöntemleri..... | 25 |
| 3.6. Önerilen Yöntem | 27 |
| 4. BULGULAR VE TARTIŞMA | 31 |
| 4.1. Ağaç Tacı Algılama Yöntemi | 31 |
| 4.2. Görüntü Segmentasyonu | 32 |
| 4.3. Deney Durumları..... | 33 |
| 4.3.1. Birinci görüntü | 34 |
| 4.3.2. İkinci görüntü | 34 |
| 4.3.3. Üçüncü görüntü | 35 |
| 4.3.4. Dördüncü görüntü | 35 |
| 4.3.5. Beşinci görüntü | 36 |

| | |
|-----------------------------------|-----------|
| 4.3.6. Altıncı görüntü | 36 |
| 4.3.7. Yedinci görüntü..... | 37 |
| 4.3.8. Sekizinci görüntü..... | 37 |
| 4.3.9. Dokuzuncu Görüntü | 38 |
| 4.3.10. Onuncu Görüntü | 39 |
| 4.4. Model Değerlendirmesi | 40 |
| 5. SONUÇ VE ÖNERİLER | 41 |
| 6. KAYNAKLAR..... | 43 |
| ÖZGEÇMİŞ..... | 49 |

TEŐEKKÜR

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

Kasım, 2023

Mohammed İssa Mohammed ALHAYANİ

ÖZET

YÜKSEK LİSANS TEZİ

UZAKTAN ALGILAMA VERİLERİNİ KULLANARAK BİREYSEL AĞAÇ TAÇ TESPİT ALGORİTMASI

Mohammed İssa Mohammed ALHAYANİ

**KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANABİLİM DALI**

Danışman: Doç. Dr. Hakan SEPET
Yıl: 2023 Sayfa: 49
Jüri: Doç. Dr. Hakan SEPET
Prof. Dr. Kamil ŞİRİN
Doç. Dr. Murat ÇANLI

Teknolojideki büyük gelişmeler, programcıların verileri yönetme yöntemlerini modernize etmelerine olanak sağlamıştır. Bugün yapay zekâ, alt alanlarından birine çok odaklanmış durumda: veri yönetimi. Düzgün çalışması için, AI sistemleri bir tür veri analizi ve yönetimi gerektirir. Ormanlık yerlerden elde edilen veriler araştırmamızda dikkate alınan verilerdir. Yüksekten uçan uçaklar tarafından çekilen fotoğrafları içeren verileri elde ediyor ve işliyoruz. Bu çalışmada Bulgaristan'da Batı Balkan sıra dağlarından ve Bağdat şehrinin farklı bölgelerinden veriler elde edilmiştir. Veritabanı, turuncgiller gibi mevsimlik veya yaprak dökmeyen ağaç türlerinin farklı resimlerini içerir. Görüntü alımına yardımcı olmak için yüksek yoğunluklu, kısa menzilli insansız hava araçları kullanılabilir.

Görüntülerin kalitesi, ağaç taçlarını tanıma sorununu bir dereceye kadar hafifletmeye yardımcı olur. Makine öğrenimi konseptine dayalı akıllı bir model oluşturuyoruz ve çeşitli görüntü işleme teknikleri kullanarak orman havadan görüntülerini analiz ediyoruz. Görüntünün kapsamlı bir tanımını sağlamak ve içindeki ağaçları belirlemek mümkündür. Ayrıca, yakalanan ağaçlar sınıflandırılır ve her kategori için veri sağlanır. Kategoriler genç ağaçlar ve yaşlı ağaçlardır. Mükemmel tanıma ve sınıflandırma doğruluğu elde edilir.

Anahtar Kelimeler: Dronlar, Nesne algılama, Maske, R-CNN, Tahmin

ABSTRACT

MASTER'S THESIS

INDIVIDUAL TREECROWNS DETECTION ALGORITHM USING REMOTE SENSING DATA

Mohammed İssa Mohammed ALHAYANİ

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

Supervisor: Assoc. Prof. Dr. Hakan SEPET
Year: 2023 Pages: 49
Juries: Assoc. Prof. Dr. Hakan SEPET
Prof. Dr. Kamil ŞİRİN
Assoc. Prof. Dr. Murat ÇANLI

Major advances in technology have allowed programmers to modernize the way they manage data. Today, artificial intelligence is very focused on one of its sub-fields: data management. To function properly, AI systems require some form of data analysis and management. The data obtained from wooded places such as forests are the data taken into consideration in our research. We acquire and process data that includes photographs taken by high-flying aircraft. In this study, data were obtained from the Western Balkan mountain ranges in Bulgaria and different regions of the city of Baghdad. The database contains different pictures of seasonal or evergreen tree species such as citrus. High-density, short-range drones can be used to aid image acquisition.

The quality of the images helps alleviate the problem of recognizing tree crowns to some extent. We build an intelligent model based on machine learning concept and analyze forest aerial images using various image processing techniques. It is possible to provide a comprehensive description of the image and identify the trees in it. In addition, the captured trees are classified and data is provided for each category. The categories are young trees and old trees. Excellent recognition and classification accuracy is achieved.

Keywords: Drones, Object detection, Mask R-CNN, Prediction

TABLolar DİZİNİ

| | Sayfa No |
|---|-----------------|
| Tablo 2.1. Önceki arařtırmaların özeti | 13 |
| Tablo 4.1. Tüm test sonuçlarının istatistiđi | 39 |
| Tablo 4.2. Model Doğruluđu | 40 |

ŞEKİLLER DİZİNİ

| | Sayfa No |
|---|----------|
| Şekil 3.1. GeoTIFF drone görüntüsü | 17 |
| Şekil 3.2. Veri kümesi bölme..... | 18 |
| Şekil 3.3. Tekrarlayan sinir ağları (RNN'ler)..... | 20 |
| Şekil 3.4. CNN katmanları | 22 |
| Şekil 3.5. Maske R-CNN mekanizması | 24 |
| Şekil 3.6. Maske R-CNN | 25 |
| Şekil 3.7. Sınıflandırma yöntemi | 26 |
| Şekil 3.8. Önerilen modelin yapı yöntemi | 28 |
| Şekil 4.1. Gör-1 girdi görüntüsü (a) ve çıktı (b) | 34 |
| Şekil 4.2. Gör-2 girdi görüntüsü (a) ve çıktı (b) | 34 |
| Şekil 4.3. Gör-3 girdi görüntüsü (a) ve çıktı (b) | 35 |
| Şekil 4.4. Gör-4 girdi görüntüsü (a) ve çıktı (b) | 36 |
| Şekil 4.5. Gör-5 girdi görüntüsü (a) ve çıktı (b) | 36 |
| Şekil 4.6. Gör-6 girdi görüntüsü (a) ve çıktı (b) | 37 |
| Şekil 4.7. Gör-7 girdi görüntüsü (a) ve çıktı (b) | 37 |
| Şekil 4.8. Gör-8 girdi görüntüsü (a) ve çıktı (b) | 38 |
| Şekil 4.9. Gör-9 girdi görüntüsü (a) ve çıktı (b) | 38 |
| Şekil 4.10. Gör-10 girdi görüntüsü (a) ve çıktı (b) | 39 |

SİMGELER VE KISALTMALAR DİZİNİ

| Kısaltmalar | Açıklama |
|--------------------|--|
| BPN | : Back-propagation neural networks (geri yayılımlı yapay sinir ağları) |
| CNN | : Convolutional neural network |
| GIS | : Geographic information system (coğrafi bilgi sistemi) |
| İHA | : İnsansız hava araçları |
| RGB | : Red, green, and blue (kırmızı, yeşil ve mavi) |
| RLM | : Regularized loss minimization |
| RTCLE | : Real-time crown loss prediction (gerçek zamanlı taç kaybı tahmini) |
| VAE | : Variational autoencoder |

1. GİRİŞ

Teknolojideki büyük gelişme, araştırmacıların görüntüleri, verilerle işleme şeklini modernize etmelerini sağladı. Veri yönetimi, günümüzde yapay zekanın en önemli alanlarından biridir. Yapay zekâ sistemleri, bir veri analizi ve yönetim biçimi oluşturmaya dayanmaktadır. Araştırmamızda ele aldığımız veriler, ormanlar gibi ağaçların bulunduğu alanların verileridir. Yukarıdan uçak ve dronlar tarafından çekilmiş görüntüler içeren verileri topluyoruz ve üzerlerine işlem yapıyoruz.

Ormanlarda bireysel ağaç envanterleri günümüzde zaman alıcı ve maliyetli saha araştırmaları yoluyla toplanmaktadır. Buna en iyi örnek Endonezya'nın tropikal turba bataklık ormanlarındaki ormansızlaşma ve arazi açımı sonucu buradaki ağaç yapılarının belirlenmesi çalışmalarıdır. Bireysel ağaç tasviri için uzaktan algılama tekniklerinin kullanılması ağaç kayıpları problemlerine uygulanabilir bir çözüm olabilir. Son yıllarda, ağaç bilgisini toplamak ve tanımlama sürecinde veri almak işleminde gereken maliyetleri ve zamanı azaltmak için uzaktan algılama yöntemleri geliştirilmiştir. Son teknolojiler ile uzaktan algılama tabanlı stratejiler, hava fotoğraflarının insan tarafından yorumlanmasıyla başladı. Bu yöntemin kullanımı, sonunda yeni veri ve süreçlerin geliştirilmesi lehine aşamalı olarak kaldırıldı (Hassan ve ark., 2020).

Arazi sıklığının artması nedeniyle, ağaç taçlarının yüksekte bir gölgelik altında bölünmesi, derin ormanlık alanların ağaç yapıları belirlenmesi gereken bir görev olarak kalmaktadır. Yüksek yoğunluklu İHA kısa menzilli insansız hava araçları, bu sorunu bir ölçüde çözmeye yardımcı olabilir. Bireysel ağaç taç segmentasyonu, alt baskın ağaçlarla sınırlı olsa bile, taç boyutu dağılımı, önceki bölge tabanlı modellere göre yerel kalibrasyona daha az bağımlı olabilen karbon haritalama yeteneklerinin yanı sıra ağaç mimarisine yeni bakış açıları sağlar (Safonova ve ark., 2019). Sciencetr.com'a göre bir orman yönetim sistemi sağlamanın önemi çok yüksektir (Anonim, 2023). Ormanlık alanlar, yerleşim alanlarından nispeten uzak, bu yüzden onları sürekli izlemek biraz zordur. Bazı bölgelerde ormanlar kesilir ve ağaçları endüstriyel veya kişisel amaçlar için kullanılmaktadır. Orman ağaçlarının kesilmesi toprak, hava ve çevresel faktörleri olumsuz yönde etkiler. Ormanların olumsuz etkilenmesi insan müdahalesinin yanı sıra bazen yanma ve hasara maruz kalarak da olmaktadır.

Ormanların doğru izlenmesi ve doğru analiz, karşılaşılabileceğimiz risklerin azaltılmasına yardımcı olur. Ek olarak, orman görüntülerini analiz etmek ve işlemek için sistemlerin sağlanması, ormanların durumu, yoğunlukları ve içindeki ağaçların türü

hakkında önceden bilgi verir. Bu bilgiler ormanları kurtarmak için yönetim kılavuzu olarak kullanılabilir.

Ormanlar, hayatımızdaki temiz havanın ve temiz bir çevrenin ana kaynağıdır. Bu nedenle onları korumak ve risklerini azaltmak için gerekli araçları sağlamak tüm insanlığa yardım eden en önemli sistemlerden biridir.

Ormanlardaki ağaçların durumunu incelemek için makine öğrenimi ve yapay zekâ algoritmalarına dayalı görüntü işleme mekanizmasını kullanan sistem sunulmaktadır. Ağaç taçları, drone tarafından çekilen görüntülerde konumları çıkarılarak keşfedilmektedir. Önerilen sistemimizi kullanarak, ormanın doğası hakkında kapsamlı bir analiz elde etmek ve ağaçların yoğunluğu ve varlık alanları hakkında bilgi edinmek, böylece onları korumak için önemli bir araç elde edilmiştir ve insanlara önemli hizmet sağlanmış olacaktır.

1.1. Araştırma Konusu

Orman verilerinin ve imaj yönetiminin önemini bilmek için ormanların günlük hayatımızdaki önemine bilmeliyiz. İnsanlar ormanların varlığından çok fayda sağlar. Ormanlar oksijen üretir ve karbondioksiti azaltır ve çok fazla yiyecek, su, kâğıt ve odun kaynağıdır (Anonim, 2022). Hayvanlar için de önemlidir, yaz günlerinde ormanın gölgesinde yaşarlar ve kışın rüzgârından korunmalarına yardımcı olurlar. Ormanların önemine rağmen, şu anda yok edilmekte ve endişe verici bir oranda geri çekilmektedir; Ormanlar, yangınlar ve kereste endüstrisi ve tarım için birçok yönden yok edilen yerlerdir. Yılda 18,7 milyon dönüm orman yok oluyor. Dünyanın en büyük yağmur ormanlarından biri olan Amazon, son yarım yüzyılda ormanlarının en az %17'sini kaybetti (WWF, 2019).

Önerilen algoritmamızda üç aşama vardır: Ön işlemenin bir parçası olarak kronlar ve iç içe geçmiş alan vurgulanabilir. Algoritmanın girdisi, RGB formatında, doğal veya yapay renkte, görünür kanalları olan bir resim olabilir. Pankromatik görüntüler de kullanılabilir.

Parlaklık histogramı, ön işlemenin bir parçası olarak daha basit taç segmentasyonu için geliştireceğiz. Oluşturulan resim üzerinde gri tonlamalı dönüştürme gerçekleştirilecektir (RGB girişi olması durumunda). İkinci adımda, ağaç tepeleri DWT filtreleme ve çoklu eşik yaklaşımı kullanılarak bölümlere ayrılabilir.

Segment sınırlarını yumuşatmak için morfolojik teknikler kullanıldıktan sonra sonuçlar siyah beyaza indirgenilecektir. Bireysel ağaç taç limitleri, deneyimli bir kullanıcı ile üçüncü adımda veri analizi kullanılarak belirlenebilir.

1.2. Problem Tanımı

Önerilen fikrimiz, ağaçların konumları için görüntü işleme yapan akıllı sistemlerden biri olarak sınıflandırılabilir. Ağaçlar ve ormanlar ekolojik dengedeki önemi nedeniyle günlük hayatımızda büyük önem ve gereklilik arz etmektedir. Yangın, ağaç kesimi gibi afetlerde orman ağaçlarının korunması gerekmektedir. Bunları korumak, miktarlarını ve türlerini bilmek için makine öğrenmesi ve görüntü işleme algoritmaları temelinde oluşturulmuş benzer sistemlere ihtiyacımız var.

Araştırma, drone kullanılarak çekilen orman ağaçlarının resimlerinin girdilerini okuyacak, görüntüyü işleyecek ve analizini sağlayacak bir mekanizma olmadan, bu alanlardaki ağaçların türlerini ve miktarlarını tahmin etmek mümkün değildir. Ağaç taçlarını tanıyarak drone görüntülerinden ağaçları tanımlamanın zorluğunu gidermek için çözümler sunulabilir.

1.3. Amaç ve Hedefler

Bu çalışmanın temel fikri, bireysel ağaç tepelerini ağaç türlerine göre sınıflandırmak için algoritmalar geliştirmektir. Bunu yapmak için, bireysel ağaç tepeleri tanımlanmalı veya alt bölümlere ayrılmalıdır. Bölümlenme aşamasının amacı, sınıflandırma aşamasında ağaç taçlarının formu kullanıldığından, ağaç taçlarını, segmentin şekli orijinal görüntüdeki ağaç taç şekliyle eşleştirecek şekilde segmentlere ayırmaktır.

Görüntü işleme ve makine öğrenimi tekniklerini kullanarak orman korumanın bir parçası olmak için, yukarıdan yakalanan görüntüleri inceleyerek ve analiz ederek ağaçları ve yoğunluklarını tespit etmek için yeni bir mekanizma geliştirme fikrini sunuyoruz.

Sistemi kurmak için gerçek ormanlarda dronlar tarafından yakalanan görüntüler kullanılmaktadır. Google'ın sunduğu bulut teknolojilerinden “Google map” ve “Google Earth” hizmetlerinde de yararlanmak mümkündür.

Ulaşmaya çalıştığımız önem, ağaçların türlerini ve yoğunluklarını bilmek için en uygun tanımlamayı ve analizi sağlamak için toplanan verileri alan ve böylece risk durumunda korunmalarını kolaylaştıran yardımcı bir araç ortaya koymaktır.

İlk kez, çok yüksek uzamsal çözünürlüklü İHA fotoğraflarından orman özniteliklerini bireysel ağaç düzeyine kadar çıkarmak için bir yöntem sunulmuştur. Multispektral ve RGB hava fotoğrafları için otomatikleştirilebilen bir yeni teknik sunuyoruz. Belirli ağaç türlerinin ve kritik durum sınıflarının tanımlanması, yaptığımız algoritmanın kullanılması ve tek tek piksellerin manuel olarak sınıflandırılmasıyla

gerçekleştirilir. Bölgesel orman alanlarında envanter ve ağaç sağlığı değerlendirmesi için, uzman verileri kullanılarak hava fotoğraflarının tematik olarak işlenmesi yüksek düzeyde fizibilite gösterebilir.

Sistemin doğruluk oranını bulmak için, hassas ölçeğin bir parametresini kullanacağız. Kappa istatistiği, Intersection over Union metric veya Jaccard Benzerlik Katsayısı gibi kullanılacak birçok ölçüm vardır. Sonuçlar ile eğitim ve sistem kurma verileri arasındaki benzerliği ölçtüğü için bu parametreleri kullanmayı düşünmüyoruz.

Toplam hata oranı yanlış kategorize edilen örnek sayısının toplam örnek sayısına bölünmesiyle hesaplanır. Genel olarak değerlendirilen sınıflar, belirtilen sınıfta yanlış kategorize edilen örneklerin sayısı açısından ortalama ihmal hatasıdır.

1.4. Tez Organizasyonu

Bu araştırma dört bölümü içerecek şekilde düzenlenmiştir. İkinci bölümde, bu alanla ilgilenen ve özellikle yukarıdan çekilen görüntülerle ilgilenen görüntü işleme sistemlerine bakan literatür taraması yapılacaktır. Üçüncü bölümde, araştırma fikrini ve içinde kullanılan algoritmaları ve araçları sunulacaktır. Dördüncü bölümde, deneyimlerimizi ve sonuçlar gözden geçirilecektir. Daha sonra, sonuçlar ve önerileri sunmak ve gelecekteki çalışmalara örnek olmak için sonuçlar tartışılacaktır.

2. ÖNCEKİ ÇALIŞMALAR

Ağaç tanımada görüntü işleme teknikleri ve makine öğrenmesinin önemi göz önüne alındığında birçok araştırmacının ilgisini çekmiştir. Ke ve Quackenbush (2011), ağaç türlerinin taçları aracılığıyla otomatik olarak algılanması konusunu tartışmışlardır. Bu çalışmada araştırmacılar, etkili bir orman yönetimi için önemli bir gerekliliğin, bilgilerin çok detaylı ve zamanında olması gerektiğini vurgulamışlardır. Yüksek çözünürlüklü uzamsal görüntülerin mevcudiyeti, orman envanteri ve analizinin yüksek verimlilik ve maliyetle yürütülmesinde yüksek doğruluk sağlamaktadır. Ağaç tacına göre ağaçların otomatik tespiti için algoritmalar, ağaçlara göre orman envanteri için standartları ve ölçümleri tartışan birçok araştırma yoluyla elde edilmiştir. Bu çalışma negatif uzaktan algılama görüntüleri ve bu yöntemle uygulanan algoritmalara odaklanmıştır. Otomatik algılama yöntemleri ağacın tepesine göre sınıflandırılmıştır. Analizi yapılan görüntüler ve türleri dikkate alınır, çalışılan alanların özelliklerinin yanı sıra bu algoritmalar bunlara uygulanır. Bu çalışmadaki araştırmacılar, ağaçların tepesini tespit etmek için niceliklerdeki belirli doğruluğu analiz etme, inceleme ve değerlendirmenin yanı sıra bu faktörlerin yöntemler üzerindeki etkilerini değerlendirmektedir. Çalışmanın sonunda araştırmacılar, şu anda uygulanmakta olan yöntemlerin ve algoritmaların ortak özelliklerini ve algoritma geliştirmelerinin gelecekte ağaç taçlarının otomatik olarak algılanması konusunda çalışmak için neler yapabileceğini açıklamıştır. Ağaçların tepesini belirlemek ve tespit etmek için niceliklerdeki belirli doğruluğu incelemek ve değerlendirmek gerekmektedir.

Başka bir çalışmada Lindberg ve Holmgren (2017) araştırmacılar, uzaktan keşif tekniklerinin hızlı gelişimini, günümüzde hava kaynaklı lazer taramanın yanı sıra fotoğraflık nokta bulutları yoluyla birçok üç boyutlu bilginin mevcudiyetine kadar tartıştılar. Çalışma, 3B verilerden tek tek ağaçları keşfetme süreçlerini ve bu tekniklerin ormancılık ve çevre bilimlerindeki uygulamalarını gözden geçirmiştir. Araştırmacılar, son yıllarda ağaçlar düzeyinde üç boyutlu verileri analiz etmek ve incelemek için tekniklerin geliştirilmesini tartışmışlardır. Önceki algoritmalar, iki boyutlu ağaç taç verilerine dayanıyordu. Bu teknikler, ağaçları analiz etmek ve onlar hakkında bilgi sağlamak için güç ve verimlilik ile karakterize idi. Üç boyutlu verilere odaklanan yöntemler de vardır, bu yöntemler mühendislik özelliklerinin kullanımını buna dahil etmek için geliştirme gerektirmekteydi. Ağaçların uzunluğunun bu süreçte büyük etkisi vardır, çünkü uzun ağaçlar yüzey modellerini kullanarak tam sonuçlar verir, ancak uzun

ağaçların altına düşen kısa ağaçlar, onları analiz etmek ve keşfetmek için daha doğru ve verimli yollar gerekmektedir. Bilimsel gelişme, bitki örtüsünü iyi gösteren haritaların geliştirilmesinde kullanılabilecek ağaçların tepesini yani ağaç gölgeliğinin üst kısmını tanımlama yeteneğine sahip birçok sensörün bulunmasına yol açmıştır.

Yüksek verimli bitmap görüntülerine veya bulutlara dayanan, bireysel ağaç tacı yöntemlerini ve bu konuda çalışan algoritmaları tartışılmaktadır. Bu algoritmalar, ağaç gövdeleri, uzunlukları, boyutları ve ağaç türleri hakkında bilgi sağlayan ve geniş bir coğrafi aralıkta bulunan ağaçların türleri hakkında bir veri tabanı sağlayan geniş alanların ağaç örtüsü hakkında eksiksiz bilgi sağlamak için kullanılır. Ağaç tacına bağlı olarak çalışmada, bu konuda birçok yöntemi incelendi. Bir nokta bulutundan tek tek ağaçları tanımlamak için mevcut olması gereken bilgilerden biri, her ağacın gerekli minimum nokta yoğunluğu seviyesini belirleyen birkaç nokta içermesidir. Kanopinin gerekli noktalarını belirlemek için ağaçların zemin yüzeyinden olan yüksekliklerinin her nokta için bilinmesi gerekir ve bu bir DEM gerektirir. Ağacın tahmini yüksekliğinin yanı sıra ağacın diğer özelliklerinin bilinmesine acil bir ihtiyaç vardır. Araştırmacılar, ağaçların ana noktalarını ve özelliklerini sınıflandırmaya yönelik başka çalışmaların da olduğuna dikkat çekmiştir.

Weinstein ve ark. (2019) uzaktan algılamayı kullanarak bu araştırmaların hızı, hacmi ve maliyeti yoluyla biyolojik çeşitlilik araştırmaları ve orman araştırmalarındaki değişiklikleri vurgulamaktadır. Araştırmacılar, neredeyse denetimli derin öğrenme tespit ağlarını kullanarak renkli görüntülerde ağaç taçlarını tespit etmek için bir yöntem belirlemişlerdir.

Tek tek ağaçların taçlarını belirlemede karşılaşılan zorluklardan biri, uzaktan algılama ve mevcut algoritmalar ile tepenin sınırlandırılmasıdır ve sonuçlar karıştırılmıştır. Araştırmacılar, RGB görüntülerinde taç tespiti amacıyla prototip oluşturma amacıyla kullanılan ağaçları oluşturmak için ışık ve menzil algılamaya dayalı denetimsiz seçimin derin öğrenme modellerinin kullanıldığını göstermiştir. Bir temel ağacın özelliklerini öğrenmek için eğitilecek bir sinir ağı için bilgi eğitim verileri mevcut olabilir, orijinal denetimsiz yaklaşımda zorluklar ve sınırlamalar olmasına rağmen, araştırmacılar daha sonra birkaç yüksek kaliteli renkli fotoğraf aracılığıyla prototipin gelişimini tartışmışlardır. Bu yöntemin doğruluğu, ulusal çevresel izleme ağında ve kanopi sahasının kullanımıyla bağlantılı olarak kullanılmasıyla doğrulanmıştır. Sonuçlar, otomatik olarak oluşturulmuş 434.551 ağaç kullanan ve modele 2.848 manuel olarak açıklanmalı ağaç sağlayan ilk modelin, peyzajda doğru keşiflere yol açtığını göstermiştir.

Analiz ve çalışma ile gözetim altındaki ilk modele kıyasla, manuel olarak açıklamalı az sayıda ağaç kullanıldığında iyi sonuçlar elde edilir.

Larsen ve ark. (2011) tarafından yapılan çalışmada, üç Avrupa ülkesindeki farklı coğrafi konumlardaki altı farklı orman tipini içeren bir görüntü veri seti kullanılarak altı ayrı ağaç tepesi algılama/sınır belirleme algoritması değerlendirilmektedir. Algoritmalar temel olarak yerel maksimum algılama, vadi izleme (VF), bölge büyümesi (RG), şablon eşleştirme (TM), ölçek uzay teorisi (SS) ve rastgele çerçevelere dayalı teknikler dahil olmak üzere farklı teknikler kullanır. Kullanılan hava resimlerinde, ormanın yapısal karmaşıklığı, tek biçimli bir plantasyondan, yalnız ağaç tepelerinin olduğu bir bölgeye ve bir tür kalın yaprak döken ormana kadar değişir. Algoritmaların hiçbiri her durumu kendi başına kapsamlı bir şekilde değerlendiremez. Çalışma, belirli ağaçlar için algılama algoritmalarını kullanmadan önce fotoğrafları tek tip orman örneklerine ayırmanın çok önemli olduğunu gösteriyor. Bunlara ek olarak, çeşitli ağaç algılama/sınır belirleme algoritmalarını değerlendirmek için standart, halka açık bir test fotoğrafları koleksiyonunun ve standart test protokollerinin gerekliliğini gösterir. Son olarak, araştırmacıların bile monoküler fotoğraflar kullanarak karmaşık orman türlerinde ağaç taçlarını tutarlı bir şekilde ayırt etmekte zorlandıklarını vurgular.

Farklı bir çalışmada Aubry-Kientz ve ark. (2019), araştırmacılar, karasal envanterlerin, farklı yükseklik ve şekillerde çeşitli ağaç taçlarından oluşan tropikal orman kanopilerinin yapısını doğru bir şekilde yakalamakta nasıl sık sık başarısız olduğundan bahsetmişlerdir. Bu bireysel kronlar, havadaki lazer tarama verileri kullanılarak tanımlanabilir, ancak tropikal ortamlarda kullanılmadan önce, boreal veya ılıman ormanlar için yapılan analitik tekniklerin değiştirilmesi gerekebilir. Araştırmacılar, Fransız Guyanası'ndaki bir çalışma konumundan toplam 39 hektarlık altı arsa üzerinde kullanılan altı alternatif segmentasyon yönteminin sonuçlarını karşılaştırmak için çalışmışlardır. Yüksek çözünürlüklü fotoğraflarla araştırmacılar, manuel olarak seçilen kronların ve otomatik olarak seçilen kronların projeksiyonuna müdahale etmişlerdir.

Ağaç çapını ağaç tacı genişliğine bağlayan model, araştırmacılar tarafından tarla stok verileriyle otomatik eşleştirmeyi takiben uyum derecesini değerlendirmek için kullanılmıştır. Çeşitli özelliklere sahip çok çeşitli sayıda kronlar, bu kriterler için çalışılan çeşitli tekniklerle ayrılmıştır. Özellikle küçük kronlar için, nokta bulutu tabanlı segmentasyon yöntemleri (AMS3D ve Graph-Cut), perde yüksekliği modellerine dayalı yaklaşımlardan sürekli olarak daha iyi performans göstermiştir. AMS3D yaklaşımı, örtüşme analizi için diğer yaklaşımlardan daha iyi performans gösterdi ve AMS3D ve

Graph-Cut, otomatik eşleşme doğrulaması için en iyi sonuçları vermiştir. Bununla birlikte, aşırı derecede çok büyük kronlar için kanopi yüksekliği modeline dayalı alternatif teknikler onlardan daha iyi performans göstermiştir.

Orman bilgilerinin yüksek çözünürlüklü uzaktan algılama verilerinden (yarı) otomatik olarak çıkarılması alanındaki kilit ilgi alanlarından biri, başka bir çalışmanın konusu olan ağaç algılama sürecidir (Hirschmugl ve ark., 2007). Mevcut ağaç tepesi haritalama tekniklerinin çoğu, resim bölümlene sürecini bir ham piksel koleksiyonuyla başlatır. Bu çalışma, ortofotolardan ve dijital stereoskopik kamera resimlerinden oluşturulan dijital yüzey modellerinden ham piksellerin (yarı) otomatik olarak alınması için çeşitli yaklaşımları araştırmış ve karşılaştırmıştır. Bu araştırma, çoklu stereo çiftlere dayalı DSM üretmek için yeni bir teknik sunuyor. UltracamD dijital kamera, yaklaşık %90 oranında stereo çakışma ile resimler üretir. DSM'lerin analizi, çoklu görüntü tekniği kullanıldığında kalitede önemli bir gelişme olduğunu göstermektedir. Genellikle küme tabanlı bir strateji olarak bilinir, tahmin edilen değerler ile gözlemlenen 356 üst katman ağaç yüksekliği arasındaki ortalama fark, 2,39 m'lik standart sapma ile yalnızca 0,77 m'dir. Sık bir doğal ormanda hem komisyonlar hem de ihmaller için kabaca %25'lik bir hata payı ile bu araştırmada tohum üretimi için ağaçları tespit etmek üzere kullanılan Şekil (2d)'deki algoritma, görülen ağaçların %64'ünü hava fotoğraflarında tespit edebilmiştir.

Dönüşüm yöntemiyle karşılaştırıldığında, ortorombisiteye dayalı yerel maksimum tekniği tipik olarak daha az doğruluk ve daha fazla isabet üretmiştir. Küme tabanlı modelin 3B tohum oluşturma sonuçlarının yaklaşık %70'i, ağaç örtüsünün en üst katmanı için doğrudur. Tüm değerlendirmeler, sahada alınan ölçümlere ve hava fotoğraflarının görsel yorumuna dayanmaktadır. Ağacın meşcere içindeki hakimiyeti ile etkin ağaç tespiti arasındaki ilişki üzerine analiz yapılır. Bastırılmış ağaçların planlandığı gibi ortadan kaldırılması muhtemeldir. Daha büyük bir komisyon hatası haricinde, otomatik olarak oluşturulan klipler, görsel yorumlama ile elde edilenlerle karşılaştırılabilir sayıda meşru isabete sahip olduğundan, segmentasyon avantajlıdır.

Ağaçların sağladığı biyolojik çeşitlilik, çevresel ve ekonomik faydalara bakarak başka bir araştırma yapılmıştır (Weinstein ve ark., 2021). Orman ekosistemlerini anlamak, tek tek ağaçlar hakkında bilgi gerektirir, ancak veri toplamanın maliyetleri ve zorlukları nedeniyle bireysel düzeyde geniş ölçekte veri elde etmek zordur. Uzaktan algılama teknolojisindeki gelişmeler, tek tek ağaçların daha önce duyulmamış bir ölçekte incelenmesine olanak sağlasa da, algılama verilerini yararlı bilgilere dönüştürmede teknolojik zorluklar devam etmektedir. Araştırmacılar, derin öğrenme tekniklerini

kullanarak Amerika Birleşik Devletleri'ndeki 37 lokasyondaki 100 milyon ağaç için bireysel düzeyde taç tahminlerinden oluşan açık kaynaklı bir veri seti oluşturdu. Bu yerler, Ulusal Çevre Gözlemevi Ağı'nın havadan izleme platformu tarafından izlendi. Yükseklik, taç alanı ve her gölgelik ağacın tepesinin coğrafi konumu, dikdörtgen bir sınırlayıcı kutu ile gösterilir. Amerika Birleşik Devletleri'nin çoğundan orman türlerini kapsayan alanlar arasında bölgesel analizler ve karşılaştırmalar sağlayarak, bu veriler, ağaçlar üzerinde bireysel düzeyde yapılan çalışmalarda önemli bir artışı teşvik etme potansiyeline sahiptir.

Ho ve ark., (2022) çalışmalarında hava robotlarının uzak bölgeleri kolayca ziyaret edebildikleri ve yüksek çözünürlüklü resim verilerini kaydedebildikleri için ormanların sağlığını izlemek gibi uygulamalar için popülerlik kazandığını belirtmişlerdir. Örneğin, uzaktan çalıştırılan hava robotları, saha araştırmaları ve yaprak örnekleme gibi emek yoğun ve genellikle manuel ormancılık işlerini otomatik hale getirebilir. Bu çalışmada, araştırmacılar tarafından bireysel ağaç tacı kaybının ciddiyetini ölçmek ve derecelendirmek için iki yeni çevrimiçi çerçeve sağlanmıştır. Bireysel ağaçlar, gerçek zamanlı taç kaybı tahmini (RTCLE) algoritması kullanılarak yerleştirilir ve ilgili taç kaybı oranı bölmelerine göre sınıflandırılır. Çeşitli açılardan orijinal fotoğrafları toplamak genellikle pahalı olduğundan, yapay olarak oluşturulmuş ağaç görüntülerinin RTCLE modelini eğitmek için kullanılıp kullanılmayacağını görmek için deneyler yapılıyor. Bulgular, sentetik veriler üzerine eğitimin, yalnızca az miktarda gerçek resim verisinin dahil edilmesiyle daha da artırılabilir bir temel ortalama doğruluğuna (mAP) ulaşılmasına yardımcı olduğunu göstermektedir.

Araştırmacılar, orijinal veri setini üretilen sentetik verilerle birleştirerek haritanın yaklaşık %60 ila %78 oranında genişletilebileceğini gösterdi. Tutarsız bir şekilde kategorize edilmiş taç kaybı verilerini yönetmek için tek ağaç taç kaybı sıralaması için iki aşamalı bir taç kaybı sıralaması (TSCLR) çerçevesi oluşturuldu. TSCLR çerçevesi, görelî taç kaybı şiddetinin bir ölçüsüne göre kategorize etmeden önce tek tek ağaçları konumlandırır. RTCLE modelini eğitmek için kullanılan birleştirilmiş veri seti, ağaç tanımlama modelini eğitmek için kullanılır ve %95'lik bir yakınlık haritası elde edildiğinden, modelin bilinmeyen veri kümelerine iyi bir şekilde genelleştirdiği çıkarımı yapılabilir. Derin temsili öğrenmeyi kullanan bir olasılık kodlayıcı, tamamen eğitilmiş bir VAE kodlayıcı modelinden alınan verileri kullanarak her ağaç için görelî taç kaybı yoğunluğunu tahmin etmektedir.

VAE, ağaç görüntülerini arka plandan bağımsız bir şekilde yeniden oluşturmak için baştan sona geliştirilmiştir. Tutarlı bir değerlendirmede, olasılıksal kodlayıcıdan tahmin edilen taç kaybı yoğunluğu, veri kümesindeki tüm ağaç türleri genelinde uzman tahminiyle genellikle orta düzeyde bir uyum gösterir. Olasılıksal bir kodlayıcı, tamamen eğitilmiş bir VAE kodlayıcı modelinden alınan verileri kullanarak her ağaç için görelî taç kaybı yoğunluğunu tahmin eder.

Bu konuda yapılan başka bir çalışmada , orman yönetimini ve çıktısını geliştirmek için kesin ağaç yoğunluğunu ve konumunu bilmenin önemine dikkat çekilmiştir (Xu ve ark., 2021). Yerel maksimum (LM) filtreleme algoritması ve uzaktan algılama teknikleri birlikte, bireysel ağaç taçlarını belirlemek için uygulanabilir bir yöntem sunarken, yine de karmaşık gölgelik yapıları altında önemli ölçüde yanlışlık yaşarlar. Bu makale, dört yüksek uzamsal çözünürlüklü fotoğraftan tek tek ağaçları tanımak için gözden geçirilmiş bir LM (RLM) yöntemini tanıttıyor ve test ediyor. RLM algoritması, hareketli pencere yönteminin aksine, resmin satır ve sütun yönlerindeki segmentlerdeki yerel maksimumu arayarak taç merkezinin tohumlarını bulur. Ardından, kalan taç merkezlerinin her birini aramak için taç merkezi çekirdeğini merkez alan değişken bir pencere kullanılır. RLM algoritması, yanlış algılamayı azaltmak için kuronlar için bölme ve birleştirme tekniklerini içerir. Sonuç, RLM algoritmasının doğruluğunun minimum taç uzunluğu katsayısına (CLmin) daha duyarlı olduğunu gösterdi. CLmin tahminleriyle desteklenen RLM yöntemi, dört resim için düşük komisyon (%9-14) ve atlama hataları (%8-15) üretirken %85 ile %91 arasında yüksek genel doğruluk elde etti. RLM algoritmasının segmentasyon ve birleştirme prosedürleri, komisyon ve ihmal hatalarını başarıyla azalttı. Bu bulgular, RLM algoritmasının, tek tek ağaçların kabul edilebilir algılama doğruluğu ile otomatik tespiti için iyi tanımlanmış parametrelerle uygulanabilir bir teknik olduğunu göstermektedir.

Ekosistem hizmetlerinin işlevsel ve coğrafi dağılımını hesaplamak için ağaç taç haritalaması esastır. Yapılan bir çalışmada bunu çalışmalarının temeli olarak kullandılar (Yang ve ark., 2022). Bununla birlikte, alan örneklemesinin ve coğrafi çeşitliliğin zaman alıcı doğası nedeniyle, kesin, güncel kentsel taç haritalaması zor olmaya devam ediyor. Diğer bir zorluk, orman haritalarının büyük ölçekli, düşük maliyetli işlenmesi için her zaman bir sorun olan verilerin fiyatıdır. Ormanlık bir ortam için denenmiş ve doğrulanmış bir model olan Novel York Central Park'taki ağaç tepesi örtüsünü tespit etmek için, gelişmiş bir derin öğrenme yaklaşımı olan maske bölgesi tabanlı evrimli sinir ağı modelini (Mask R) birleştirerek yeni bir çerçeve oluşturduk. (-CNN), Google Earth

verileriyle. Öncelikle düzensiz ağaç taç örtüsü ile kentsel. Bulgular, tüm araştırma alanı için, taç bölgesi %81,8 algılama oranına sahipti ve Mask R-CNN taç algılama modeli tarafından tahmin edilen ağaç sayısı %82,8 algılama oranına sahipti. Çıkarılan ağaç sayılarının sırasıyla %87,5'i ve %81,6'sı ile algoritma, yalnız ağaçları ve kapalı ormanlık ağaç bölgelerini tanımlayabilmektedir.

Araştırma, ağaç tepesi tanımlama algoritmasının, kentsel ağaç tepesi saçaklarını haritalamak için önemli bir vaatte bulunduğunu ve son derece karmaşık durumlarda ağaç taçlarını güvenilir bir şekilde tanıyabildiğini göstermektedir.

Chang ve ark. (2013), LiDAR verilerini kullanarak ağaç taçlarını tespit etmek için ormanlardaki yerel maksimumlar ve minimumlar arasındaki geometrik bağlantıya dayalı bir yöntem önerdiler. LiDAR verilerinden yerel maksimum ve minimum değerler çıkarılarak ağaç tepe noktaları ve taç limitleri belirlendi. Dört yerel minimumdan hesaplanan ağaç dairelerinin tepesine en yakın olanı ağaç taçları olarak yerleştirildi. Nokta yoğunluğu kabaca 4,3 nokta/m² olan Kore'deki sık ve karışık ormanlardan elde edilen LiDAR verilerini kullanarak, referans ağaç taçlarının %77'sini tanımlayabildik. Bulgular ve arazi verileri arasındaki regresyon çizgisi, ağaç yüksekliğinin ve taç çapının hafife alındığını göstermiştir. Orman koşullarının ve daha yüksek nokta yoğunluğuna sahip verilerin etkisi daha fazla incelenmelidir.

Başka bir çalışmada, uzaktan algılamadan elde edilen verileri kullanan otomatik bireysel ağaç tacı tanımlama ve haritalamanın (ITCD), etkili, kesin ve kapsamlı orman izleme için giderek daha önemli hale geldiğini vurgulamışlardır (Zhen ve ark., 2016). LiDAR verilerini kullanan çalışmalara vurgu yapan bu çalışma, 1990'dan 2015'e kadar ITCD araştırmasındaki gelişmeleri veri türü/orman, kullanılan teknik, doğruluk değerlendirmesi ve araştırma amacı dahil olmak üzere çeşitli bakış açılarından incelemektedir. Bu gözden geçirme, ITCD araştırmalarında aktif kaynakların artan önemini göstermektedir. Tüm zaman aralığında, başta LiDAR olmak üzere aktif verileri kullanan çalışmalar toplam artışın %80'ini oluştururken, pasif verileri kullanan veya pasif ve aktif verileri birleştiren çalışmalar sırasıyla toplam artışın yalnızca %8'ini ve %12'sini oluşturdu. Üstelik, ITCD araştırmaları, pasif veri kaynakları için oluşturulan algoritmaların artımlı iyileştirmelerinden LiDAR gibi aktif veri kümelerinin ayırt edici özelliklerinden yararlanan benzersiz stratejilere kaydı. Yayınlanan ITCD araştırmalarının çoğunluğu hala kapalı (%41) yumuşak ağaç veya karışık ormanlar (%22) üzerinde yoğunlaşmaktadır, ancak bu ilerlemeler artık daha karmaşık orman ortamlarının (ör. kapalı sert ağaç ormanları, banliyö/kent ormanları) araştırılmasına olanak sağlamaktadır.

Çalışmaların sadece dörtte biri (%23) eksiksiz, çok düzeyli bir değerlendirme bildirirken, neredeyse üçte biri (%30) ağaç düzeyinde bireysel değerlendirme gerçekleştirdi. ITCD verilerini kullanarak orman parametrelerinin hesaplanmasıyla ilgili araştırmaların yaklaşık üçte birinde (%32) ITCD'ye özgü bir değerlendirme bulunmamaktadır.

Belirli algoritmaların uygulanması hakkında özel önerilerde bulunmak amacıyla, ITCD algoritmalarını değerlendirmek ve karşılaştırmak için iki seviyeli bir kıyaslama çerçevesi oluşturmak gereklidir. Yöntemlerin karşılaştırılması, referans verilerinin seçimi ve değerlendirme ölçeği nedeniyle hala karmaşıktır. Ancak, otomatikleştirilmiş BİT, uzaktan algılanan aktif verilerin ve yeni platformların büyümesi nedeniyle hem ormancılık hem de uzaktan algılama sektörleri için uygulanabilir bir teknoloji ve arzu edilen bir çalışma konusu olmaya devam edecektir.

Wang ve ark. (2004) yaptıkları çalışmalarında, orman ve ağaç niteliklerini doğrudan hava resimlerinden tahmin etme yeteneğinin, orman örnekleme maliyetini büyük ölçüde azaltabileceğini iddia ettiler. Bunu yapmak için, tek tek ağaçların yanı sıra her birini çevreleyen tepenin kapsamını içeren bölgeyi kesin olarak tanımlayabilmek gerekir. Normalde bu iki aşama ayrı ayrı yürütülür. Bu çalışmada araştırmacılar, bireysel ağaç tepesi sınırlarını ve ağaç tepesi konumlarını hesaplamak için standart bir çerçeve kullandılar. Ek olarak, kenar tespiti ile başlayan ve etiket kontrollü havza segmentasyonu ile biten iki aşamalı bir strateji kullanıldı. Arka plan maskeleyme için en az etkili ölçek, Gaussian'ın Laplace yaklaşımı kullanılarak kenarları tespit etmek için kullanıldı. Kenar haritasındaki kalan ağaç öğeleri, sekiz bağlantı diyagramı kullanılarak etiketlendi. Ağaç tepeleri daha sonra sırasıyla radyometri ve geometri kullanılarak modellenir. Daha özel olarak, ağaç tepelerinin yerel bir radyasyon maksimumunu temsil ettiği ve ağaç tepesinin ortasına yakın bir yerde konumlandığı düşünülmektedir. Birbirine değen ve topaklanan ağaçları daha iyi ayırt edebilmek için, Havza bölümlenmesini yönlendirmek ve tek tek ağaç taçlarından oluşan bölümlenmiş bir görüntü oluşturmak için türetilen ağaç tepe noktasından bir işaretleyici resim oluşturuldu. Araştırmacıların tekniğini oluşturmak için deney grubunun ticari olarak zayıf CASI resmi kullanıldı. Ağaçların ve taçlarının sayısının belirlenmesinde, bu otomatik yaklaşımlar ile el sınırlamasının sonuçları arasında umut verici bir anlaşma bulunmuştur.

Aynı resim malzemesini ve referans verilerini kullanan diğer araştırmacılar, yüksek uzamsal çözünürlüklü hava fotoğraflarında tek tek ağaç taçlarını tespit etmek için üç görüntü işleme tekniği yayınladılar (Erikson ve Olofsson, 2005). İlk teknik, şablonları kullanarak ağacın taçlarını arar. Diğer iki yaklaşım, genişlemeden yararlanır. Biri bulanık

kurallarla desteklenirken, diğeri Brownian hareketle oluşturulan bir resimden yararlanır. İki Pinus Sylvestris L. ve iki Picea abies Karst'ta.

Bir boreal ormandaki köknar ağaçları, her üç teknik de görünür gün ışığı ağaçlarının %80'ini veya daha fazlasını ifşa eder. Büyük ağaç taçlarını bulmak, tüm yaklaşımları kullanarak küçük ağaç taçlarını bulmaktan daha kolaydır.

Wu ve ark. (2020), meyve bahçelerinde ekin verilerinin toplanmasının genellikle fiziksel ölçüm ve görsel incelemeyi içerdiğini, bunun da zaman alıcı, emek yoğun ve pahalı bir süreç olduğunu vurguladılar. Ağaç geliştirme dinamiklerini izlemek ve çiftlik yönetimini geliştirmek için doğru ve hızlı ürün verilerinin toplanması çok önemlidir. Bu çalışmada, insansız hava araçlarından (İHA'lar) uzak fotoğraflar ve derin öğrenme evrişimli sinir ağları kullanılarak, tek tek ağaçları otonom olarak algılamak ve segmentlere ayırmak ve taç, çevre ve taç genişliklerini ölçmek için bir yöntem sağlanmaktadır. Bir elma ağacında bırakma bölgesi. Elma ağaçlarının 50 adet yüksek çözünürlüklü fotoğrafı, uyku halindeyken (çıplak dallar) drone sistemi kullanan bir meyve bahçesinde çekildi ve ardından her bir elma ağacı, bir R-CNN daha hızlı nesne detektörü kullanılarak tanımlandı. U-Net derin öğrenme ağı, her ağacı bu bulgulara göre bölümlere ayırdı. İçbükey ağaç sınırları, etkili bir kırpma yaklaşımı kullanılarak anlamsal bölümlere ayırıldı ve taç niteliklerinin doğruluğu, el seçimiyle eşleştirildi. Elde edilen sonuçlara göre, önerilen uydu görüntüleri yöntemi, elma ağaçlarının geçerlilik ve bilgi çıkarma oranlarının her ikisinde de %91.1 ve %94.1 olarak belirlenmesi ve nitelendirilmesi için kullanılabilir; şubelerini %97,1 ile en yüksek derece ile bölerek; ve tepe katsayısını %92'yi aşan bir genel doğrulukla yaklaşık olarak hesaplamıştır.

Tablo 2.1. Önceki araştırmaların özeti

| # | Yöntem | Amaç | Elde edilen sonuç |
|----------------------------|---|--|---|
| Ke ve Quackenbusch, 2011 | Yerel maksimum filtreleme, Vadi takip algoritması | Pasif uzaktan algılamada otomatik bireysel ağaç tepesi tespit yöntemlerini incelemek | Mevcut algoritmalar iyileştirildi ve bir uygulamayla uygun şekilde eşleşeceği değerlendirildi |
| Lindberg ve Holmgren, 2017 | Yüzey modellerine dayalı yöntemler | Ağaçları tanımlamak için 3 boyutlu verilere sahip gelişmiş sensörler kullanmak | 3 boyutlu verilerden tek tek ağaçlar çıkarıldı ve ormancılıkta ve çevrede uygulandı |

| | | | |
|----------------------------|--|--|--|
| Weinstein ve ark., 2019 | LIDAR algoritması | Yarı denetimli öğrenme sinir ağları ile bireysel ağaç tepesi tespiti | Az sayıda RGB görüntüsü ve denetimsiz yöntemler kullanılarak geliştirilmiş bir model tanıtıldı ve ortaya çıkan modeller, yüksek kaliteli etiketli verilerle yeniden gelişti |
| Aubry-Kientz ve ark., 2019 | Segmentasyon | Tropikal ormanlarda ağaç tepesi tanımlama algoritmalarının performansının değerlendirilmesi | Ağaç taçlarının tespitinde kanopi yüksekliği modelini temel alan yöntemlerin diğer modellere göre daha iyi performans sağladığı görüldü. |
| Weinstein ve ark., 2021 | Derin öğrenme yöntemleri | 100 milyon ağaç için bireysel düzeyde ağaç tacı tahminlerinin açık kaynak veri kümesinin üretilmesi. | Ağaçlar üzerinde bireysel düzeydeki araştırmaları büyük ölçüde genişletme potansiyeline sahip veriler sağlanmaktadır. |
| Ho ve ark., 2022 | Revize edilmiş yerel maksimum filtreleme | Yüksek mekansal çözünürlüklü görüntülerden bireysel ağaç tepesi tespiti | Ağaç tanımlaması yüksek doğrulukla sağlandı ve ihmal hataları etkili bir şekilde azaltıldı. |
| Xu ve ark., 2021 | Evrişimli sinir ağı | Google earth ağaç taçlarını algılama ve haritalama | Ağaç taçları oldukça karmaşık ortamlarda doğru bir şekilde tespit edilmiştir ve kentsel ağaç taç örtülerinin haritaları yapıldı |
| Wu ve ark., 2021 | Derin öğrenme | Uzak görüntülerden elma ağacı taç bilgilerinin çıkarılması | Elma ağaçlarının yüksek doğrulukla tespit edilip sayılması ve dallarının bölünmesi için uzaktan algılama teknolojisi kullanıldı. Model, meyve bahçesi ağaçlarının büyümesini dinamik olarak izlemek için kullanılabilir. |

3. MATERYAL VE METOT

3.1. Görüntü Verileri

Görüntü verileri adlı dosya, BOS kurulum prosedürünü yürütürken yüklenen görüntüyü betimleyen verileri içerir. Sağlanan veriler, birincil cilt grubu içindeki mantıksal hacimlerin ve dosya sistemlerinin boyutlarını, terminolojisini, kartografisini ve montaj konumlarını içerir (Jain, 1981). Görüntü veri dosyasının oluşturulması, mksz file komutuyla kolaylaştırılır. Dosyanın kullanıcı tarafından değiştirilmesi tavsiye edilmez. Herhangi bir ilişkili alanı uygun şekilde ayarlamadan tek bir alan değerini değiştirmek, başarısız bir kurulum ve hasarlı bir yedek temsile yol açabilir. Bu önerinin yegâne istisnası, SHRINK alanıyla ilgilidir. Kullanıcı, bu alanda ayarlamalar yapma seçeneğini elinde tutar, böylece BOS'un kurulum rutinlerini, görüntü veri dosyasında özetlenen spesifikasyonlara uygun olarak dosya sistemlerini oluşturmaya yönlendirir. Alternatif olarak, kullanıcı, yalnızca içlerinde bulunan tüm verileri barındırmak için yeterli boyutta olan dosya sistemleri oluşturmayı seçebilir.

BOS'un kurulum işlemi de görüntüden girdi alır. Kurulmakta olan makinenin varsayılan ayarları hakkında bilgi içeren bir veri kümesi. BOS kurulumu tarafından donanım yapısı ve mevcut birim kök grubu sorguları aracılığıyla elde edilen değerlerin yerini veri dosyası alacaktır. Görüntü Verisi olarak belirtilen arayüz, bir resim ögesi içindeki belirlenmiş bir bölgenin temel piksel verilerine ilişkindir.

Bir görüntünün oluşturulması, bir resme bağlı Canvas Rendering Context 2D varlığı üzerinde Image Data oluşturucu veya oluşturucu teknikleri kullanılarak elde edilir. Bu teknikler, Görüntü verileri oluşturmayı ve görüntü verilerini almayı içerir. Put Image Data'nın kullanımı, kanvasın bir bölümünü yapılandırmak için de uygulanabilir.

Bir görüntü verisi varlığı oluşturma işlemi, sağlanan bir Uint8 sıkıştırılmış dizinin ve eklenen görüntünün boyutlarının kullanılmasını içerir. Bir dizinin yokluğunda sistem, saydam ve siyah renkli bir dikdörtgeni gösteren bir görüntü oluşturur. Görüntü verisi oluşturma seçeneğine bu bağlamda erişilemediğinden, bir nesne oluşturmak için yaygın yöntemin bu yaklaşımdan geçtiğine dikkat edilmelidir.

3.2. Coğrafi TIFF

GeoTIFF'ler, uydu ve havadan görüntü verilerinin depolanması için kullanılan yaygın raster görüntü dosyası formatıdır. Bunlara, görüntünün uzamsal konumunun bir tanımını sağlayan coğrafi meta veriler eşlik eder (Pratama, 2020). GeoTIFF'ler, sıkıştırma, düzenleme ve aktarma gibi çeşitli işlemler boyunca kalitelerini korurken, çok

çeşitli CAD ve GIS uygulamalarıyla yüksek uyumluluk sergiler. GeoTIFF'ler, drone haritalama iş akışlarında hem ortofotoları hem de dijital yükseklik modellerini (DEM'ler) kapsayabilir.

Erişimlerini ve gösterimlerini kolaylaştırmak için GeoTIFF formatındaki görüntüler için hem tescilli hem de açık kaynaklı çok çeşitli görüntüleyiciler mevcuttur. Bu yazılım çözümlerini kullanarak GeoTIFF haritaları oluşturmak, basit bir sürükle ve bırak işlemini içerebileceğinden basit bir süreç olabilir. Çevrimiçi bir programda bir harita oluşturma işlemi, bir GeoTIFF dosyasının yüklenmesini ve mekansal referans sistemi, harita formatı ve boyutlandırma parametrelerinin belirtilmesini içerir. Harita daha sonra belirtilen uzamsal referansa göre işlenir. Jeo uzamsal veriler, bir harita üzerinde temsil edilen vektör formatlarından çıkarılır ve daha sonra, kaynak dosyadaki projeksiyonun farklı olduğu durumlarda, haritanın belirlenen çıktı projeksiyonuna dönüştürülür. Dijital haritacılık alanında, özellikle dronlar aracılığıyla elde edilen anket verileri gibi coğrafi referanslı görüntülerle ilgili olarak, GeoTIFF formatının mevcut en uygun seçenek olduğu düşünülmektedir (Tang ve Shao, 2015).

İlgili coğrafi verilerle birlikte hacimli görüntü dosyalarının saklanması, iletilmesi ve sergilenmesi amacıyla yaygın ve güvenilir dosya formatı kullanılmaktadır. GeoTIFF biçimlendirmesi kullanılarak görüntü dosyalarına gömülen, konum açısından zengin coğrafi verilerin oluşturulması, sürekli olarak milyarlarca kayıt üretir. Bu veriler, mekansal kullanımlar için bir dizi için oldukça değerlidir. CBS sistemleri, çok yönlü çevresel olayların ve ekonomik durum modellerinin daha iyi anlaşılmasını kolaylaştıran katmanlı haritalar oluşturmak amacıyla coğrafi meta verileri korumak, değerlendirmek ve kullanmak için kullanılır.

TIFF dosya biçimi, görüntü depolama amacıyla kullanılır. Etiketli Görüntü Dosyası Formatı (TIFF), diğerlerinin yanı sıra yayıncılık, sayfa düzeni uygulamaları ve 3 boyutlu görüntüleme uygulamaları gibi çeşitli endüstriler tarafından yaygın olarak kullanılır ve onaylanır (Varghese ve ark., 2017). Söz konusu format, bit eşlemleri bir yapı kullanan ve birden çok çözünürlüğü barındırabilen bir görüntü türüdür.

Bir GeoTIFF, hem görüntü verilerini hem de meta verileri içeren bir dosya formatı türü olarak tanımlanabilir. Bir GeoTIFF dosyasındaki meta veriler, görüntü verilerinin coğrafi konumu ve projeksiyonu hakkında bilgi sağlar. TIFF dosya formatı, görüntü verilerinin yanı sıra coğrafi referans meta verilerini birleştirme yeteneğine sahiptir (Mahammad ve Ramakrishnan, 2003). Coğrafi referanslama süreci, bir özelliğin uzamsal konumunun belirlenmesini içerir. Görüntü ile belirli bir koordinat seti arasında bir ilişki

kurar. Ek olarak, GeoTIFF'ler, belirli bir konumdaki diğer çeşitli coğrafi özelliklerin konumunu tespit etme yeteneğine sahiptir. Şekil (3.1), GeoTIFF formatında bir ağaç alanı resmi örneğidir.



Şekil 3.1. GeoTIFF drone görüntüsü

İnsansız hava araçları (İHA'lar) kullanarak şantiyelerinin havadan etüdünü gerçekleştiren sörveyörler, verilerini analiz etmek ve istenen topografyayı elde etmek için gereken kazı ve dolgu miktarlarını belirlemek için Propeller gibi bir fotogrametrik yazılım sisteminden yararlanabilirler. projenin önceki seviyeleri ve amaçlanan tasarım yüzeyleri. Veriler, GeoTIFF veya diğer dosya formatları gibi çeşitli koordinat referans sistemlerinde indirilebilir. GeoTIFF'ler, drone haritalama iş akışlarında hem ortofotografiyi hem de dijital yükseklik modellerini (DEM'ler) kapsayabilir. Ölçümlerin tamamlanmasının ardından, toplanan veriler ekip ve diğer ilgili paydaşlar arasında dağıtılabılır. Gömülü GIS verilerini içeren GeoTIFF dosyaları, ileriye dönük geliştirme girişimlerinin analizini kolaylaştırma potansiyeline sahiptir.


3.3. Veri Kümesi

İdeal ve alışılmadık bir model oluşturmak için kendi verilerimizi topladık. Toplanan görüntüler Bağdat/Irak'taki farklı orman ve çiftliklerdeki ağaç taçlarının resimlerinden oluşmaktadır. Bunun yanı sıra Bulgaristan batı balkan sıradağlarına ait görüntülerden de karşılaştırma amacı ile faydalandık. Fotoğraf çekmek için yüksek kaliteli dronelar ve yüksek çözünürlüklü kameralar kullanıldı. Farklı özellik ve açılarla çok sayıda resim toplandı. Bu görüntüler sistem oluşturmada, eğitimde ve bazıları sistem testi için kullanıldı.

Veri setimiz, sistemin oluşturulmasında kullanılan birçok veriden oluşmaktadır. Sistemin yüksek verimle çalışmasını sağlayan uygun bir veri setine ulaşmak için farklı bölgeler için büyük tarım alanları için veriler toplandı ve bu sayede pratikte iyi sonuçlar elde edildi. Bu veriler, yüksek sonuçlar elde etmek için bu alanda daha önce yapılmış çalışmalara dayanan sistemimizin temel yapı taşı olacak şekilde oluşturuldu. Mevcut veriler, yüksek çözünürlüklü görüntü alan özel drone'lar tarafından geniş alanlara dikilen ağaçların taç verilerini gösteren ekili alanlardan alınan görüntülere ilişkin verilerdi.

Sisteme özellik eklemek, birçok önemli özelliğe sahip görseller üzerinde eğitim alma ihtiyacını doğurmaktadır. Sistem verimliliğini artırmak için diğer görüntüler veri kümemizle birleştirilebilir. Modeli geliştirmek için özellikler eklemek, modelin farklı durumlardaki ağaçları tanımasını sağlayacaktır. Sistemin kullanımı sadece görsellerimiz ile sınırlı değildir, farklı nitelikteki görsellere de uygulanabilmektedir.

Dosya ve veri niteliğindeki bu görüntüler GeoTiff teknolojisi kullanılarak işlenmekte ve büyük miktarda veriden ayıklanmış veri şeklinde işlenmektedir. Farklı yüksekliklerde ve farklı açılarda yüksek çözünürlüklü görüntüler çekmek için dronlar kullanıldı, bu da bize doğruluk ve verimlilik açısından en iyi sonuçları verdi. Makine öğrenimi, önerilen sisteme göre ağaçların ve ekili alanların farklı özelliklerini tahmin etmek ve bu ağaçların özelliklerini elde etmek için kullanılan algoritmalar tarafından önerilen sistem aracılığıyla bunları işlemek için kullanılır ve bu da bize yüksek doğrulukta pratik sonuçlar verir. Şekil (3.2)'de gösterildiği gibi bu veriler toplanır, veri seti oluşturulur, işlenir ve işlenmek üzere sisteme girecek veriler iki parçaya bölünür.



Şekil 3.2. Veri kümesi bölme

Veriler, incelenen alanların özellikleri hakkında doğru sonuçlar verecek ve taçlarından ağaçların özelliklerini tahmin edecek şekilde verileri hazırlayan makine öğrenimi algoritmaları aracılığıyla sistemin eğitilmesine yönelik veriler de dahil olmak

üzere iki bölüme ayrılmıştır. Diğer bölüm ise veriler modele girilip önerilen makine öğrenmesi algoritmaları tarafından işlendikten sonra önerilen modeli test etmektir.

3.4. Derin Öğrenme

Derin öğrenme, üç veya daha fazla katmandan oluşan sinir ağlarının kullanılmasıyla karakterize edilen, makine öğreniminin bir alt alanını oluşturur. Sinir ağları, yeterliliğini taklit etmekte yetersiz kalsa da, insan beyninin eylemlerini kopyalamaya çalışır ve böylece çok miktarda veriden bilgi edinmesini sağlar. Yalnız bir katman içeren bir sinir ağı, gerçek değerlere oldukça yakın tahminler üretebilse de, tamamlayıcı gizli katmanların dahil edilmesi, optimizasyon sürecini geliştirebilir ve tahminlerin kesinliğini artırabilir (Learning, 2020).

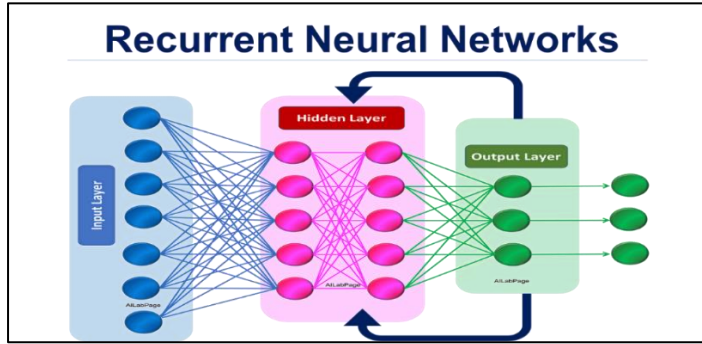
Derin öğrenme tekniklerinin kullanılması, analitik ve fiziksel görevleri insan müdahalesine ihtiyaç duymadan yürüterek otomasyonu geliştirme kapasitesine sahip çok sayıda yapay zekâ (AI) uygulaması ve hizmetinin arkasındaki temel itici güçtür (Shakya, 2020). Derin öğrenme teknolojisi, dijital asistanlar, sesle etkinleştirilen televizyon uzaktan kumandaları ve kredi kartı dolandırıcılığı tespiti dahil ancak bunlarla sınırlı olmamak üzere, sıradan ürün ve hizmetlerin temelini oluşturur. Ek olarak, otonom araçlar gibi gelişen teknolojilerin temel bir bileşenidir.

Yapay sinir ağları olarak da bilinen derin öğrenme sinir ağları, veri girişleri, ağırlıklar ve önyargıların bir karışımını kullanarak insan beyninin işlevselliğini kopyalamaya çalışır. Bu öğeler, verilerdeki nesnelere doğru bir şekilde tanımak, sınıflandırmak ve tanımlamak için birlikte çalışır.

Derin sinir ağları, birbirine bağlı çok sayıda düğüm katmanından oluşur ve her katman, önceki katmana dayalı olarak tahmini veya sınıflandırmayı aşamalı olarak iyileştirir ve optimize eder. Verilerin ağ üzerinden sıralı bir şekilde iletilmesi işlemi, ileri yayılım olarak adlandırılır. Derin bir sinir ağının görünür katmanları, girdi ve çıktı katmanları olarak adlandırılır. Bir derin öğrenme modelinin giriş katmanı, giriş verilerini almak ve işlemekten sorumluyken, çıkış katmanı nihai tahmin veya sınıflandırmayı oluşturmaktan sorumludur.

Geri yayılım, tahmin hatalarını hesaplamak ve ardından fonksiyonun ağırlıklarını ve yanlılıklarını değiştirmek için gradyan iniş gibi teknikleri kullanan algoritmik bir süreçtir. Bu, modeli eğitme nihai hedefiyle, modelin katmanları arasında geriye doğru gidilerek elde edilir. Birlikte, ileri yayılım ve geri yayılım, bir sinir ağının tahminler üretmesini ve herhangi bir hatayı uygun şekilde düzeltmesini sağlar. Zaman geçtikçe, algoritma giderek daha doğru hale gelir.

Aşağıdaki açıklama, en temel derin sinir ağı türünü en kolay kavramlarla açıklar. Derin öğrenme algoritmaları, yüksek düzeyde karmaşıklıkları ile karakterize edilir ve belirli veri kümelerini veya sorunları ele almak için uyarlanmış çeşitli sinir ağı mimarilerini kapsar. Örnek olarak, Evrişimli sinir ağları (CNN'ler), ağırlıklı olarak bilgisayarla görme ve görüntü sınıflandırma alanlarında kullanılır. Bir görüntüde bulunan özellikleri ve kalıpları tanımlama yeteneğine sahiptirler, böylece nesne algılama veya tanıma gibi görevleri kolaylaştırırlar. 2015 yılında bir CNN, bir nesne tanıma mücadelesinde ilk kez bir insanı geride bıraktı. Şekil (3.3)'te gösterilen tekrarlayan sinir ağları (RNN'ler), sıralı veya zaman serisi verilerini etkili bir şekilde modelleme yeteneklerinden dolayı doğal dil işleme ve konuşma tanıma alanlarında yaygın olarak kullanılır.



Şekil 3.3. Tekrarlayan sinir ağları (RNN'ler)

3.4.1. Derin öğrenme uygulamaları

Derin öğrenme uygulamaları, çeşitli ürün ve hizmetlere entegre edilmesiyle günlük hayatımızda her yerde bulunur hale gelmiştir. Ancak, kullanıcılar genellikle arka planda gerçekleşen karmaşık veri işlemeden habersizdir. Yasa uygulama alanında derin öğrenme algoritmaları, olası dolandırıcılık veya suç teşkil eden davranışlara işaret edebilecek tehlikeli kalıpları tespit etmek için işlemsel verileri inceleme ve bunlardan bilgi edinme yeteneğine sahiptir. Konuşma tanıma ve bilgisayar görüşü gibi derin öğrenme uygulamalarının kullanılması, araştırma analizinin etkinliğini artırabilir. Bu uygulamalar, ses ve video kayıtları, görüntüler ve belgeler gibi çeşitli kaynaklardan desenler ve kanıtlar çıkararak, kolluk kuvvetlerinin çok büyük miktarda veriyi daha yüksek hız ve hassasiyetle analiz etmesine yardımcı olur.

Diğer alanlarda finansal hizmetlerin sağlanması gibi tahmine dayalı analitik, hisse senetlerinin algoritmik ticareti, kredi onayları için ticari risklerin değerlendirilmesi, hileli faaliyetlerin belirlenmesi ve müşteriler için kredi ve yatırım portföylerinin yönetimini

kolaylaştırmak için kullanılan finansal kurumlar arasında yaygın bir uygulamadır. Bir satın alma veya işlem öncesinde, sırasında ve sonrasında müşterilere yardım ve destek sağlanmasına genellikle müşteri hizmetleri denir.

Çok sayıda kuruluş, derin öğrenme teknolojisini müşteri hizmetleri prosedürlerine entegre eder. Çeşitli uygulamalarda, hizmetlerde ve müşteri hizmetleri portallarında kullanılan sohbet robotları, yapay zekânın basitleştirilmiş bir tezahürüdür. Geleneksel sohbet robotları, çağrı merkezi tarzı menülerde sıklıkla karşılaşılan doğal dil işleme ve görsel tanıma tekniklerini kullanır. Bununla birlikte, gelişmiş sohbet robotu çözümleri, makine öğrenimi yoluyla şüpheli sorulara birden çok yanıt olup olmadığını belirlemeye çalışır. Chatbot, aldığı geri bildirimlere göre doğrudan yanıtlar sağlamaya veya konuşmayı bir insan kullanıcıya yönlendirmeye çalışır. Yan sırada sağlık hizmeti sağlayan uygulamalarda, Hastane kayıtlarının ve görüntülerinin dijitalleştirilmesi, derin öğrenme yeteneklerinin sağlık hizmetleri sektörüne entegrasyonunu kolaylaştırarak önemli faydalar sağladı. Görüntü tanıma teknolojisinden yararlanan uygulamalar, tıbbi görüntüleme uzmanlarına ve radyologlara daha fazla sayıda görüntüyü daha kısa bir süre içinde analiz etme ve değerlendirme konusunda yardımcı olma potansiyeline sahiptir. Önem sağladığı için ağaç taçlarını algılama işlemlerinde de kullanılır.


3.4.2. Evrişimsel Sinir Ağı

Bir evrişimli sinir ağı, bir görüntünün farklı özelliklerini ayırt etme yeteneği ile onlarca ila yüzlerce arasında değişen çok sayıda katman içerme potansiyeline sahiptir (Albawi ve ark., 2017). Evrişimli sinir ağları, farklı çözünürlüklerde bireysel eğitim görüntülerine uygulanan filtreler kullanır. Ortaya çıkan kıvrımlı görüntüler daha sonra sonraki katmanlar için girdi olarak kullanılır. Filtreler, parlaklık ve konturlar gibi ilkel özellikler olarak başlayabilir ve varlığı belirgin şekilde betimleyen niteliklere doğru karmaşıklıkta ilerleyebilir.

Evrişimli Sinir Ağı (CNN), bir başlangıç girdi katmanı, bir son çıktı katmanı ve çoklu ara gizli katmanlardan oluşur.

Belirtilen katmanlar, veriye özgü ayırt edici özellikleri elde etmek için veriyi değiştirmeyi amaçlayan işlemleri yürütür. Evrişim, aktivasyon (ReLU) ve havuzlama, sinir ağlarında en sık kullanılan katmanlar arasındadır. Şekil (3.4), CNN algoritması katmanlarını bir Evrişim, Konvolüsyon süreci, girdi görüntülerinin, görüntüler içindeki belirli özellikleri seçerek etkinleştiren bir dizi evrişimli filtreye tabi tutulmasını içerir. Ve doğrultulmuş lineer birim (ReLU)Düzeltilmiş Doğrusal Birim (ReLU) aktivasyon işlevi, pozitif değerleri korurken negatif giriş değerlerini sıfıra dönüştürerek hızlandırılmış ve

verimli eğitimi kolaylaştıran bir tekniktir. İncelenmekte olan fenomen bazen aktivasyon olarak adlandırılır, çünkü yalnızca aktifleştirilmiş özellikler bir sonraki tabakaya yayılır (Agarap, 2018). Havuzlama olarak bilinen doğrusal olmayan aşağı doğru örnekleme süreci, çıktıyı düzene sokar ve ağ içinde öğrenmeyi gerektiren parametre sayısını etkili bir şekilde azaltır.



Şekil 3.4. CNN katmanları (Anonim, 2019)

Evrişimli sinir ağları (CNN'ler), birkaç yapay nöron katmanından oluşur. Yapay nöronlar, çeşitli girdilerin ağırlıklı ortalamasını hesaplayarak ve çıktı olarak bir ateşleme değeri üreterek, canlı nöronlarda meydana gelen davranışa yaklaşan hesaplama algoritmalarıdır. Konvolüsyonel Sinir Ağlarında, bir görüntünün girişi, daha sonra bir sonraki katmana iletilen her katman tarafından çoklu aktivasyon fonksiyonlarının üretilmesiyle sonuçlanır. Tipik olarak, ilk işleme katmanı, düz veya çapraz kenarlar gibi temel özelliklerin çıkarılmasından sorumludur. Yukarıda bahsedilen sonuç daha sonra, köşeler veya birleştirilmiş sınırlar gibi karmaşık özellikleri tanımladığı sonraki katmana iletilir. Ağ ilerledikçe, nesnelere ve yüzler gibi giderek karmaşıklaşan özellikleri tanımlayabilir hale gelir. Konvansiyonel bir sinir ağının aksine, Evrişimli Sinir Ağı (CNN), belirli bir katmandaki tüm gizli nöronlar arasında paylaşılan ağırlık ve yanlılık değerlerini kullanır.

Bu, gizli nöronların her birinin, görsel temsilin farklı alanlarında bir sınır veya bir küme gibi ortak bir özelliği ayırt ettiği anlamına gelir. Bu özellik, ağa bir görüntü içindeki nesne çevirilerine dayanma yeteneği verir. Örnek olarak, otomobilleri tanımlamak için eğitilmiş bir sinir ağı, otomobilin görüntüdeki konumundan bağımsız olarak bu görevi gerçekleştirme yeteneğine sahip olacaktır. Çoklu katmanlardaki özellikler hakkında bilgi edinilmesi üzerine, evrişimli sinir ağının yapısı sınıflandırma görevine doğru geçiş yapar.

Modelin sondan bir önceki katmanı, K-boyutlu bir vektör oluşturan tamamen bağlantılı bir katmandır; burada K, tahmin edilebilecek sınıfların sayısını temsil eder. Bu vektör, görüntü sınıflandırması amacıyla her bir sınıfla ilişkili olasılıkları içerir (Qi ve ark., 2017)

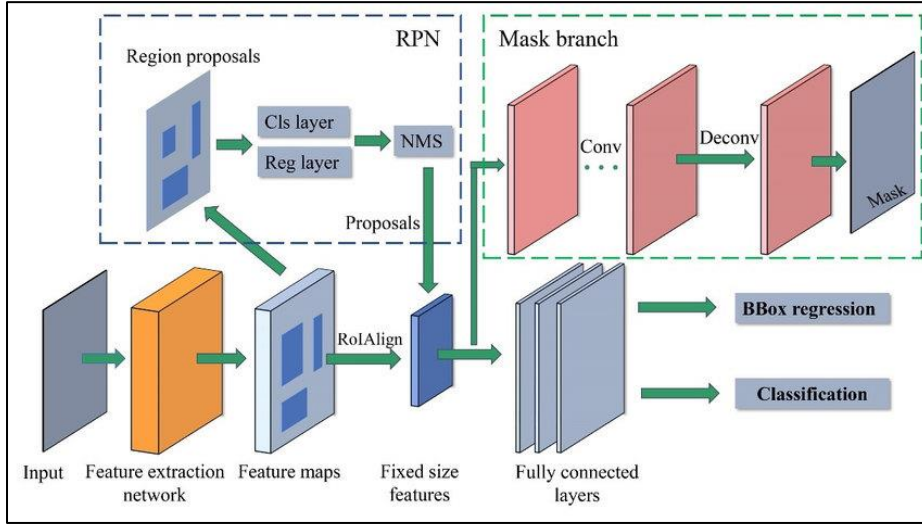
Konvolüsyonel Sinir Ağı (CNN) çerçevesinin nihai katmanı, nihai sınıflandırma sonucunu sağlamak için bir sınıflandırma katmanı kullanır. Evrişimli sinir ağları (CNN'ler), görüntü ve zaman serisi verilerindeki temel özellikleri ortaya çıkarmak ve elde etmek için en uygun çerçeveyi sunar. Konvolüsyonel Sinir Ağları (CNN'ler), aşağıdakiler dahil olmak üzere çeşitli uygulamalarda kullanılan çok önemli bir teknolojik gelişmedir (Rivas ve ark., 2018).

3.4.3. Mask RCNN (Bölge tabanlı evrişimli sinir ağı)

Örnek segmentasyonu, bir nesnenin tanımlanmış her örneği için bir segmentasyon haritası üreten bir nesne algılama çeşididir. Örnek bölümlenme yaklaşımı, nesne sınıflarından bağımsız olarak ayrı nesnelerin ayrı varlıklar olarak değerlendirilmesini içerir. Buna karşılık, anlamsal bölümlenme yaklaşımı, aynı sınıfa ait tüm nesnelerin birleşik bir varlık olarak gruplandırılmasını içerir (Bharati ve Pramanik, 2020).

Mask R-CNN, piksel düzeyinde segmentasyon yoluyla nesnelerin tanımlanmasını sağlayan, örnek segmentasyonu için yaygın olarak kullanılan bir derin öğrenme tekniğidir. Mask R-CNN algoritması, birden çok sınıfı ve üst üste binen nesnelere barındırabilir. Şekil (3.5), Mask R-CNN mekanizmasını göstermektedir. Örnek segmentasyonunun kullanılması, hasarın büyüklüğünün belirlenmesinin büyük önem taşıdığı hasar tespiti gibi sorunların çözülmesini sağlar. Ek bir uygulama senaryosu, ortamdaki her aracın kesin konumunu belirlemenin çok önemli olduğu otonom araçlarla ilgilidir. Her yapı için farklı bina ayak izleri üretme görevi, Coğrafi Bilgi Sistemleri (GIS) alanında geniş çapta incelenen bir konudur (Chang, 2006). Kullanım, Mask R-CNN modelinin uygulanması yoluyla pratik sorunların ele alınmasında belirgin bir avantaj sağlar.

Mask R-CNN, Faster R-CNN temel alınarak oluşturulmuş örnek segmentasyonu için en gelişmiş algoritmadır. Faster R-CNN modeli, bölgeler üzerinde çalışan ve nesnelere için karşılık gelen sınıf etiketleri ve bir güven puanı ile birlikte sınırlayıcı kutular üreten bir evrişimli sinir ağı türüdür (Ren ve ark., 2015).

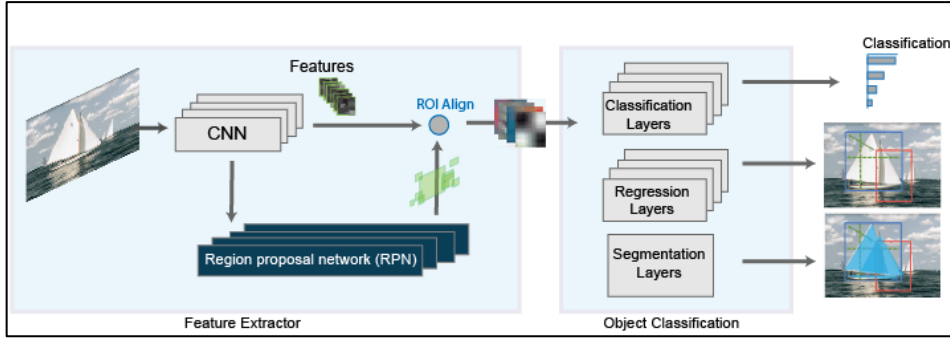


Şekil 3.5. Maske R-CNN mekanizması (Yang ve ark., 2020)

Önceden eğitilmiş bir Mask R-CNN ağı oluşturulması, mask rcnn nesnesinin kullanılmasıyla gerçekleştirilebilir. Sınır ağı, MS-COCO veri seti kullanılarak eğitildi ve 80 farklı kategoriye ait nesnelere doğru bir şekilde tanımlama yeteneğine sahip (Lin ve ark., 2014). Örnek segmentasyonunu yürütmek için, mask rcnn nesnesiyle bağlantılı olarak Segment Objects işlevini kullanın. Transfer öğrenimi, tamamlayıcı sınıfları tespit etmek veya diğer ağ parametrelerini ayarlamak amacıyla ağı değiştirmek için kullanılabilir.

Mask R-CNN için transfer öğrenimi süreci tipik olarak aşağıdaki adımları içerir, Bir Mask R-CNN modelinde transfer öğrenmeyi uygulamak için mask rcnn nesnesini kullanın, Eğitim amacıyla bir veri kümesi oluşturun, Model eğitimi yürütmek için tren Maskesi RCNN işlevini kullanın ve Mask R-CNN modeli, Örnek Bölümleme işlevini değerlendir kullanılarak değerlendirilebilir (Han ve ark., 2021).

Bir Mask R-CNN ağı için transfer öğrenmeyi kolaylaştırmak amacıyla, bir maske R-CNN nesnesinin oluşturulması sırasında sınıf adlarını ve bağlantı kutularını belirtmek gerekir. Ağ girişinin boyutu ve ROI havuzunun boyutları gibi tamamlayıcı ağ özelliklerini belirtmek mümkündür. Şekil (3.6), Mask R-CNN'nin nasıl çalıştığını gösterir.



Şekil 3.6. Maske R-CNN (Anonim, 2023b)

Mask R-CNN mimarisi, iki aşamalı bir çerçeveden oluşur. İlk aşama, nesne teklifleri için sınırlayıcı kutuları öngörmek için bağlantı kutularını kullanan bir bölge teklif ağı (RPN) içerir. Sonraki aşama, önerilen bölgeleri geliştiren, bunlar üzerinde sınıflandırma yapan ve yukarıda belirtilen öneriler için piksel düzeyinde segmentasyonu hesaplayan bir R-CNN detektörünü içerir (Ren ve ark., 2015).

3.5. Sınıflandırma Yöntemleri

Sınıflandırma, kavramları ve varlıkları önceden belirlenmiş gruplara veya "alt popülasyonlara" göre tanımlama, anlama ve kategorize etme sistematik prosedürünü ifade eder. Makine öğrenimi programları, gelecek veri kümelerini farklı kategorilerde sınıflandırmak için önceden kategorize edilmiş eğitim veri kümelerini ve bir dizi algoritmayı kullanır.

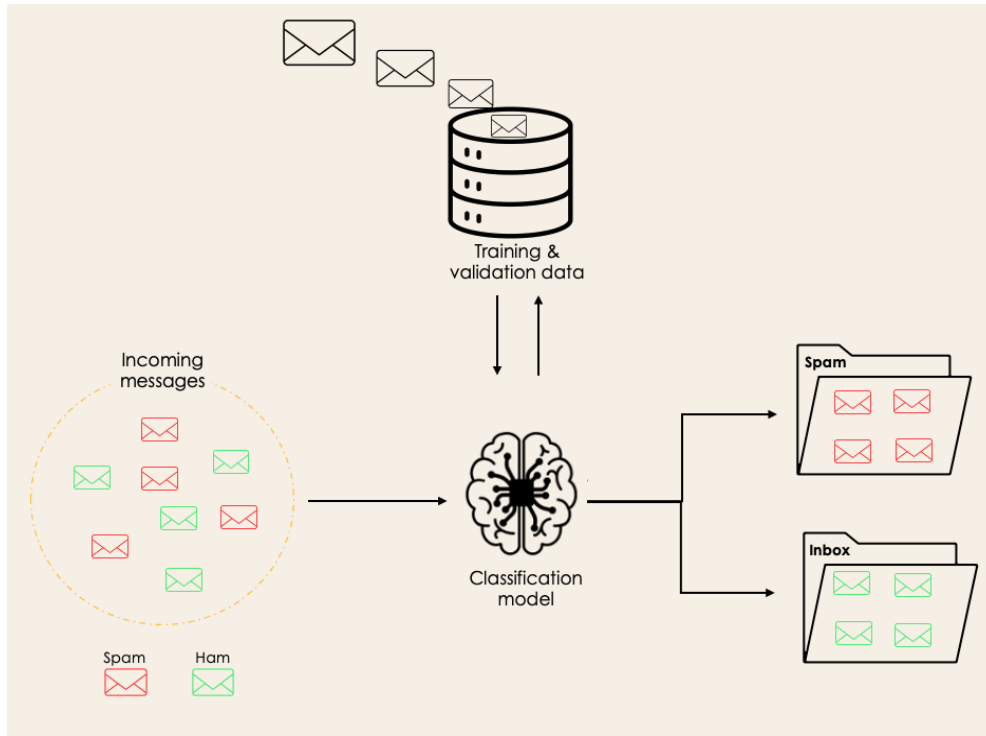
Makine öğrenimi sınıflandırma algoritmaları, gelecekteki verilerin önceden belirlenmiş kategorilerden birine atanma olasılığını tahmin etmek için girdi eğitimi verilerinden yararlanır. E-postaları "istenmeyen posta" veya "istenmeyen posta" olarak kategorize etme işlemi, sıklıkla kullanılan bir sınıflandırma uygulamasıdır.

Kısaca, sınıflandırma, sonraki veri setlerinde aynı kalıpları (karşılaştırılabilir ifadeler veya duygular, miktar zincirleri vb.) tanımlamak için eğitim verileri üzerinde sınıflandırma algoritmalarının kullanılmasını içeren bir tür "örnek tanıma"dır. İçerik analizi programları, görünüşe dayalı duyarlılık analizi gibi görevleri yürütmek için sınıflandırma yöntemlerini kullanabilir. Bu süreç, organize olmayan yazılı materyalin konusuna ve olumludan olumsuzla ve diğer ilgili duygulara kadar değişebilen görüş kutuplarına göre kategorize edilmesini içerir.

Veri sınıflandırması, çeşitli dosya biçimlerini ve diğer önemli kurumsal verileri düzenlemek ve tanımlamak için metodik bir yaklaşımdır. Bu teknoloji ağırlıklı olarak büyük kuruluşlarda sıkı uyumluluk protokollerine uyan güvenlik çerçeveleri oluşturmak için kullanılır. Bununla birlikte, daha küçük ayarlarda da kullanılabilir. Veri sınıflandırma

süreci, saklanan bilgilerle ilişkili hassasiyet seviyesinin anlaşılmasında çok önemli bir rol oynar, böylece uygun siber güvenlik önlemlerinin, erişim kontrollerinin ve izleme protokollerinin formüle edilmesini sağlar (Chen ve ark., 2020).

Sınıflandırma, belirli bir girdi veri kümesi için uygun etiketi tahmin etmek üzere bir model kullanan denetimli bir makine öğrenimi tekniği olarak tanımlanabilir. Sınıflandırma işlemi sırasında model, eğitim verileri kullanılarak kapsamlı bir eğitime tabi tutulur ve daha sonra yeni, gözlemlenmemiş veriler üzerinde tahmin için kullanılmadan önce test verileri üzerinde değerlendirilir. Şekil (3.7) bir algorithmada gösterildiği gibi, bir e-postanın spam veya ham (spam olmayan) olarak kategorize edilip edilemeyeceğini tahmin etme becerisini kazanma kapasitesine sahiptir.



Şekil 3.7. Sınıflandırma yöntemi (Pradeep, 2017)

Bulunduğu yer ve gerekli koruma protokolleri de dahil olmak üzere bir kuruluşun verileriyle ilgili yetersiz farkındalık, veri gizliliğinin ve güvenliğinin tehlikeye atılmasına yol açabilir. "Kişinin verilerini bilmesi" ifadesi, bir şirket içindeki tüm "hassas" bilgilerin yerinin anlaşılmasıyla ilgilidir. Veri sınıflandırma işlemi, bir kuruluşun ağları, paylaşım platformları, uç noktaları veya bulut dosyaları boyunca konumlanmış olabilecek hassas verilerin tanınmasını ve sınıflandırılmasını sağlamaya hizmet eder (Leith ve Piper, 2013)

Bu metodoloji, gizli bilgiler hakkında önemli bakış açıları elde etmek için tutarlı ve yapılandırılmış bir yaklaşımı garanti eder. Sistemin işleyişi, hem kurumsal hem de

düzenleyici gerekliliklere uygun olarak her bir veri kategorisini işlemek ve korumak için uygun önlemleri belirleyen veri özniteliklerinin oluşturulmasına dayanır. Kuruluşlar, veri erişilebilirliğinin rahatlığını kullanarak veri ayak izlerini etkili bir şekilde azaltabilir, veri açığa çıkma risklerini azaltabilir, veri korumadaki fazlalıkları ortadan kaldırabilir ve güvenlik kaynaklarını daha verimli bir şekilde tahsis edebilir.

3.6. Önerilen Yöntem

Daha önce yapılan birçok çalışmadan sonra ve araştırmacıların bu alanda sundukları ışığında, gelişmiş derin öğrenme yöntemlerinin uzaktan algılama verilerini analiz etmede ve yer bilimi problemlerini çözmede yüksek verimlilik ve doğruluğa sahip olduğu kanıtlanmıştır. Bu çalışma, farklı geniş tarım alanlarının görüntüleri şeklinde dronlar aracılığıyla ağaçlar taçlarının arasından alınan bir dizi verinin analizini ve tahminini oluşturmak için makine öğrenimi algoritmalarını kullanmak için derin öğrenmenin kullanımında yeni bir kavram önermektedir.

Veriler analiz edilirken, bu verileri net bir şekilde bölümlere ayırmak için aydınlatma yoğunluğu, ağaçların uzunluğu, görünüm açıları ve birbirleriyle örtüşmeleri aracılığıyla görüntülerin safsızlıkları ve bozulmaları da dikkate alınır. İşlenmeye hazır bir şekilde bu görüntüler, ağı eğitmek için manuel olarak etiketlenmiş eğitim örnekleriyle eşleştirilmiştir. Ağaçları tanımlamak ve görüntülenmiş verileri bölümlere ayırmak için önerilen birçok yöntemle rağmen, her yöntemin kendi dezavantajları vardır. Veri işleme yöntemlerinin azalmasıyla, ağaç taçlarının farklı renklerinin ortaya çıkması ve safsızlıkların ortaya çıkması yoluyla, aydınlatma ve gölge açısındaki farklılıkları belirlemek ve tahmin etmek zordur, bu da ağaç tepelerini keşfetmenin doğruluğunu zayıflatır ve ağaç tacının sınırlarını belirler. Görüntü işleme sistemlerinde sonuçları tahmin etme yeteneği, görüntü kategorilerinin ve istenen çıktıların önceden tanımlanmasına bağlıdır. Makine öğrenimi algoritmaları, işleme sonuçlarını tahmin edebilen sistemler oluşturma potansiyeline sahiptir. Ağaçları ayırt etmek için makine öğrenimi algoritmalarının ve araçlarının birleşimini içeren bir proje çerçevesi kullanılır.

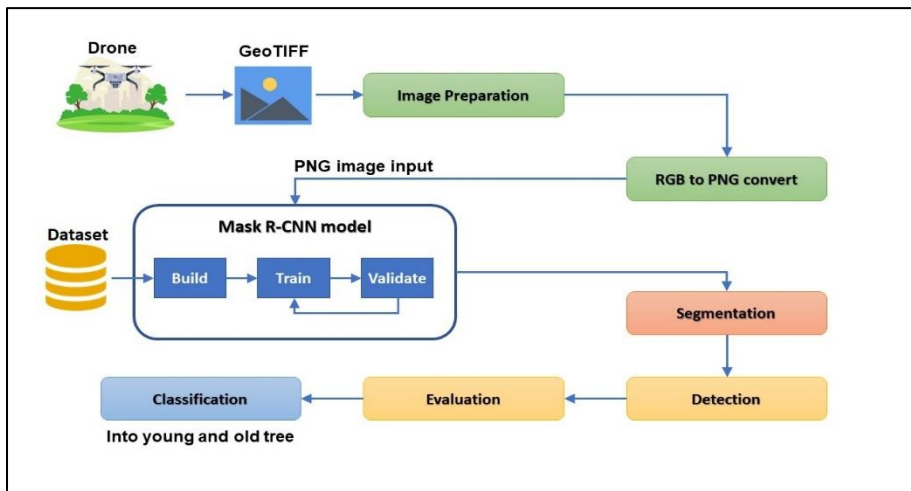
Bu çalışmanın birincil bileşenleri, havadan görüntü verilerinin yorumlanmasını, RGB görüntülerinden ağaç tacı ayırma amacıyla Mask R-CNN'nin kullanımını ve görüntü modellerinin ve ağaç yaşı analizi için betiklerin uygulanması yoluyla ağaç taçlarının tanınmasını kapsar (Zhao ve ark., 2020). Ağaçların doğru sınırlarını elde etmek için en son teknoloji ürünü derin öğrenme tanıma ve segmentasyon tekniklerini içeren gelişmiş makine öğrenimi çerçevelerinin kullanılması için, köklü bir derin öğrenme modeli olan Mask R-CNN, ağaç taçlarını etkili bir şekilde ayırt etmek için kullanıldı.

Önceden var olan bir model kullanılarak, ağaç saçaklarının yeri ve kapsamını belirlemek için insansız bir hava aracı tarafından yakalanan yüksek seviyeli bir RGB görüntüsü kullanıldı.

Ağaçlar, drone görüntülerini besleyerek ve nokta bulutlarını, derin öğrenme evrimsel sinir ağları kullanarak ve yüksek eğitim parametrelerini çeşitli yöntemlerle ayarlayarak birden çok kavramsal katmanı besleyerek tanımlanır, bu da makul bir aralıkta olan parametre seçimleriyle sonuçlanır. Bu da ağaç taçlarını etkili bir şekilde ayırt etmek için kullanıldı. Bu iyileştirme hedefleri, sonuçları iyileştirmek için diğer çalışmalarını harekete geçirdi. Bu çalışma sırasında önerdiğimiz model ile hava fotoğraflarından ağaçların yaşını keşfetmede sonuçların etkinliğini artırmaya çalıştık.

Sistem, arboreal numunelerin insansız hava araçları (İHA'lar) tarafından yakalanan hava görüntülerine dayalı olarak çalışır. Fotoğraflar, hassasiyeti ve üretkenliği artıran en uygun perspektifi belirlemek için farklı yüksekliklerde çekilir (He ve ark., 2020). Önerilen sistemin ilk aşaması, görüntülerin GeoTIFF formatında çıkarılmasını içerir. Görüntülerin sisteme girilmesinin ardından söz konusu görüntülerin işlenmesi ve hazırlanması gerçekleştirilir.

Ön işleme aşaması, görüntü iyileştirme, keskinleştirme, görüntü ölçekleme ve kusur giderme gibi çeşitli teknikleri kapsar. Ardından gelen prosedür, görüntülerin RGB formatından PNG'ye dönüştürülmesini gerektiren Mask R-CNN modeline görüntülerin girilmesini içerir. Önceden eğitilmiş olan Mask R-CNN, belirli görüntü formatlarında çalışacak şekilde tasarlanmıştır (Ujgare ve Baviskar, 2013). Modelimizin yapısını şekil 3.8 'de görebiliriz.



Şekil 3.8. Önerilen modelin yapı yöntemi

Ardından, takip eden adım, ağaçları tasvir eden görüntünün bölümlere ayrılmasını gerektirir, böylece tek tek ağaçlara karşılık gelen farklı bölgelerin tanımlanması sağlanır. Segmentasyon, ağaç tespiti için birincil model sonucu olarak kabul edilir. Modelin bulguları ağaçlı alanları tanımak için kullanılır ve her ağaçlık bölgeye bir yüzde doğruluğu atanır. Tanımlanan bitkileri kategorize etmek için bir sınıflandırma sistemi uygulandı ve onları zamansal kökenlerine göre iki ayrı gruba ayırdı: old ve young. Sınıflandırma sürecinde kullanılan birincil kriterler, ağacın yaşının bir göstergesi olarak hizmet eden çevresi ve hava morfolojisidir (Di Gregorio, 2005).

Önerilen sistemimizi farklı kılan şey, ağaç taçlarını farklı durumlarda ve birden fazla koşulda ayırt edebilme yeteneğidir. Sistemin kullanım durumları arasında yılın farklı mevsimlerine ait görüntüler, çeşitli ağaç türlerinin görüntüleri, ağaçların ve kullanılmayan alanların bulunduğu görüntüler, renk kontrastı ve farklı çekim açıları yer alır. Bahsedilenlerin tümü, sistemimizin üzerinde çalışmanın doğruluğu ile karakterize edildiği durumlardır. Sistemin doğruluğu bir dizi temel deneyle değerlendirilir. Bu deneyimlerin her biri akademik literatürde genellikle bir vaka olarak anılır. Sistemin doğruluğu, her deneme için doğruluk oranı hesaplanarak hesaplanabilir. Ormanın durumunun tanımlanması ve ağaçların sınıflandırılması ve tanımlanması amacıyla sistem aşağıda birçok durumda denenebilir ve uygulanabilir.

4. BULGULAR VE TARTIŞMA

4.1. Ağaç Tacı Algılama Yöntemi

Çalışma Yerel nüfus için gıda korunur, toprak korunur, iklim değişikliği azaltılır, hayvanlara ev diyebilecekleri bir yer verilir ve orman ekosistemleri sayesinde su akışı düzenlenir (FAO, 2010). Biyoçeşitliliğin korunması söz konusu olduğunda, ormanlar kilit bir rol oynamaktadır. Örneğin Amazon yağmur ormanları, dünyadaki karasal türlerin yaklaşık %25'ine ev sahipliği yapar ve dünyadaki toplam karasal fotosentezin %15'ini üretir (Malhi ve ark., 2008). Uydu görüntüleme teknolojisi geliştikçe, uzaktan algılama, ormancılık ve ormansızlaştırılmış alanların izlenmesi gibi alanlarda kullanım alanı bulan daha büyük alanlarda daha kesin veriler toplayabilmektedir (Heumann, 2011). Uzaktan algılama verilerinden derlenen ölçümler, geleneksel saha kampanyalarından daha az parayla geniş bölgeleri kapsayan orman envanterleri oluşturma potansiyeline sahiptir.

Yönetim kararlarının alınması için ağaçların, orman arazilerinin, meşcerelerin ve geniş bölgelerin miktarı ve büyümesi bir envantere tanımlanmalıdır (Hyypä ve ark., 2008). Bir orman envanterini tamamlamak için saha araştırmaları yapmak çok zaman ve para gerektiriyordu. Bu araştırmalar, yerini, türünü, göğüs yüksekliğindeki çapını, yüksekliğini ve taç genişliğini belirlemek için bir arsadaki her bir ağacın ölçülmesini içeriyordu. Hava görüntülerinin orman envanteri ve analizi için kullanılması yirminci yüzyılın ortalarından beri devam etmesine ve bu veri kaynaklarının yeni olanaklar açmasına ve orman verimliliğini artırmasına rağmen envanter, bu tür verilerin görsel yorumu pahalı ve zaman alıcı olmaya devam etmektedir (Alemdag, 1986).

Tek tek ağaçlar tespit edilebilir ve sınırları bir dizi farklı yol kullanılarak tanımlanabilir. İşlenmemiş veya işlenmiş gri ölçekli resimde yerel maksimumları bulmak, ağaç taçlarını tespit etmenin en eski ve en kolay yöntemidir. Belirli bir kısıtlama setinin ardından, bu maksimum değerler, ağaç tepelerini alan olarak belirlemek için de kullanılabilir. Görüntülenen her ağaç tacı, yerel maksima yaklaşımlarının ilkelerine göre tek bir "en parlak noktaya" sahiptir ve taçlar arasındaki boşlukların, taçların doğrudan güneş tarafından aydınlatılan bölgelerinden daha koyu olduğu varsayılır (Weinstein ve ark., 2020). Gölge piksellerin bir görüntüdeki ağaç taçlarını çizen sınırlar oluşturmak için bir dizi kritere göre birbirine zincirlendiği 'vadi izleme' tekniği de benzer şekilde taçlar arasında gölgeleme varsayımına dayanır.

Uydu görüntülerinde ağaçları tanımlamak için kullanılacak birtakım teknikler de vardır. Şablon, daha sonra görüntüdeki ağaçlarla aynı şekilde görülen ve aydınlatılan

bir 3B ağaç taç modeli yansıtılarak yapılır. Ağaç tepelerinin çıkarılması da çeşitli olasılıksal yaklaşımlardan yararlanmıştır. MPP'de, bir orman meşceresinin bir dizi elips olarak modellenebileceği de gösterilmiştir (Perrin ve ark., 2006). Bu stokastik yaklaşımların her ikisi kullanılarak bir optimizasyon sorunu oluşturulur ve optimum çözümleri bulmak için simüle edilmiş bir tavlama ayarı içinde klasik bir optimizasyon tekniği uygulanır.

Ağaç türleri daha iyi sınıflandırılabilir, büyüme zaman içinde ölçülebilir ve taç boyutu, kapanma, gölgelik yapısı, yükseklik ve biyokütle tahminlerinin tümü, kesin olarak ana hatları çizilen ağaç taçlarının yardımıyla yapılabilir, bu da onları hassas ormancılığın çok önemli bir parçası haline getirir. . Ağaç tanımlama ve tanımlama yaklaşımları, araştırmacılar tarafından çok çeşitli amaçlar için kullanılmış ve bunları tanımlamak için çok sayıda jargon türetilmiştir (Wäldchen ve ark., 2018). Ağaçları taçlarına göre tanıma sorunuyla başa çıkmak için geliştirilmiş birçok başka yaklaşım vardır ve bu yöntemlerden bazıları zaten ele alınmıştır. Sağladığımız yaklaşımda, mümkün olan en yüksek düzeyde doğruluk sağlayan algoritmalar kullanarak çok etkili bir model oluşturuyoruz. Girdi fotoğraflarındaki ağaçların algılama modeli, veri kaynağı olarak gerçek fotoğraflar kullanılarak oluşturulur ve eğitilir. Koleksiyondaki fotoğraflar, kendi sinir ağıımızı eğitmek için kullanılıyor. Sistemi test etmek için başka fotoğraflar eklenmiştir. Test örneklerinin sayısı altıydı ve her biri için farklı özelliklere sahip resimler seçildi. Sonraki paragraflarda, gerçekleştirilen sonuçlar ve değerlendirmeler sunulacaktır. Sunduğumuz model hem karar verenler hem de ormanları izleyenler için yararlı bir araç olabilir. Ağaçların keşfinden sonra, mevcut durumlarıyla ilgili raporlar sunabilirsiniz ve yeni ortaya çıkarılan ağaçlar iki kategoriye ayrılır: genç ağaçlar ve yaşlı ağaçlar.

4.2. Görüntü Segmentasyonu

Hava fotoğrafı analizi, örüntü tanıma ve ağaç tanıma, görüntü bölümlenme ile başlar. Görüntü işlemedeki en zorlu görevlerden biridir, ancak nihai çıktının kalitesini belirlediği için görüntü analizi ve örüntü tanıma sistemi için hayati önem taşır. Bir resmi bölümlere ayırmak, onu her biri kendi başına homojen olan ancak birleşik değerleri olmayan daha küçük, daha yönetilebilir parçalara ayırmayı içerir (Minaee ve ark., 2021). Farklı resim bölümlenme yöntemleri, bir alandaki gri tonlama değerlerinin tutarlılığına veya değişkenliğine odaklanır. Süreksizlik yöntemi genellikle, gri tonlamadaki ani kaymalara dayalı olarak farklı noktaları, çizgileri ve kenarları belirleyerek bir resmi bölümlere ayırır.

Eşikleme, kümeleme, bölge genişletme ve bölge konsolidasyonu gibi yöntemlerin tümü homojenliğe dayalı yöntemlere örnektir. Görüntü işlemede kullanılan bir diğer

popüler renk alanı, insan görsel sistemi için daha doğal olan HSI (ton-doygunluk-yoğunluk) şemasıdır (Shabdin, 2016). Ton-doygunluk-yoğunluğu (HSI) renk uzayının farklı yinelemeleri, ton-doygunluk-parlaklık (HSB), ton-doygunluk-açıklık (HSL) ve ton-doygunluk-değeri (HSV) renk uzayı gösterimlerini içerir. HSI sistemi, bir görüntünün renk ve yoğunluk verilerini çözer.

Renk bilgisini ifade etmek için ton ve doymuluk değerleri kullanılırken, ışık miktarı bir görüntünün yoğunluğunu tanımlamak için kullanılır. Ton, en temel renk özelliğidir ve ışığın spektrum dalga boylarının dağılımına dayanır (Lim ve ark., 2015). BT' spektral dağılım eğrisinin zirve yaptığı noktadır. Doymuluk değeri, rengi oluşturmak için ne kadar saf beyaz ışığın kullanıldığını gösterir. Zirvenin spektrumun geri kalanından ne kadar yüksek olduğunu ölçer.

Örüntü tanıma, sinir ağlarının en yaygın kullanımlarından biridir. Sınıflandırma ve kümeleme, doğrusal olmayan özelliklerinden ve gelişmiş paralel işleme kapasitesinden yararlanır. Bir dizi talimatı sırayla çalıştırmak yerine, paralel işleme birbirine bağlı ağlar aracılığıyla birkaç rakip fikri aynı anda keşfetmenize olanak tanır. Bir sinir ağına, birkaç hesaplama düğümü, değişen ağırlıklardaki bağlantılarla birbirine bağlanır. Sonuç olarak, tüm ağ çok karmaşık bir karşılıklı bağımlılık koleksiyonunu yansıttığından, oldukça genel bir işlevin modellenmesi mümkündür. Uzun eğitim süresine rağmen, ilk kurulum tamamlandıktan sonra ağ tabanlı sınıflandırma genellikle oldukça hızlıdır. Yaklaşımımız, kullandığımız fotoğraflardaki kafaları belirlemek için bir sinir ağının segmentasyon sonuçlarına dayanıyor.

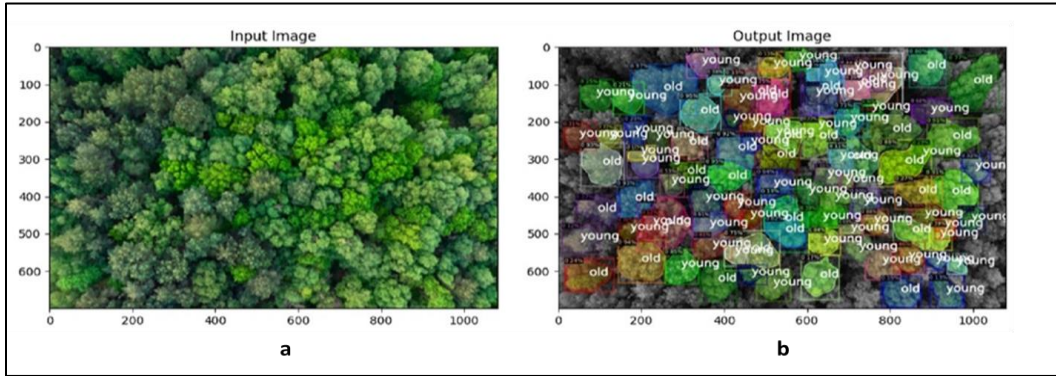
4.3. Deney Durumları

Drone görüntülerini kullanarak sistemimizi test edeceğiz. Görüntüler ormanlık alanlarda çekilmiştir ve ağaç tacı tespiti ve sınıflandırmasını test etmek için iyidir. Deneylerde kullanılan görüntüler kendi topladığımız veriler yanında, diğer çalışmalardanda getirilen görüntülerden alınmıştır (Lundgren, 2015; Braga ve ark., 2020; Sun ve ark., 2022;).

Sistemi test etmek için farklı özelliklere sahip bir dizi görüntü seçiyoruz. Test görselleri veri setimizdeki görselleri ve diğer kaynaklardan görselleri içerir. Genel olarak yılın farklı mevsimlerinde ağaçların fotoğrafları çekilmiş olup, modelin ağaçları keşfetme ve sınıflandırma konusundaki gücünü göstermek amacıyla boş alanlı resimlerin yanı sıra farklı çekim açılarına sahip resimler de yer almıştır.

4.3.1. Birinci görüntü

Bu örnekte, Şekil 4.1'de gösterilen resim kullanılır. (a) görüntüsü giriş görüntüsünü temsil ederken (b) bu durum için çıktıyı temsil eder. Eğitim prosedürlerinin başarıyla tamamlanmasının ardından, bu görüntü önerdiğimiz modele yüklenir ve okunur. Bu fotoğraf yılın bu mevsiminde ağaçların yeşil rengini güzel bir şekilde gösteren bir renk seviyesiyle çekilmiştir.

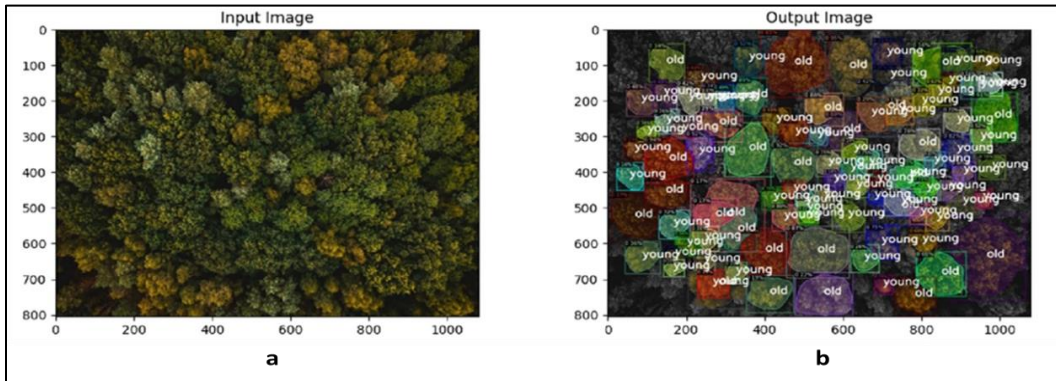


Şekil 4.1. Gör-1 girdi görüntüsü (a) ve çıktı (b)

Model bu resim içerisinde toplam 86 ağaç tanımlamıştır. Birincil resim bölümlere ayrılır ve daha sonra resimlerin her biri tanınabilir. Ağaçların 28 yaşlı ve 58 genç ağaç olarak sınıflandırılması nedeniyle ağaçlar 28 ve 58 ağaca ayrılmıştır. Tanınmayan ağaç sayısı bu görüntüde 4 ağaçtır.

4.3.2. İkinci görüntü

Şekil 4.2 bu durum için görsel temsiller sağlar. Resim (a), görevden çekilen birincil drone görüntüsüdür. Resim (b), resimlerin yapımında önerdiğimiz model kullanıldığında ne olduğudur. Görüntü, ilk testteki görüntüden tamamen farklı bir renk seviyesinde çekilmiştir. Burada yeşil renk ağaçlarda ve yılın farklı mevsimlerinde daha koyu bir şekilde alınmıştır.

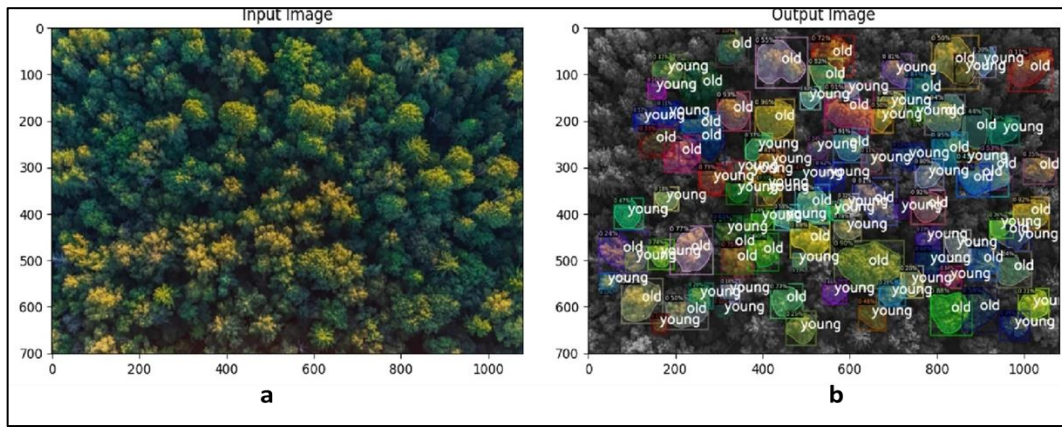


Şekil 4.2. Gör-2 girdi görüntüsü (a) ve çıktı (b)

Bu görüntüde toplam 95 ağaç türü tespit edilmiştir. Ana resim bölündükten sonra içindeki resimler tanımlanabilir. Hem büyük hem de küçük ağaçlar olduğu için iki gruba ayrıldı: old (29) ve young (66) ağaçlar. Tanınmayan ağaçlar dört tanedir.

4.3.3. Üçüncü görüntü

Bu durum, bu sayfanın ilerleyen kısımlarında bulunabilecek olan Şekil 4-3'te gösterilmektedir. Bir drone tarafından çekilen ana görüntü, görüntüde gösterilmektedir. (a). Görüntü (b), önerdiğimiz modelin görüntü oluşturma sürecinde uygulanmasının sonucudur. Bu testteki görüntü, birinci ve ikinci duruma göre yeşil ve sarının farklı bir renk tonunu içeriyor.

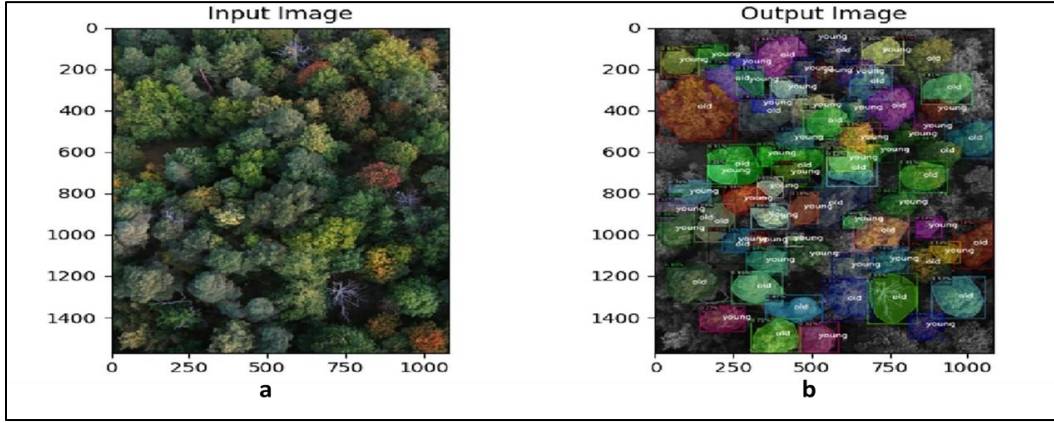


Şekil 4.3. Gör-3 girdi görüntüsü (a) ve çıktısı (b)

Bu resimde algoritma tarafından tanımlanan toplam 93 bitki var. Birincil görüntünün bölümlere ayrılması, resimleri bulmak için kullanılır. Ağaçlar yaşlı ve genç olmak üzere iki gruba ayrıldı çünkü orada hem büyük hem de küçük ağaçlar var: 43 old ağaç ve 50 young ağaç. Tespit edilmeyen ağaçlar sayısı eşitler yeddiye.

4.3.4. Dördüncü görüntü

Bu test Şekil 4.4'te gösterilmektedir. Ana görüntü (a) kısmında gösterilmektedir. Modelin çıktısı resim (b)'dedir. Bu testteki görüntü sadece yeşilin tonlarını içermiyor, aynı zamanda birçok rengi de içeriyor. Farklı görüntülerdeki ağaçların tanınması, sistemin birçok görüntü durumuna uygulanabilir olmasını sağlar.

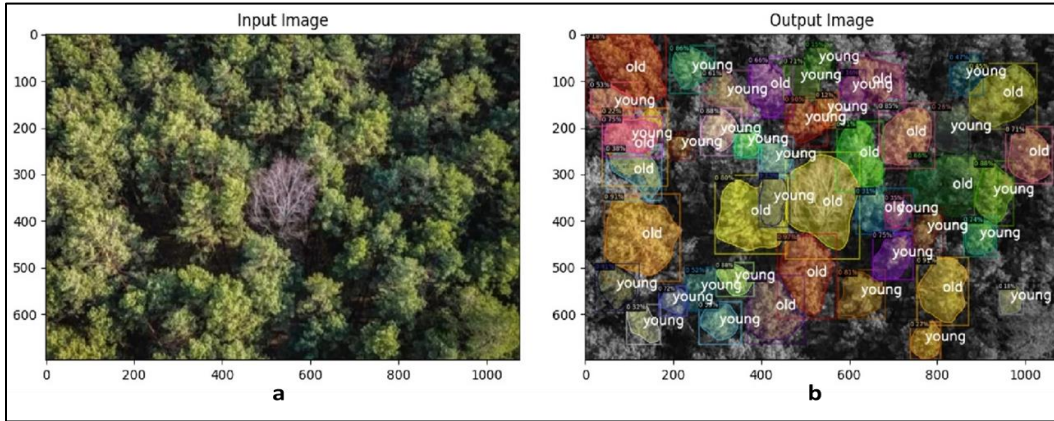


Şekil 4.4. Gör-4 girdi görüntüsü (a) ve çıktısı (b)

Bu testte yaşlı çeşitte 30, genç çeşitte ise 41 ağaç tespit edilmiştir. Toplam tanınan ağaç sayısı 71 olup sistem bu görüntüde 5 ağacı tanımamıştır.

4.3.5. Beşinci görüntü

Şekil 4.5 bu durumda test için kullanılan görüntüyü içerir. Bu görselin seçilmesinin nedeni, diğer ağaçlar arasında sistemin yaşlı ağaç olarak tanıdığı çok yaşlı bir ağacı içermesidir. Şekil hem giriş görüntüsünü hem de tanınan ağaçları içeren görüntüyü içerir.




Şekil 4.5. Gör-5 girdi görüntüsü (a) ve çıktısı (b)

Yapılan bu testte modelimiz 17 old ve 29 young, toplam 46 ağaç tespit etmektedir. Girdi görüntüsünün tüm ağaçları tespit olmuştur sadece 2 ağaç tespit olamadı.

4.3.6. Altıncı görüntü

Şekil 4.6 test için kullanılan görüntüyü içermektedir ve önceki tüm durumlardan farklıdır. Önceki testlerin tümü ağaçlara dik bir açıyla çekilen resimler içindi. Bu durumda fotoğraf dikey olarak değil açılı olarak çekilmiştir.

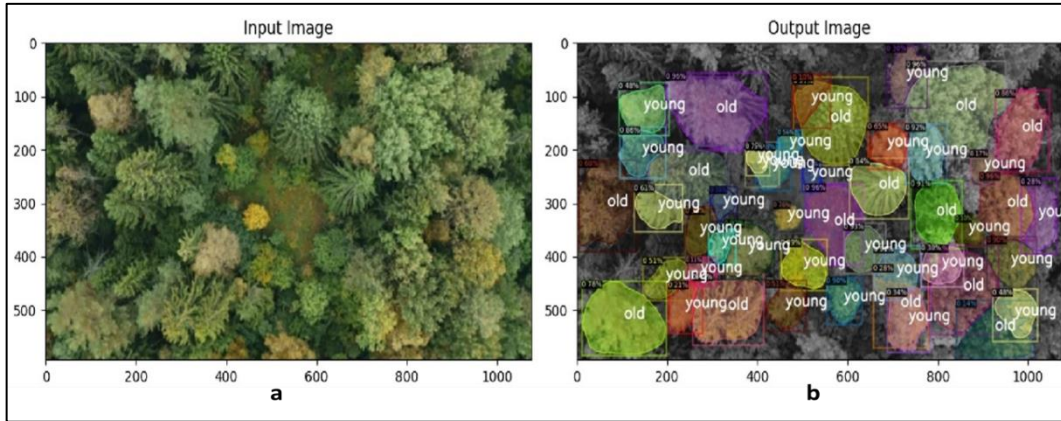


Şekil 4.6. Gör-6 girdi görüntüsü (a) ve çıktısı (b)

Bu testte 44 ağaç tespit edilmiştir. İki sınıfa ayrılınca 17 old ve 27 young ağaç elde edilmiştir. Tespit olmayan ağaçların sayısı ikidir.

4.3.7. Yedinci görüntü

Şekil 4.7'de bu durumdaki testin görüntüsü bulunmaktadır. Görüntünün tek çeşit ağaçlar değil, farklı türde ağaçların bulunduğu bir ormanda çekilmiş olması seçilme sebebidir. Sisteme giriş görüntüsü ve çıkış görüntüsü görüntülenebilir.

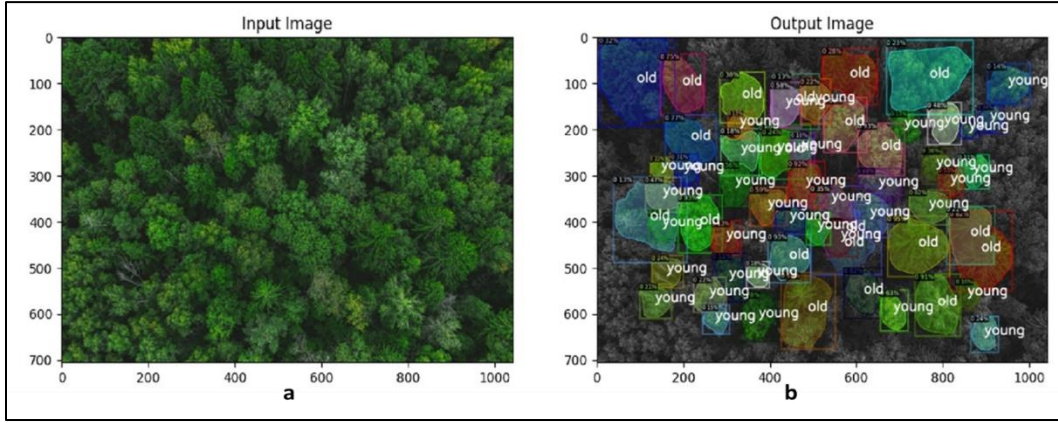


Şekil 4.7. Gör-7 girdi görüntüsü (a) ve çıktısı (b)

Bu görüntüde tüm ağaç taçları tespit edilmiştir sadece bir ağaç tanıtılmadı. Toplam 44 ağaç sınıflandığında, 14 old ve 30 young diye sayıldı.

4.3.8. Sekizinci görüntü

Bu testte, Şekil 4.8'de gösterildiği gibi, önceki durumlara göre daha fazla iç içe geçmiş ağaçların resmi seçilir. Görüntünün tüm ağaçlar için tek tip bir renk tonuna sahip olduğunu söyleyebiliriz ki bu da bahar yeşili rengidir.

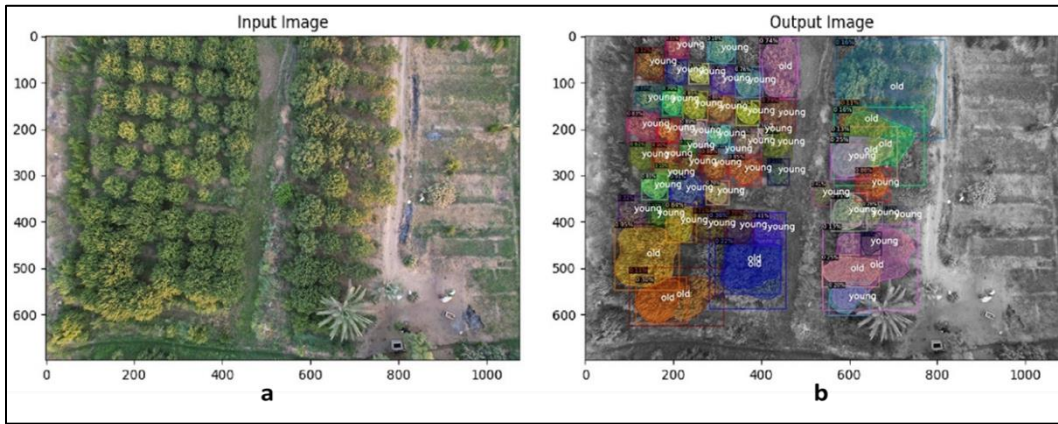


Şekil 4.8. Gör-8 girdi görüntüsü (a) ve çıktısı (b)

Bu durumda sistem de iyi çalışıyor. Sistemin tanımadığı 4 ağaçtan bağımsız olarak 58 ağacın taçları tespit edildi. Ağaçlar 19 old ve 39 young olarak sınıflandırıldı.

4.3.9. Dokuzuncu Görüntü

Test görüntüsü Şekil 4.9'daki gibi tarafımızdan toplanan verilerden seçilmiştir. Bu fotoğraf Bağdat'ta bir çiftlikte çekildi. Bu görüntü özellikle ekili alanları ve yürüyüş yolunu ve bitişikteki kullanılmayan arazileri içeren diğer alanları içerdiği için seçilmiştir.

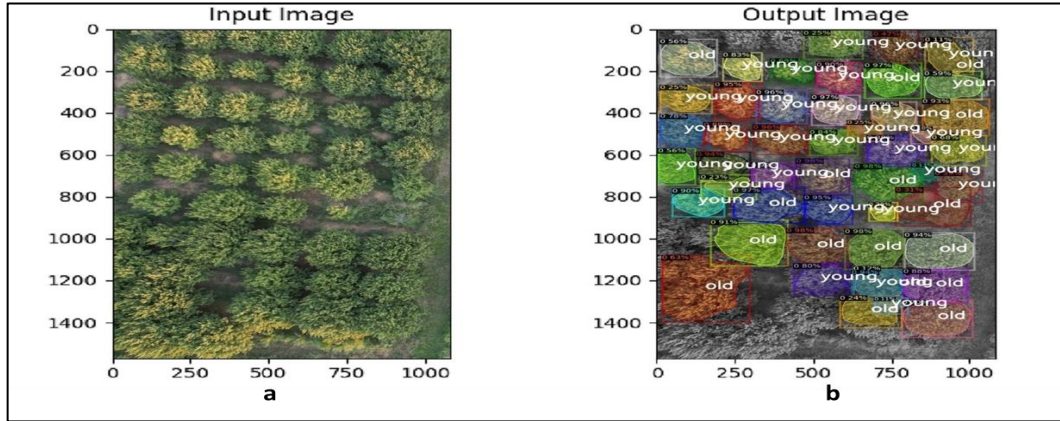


Şekil 4.9. Gör-9 girdi görüntüsü (a) ve çıktısı (b)

Bu görüntüde mükemmel tanıma ve sınıflandırma sonuçları elde edildi. Sonuçlar sistemin benzer görüntüleri tanıma konusundaki doğruluğunu ve uyumluluğunu göstermektedir. 58 ağaç tespit edildi, 5 tanesi ise tespit edilemedi. Sistem tarafından tanınan ağaçlar 12 old ve 46 young olarak sınıflandırıldı.

4.3.10. Onuncu Görüntü

Son testin resmi Şekil 4.10'da görülebilir. Bu görsel aynı zamanda veri setimizde topladığımız görsellerdendir. Bu çiftlikteki ağaçlar düzenli bir şekilde dikildi. Sonuçlar ağaç taçlarının iyi tanındığını ve sınıflandırmanın doğruluğunu gösterdi.



Şekil 4.10. Gör-10 girdi görüntüsü (a) ve çıktısı (b)

Sonuçlar 16 old ve 30 young ağaç tespiti gösterdi. Tespit edilen 46 ağaç yanında sadece 4 ağaç tespit edilmemiştir. Testleri özetleyebilir ve her durumda yakalanan ağaçların istatistiğini aşağıdaki tablo (Tablo 4.1) 'de listeye biliriz.

Tablo 4.1. Tüm test sonuçlarının istatistiği

| Test No | Toplam Algılama Sayısı | Yaşlı Ağaçlar | Genç Ağaçlar | Algılanmayan Ağaçlar |
|---------|------------------------|---------------|--------------|----------------------|
| Gör. 1 | 86 | 28 | 58 | 5 |
| Gör.2 | 95 | 29 | 66 | 4 |
| Gör.3 | 93 | 43 | 50 | 7 |
| Gör. 4 | 71 | 30 | 41 | 5 |
| Gör. 5 | 46 | 17 | 29 | 2 |
| Gör. 6 | 44 | 17 | 27 | 2 |
| Gör. 7 | 44 | 14 | 30 | 1 |
| Gör. 8 | 58 | 19 | 39 | 4 |
| Gör. 9 | 58 | 12 | 46 | 5 |
| Gör. 10 | 46 | 16 | 30 | 4 |

Tanımlama sürecindeki doğruluk, resimlerdeki ağaçların yerini belirleme sürecindeki her adımın bir bileşenidir. Bu yüzdeler karşılaştırma için temel alınarak sistemin doğruluk sayıları belirlenebilir. Bu sayının nispeten yüze yakın olması sistemin güvenilir olduğunu gösterir.

4.4. Model Değerlendirmesi

Ağaç algılama adımı sırasında algoritmanın ölçüm hassasiyeti, model değerlerine dayalı olarak %94'luk bir en iyi durum senaryosu doğruluğu elde etmemizi sağlar. Tablo 4-2'de, tüm farklı deneyin her biri için algoritmanın ne kadar doğru olduğuna bir göz atıyoruz. Doğruluk, geleneksel ve diğerleri de dahil olmak üzere birden fazla yolla bilinebilir. Sistemin ağaçları tanımadaki doğruluğunun, görüntüdeki ağaçlar ile tanınan ağaçlar arasındaki oranın bilinmesinden kaynaklandığı söylenebilir.

Tablo 4.2. Model Doğruluğu

| Test no | Doğruluk oranı | Yanlışlık oranı |
|---------------------------|----------------|-----------------|
| Gör. 1 | 0,9450 | 0.0550 |
| Gör.2 | 0.9595 | 0.0405 |
| Gör.3 | 0.9300 | 0.0700 |
| Gör. 4 | 0.9342 | 0.0658 |
| Gör.5 | 0.9583 | 0.0417 |
| Gör.6 | 0.9565 | 0.0435 |
| Gör. 7 | 0.9777 | 0.0223 |
| Gör.8 | 0.9354 | 0.0646 |
| Gör.9 | 0.9206 | 0.0794 |
| Gör.10 | 0.9200 | 0.0800 |
| Toplam ve ortalama | 0.9437 | 0.0563 |

Doğruluk için hem gerçek ağaçların sayısını hem de tanımlanan ağaçların sayısını test etmek çok önemlidir. Belirli bir alanda ağaçların bulunma olasılığı yüzde olarak ölçülür. Gereksinimlerin karşılanma derecesi, küçük veya büyük ağaçların sınıflandırılmasını ayırt eder. Önerilen teknik, test senaryolarına dayalı olarak %94,37'ye eşit bir doğruluk oranıyla kanıtlanmış bir başarı geçmişine sahiptir.

5. SONUÇ VE ÖNERİLER

Önerimiz, akıllı ağaç site görüntü işleme sistemlerinden biri olarak kategorize edilebilir. Ormanların yönetimine ve ağaçların bakımına yardımcı olacak bir araç sağlamanın önemi gizli değildir. Çevre unsurlarını korumak ve bunların durumlarını açıklayan ve bunlar hakkında rapor veren sistemlerin sağlanmasına yardımcı olmak, birçok durumda karar vericilere yardımcı olur. Çalışmanın odağında drone'ların orman ve ağaçların taçlarını tespit ederek yukarıdan çektiği görüntüler yer alıyor.

Bu projenin birincil amacı, bireysel ağaç tepelerini türlere göre sınıflandırmak için algoritmalar geliştirmektir. Bunu başarmak için, bireysel ağaç başları seçilmeli veya ayrılmalıdır. Bölütleme aşamasının amacı, ağaç taçlarını, şekli orijinal görüntüdeki tacinine karşılık gelen parçalara bölmektir. Sınıflandırma aşamasında ağaç taçlarının morfolojisi kullanılır. Görüntü işleme ve makine öğrenimi tekniklerini kullanarak, orman korumanın bir parçası olarak yukarıdan alınan görüntüleri inceleyip analiz ederek ağaçları yaşa göre algılamak ve sınıflandırmak için yeni bir mekanizma geliştirmeyi öneriyoruz.

Gerçek ormanlarda dronlar tarafından yakalanan görüntüler, sistemi yapılandırmak için kullanılır. Bağdat'ın farklı bölgelerinden toplanan bir dizi veri üzerinde çalışma yapıldı. İdeal bir model elde etmek için özellikle hazırlık ve test aşamalarında bazı görüntüler modele dahil edildi. Ulaşılan amaç, ağaçların türlerini ve yoğunluklarını belirlemek, en uygun tanımlama ve analizi sağlamak için toplanan verileri kullanan ve böylece bir tehdit durumunda korunmalarını kolaylaştıran kullanışlı bir aracın oluşturulmasıdır. Deneyler, sistemin istisnai bir hassasiyetle çalıştığını gösteriyor. İncelenen vakalar için doğruluk oranı %94,37 idi.

Önerilen sistemimiz gelecekteki ihtiyaçlara ayak uydurabilmek için takip ve geliştirme gerektiren akıllı sistemler gibidir. Modelin tercih edilmesini sağlamak için yaprak tanımayı içeren başka bir sınıflandırma mekanizması daha sonra dahil edilebilir. GAN teknolojileri, sistemin doğruluğunu ve verimliliğini artırmaya yardımcı olan veri kümesi görüntülerini genişletmek için kullanılabilir. Kullanım sırasında ihtiyaç duyulan özelliklerle resimler artırılabilir.

6. KAYNAKLAR

- Agarap, A.F. (2018). *Deep learning using rectified linear units (ReLU)*. <https://arxiv.org/pdf/1803.08375.pdf>, Erişim Tarihi: 01.11.2023
- Albawi, S., Mohammed, T.A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. *In 2017 international conference on engineering and technology*, 1-6.
- Alemdag, I. S. (1986). Estimating oven-dry mass of trembling aspen and white birch using measurements from aerial photographs. *Canadian Journal of Forest Research*, 16(1), 163-165.
- Anonim. (2019). *Derin Öğrenme Nedir? Bilmeniz Gereken Üç Şey*. <https://www.edge-ai-vision.com/2019/05/what-is-deep-learning-three-things-you-need-to-know/>, Erişim Tarihi: 01.11.2023
- Anonim. (2022). *Save the Plankton, Breathe Freely*. <https://www.nationalgeographic.org/activity/save-the-plankton-breathe-freely/>, Erişim Tarihi: 01.11.2023
- Anonim. (2023). *FSC-COC orman yönetim sisteminin faydaları nelerdir?* <https://www.sciencetr.com/ar/belgelendirme/sistem-belgelendirme/fsc-coc-orman-yonetim-sistemi/fsc-coc-orman-yonetim-sistemi-faydalari-nelerdir>, Erişim Tarihi: 01.11.2023
- Anonim, (2023b). *Getting Started with R-CNN, Fast R-CNN, and Faster R-CNN*. <https://www.mathworks.com/help/vision/ug/getting-started-with-r-cnn-fast-r-cnn-and-faster-r-cnn.html>, Erişim Tarihi: 01.11.2023
- Aubry-Kientz, M., Dutrieux, R., Ferraz, A., Saatchi, S., Hamraz, H., Williams, J., & Vincent, G. (2019). A comparative assessment of the performance of individual tree crowns delineation algorithms from ALS data in tropical forests. *Remote Sensing*, 11(9), 1086.
- Bharati, P., & Pramanik, A. (2020). Deep learning techniques R-CNN to mask R-CNN: a survey. *Computational Intelligence in Pattern Recognition: Proceedings of CIPR*, 657-668.
- Chang, A., Eo, Y., Kim, Y., & Kim, Y. (2013). Identification of individual tree crowns from LiDAR data using a circle fitting algorithm with local maxima and minima filtering. *Remote sensing letters*, 4(1), 29-37.

- Chang, K. T. (2006). *Introduction to geographic information systems*. Boston: McGraw-Hill Higher Education.117-122 .
- Chen, R. C., Dewi, C., Huang, S. W., & Caraka, R. E. (2020). Selecting critical features for data classification based on machine learning methods. *Journal of Big Data*, 7(1), 52-56.
- Di Gregorio, A. (2005). *Land cover classification system: classification concepts and user manual*. 2. Edt. Food & Agriculture Org.
- Erikson, M., & Olofsson, K. (2005). Comparison of three individual tree crown detection methods. *Machine Vision and Applications*, 16(4), 258-265.
- FAO. (2010). *Global Forest Resources Assessment 2010-Brazil Country Report*; Technical Report; Food and Agriculture Organization of the United Nations: Rome, Italy.
- G. Braga, J.R., Peripato, V., Dalagnol, R.P., Ferreira, M., Tarabalka, Y., Aragão, L.E. & Wagner, F.H. (2020). Tree crown delineation algorithm based on a convolutional neural network. *Remote Sensing*, 12(8), 1288.
- Han, Q., Yin, Q., Zheng, X., & Chen, Z. (2021). Remote sensing image building detection method based on Mask R-CNN. *Complex & Intelligent Systems*, 1-9.
- Hassan, S., Berke, L., Vahdani, E., Jing, L., Tian, Y., & Huenerfauth, M. (2020). An isolated-signing RGBD dataset of 100 American Sign Language signs produced by fluent ASL signers. *Technological Challenges and Application Perspectives*; 89-94.
- He, G., Yang, H., Pan, R., Sun, Y., Zheng, P., Wang, J., & Guo, S. (2020). Using unmanned aerial vehicles with thermal-image acquisition cameras for animal surveys: a case study on the Sichuan snub-nosed monkey in the Qinling Mountains. *Integrative zoology*, 15(1), 79-86.
- Heumann, B. W. (2011). Satellite remote sensing of mangrove forests: Recent advances and future opportunities. *Progress in Physical Geography*, 35(1), 87-108.
- Hirschmugl, M., Ofner, M., Raggam, J., & Schardt, M. (2007). Single tree detection in very high resolution remote sensing data. *Remote Sensing of Environment*, 110(4), 533-544.
- Ho, B., Kocer, B. B., & Kovac, M. (2022). Vision based crown loss estimation for individual trees with remote aerial robots. *ISPRS Journal of Photogrammetry and Remote Sensing*, 188, 75-88.

- Hyypä, J., Hyypä, H., Leckie, D., Gougeon, F., Yu, X., & Maltamo, M. (2008). Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. *International Journal of Remote Sensing*, 29(5), 1339-1366.
- Jain, A. K. (1981). Image data compression: A review. *Proceedings of the IEEE*, 69(3), 349-389.
- Ke, Y., & Quackenbush, L. J. (2011). A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *International Journal of Remote Sensing*, 32(17), 4725-4747.
- Larsen, M., Eriksson, M., Descombes, X., Perrin, G., Brandtberg, T., & Gougeon, F. A. (2011). Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions. *International Journal of Remote Sensing*, 32(20), 5827-5852.
- Learning, D. (2020). *Deep learning. High-dimensional fuzzy clustering*. https://www.icpme.us/courses/CIBC_PDF/4.1%20CAD_Radiomics_and%20AI%20in%20Brazil%20Imaging_Giger.pdf, Erişim Tarihi: 01.11.2023
- Leith, H. M., & Piper, J. W. (2013). Identification and application of security measures for petrochemical industrial control systems. *Journal of Loss Prevention in the Process Industries*, 26(6), 982-993.
- Lim, Y. S., La, P. H., Park, J. S., Lee, M. H., Pyeon, M. W., & Kim, J. I. (2015). Calculation of tree height and canopy crown from drone images using segmentation. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 33(6), 605-613.
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., & Zitnick, C. L. (2014). Microsoft coco: Common objects in context. *In Computer Vision—ECCV, 13th European Conference*, 13, 740-755.
- Lindberg, E., & Holmgren, J. (2017). Individual tree crown methods for 3D data from remote sensing. *Current forestry reports*, 3(1), 19-31.
- Lundgren, B. (2015). *Forests and trees: Their roles and opportunities in Africa's economic development, food security and environmental health*. In Nairobi, Kenya, African Forest Forum.
- Mahammad, S. S., & Ramakrishnan, R. (2003). GeoTIFF-A standard image file format for GIS applications. *Map India*, 28-31.

- Malhi, Y., Roberts, J. T., Betts, R. A., Killeen, T. J., Li, W., & Nobre, C. A. (2008). Climate change, deforestation, and the fate of the Amazon. *Science*, 319(5860), 169-172.
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D. (2021). Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 44(7), 3523-3542.
- Perrin, G., Descombes, X., & Zerubia, J. (2006). *A non-Bayesian model for tree crown extraction using marked point processes*. <https://inria.hal.science/inria-00070180/document>, Erişim Tarihi: 01.11.2023
- Pradeep, M. (2017) *Data Science Simplified Part 10: An Introduction to Classification Models*, <https://www.datasciencecentral.com/data-science-simplified-part-10-an-introducti-on-to-classification/>, Erişim Tarihi: 01.11.2023
- Pratama, B. M., Gunawan, D., & Gultom, R. A. G. (2020). Deep learning-based object detection and geographic coordinate estimation system for GeoTiff imagery. *In Journal of Physics: Conference Series*, 1577(1)120-123).
- Qi, C. R., Su, H., Mo, K., & Guibas, L. J. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 652-660.
- 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.
- Rivas, A., Chamoso, P., González-Briones, A., & Corchado, J. M. (2018). Detection of cattle using drones and convolutional neural networks. *Sensors*, 18(7), 2048.
- Safonova, A., Tabik, S., Alcaraz-Segura, D., Rubtsov, A., Maglinets, Y., & Herrera, F. (2019). Detection of fir trees (*Abies sibirica*) damaged by the bark beetle in unmanned aerial vehicle images with deep learning. *Remote sensing*, 11(6), 643.
- Shabdin, M. K., Shariff, A. R. M., Johari, M. N. A., Saat, N. K., & Abbas, Z. (2016). A study on the oil palm fresh fruit bunch (FFB) ripeness detection by using Hue, Saturation and Intensity (HSI) approach. *In IOP conference series: earth and environmental science* 37(1), 1-10.
- Shakya, S. (2020). Analysis of artificial intelligence based image classification techniques. *Journal of Innovative Image Processing (JIIP)*, 2(1), 44-54.

- Sun, C., Huang, C., Zhang, H., Chen, B., An, F., Wang, L., & Yun, T. (2022). Individual tree crown segmentation and crown width extraction from a heightmap derived from aerial laser scanning data using a deep learning framework. *Frontiers in plant science*, 13.
- Tang, L., & Shao, G. (2015). Drone remote sensing for forestry research and practices. *Journal of Forestry Research*, 26, 791-797.
- Ujgare, N. S., & Baviskar, S. P. (2013). Conversion of DICOM Image in to JPEG, BMP and PNG Image Format. *International Journal of Computer Applications*, 62(11).
- Varghese, A., Gubbi, J., Sharma, H., & Balamuralidhar, P. (2017, May). Power infrastructure monitoring and damage detection using drone captured images. In *2017 international joint conference on neural networks (IJCNN)*, 1681-1687.
- Wäldchen, J., Rzanny, M., Seeland, M., & Mäder, P. (2018). Automated plant species identification-Trends and future directions. *PLoS computational biology*, 14(4).
- Wang, L., Gong, P., & Biging, G. S. (2004). Individual tree-crown delineation and treetop detection in high-spatial-resolution aerial imagery. *Photogrammetric Engineering & Remote Sensing*, 70(3), 351-357.
- Weinstein, B. G., Marconi, S., Bohlman, S. A., Zare, A., & White, E. P. (2020). Cross-site learning in deep learning RGB tree crown detection. *Ecological Informatics*, 56.
- Weinstein, B. G., Marconi, S., Bohlman, S. A., Zare, A., Singh, A., Graves, S. J., & White, E. P. (2021). A remote sensing derived data set of 100 million individual tree crowns for the National Ecological Observatory Network. *Elife*, 10.
- Weinstein, B. G., Marconi, S., Bohlman, S., Zare, A., & White, E. (2019). Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. *Remote Sensing*, 11(11), 1309.
- Wu, J., Yang, G., Yang, H., Zhu, Y., Li, Z., Lei, L., & Zhao, C. (2020). Extracting apple tree crown information from remote imagery using deep learning. *Computers and Electronics in zAgriculture*, 174.
- WWF, (2019). *Forest Habitat*. www.worldwildlife.org, Erişim Tarihi: 01.11.2023
- Xu, X., Zhou, Z., Tang, Y., & Qu, Y. (2021). Individual tree crown detection from high spatial resolution imagery using a revised local maximum filtering. *Remote Sensing of Environment*, 258.
- Yang, M., Mou, Y., Liu, S., Meng, Y., Liu, Z., Li, P. & Peng, C. (2022). Detecting and mapping tree crowns based on convolutional neural network and Google Earth

- images. *International Journal of Applied Earth Observation and Geoinformation*, 108.
- Yang, Z., Dong, R., Xu, H., & Gu, J. (2020). Instance segmentation method based on improved mask R-CNN for the stacked electronic components. *Electronics*, 9(6), 886.
- Zhao, Y., Po, L. M., Yan, Q., Liu, W., & Lin, T. (2020). Hierarchical regression network for spectral reconstruction from RGB images. *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 422-423.
- Zhen, Z., Quackenbush, L. J., & Zhang, L. (2016). Trends in automatic individual tree crown detection and delineation-Evolution of LiDAR data. *Remote Sensing*, 8(4), 333.

ÖZGEÇMİŞ

| KİŞİSEL BİLGİLER | |
|-------------------------|---------------------------------|
| Adı Soyadı: | Mohammed Issa Mohammed Alhayani |
| Uyruğu: | Irak |
| Orcid Numarası: | 0000-0001-7908-3061 |

| EGİTİM BİLGİLERİ | |
|-------------------------|----------------------------------|
| Lisans | |
| Üniversite: | Al Mamoon University |
| Bölüm: | Bilgisayar |
| Anabilim Dalı: | - |
| Mezuniyet Yılı: | 2015 |
| Yüksek Lisans | |
| Üniversite: | Kırşehir Ahi Evran Üniversitesi |
| Enstitü: | Fen Bilimleri Enstitüsü |
| Anabilim Dalı: | İleri Teknolojiler Anabilim Dalı |
| Mezuniyet Yılı: | 2023 |
| | |

| Tezden Üretilen Makaleler ve Bildiriler |
|---|
| Al-hayani, M.I.M. & Sepet, H. (2024). Improve The Detection Of Tree Crowns On Drone Images By Machine Learning Algorithm. Humanities & Natural Sciences Journal, 4(5): 416-424. |