



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



**ŞEHİRLERDE BULUNAN PARK VE
BAHÇELERDEKİ AĞAÇ YOĞUNLUĞUNUN
BELİRLENMESİNDE DRON YARDIMIYLA
ÇEKİLEN GÖRÜNTÜLERİN İŞLENMESİ**

HASSAN HAWAS HAMEEDI AL-HUSSEINI

YÜKSEK LİSANS TEZİ

KIRŞEHİR

2023



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



**ŞEHİRLERDE BULUNAN PARK VE
BAHÇELERDEKİ AĞAÇ YOĞUNLUĞUNUN
BELİRLENMESİNDE DRON YARDIMIYLA
ÇEKİLEN GÖRÜNTÜLERİN İŞLENMESİ**

HASSAN HAWAS HAMEEDI AL-HUSSEINI

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 Arařtırma ve Yayın Etięi Yönergesini okuduęumu ve anladığımı ve Kırőehir Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduęum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettięimi,
- Tüm bilgi, belge, deęerlendirme ve sonuçları bilimsel etik kurallarına uygun olarak sunduęumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir deęişiklik yapmadığımı,
- Tez olarak sunduęum bu çalışmanın özgün olduęunu,

bildirir, aksi bir durumda bu konuda hakkımda yapılacak tüm yasal işlemleri ve aleyhime doğabilecek tüm hak kayıplarını kabullendięimi beyan ederim. 09/11/2023

Hassan Hawas Hameedi AL-HUSSEINI

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. Amaç ve Hedefler.....	2
1.2. Dijital Fotoğraflar.....	3
1.2.1. Raster ve vektör görüntü dosyaları.....	4
1.2.2. Dijital fotoğraf türleri	4
1.2.3. Görüntü veri kümeleri	5
1.3. Nesne Algılama ve Görüntü Tanıma.....	6
2. ÖNCEKİ ÇALIŞMALAR	9
2.1. Drone Görüntüleri	11
2.2. Görüntü İşleme	13
2.3. İHA Görüntüleri	14
2.4. Benzer Çalışmalar	17
3. MATERYAL VE METOT	21
3.1. Çalışma Metodu	21
3.2. Veri Seti.....	23
3.3. Çalışma Alanı.....	24
3.4. Veri Bölme	25
3.5. Derin Sinir Ağı.....	26
3.5.1. Konvolüsyonel sinir ağı	26
3.5.2. Evrimsel katman.....	28
3.5.3. Destek vektör makinesi	29
3.5.4. CNN-LSTM	30
3.6. Sinir Ağı Katmanları	31
3.7. Önerilen Model	32
4. BULGULAR VE TARTIŞMA	35

4.1. Palmiye Veri Tabanı.....	35
4.2. Deneysel Bulgular	36
5. SONUÇ VE ÖNERİLER	43
6. KAYNAKLAR.....	45
ÖZGEÇMİŞ.....	51

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.

Tezimi, ailem başta olmak üzere özellikle Babam, Annem, Kardeşlerim ve eşim'e ithaf ederim.

Kasım, 2023

Hassan Hawas Hameedi AL-HUSSEINI

ÖZET

YÜKSEK LİSANS TEZİ

ŞEHİRLERDE BULUNAN PARK VE BAHÇELERDEKİ AĞAÇ YOĞUNLUĞUNUN BELİRLENMESİNDE DRON YARDIMIYLA ÇEKİLEN GÖRÜNTÜLERİN İŞLENMESİ

Hassan Hawas Hameedi AL-HUSSEINI

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

**Danışman: Doç. Dr. Hakan SEPET
Yıl: 2023 Sayfa: 51
Jüri: Doç. Dr. Hakan SEPET
Prof. Dr. Kamil ŞİRİN
Doç. Dr. Murat ÇANLI**

Modern teknolojilerin tanıtılması gereken en önemli yönlerden biri çevresel boyuttur. İçinde yaşadığımız çevre, kaynaklarının korunmasını içerir ve bu kaynakların en önemlisi ağaçlardır. Bilgisayar görüşü ve makine öğrenimi algoritmalarındaki görüntü tanımadaki büyük ilerlemeler, orman yönetimine yardımcı olacak araçlar sağlamayı amaçlamaktadır. Ağaçların taçlarını belirlemek için drone tarafından yakalanan görüntülerin işlenmesi için akıllı araçlar sağlanabilir. Yüksek biyoçeşitlilik, hem bireysel hem de bölge çapında doğal kaynakları korumak ve yönetmek için stratejiler gerektirir. Bu yazıda makine öğrenimini kullanıyoruz ve ağaç tespiti ve sınıflandırması için otomatik bir yaklaşım geliştirmeye odaklanıyoruz. Sistem, Irak Selahaddin'deki hurma ormanlarının fotoğrafları ve çevresine uygulanmıştır. Sistemi eğitmek ve test etmek için veri seti olarak yüksek çözünürlüklü görüntüler kullanılmıştır. Palmiye ağaçları için ağaç tacı tespit doğruluğu %92'ye ulaşırken, ekili alanların tespiti için testler yapılıyor. Bireysel ağaç taçlarının tespiti ve karakterizasyonu, palmiye ağaçları için bir orman gözetim yaklaşımı geliştirmenin ilk adımıdır. Ormanların durumu açıklanabilir ve önerilen sistemimizin bir çıktısı olarak tanımlayıcı bir analiz sağlanabilir.

Anahtar Kelimeler: Palmiye, Nesne algılama, Ağaç tacı algılama, Drone görüntüleri, Makine öğrenme

ABSTRACT

MASTER'S THESIS

PROCESSING IMAGES TAKEN BY DRONES FOR DETERMINING THE TREE DENSITY IN PARK AND CITIES GARDENS

Hassan Hawas Hameedi AL-HUSSEINI

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

**Supervisor: Assoc. Prof. Dr. Hakan SEPET
Year: 2023 Pages: 51
Juries: Assoc. Prof. Dr. Hakan SEPET
Prof. Dr. Kamil ŞİRİN
Assoc. Prof. Dr. Murat ÇANLI**

One of the most important aspects in which modern technologies should be introduced is the environmental dimension. The environment we live in includes the protection of its resources, and the most important of these resources is trees. Major advances in image recognition in computer vision and machine learning algorithms aim to provide tools to assist forest management. Intelligent tools can be provided for processing images captured by the drone to identify the crowns of trees. High biodiversity requires strategies to conserve and manage natural resources, both individually and across the region. In this article, we use machine learning and focus on developing an automated approach for tree detection and classification. The system has been applied to photographs of date palm forests and their surroundings in Saladin, Iraq. High resolution images were used as dataset to train and test the system. While the crown detection accuracy for palm trees reaches 92%, tests are carried out to determine the cultivated areas. Detection and characterization of individual tree crowns is the first step in developing a forest surveillance approach for palm trees. The state of forests can be described and a descriptive analysis provided as an output of our proposed system.

Keywords: Palm, Object detection, Crown detection, Drone footage, Machine learning

TABLolar DİZİNİ

	Sayfa No
Tablo 4.1. Modelde tespit edilen palmiye ağaçlarının bilgileri.....	37
Tablo 4.2. Tespit edilen 15 palmiye ağacı tepesinin IoU ve F-skoru	39
Tablo 4.3. Algılanan palmiye ağaçları, kayıp ve kapalı alan	41

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 3.1. Veri kümesi görüntüleri örneği.....	24
Şekil 3.2. Çalışma alanı-Salahaldeen, Irak	25
Şekil 3.3. Bir konvolüsyonel sinir ağının iş akışı	28
Şekil 3.4. 2x2 çekirdek tarafından gerçekleştirilen havuzlama işlemi.....	28
Şekil 3.5. Bırakma şeması.....	29
Şekil 3.6. Bir LSTM'nin geliştirilmiş hücre yapısı.....	31
Şekil 3.7. CNN ve LSTM modelleri birleştirildi	31
Şekil 3.8. RNN çıktısının üretildiği ve referans verilerinin gizli nöron aracılığıyla beslendiği, RNN modelinin değiştirilmiş bir versiyonu.	32
Şekil 3.9. Önerilen model diyagramı	33
Şekil 4.1. Irak'ta palmiye ağaçları.....	35
Şekil 4.2. Irak'ta alınan palmiye ağaçlarının konumu.....	36
Şekil 4.3. Sunulan modelin sonucu	37
Şekil 4.4. palmiye ağacı taçlarının kapladığı alan	39
Şekil 4.5. Sunulan modelin deneysel sonuçları.....	40
Şekil 4.6. Tablo 4.3'te test edilen görüntülerin kapsanan alanı.....	41

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar	Açıklama
Y	: Çıktı uzayı
Y_t	: t zamanına ait zaman serisi
α	: Düzgünleştirme sabiti
β	: Çarpma sabiti
F_t	: t döneminin tahmin verisi,
δ	: Fonksiyon sabiti
w_{1j}	: 1 numaralı girdinin j. ağırlık değeri
f	: Etkinlik fonksiyonu
O_j	: j. eşik değeri
V_i	: i. Değere ait toplama işlevi
n	: Dönem sayısı

Kısaltmalar	Açıklama
AR	: Otoregresif Süreç
ARIMA	: Birleştirilmiş Otoregresif Hareketli Ortalama Modeli
ARMA	: Otoregresif Hareketli Ortalama Süreci
HA	: Harmoni Arama
HKO	: Hata Karelerinin Ortalaması
IMF	: Öz Kip İşlevleri Fonksiyonu-Intrinsic Mode Function
KEKK	: Kısmi En Küçük Kareler
MA	: Hareketli Ortalama Süreci
MEB	: Millî Eğitim Bakanlığı

1. GİRİŞ

Son zamanlarda özellikle teknolojinin gelişmesiyle birlikte görüntü tanımlama ve işleme yapay zekanın ön sıralarında yer almaktadır. Görüntü tanıma ve görüntü işleme uygulamaları günümüzde en çok talep gören uygulamalar arasındadır. Görüntüler üzerinde gerçekleştirilen işlemler, görüntü alanını analiz etmeyi, en önemli bileşenlerini belirlemeyi ve içindeki nesnelere sınıflandırmayı içerir. Tarım alanlarının ve bölgelerin durumunun yorumlanabilmesi için alanın kapsamlı bir şekilde anlaşılması gerekmektedir. Öngörülen sorunlara erken çözümler bulmadan önce fark edilmesi gereken çok sayıda farklı alan olduğu için öncelikler belirlememiz gerekiyor. Drone'lar tarafından çekilen hava fotoğraflarının ve filmlerin "temel araçlar" olması gerektiğini öneriyoruz. Bunlar, kolayca yorumlanabilen ve görüntülerin bilimsel olarak yorumlanabilirliği sayesinde paydaşlar arasında ortak bir anlayış oluşturma potansiyeline sahip manzara temsilleri olmalıdır.

Irak'ta çok çeşitli ekili alanların çeşitli perspektiflerinden dronlar tarafından çekilmiş fotoğraf ve videolar elde ettik. Bu fotoğraflar ve videolar tarım alanlarını, palmiyeleri ve yeşil alanları gösteriyor. Web-dağıtık veri setlerinden elde edilen resimlerle karşılaştırıldığında, bir video drone tarafından bir açıyla eğikken çekilen görüntülerin yorumlanabilirliği, odak grup görüşmeleri kullanılarak değerlendirildi. Resimlerimizin tüm veri kümelerinde, özellikle de Salah al-Din Valiliği'ndeki komşu bölgelerde gelişmiş tanımlama sonuçları ürettiğini gösterdik. Bu, bu tür görüntülerin, ağaçların ve ekili alanların görüntülerini anlama konusunda daha önce deneyimi olmayan insanları güçlendirmede yardımcı olduğunu göstermektedir.

Görüntü tanıma, bilgisayar görüşü ve makine öğrenimi tekniklerindeki son gelişmeler, ormanların yönetiminde yardımcı olabilecek teknolojilerin yaratılmasında kullanılıyor. Ağaçların taçlarını belirlemek için insansız hava aracı tarafından çekilen fotoğrafların analizi için akıllı araçların sağlanması olasılığı vardır. Hurma tarımı için kullanılan alanın yönetimi, büyük ölçüde hurma bitkilerinin doğru bir şekilde tanımlanmasına ve sayılmasına dayanmaktadır. Tarımla ilgili kararların alınmasına yardımcı olacak araçların kullanılabilir hale getirilmesi ve tarımsal üretim potansiyelinin kapsamının anlaşılması gerekmektedir.

Tarım yapılacak alanların yerinin belirlenmesi için taçların incelendiği ağaçların sınıflandırılmasının tamamlanması gerekmektedir. Bu çalışmanın sonuçları, yüksek çözünürlüklü drone fotoğraflarından yararlanan avuç içi tanımaya yeni bir yaklaşım

sunuyor. Palmiye ağaçları, Irak'a özgü en belirgin ağaç türlerinden biri olarak iyi tanınmaktadır. Orta ve güney bölgelerde ticari olarak büyük miktarlarda yetiştirilirler. Veriler, onlarla birlikte model oluşturmak amacıyla toplanır. Fotoğrafların sistemde kullanılabilmesi için önce incelenmeleri ve tanımlayıcı özelliklerinin ayıklanması gerekir. Gelecekte, teknik, çeşitli türlere ait ağaçları aramak için ormanları araştırmak için uygulanabilir.

Kırpılan ve kırılmayan bölgenin bir açıklamasının sağlanmasının takip ettiği özellik seçimi ve tanıma süreci, önerilen algoritmanın ve onun birincil bileşenlerinden birinin başarısına birincil katkı sağlar. Sistemin eğitimi ve testi için veri seti yüksek çözünürlüklü görüntülerden oluşturulmuş ve bu görüntüler kullanılmıştır. Palmiye ağaçlarının taç tanıma doğruluğunun iyi seviyeye ulaşmış olmasına rağmen, palmiye ağaçlarının taçlarının tanımlanması ve tanımlanması, palmiyeler için bir orman izleme planı geliştirmenin ilk adımıdır.

Genel olarak, drone fotoğrafçılığının estetik değeri ve algılanan profesyonel avantajları için yüksek düzeyde bir takdir vardır; ancak, teknolojinin yaygın kabulü, teknolojik engellerin varlığı nedeniyle engellenmektedir. Öte yandan, tarlalarda ağaç dağılımının oluşumunu geometrik bir şekilde açıklamak için çözüm bulma sürecine ışık tutuyoruz. Ağaçları belirledikten sonra, ekili bölümün peyzajın ekilmemiş kısmına oranlarını belirlemek için görüntü analizi gösteriyoruz. Çevre yöneticilerinin ve çevrecilerin, daha etkili çok paydaşlı iş birliği için kullanılacak sezgisel peyzaj temsilleri oluşturmak için giderek daha uygun fiyatlı hale gelen video dronları kritik bir şekilde kullanmalarını öneriyoruz.

1.1. Amaç ve Hedefler

Bu çalışmanın birincil amacı, ekili ağaçsıl örneklerini kapsayan görsellerin kesin bir tasvirini sağlamaktır. İnsansız hava araçları (dron'lar) tarafından çekilen görüntülerin analizi için görüntü işleme teslimi devam etmektedir. Ağaçların tanımlanması, makine öğrenimi metodolojilerini kullanan segmentasyon teknikleriyle elde edilebilir. Bölgenin kesin sınırı, ekilmiş ve ekilmemiş kısımlar arasında ayırım yapılarak tespit edilebilir. Önerdiğimiz yöntem, ormanlık afet senaryolarında değerli bir araç olarak hizmet etme potansiyeline sahiptir. Önerilen konsept, ekili alan ve çiftçilerin ağaçla ilgili gereksinimleri hakkında fikir edinmek isteyen paydaşlar için değerli bir kaynak olma potansiyeline sahiptir. Ekibimiz tarafından önerilen teorinin değerlendirilmesi, derin öğrenme metodolojileri kullanılarak gerçekleştirilmiştir.

1.2. Dijital Fotoğraflar

Dijital fotoğrafçılık, dijital görüntüleri veya fotoğrafları yakalamak, üretmek, değiştirmek ve dağıtmak için elektronik ve hesaplamalı cihazların kullanılmasını ifade eder. Elektronik veya bilgisayar tabanlı fotoğrafçılık hizmetlerinin sağlanması, çeşitli teknolojilerin kullanılmasını içerir (Lim, 2006). Sosyal bilimciler için görüntüler özellikle çekici bir veri kaynağı sunar. "Veri olarak görüntüler" terimi, niceliksel olarak analiz edilebilen ve makine öğrenimi teknikleri kullanılarak iyileştirilebilen, dijital olarak depolanan büyük miktarda bilgiyi giderek daha fazla ifade ediyor. Bununla birlikte, bu görüş, resimlerin sosyal bilimciler için bilgi kaynakları olarak anlaşılabilirliği sayısız başka yolu açıklamakta başarısız olur (Spencer, 2022).

Sosyal bilimciler için görüntüler özellikle çekici bir veri kaynağı sunar. "Veri olarak görüntüler" terimi, niceliksel olarak analiz edilebilen ve makine öğrenimi teknikleri kullanılarak iyileştirilebilen, dijital olarak depolanan büyük miktarda bilgiyi giderek daha fazla ifade ediyor. Bununla birlikte, bu görüş, resimlerin sosyal bilimciler için bilgi kaynakları olarak anlaşılabilirliği sayısız başka yolu açıklamakta başarısız olur.

Dijital fotoğrafçılık yaklaşık otuz yıldır var olmasına rağmen, yeni ilerlemeler ve iyileştirmeler hala düzenli olarak belgelenmektedir. Dijital teknolojinin getirdiği gelişmeler sonucunda tüm teknoloji dijital formata dönüşmüştür. Görüntüleme alanında kameraların kalitesi, görüntüler, görüntü netliği, görüntü aktarımı, görüntü depolama ve diğer hassas yüzeyler açısından önemli ilerlemeler kaydedilmiştir (Lu ve ark., 2022). Son araştırmalarda görüntü işleme ve dijital görüntülemenin önemine dair daha fazla kanıt verilmiştir. Bununla birlikte, bu iki alanın birbiriyle nasıl etkileşime girdiğini tam olarak anlamak için daha yeni teknolojiler hakkında daha fazla bilgi gereklidir. Sonuç olarak, bu özel çalışmanın ana odak noktası, dijital fotoğrafçılık alanında yapılan son gelişmelerdir. Büyük verinin bugün ve çağında, dijital fotoğrafçılıktaki teknolojik gelişmelerin önemini de gün ışığına çıkarıyor. Çoğu durumda, akıllı sistemler tarafından üretilen kalite düzeyi, resim elde etme prosedürlerinin etkinlik düzeyiyle doğrudan ilişkilidir (Green ve ark., 2018).

Sunduğumuz yöntem bağlamında, sonuçlar drone tarafından çekilen fotoğrafların kalitesi hakkında çok şey söylüyor. Kullanılan dijital resimler ile sistemin ulaştığı verimlilik düzeyi arasında doğrudan bir bağlantı olduğunu söyleyebiliriz. Etiketli veriler, akademisyenler tarafından büyük veri ve görüntülerde makine öğrenimi gibi alanlarda sınıflandırma yöntemleri geliştirmek için kullanılır.

DPI, "nokta/inç" anlamına gelir ve PPI, "inç başına piksel" anlamına gelir. Bu ölçü birimleri, görüntüdeki piksel yoğunluğunun kullandığınız yönteme uygun olup olmadığını belirlemek için gereklidir. İhtiyacınız olan DPI veya PPI belirlerken dikkat etmeniz gereken en büyük şey, görüntünün tanıma veya analiz için kullanılıp kullanılmayacağıdır (Wang ve ark., 2022).

Web siteleri, görüntüleri düşük bir çözünürlük olan 72 dpi'de görüntüler; ancak bu çözünürlükteki görüntüler web'de gerçekten net görünür. Akıllı modeller oluşturmak için nispeten yüksek çözünürlüklü görüntülerle çalışmak gerekir (Zhao ve ark., 2018). Nitel akademisyenler için standart bir yöntem olan içerik analizi, etiketleme prosedürünün merkezinde yer alır. Bu nedenle, nicel analizler nitel yöntemlere dayanır ve her ikisi de resimlerin kullanılması yoluyla dünyayı anlamlandırmada yararlı olabilir.

1.2.1. Raster ve vektör görüntü dosyaları

Raster görüntüler, görsel bir sunum oluşturmak için ayrı piksellerin veya farklı birimlerin düzenlenmesi yoluyla oluşturulur. JPEG, GIF ve PNG, raster görüntü dosyası biçimleridir. İnternette veya basılı materyallerde keşfedilen her görüntü bir tür raster görüntüdür. Piksellerin oranı, çözünürlükleri tarafından belirlenir ve amaçlanan kapasitelerinin ötesinde bir alanı işgal edecek şekilde genişletilirse, bozulmaya uğrayarak net olmayan veya bulanık görüntülerin üretilmesine yol açabilirler (Church ve ark., 2013). Piksel kalitesini korumak için, raster görüntüleri çözünürlüklerinden ödün vermeden yeniden boyutlandırmak mümkün değildir. Sonuç olarak, tarama dosyalarının amaçlanan uygulama için gereken kesin boyutlarda kaydedilmesi gerekliliğini akılda tutmak çok önemlidir.

Vektör grafikleri daha fazla esnekliğe sahiptir. Yapılarında piksel yerine orantısal formüller kullanılır. EPS, AI ve PDF dosya formatları, sık sık boyut ayarlamaları gerektiren grafikler oluşturmak için idealdir (Tan, 2006). Logo ve marka grafiklerinin bir vektör formatında tasarlanması ve her zaman bir ana dosyanın muhafaza edilmesi tavsiye edilir. Vektörlerin çok yönlülüğü, bir posta pulununkinden 18 tekerlekli bir aracınkinden kadar değişen boyutlara ölçeklenebilme kapasiteleri ile kanıtlanmıştır.

1.2.2. Dijital fotoğraf türleri

JPEG veya JPG Ortak Fotoğraf Uzmanları Grubu, PNG-Taşınabilir Ağ Grafikleri, GIF-Grafik Değişim Formatı, TIFF-Etiketli Resim Dosyası ve daha fazla resim formatı günümüzde yaygın olarak kullanılmaktadır. Tür çeşitliliği, dijital görüntüler üreten veya bunları kullanan çok sayıda uygulamadan kaynaklanmaktadır (Khalifa ve ark, 2022).

Veri kümeleri, görüntü koleksiyonu aynı türde olmadığında, çoğunlukla büyük miktarda görüntü üretir; önce ön işleme adımlarına girmesi gerekecektir. Genellikle "nokta/inç" ölçeği olarak bilinen DPI ölçeği, dijital resim türlerinin en temel özelliklerinden biridir. DPI, "dots per inch" in kısaltmasıdır, PPI ise "pixels per inch" in kısaltmasıdır. Bu ölçü birimleri görüntünün piksel yoğunluğunun kullanılan sisteme uygun olup olmadığını tespit etmek için gereklidir (Zeng ve ark., 2017). JPEG sıkıştırma kullanılan kayıplı bir sıkıştırma tekniği olan ayrık kosinüs dönüşümü (DCT), dijital görüntüleri sıkıştırmak için kullanılan teknolojide büyük bir gelişmeydi. JPEG sıkıştırması, DCT sıkıştırmasını kullanır. JPEG, resimleri önemli ölçüde daha küçük boyutlu dosyalara sıkıştırma yeteneği nedeniyle son yıllarda en popüler hale gelen resim dosyası formatıdır.

Dijital tekrar fotoğrafçılığı, insan gözlemciler tarafından bitki örtüsü durumunun geleneksel değerlendirmelerine göre lojistik, süreklilik, tutarlılık ve nesnellik açısından sağladığı faydalar nedeniyle fenolojik araştırmalar için önemli bir uzun vadeli veri kaynağı olma potansiyeline sahiptir. Bunun nedeni, dijital tekrarlı fotoğrafçılığın aynı kamera kullanılarak tekrar tekrar yapılabilmesidir (Hilker ve ark., 2010; Sonnentag ve ark., 2012). Dijital resimlerin kırmızı, yeşil ve mavi (RGB) renk kanallarının her birinde bulunan bilgi, dijital tamsayılar biçiminde bağımsız olarak alınabilir ve daha sonra bilgi, renk indeksleri kullanılarak özetlenebilir. Bunlar, ExG ve gcc üzerindeki günlük, mevsimsel ve hava durumuna bağlı değişimlerin neden olduğu sahne ışığındaki değişikliklerin yanı sıra dijital kamera ve resim dosyası türü seçimini içerir.

1.2.3. Görüntü veri kümeleri

Veri kümesi, bir yapay zekâ girişiminde kullanılmak üzere derlenmiş bir veri derlemesidir. Makine öğrenimi ve yapay zekâ (AI) algoritmalarının performansını test etmek, eğitmek ve değerlendirmek amacıyla seçilen bir dijital görüntüler koleksiyonu, genellikle bilgisayarla görme algoritmaları, görüntü veri kümesi olarak bilinir.

Görüntü veritabanları, algoritmaların fotoğraflarda yer alan bilgileri tanımlamak ve tanımak ve bu görevlerle ilgili diğer bilişsel etkinlikleri gerçekleştirmek için gerekli bilgileri edinmesini sağlar. Örneğin, AI algoritmalarına fotoğrafları etiketleme, araç plakalarını okuma ve tıbbi resimlerdeki tümörleri tanıma öğretiler (Dang-Nguyen ve ark., 2015). Diğer uygulamalar, araç plakalarının okunmasını içerir. Görüntü veri kümeleri, algoritmaların görüntülerde bulunan bilgileri algılamak ve tanımak ve bu alanla bağlantılı diğer bilişsel görevleri gerçekleştirmek için gerekli bilgiyi edinmesini sağlar.

AI sistemlerine çok çeşitli görevleri yapmaları öğretilir. Veri kümeleri, çeşitli bilgi parçalarının önemini izlemek ve değerlendirmek için yararlı araçlardır. Araştırma ve değerlendirme prosedürlerini hızlandırmaya yardımcı olmanın yanı sıra, ilgili bilgileri veri setlerinde derlemek çok yardımcı olabilir (Schepaschenko, 2017). Bilgisayarlı görüde kullanılan algoritmalar yalnızca resimleri değiştirmekle kalmaz, aynı zamanda gerçek dünyada çok çeşitli potansiyel uygulamaları olan tamamen yeni görüntüler de üretir.

Ormanlar, ağaç izleme ve ağaçların ve ekili alanların durumunun yüksek doğrulukta bir tanımını verme ile ilgili veriler, iki farklı veri biçimine ayrılabilir. İlk kategori, uzak sensörler tarafından toplanan bilgilerden oluşur. Diğer veri türü ise dronlar tarafından çekilen fotoğraflardır. Uzaktan algılama olarak bilinen çalışma alanı, son derece hızlı bir şekilde genişlemektedir (Kwenda ve ark., 2022). Bilgisayar teknolojisindeki gelişmelerle birlikte yüksek çözünürlüklü uzaktan algılama cihazlarının ortaya çıkışı, uzaktan algılama topluluğunun beklentilerinde ve yöntemlerinde önemli değişimlere neden oldu.

Orta çözünürlüklü fotoğraflara kıyasla, uzaktan algılama ile toplanan verilerin mekansal çözünürlüğü çok daha yüksek olup, Dünya yüzeyi hakkında daha fazla detayın ayırt edilmesini mümkün kılmaktadır (Galiatsatos ve ark., 2020). Orman fotoğraflarının değerlendirilmesi ve kategorize edilmesi amacıyla makine öğrenimi tekniklerinin kullanımı, dronlardan elde edilen hava görüntülerinde arazi örtüsü modellerinin otomatik olarak sınıflandırılmasını kolaylaştırmak için sürekli olarak geliştirilmektedir.

1.3. Nesne Algılama ve Görüntü Tanıma

Bilgisayarla görme alanı, bir görüntüde veya hareketli resimde bulunan belirli bileşenleri tanımak için "nesne algılama" olarak bilinen bir teknik kullanır. Derin öğrenme ve makine öğrenmesi gibi öğrenme algoritmaları, nesne tanımlama sürecinde sıklıkla kullanılır. Nesne algılama, bir görüntü veya videodaki belirli bileşenleri tanımlamak ve yerleştirmek için bilgisayar görüşünü kullanan bir tekniktir. Bu, görüntünün veya videonun içeriği analiz edilerek gerçekleştirilebilir.

Nesne tanımlama, nesnelerin nerede bulunduğunu ve sahne boyunca nasıl hareket ettiklerini tam olarak belirlemek için bir sahnedeki belirli bileşenlerin etrafında sınırlayıcı kutular oluşturur (Magdeev ve Tashlinskii, 2019). Gerçek zamanlı video çerçevelerinde bulunan ilgi çekici öğeleri belirlemek, bu öğeleri yerleştirmek ve bunu minimum düzeyde kesinlik sağlarken yapmak için Gerçek Zamanlı Nesne Tespiti olarak bilinen bilgisayarla görme çalışması gereklidir.

Görüntü Yerelleştirme kavramı çerçeveye giriyor. Bir resimdeki tek bir ögenin kesin konumunu belirlemeye yardımcı olur. Sahnede birden fazla öge varsa, öge Tespiti fikrine geri dönüyoruz. OD ile hem nesne sınıflandırması hem de tahmini konum mümkündür. Görüntünün kompozisyonunu anlamak hem nesne algılama hem de sınıflandırma için bir ön koşuldur. Bu gibi durumlarda, Görüntü Bölümlene yararlı olur (Chen ve ark., 2014).

Çeşitli görüntü tanıma kıyaslamalarında, derin evrişimli sinir ağları en son teknolojide veya buna yakın olduğu düşünülen sonuçlar elde etmiştir. Resimdeki her nesne sınıfı için bir sınırlayıcı kutu ve bir güven puanı tahmin eden bir ızgara, çeviri alt görevi için kazanan model oldu. Bu türden bir model, nesnelere var olduğu daha geniş çevreyi temsil edebilir. Bunu takiben, bir sinir ağı modeli oluşturularak, her kutu için resmin o bölümündeki herhangi bir öğeyi içermesi olasılığıyla orantılı olarak bir puan veren modeller sağlanmıştır. Bu modeller, sınıftan bağımsız sınırlayıcı kutuların bir koleksiyonunu öngörür.

Model, her sınıfla ilişkili örneklerin sayısındaki doğal değişkenliği ele alma yeteneğine sahiptir ve ağı en yüksek seviyelerinde sınıflar arasında genelleme sağlar. İşlemin son aşamalarında, yüksek oranlara sahip olmayan kutulardan kurtulmak ve en yüksek değere sahip sınırlayıcı kutuyu korumak için çeşitli yöntemler kullanılır. Bu, resim nesnelere doğru şekilde tanınmasını garanti etmeye yardımcı olur (Islam, 2018). Bizim sistemimizde olduğu gibi akıllı sistemlerin başarısına yardımcı olan en temel teknolojilerden biridir ve kullandığımız teknolojilerden biri de fotoğraflardaki nesnelere tanıma yeteneğidir.

Resim, "bölümler" dediğimiz daha küçük parçalara bölünebilir. Görüntünün veri içermeyen bölümleri olacaktır, bu nedenle tüm şeyi bir kerede işlemek iyi bir plan değildir. Resim ilgili bölümlerin kullanılabilmesi için önce parçalara bölünürse daha verimli işlenebilir. Kısacası, görüntü bölümlene bu şekilde gerçekleştirilir. Muhtemelen piksellerin bir resmin yapı taşları olduğunu zaten biliyordunuz. Resim bölümlendirmeyi kullanarak, karşılaştırılabilir özelliklere sahip pikselleri toplar ve düzenleriz.

Nesne Algılama modellerini kullanırken, algılanan her sınıfın etrafında yalnızca bir dikdörtgen oluşturabiliriz. Bununla birlikte, sınırlayıcı çerçeveler her zaman dikdörtgen veya kare olduğundan, ögenin biçimi belirlenemez (Oh ve Kang, 2017).

Öte yandan, bir resimdeki nesnelere, bir görüntü bölümlene algoritması tarafından oluşturulan bir maske kullanılarak görüntüden gizlenebilir. Bu yöntemi kullanarak, tasvir edilen nesne(ler) hakkında çok daha derin bir kavrayış elde edebiliyoruz.

Görüntü Sınıflandırma, bir görüntüyü oluşturan unsurları sınıflandırmamıza yardımcı olan bir araçtır. Görüntü Yerelleştirme, bir görüntü içindeki tek bir nesnenin tam konumunu belirleyebilirken, Nesne Algılama, bir görüntü içindeki çok sayıda nesnenin tam konumunu belirleyebilir. Görüntü Segmentasyonu daha sonra resimlerde bulunan her bir nesnenin piksel piksel bindirmesini üretecektir (Manaa ve ark., 2023). Resim bölütleme işlemi sayesinde, görüntünün içerdiği çeşitli nesnelerin biçimlerini belirleyebileceğiz.

2. ÖNCEKİ ÇALIŞMALAR

Orman malzemeleri, Qi ve ark. (2022) tarafından yapılan ayrıntılı bir araştırmanın konusuydu. Sorumlu orman kaynak yönetimi için çok önemli olan birçok bireysel ağaç özelliğinin, karmaşık gölgelik örtüsü koşulları altında tam olarak ölçülmesi zordur. Ayrıntılı ağaç yapılarını daha iyi ayırt edebilen daha yüksek yoğunluklu nokta bulutlarının toplanmasına izin veren drone lazer tarama (DLS) ve mobil lazer taramanın (MLS) geliştirilmesiyle çalışmaların dosyalanması basitleştirildi. Dahil edilen araştırma, DLS ve MLS kayıtlarının hem ayrı ayrı hem de toplu olarak değerli olduğunu gösterdi. Noktanın dikey olasılık yoğunluk dağılımına dayalı olarak ikincisini daha fazla dikkate alan bir ağırlıklandırma yöntemi kullanarak düz birleştirme ve yeni stratejiye baktılar.

Kesinliği değerlendirmek için nicel yapı modellerinden elde edilen yedi ağaç özelliği kullanılmıştır. Bulgulara dayalı olarak, ağırlıklı veriler, QMS modelleme etkinliği açısından karma verilere ve MLS verilerine göre ortalama %20 daha üstündür. Ağaç özelliklerini tahmin ederken, birleştirilmiş ve ağırlıklandırılmış veriler, tüm gölgeliklerde DLS/MLS verilerine benzer şekilde davrandı. Araştırmacılar, modele gövde ve dal miktarları dahil edildiğinde, gölgelik korumasının modelleme doğruluğunu artırdığını bulmuşlardır. Genel olarak, raster DLS ve MLS kombinasyonu sayesinde kapsamlı ağaç düzeyinde veriler elde edildi.

Ormanların ve ağaçların mimarisi Zhang ve ark. (2022) tarafından incelenmiştir. Ormanın öne çıkan özelliği, onu oluşturan türlerin dikey dizilişidir. Özel sefalik farklılaşma, ağaç topluluklarının bir araya gelmesine katkıda bulunabilecek, üzerinde yeterince çalışılmamış bir faktördür. Bu çalışmada araştırmacılar, Çin'deki beş subtropikal orman arazisinde kanopi yapısının mekansal değişkenliğini değerlendirmek için insansız bir hava aracı kullandılar. Araştırmanın amacı, ağaç çeşitliliği ve tür dağılımını şekillendirmede gölgelik yapısı ve topografyanın önemini belirlemektir. Sonuçları optimize etmek için gölgelik özelliklerinin, topografik bilgilerin ve 533.000'den fazla kişinin ve 600'den fazla ağaç türünün mekansal dağılımının entegrasyonu gerçekleştirildi.

Çalışma, tür çeşitliliği ile ilgili olarak bireysel değişkenlerin ilgili önemini değerlendirmek için eşzamanlı uzamsal otoregresif hata modelleri kullandı. Çalışma bulguları, gölgelik yapısı değişkenlerinin, tüm orman katmanları ve parsellerinde ağaç zenginliği modellerinin belirlenmesinde önemli bir rol oynadığını göstermektedir. Bununla birlikte, bu etkilerin etkisi ve yönü farklı siteler arasında değişiklik göstermiştir.

Arařtırmacılar, bu ormanlardaki türlerin dağılımının, gölgelik yapısı ve topografya arasındaki etkileşimden etkilendiđi sonucuna vardılar. Çalışmamızın sonuçları, toplulukların bir araya gelişini anlamada kanopi yapısını ve ilişkili ekolojik mekanizmaları dikkate almanın önemini vurgulamaktadır.

Multispektral drone görüntülerinin önemi ve arboreal mahsullerin gölgelik mimarisini ölçmek için değerli bir araç olarak kullanımı yaygın olarak kabul edilmektedir. Tu ve ark. (2020), seyahat düzenlemelerini optimize etmek için çeşitli konfigürasyonlar tasarlama konusunda araştırma yaptı. Planlamanın önemi, ağaçların ve ekinlerin biyofiziksel özelliklerinden elde edilen görüntülerin ve haritaların kalitesini artırma yeteneğinde yatmaktadır. Uçuş planlama sürecinde, uçuş irtifası, görüntü örtüşme derecesi, uçuş yönü, uçuş hızı ve güneş irtifası gibi çeşitli parametrelerin dikkate alınması gerekir. İnsansız hava araçları tarafından çekilen en uygun hava fotoğraflarını oluşturmak için kapsamlı arařtırmalar yapılmıştır.

Önceki arařtırmalar, bireysel deđişkenlerin görüntülerin kalitesi üzerindeki etkisini deđerlendirdi, ancak birden fazla deđerşken arasındaki etkileşim henüz keşfedilmemiş durumda. Arařtırmacılar tarafından yürütölen çalışma, görüntü hizalama, nokta bulutu yoğunlaştırma, 3B model oluřturma ve orto-mozaiikleme dahil olmak üzere işlemenin her aşamasında çeşitli uçuş deđerşkenlerinin veri kalitesi ölçümleri üzerindeki etkisini gösterdi. Bulgular, güneş irtifasının yüksek olduđu dönemlerde ve düşük görüntü açılarında çite yakın uçmanın veri kalitesini artırdığını gösteriyor. Gerekli ileri çakışmayı elde etmek için, uçuş için en uygun hızı oluřturmak zorunludur. Biyofiziksel özellikler tarafından oluřturulan sonraki algoritmaların ve haritaların kesinliđi, artan güven ile geliştirilmiştir.

Ağaçların havadan görüntüleri, seçilen ağaçların ilerlemesini veya genişlemesini izlemek için de kullanılır. Holden ve ark. (2021), istilacı yabancı bitki yönetimi için uzaktan algılamada operasyonel ilerleme elde etmedeki zorlukları ele almak için havadan görüntü analizi ve ağaç büyümesini izlemenin kullanımını üzerine bir çalışma yürütmüştür.

Arařtırma, sonuç olarak istilacı yabancı ağaçlar tarafından su güvenliğine tehdit oluřturan su kuleleri üzerinde yürütölen kapsamlı uzaktan algılama arařtırmalarının eksikliđi nedeniyle başlatılmıştır. Google Earth Engine platformunun hesaplama yeteneklerini açık erişimli Sentinel görüntüleriyle entegre eden yeni bir disiplinler arası metodoloji kullanıldı. Güney Afrika Burnu'nun Güney-Batı bölgesinde yer alan önemli bir su toplama alanındaki yerli olmayan ağaç türlerinin sıklığı ve konsantrasyonunun kesin ve güncel bir şekilde anlaşılmasını kolaylařtırmak için drone teknolojisinden ve

saha gezilerinden faydalanılmıştır. 20 metre. Elde edilen sonuçlardan çıkarılan öneriler, kullanılan tipik olarak sınırlı örnek boyutları göz önüne alındığında, multispektral sınıflandırmalarda büyük ölçüde doğruluk istatistiklerine güvenme konusunda dikkatli olunmasını önermektedir. Egzotik ağaçların ayırt edilmesi, elektromanyetik spektrumun kırmızı kenar ve kısa dalga kızılötesi bölgelerinde bulunan zengin spektral verilerin kullanılmasını gerektiriyordu. Makul istatistiksel doğruluğa rağmen, dönem boyunca erişilebilen eskimiş haritalar göz önüne alındığında, sonuçlar alan için kayda değer bir ilerleme gösterdi. Çalışmanın bulguları, karar vericilerin egzotik ağaçları etkili bir şekilde yönetebilen özelleştirilmiş ürünlere ihtiyaç duyduğunu ifade ettiğini göstermektedir.

Ağaç takibi çalışması, yalnızca benzersiz ağaç türlerinin ve büyüme hızlarının incelenmesini kapsamaz, aynı zamanda ormanlık bölgelerdeki olumsuz olayların araştırılmasını da kolaylaştırır. İskandinavya'nın yanan bölgelerinde, yangınların yaygın bir sonucu olan kök hasarının bir sonucu olarak ağaçların yaygın bir şekilde kesilmesi yaşanıyor. Bohlin ve ark. (2017), yangınlardan önce ve sonra düşen ağaçların oranını tahmin etmede lidar verilerinin kullanımını göstermek için bir keşif çalışması yürütmüştür. Konuyla ilgili ayrıntılı bir inceleme yapılmadığı için bu çalışma yapılmıştır. İsveç'te 2014 yılında bir yangın olayına maruz kalan bir bölge, 2011 ve 2015 yıllarına ait havadan lidar verilerine sahip olması nedeniyle seçildi. Yangından önceki ve sonraki örnekleri kapsayacak şekilde üç veri seti düzenlendi. İki senaryoyu birleştirmek için. Araştırmacılar, düşen ağaçların oranını tahmin etmek için istatistiksel bir yöntem olarak kesirli lojistik regresyonu kullandılar.

Çalışma, geniş bölgelerde yangın sonrası günlük kaydını tahmin etmek için sahadan türetilen eğitim verileriyle birlikte çok zamanlı lidar teknolojisi kullanmanın potansiyelini gösterdi. Bineklerin yüksek yoğunlukta tepe yangınlarına maruz kaldığı durumlarda modelin performansına gereken değer biçilmemiştir. Bu oluşumun olası nedeni, Sonsuz Kara Ağaçların iskelet yapılarından yayılan minimum seviyedeki yankılanmalara bağlanabilir. Model, yangının etkilerinin peyzaj düzeyinde analizini yapmak ve yaprak döken ağaçlar arasındaki ilişkiyi araştırmak için bir araç olarak kullanıldı.

2.1. Drone Görüntüleri

Çok sayıda çalışma, drone görüntülerinin çeşitli alanlarda son derece önemli olduğunu kanıtlamıştır. Kalabalık analizi disiplini, son zamanlarda dronlar tarafından çekilen fotoğrafları bir dizi farklı uygulamada kullanmaya başladı. Son yıllarda, kalabalık analizi için dronların kullanımına yönelik ilgide büyük bir artış oldu. Bu çoğunlukla,

dronların hem çalıştırılmasının basit hem de uygun fiyatlı olmasına atfedilebilir. Castellano ve ark. (2023), insansız hava araçlarıyla kalabalık akışını tespit etme sorununa bir çözüm bulmak için, tam evrişimli ağlarla birlikte yoğunluk tabanlı kümelemenin kullanımı üzerine bir araştırma üstlendi. Araştırmalarının amacı, söz konusu sorunun bu teknoloji kullanılarak etkili bir şekilde nasıl ele alınabileceğini gösteren kanıtlar sağlamaktır.

Drone ile çekilen video görüntülerinde kalabalık hareketlerinin görülebileceği belirlendi. Araştırma, bir kalabalığın içindeki yüksek nüfuslu konumların merkezlerini bulmak ve ardışık kareler üzerindeki hareketlerini izlemek amacıyla kalabalık toplama süreci hakkında bilgi edinmek için tamamen evrişimli bir ağdan yararlandı. Bu, çalışmanın amacına ulaşmak için yapılmıştır. Önerilen yöntemin etkinliği ve verimliliği, VisDrone Challenge Crowd Count için kullanılan veri kümelerinde kullanılmasıyla gösterildi. Bu veri kümeleri, statik fotoğraflar yerine video dizilerinin varlığıyla ayırt edilir. Elde edilen sonuçlar cesaret vericidir ve sağlanan teknolojinin, kalabalık bir ortamda insansız hava araçları (İHA'lar) tarafından sergilenen karmaşık kolektif davranışların incelenmesine ilişkin benzersiz bilgiler verme potansiyeline sahip olduğunu göstermektedir.

Ancak drone tarafından çekilen fotoğraflar hasat kontrollerinde kullanıma sunuldu. Verimlilik için çok önemli bir çevresel önlem, gölgelik yüksekliğidir. Ürünler için bir büyüme göstergesi olarak ve biyokütle ve tarımsal üretim modellerinde bir girdi olarak kullanılır. Kanopi üstü drone görüntüleri coğrafi referanslı veya coğrafi referanssız olabilir ve her ikisi de Valluvan ve ark. (2023) tarafından oluşturulan yeni yarı otomatik kanopi yükseklik tahmin modeli tarafından desteklenir. Model, hareketten yapı yöntemiyle yükseklik belirleme için kullanılan çokgen ızgaraları elde eder, ardından çokgen üçgenleme yoluyla yoğun bir nokta bulutunu yeniden oluşturur. Orta ve güney Hindistan'ın yarı kurak bir bölgesindeki mısır mahsulünden elde edilen veriler, 2018-2019 baharında yöntemi değerlendirmek için kullanıldı. Bitkileri bir metre çubuğuyla manuel olarak saymak, zemin gerçeği kanopi yüksekliğini verdi.

İnsanlar, savanın ekolojiye katkısından büyük ölçüde yararlanır. Afrika savanı önemli bir ekolojik bölgedir. Fotogrametrik analiz ve İHA görüntülerinin kullanılması, hassas 3B modellerin oluşturulmasına olanak tanır. Ağaç gruplarının organizasyonu bu araçlarla daha iyi tarif edilebilir. Bossoukpe ve ark. (2021) tarafından bir araştırma yapılmıştır. Ovalardaki ağaçları karakterize etmek için ticari ekonomik dronları kullanmanın fizibilitesini değerlendirmek. Senegal'in kuzeyindeki yirmi dört parselin

haritası bir Dji Spark drone kullanılarak çıkarıldı. Toplanan fotoğraflardan detaylı bir orman yükseklik modeli oluşturulmuştur. Rastgele seçilen 200'den fazla ağacın boyları ve taç yayılımları arazide manuel olarak kaydedildi. Taç bölgesinin drone okumaları, sahada alınanlarla yüksek oranda ilişkiliydi. Ağaç türleri hakkında tahminlerde bulunmak için rastgele orman sınıflandırması kullanıldı.

Bu araştırmalar, ağaç toplulukları ve bilgi yayma arayışında ormanlardaki ağaç yapılarını değerlendirmek için ormancılık kuruluşları ve araştırmacılar tarafından uygun fiyatlı insansız hava araçları kullanmanın uygulanabilirliğini doğrulamaktadır.

2.2. Görüntü İşleme

Görüntüyü dijital formata dönüştürme ve ondan değerli bilgiler elde etmek için belirli işlemleri yürütme sürecine görüntü işleme denir. Görüntü işleme bağlamında, tüm görüntüleri önceden belirlenmiş sinyal işleme tekniklerinden geçen iki boyutlu sinyaller olarak kabul etmek yaygın bir uygulamadır. Görüntü işleme alanı, modeller tarafından kullanımlarına hazırlanmak için çeşitli görüntülerin ön işlenmesini ve manipüle edilmesini içerir. Görüntülerle birlikte derin öğrenme ve makine öğrenimi algoritmalarının kullanılması, görüntü işleme uygulamalarının geliştirilmesini kolaylaştırabilir. Görüntü matrisinin yapısının manipülasyonu, istenen dijital görüntü formatını elde etmek için piksel değerlerinin değiştirilmesini içeren görüntü işleme operasyonlarını oluşturur.

Ağaç ve orman görüntülerinin kullanımı, ekili alanların ve ormanların yönetiminde paydaşlara yardımcı olan akıllı sistemler için bir girdi görevi görür. Bölgenin daha kapsamlı bir şekilde anlaşılmasını kolaylaştırmak için görüntü işlemede drone görüntülerinden sıklıkla yararlanılmaktadır. Drone resimleri, doğru ağaç tespiti için kamera yönü, sahne derinliği ve yeşillik mevcudiyeti gibi faktörleri hesaba katan dikkatli bir işleme gerektirir. Drone görüntülerinde palmiye ağaçlarını sayma metodolojisi, Chowdhury ve ark. (2022) tarafından yazılan bir makalede açıklanmıştır.

Bir resimdeki baskın noktaları bulmak için yeni bir yöntem, genel gradyan vektörünün yönünü izleyerek uygulandı. Simetri oluşturmak için resim öğelerinin gradyan yönlendirmesi kullanıldı. Çalışmanın öncülü, ağaç dallarının gövdelerindeki yönüne bakılarak oluşturulmuştur. Çalışmadaki görüntü işlemede, diyagonal baskın noktalar başka bir diyagonal baskın nokta ile kesişene kadar uzatılmıştır. Modelin çıktı alanı, resimdeki tüm ağaçların geometrik merkezlerini kapsar. Karmaşık arka planların etkisini azaltmak için YOLOv5 mimarisinin sözde ilgi alanını ortadan kaldırma yeteneği araştırıldı.

Bu deęişiklięin bir sonucu olarak, hurma ailesinin tüm üyeleri, palmiye yaęı bitkileri de dahil olmak üzere, artık büyücülerin çetesine dahil ediliyor. Önerilen teknik, dron tarafından yakalanan resimlerden oluşan veri setindeki deneysel bulguların ve çeşitli bitkilerin otonom bir hava aracı tarafından çekilen hindistancevizi görüntülerinden oluşan altın standart veri setinin kanıtladığı gibi etkilidir. Kore'deki birçok çam ağacı kuraklıktan öldü. Drone resimlerinin, ölmekte olan bitkilerin erken bir aşamada tespit edilebilmesi için görüntü analiz yöntemleri kullanılarak işlenmesi gerekiyordu.

Drone tabanlı uzaktan algılama, Syifa ve ark. (2020) çam ağacı benzeri semptomlar sergileyen bitkileri belirlemek için. Dronlar, mükemmel görüntü netliği ve erişilebilirliği nedeniyle çam ağaçlarının uzaktan algılanması için kullanılmıştır. Sağlıklı ve hastalıklı çam ağaçlarının tespiti için drone ile çekilen fotoğraflar analiz edilerek arazi örtüsü haritası oluşturulmuştur. Bitki örtüsü hasarını kategorize etmek için yapay sinir ağları (YSA) ve destek vektör makineleri (SVM) kullanıldı. Verilerine göre SVM, solmuş bitkileri belirlemede YSA'dan daha iyi performans gösterdi. Bir GPS birimleri ağı bilgileri topladı. Çalışmada sunulanlar gibi görüntü analizini kullanan araştırma, ağaç kategorizasyonu için görüntülerin değerini gösterebilir. Her iki algoritma da sağlıklı ve zarar görmüş bitkileri belirlemek için görüntü verilerini kullanabilir.

Görüntü işleme uygulamalarının, özellikle dron görüntülerini içerenlerin yaygın olarak çoğalması göz önüne alındığında, dikkatleri görüntülerin uygun dijital kodlamasına yönlendirmek uygundur. Dijital verileri işlemek için bilgisayarlar, robotlar ve diğer cihazlar gibi makinelerin görüntüleri ve ilgili bilgileri kullanmasını sağlayan çeşitli teknikler geliştirilmiştir.

2.3. İHA Görüntüleri

İnsansız hava araçları İHA, içinde pilot bulunmasına gerek kalmadan uçuş yapabilen hava araçları kategorisidir. Uçağın kendisi, sensör yükleri ve bir yer kontrol istasyonu ile birlikte, insansız hava aracı sistemlerini oluşturan üç bileşendir. İHA'dan elde edilen bilgiler ve resimler çeşitli kullanımlara konur. İnsansız hava araçları (İHA), yüksek mekansal çözünürlüğe ve zamansal çeşitliliğe sahip bilgi sağlayan orman izleme için yaygın olarak kullanılmaktadır. Bu görüntüleri kullanarak orman tanımada spektral tepkileri analiz etmek için bir çalışma sunulmuştur (Gallardo-Salazar, 2023). Sensör donanımlı dronların avantajları, ağaç taçlarının çok bantlı görüntülerini sağlamalarını sağlar. İklimsel faktörlerin etkisini bir yıl boyunca analiz etmek için Meksika'daki çalışma alanı için veriler toplanır. Toplanan görüntüler, NASA meteorolojik deęişkenleri hakkındaki verilerle birleştirilir. Önerilen model, üç tür çalışma örneęi arasındaki

tutarsızlığı tespit edebildi. Doğrusal ilişki prosedürü, değişikliklerin iklim koşuluyla ne ölçüde ilişkili olduğunu belirlemek için yapılır. Bağıl nem ve sıcaklığın etkisi model tarafından tespit edildi. Daha karmaşık orman analizlerinde, diğer bitki örtüsü indekslerinin dikkate alınmasına ek olarak, hiperspektral sensörler ve LiDAR'ın birleştirilmesi gerektiği sonucuna varılmıştır.

Belirli bir alandaki ağaç taçlarını belirlemek ve ağaç yoğunluğunu değerlendirmek için sensörlerin kullanılması, orman ekosistemlerinin dinamiklerini anlamak için hızlı bir yöntem sunar. Bu analizler, biyoçeşitlilik ve ekosistemin korunması alanlarında büyük önem taşımaktadır. İnsansız hava araçları (İHA) tarafından elde edilen uzaktan algılama verileri ve RGB görüntüleri kullanılarak ağaç taçlarının tanımlanması ve taç alanının tahmini kolaylaştırılmaktadır (Gan ve ark., 2023). Bu çalışma, derin öğrenme modellerinden yararlanan yeni ve verimli bir yaklaşım sunmaktadır. İki derin öğrenmeye dayalı yaklaşımın, yani DeepForest ve Detectree2'nin potansiyeli, ağaç tacı algılama ve RGB görüntülerinden tanımlama bağlamında değerlendiriliyor. Modelin hava fotoğrafları, alpin ılıman yaprak döken bir ormanda insansız hava aracı (İHA) kullanılarak elde edilmiştir. Dört ağaç türü arasında toplam 499 dijital taç tahsis edildi. Elde edilen bulgulara göre, Detectree2'nin 0,52 F1 puanı alan DeepForest'e kıyasla daha yüksek bir F1 puanı olan 0,57'ye ulaştığı ve bu da üstün performans gösterdiği gözlemlendi.

Uzamsal çözünürlüğün ağaç tepesi algılama tahmininin doğruluğu üzerindeki etkisi, özellikle çözünürlük 0,1 m'yi aştığında belirgindi (Gan ve ark., 2023). Bu çalışmanın bulguları, değerlendirilen tekniklerin, yüksek çözünürlüklü optik görüntülerde tek tek ağaçların saçaklarını tespit etmede yüksek düzeyde yeterlilik gösterdiğini göstermektedir. Sonuç olarak, bu yöntemler, çeşitli orman ekosistemlerinde kullanılabilir yaklaşımlar sağlama konusunda umut vaat etmektedir.

Derin öğrenme yöntemleri, bireysel ağaç taçlarının bölünmesi ve sınıflandırılmasıyla ilgili çok sayıda çalışmada sıklıkla kullanılmaktadır. BlendMask kullanımı, kayda değer bir doğruluk düzeyiyle sınıflandırma sonuçları elde etmek için bir araştırma çalışmasında kullanıldı (Zhou ve ark., 2023). Bu çalışmada sunulan algoritma, örnek düzeyinde bilgileri sorunsuz bir şekilde entegre etmek için hem Mask R-CNN hem de Yolact'ın güçlü yönlerinden yararlanan modern ve etkili bir yaklaşımdır. Anlatının ortamı, karışık geniş yapraklı ormanların varlığıyla karakterize edilen heterojen bir ekosistem içinde gerçekleşir. Bu tekniklerin uygulanması, kron segmentasyonu ve sınıflandırma sonuçlarının kesinliğini büyük ölçüde artırır. Çin'de bulunan Jing Yue

orman sahasında gerçekleştirilen insansız hava aracı (İHA) görüntü alımında toplam üç iğne yapraklı tür ve beş geniş yapraklı tür kullanıldı.

Bulgular, bu çalışmada önerilen yöntemin test grubu içinde en yüksek katsayısı ve genel doğruluğu (%92,14) sergilediğini göstermektedir (Zhou ve ark., 2023). Çam da dahil olmak üzere çeşitli ağaç türleri için ortalama %90'ı aşan önemli düzeyde doğruluk elde edildi. Bu çalışmanın bulguları, BlendMask modelinin birden fazla ağaç türünün sınıflandırılmasına ve tek tek ağaç taçlarının segmentasyonuna uygulandığında olumlu sonuçlar verdiğini göstermektedir. Geniş yapraklı ormanların ve yüksek yoğunluklu kanopilerin aksine, bu model iğne yapraklı ormanlar ve orta ve düşük meşcere yoğunlukları ile karakterize edilen senaryolar için daha uygun olduğunu göstermektedir.

Bitki örtüsü fenolojisi, insansız hava aracı (İHA) görüntülerinin kullanımının kapsamlı bir şekilde dahil edildiği önemli bir çalışma alanı olarak ortaya çıkmıştır. İnsansız hava araçları (İHA) tarafından yakalanan görüntülerin analizi yoluyla ılıman ormanların ekosistemini anlamak amacıyla bir araştırma çalışması yapılmıştır (Ge ve ark., 2023). Yüzey yakınlık sensörlerinin mevcut gelişimi, kanopi ölçeğinde fenolojiyi etkili bir şekilde izlemek için insansız hava aracından türetilen göstergelerin sınırlı yetenekleriyle sonuçlanmıştır. Araştırma, 104 aşamada yaprak dökümünü gözlemlemek için verilerin bir yıl boyunca toplandığı Lős Platosu'nda gerçekleştirildi.

Bitki örtüsü indeksinin tespiti, araştırılan ağaçların yapraklarını analiz etmek için renk kanallarının kullanılmasını içerir. Ağaç tacı tespiti için ölçek, yeşil ve kırmızı renk koordinatları kullanılarak belirlenir. Genel olarak, bulgular, sonbahar ağaç tacı ölçeği fenotipik ölçümlerini doğru bir şekilde tahmin etme olasılığının güçlü olduğunu gösterdi. Ek olarak, sonuçlar topoğrafyanın vejetasyon tipi ve kompozisyonu üzerinde kontrol sağlayarak vejetasyon olgusunu dolaylı olarak etkilediğini öne sürdü (Ge ve ark., 2023). İHA'dan türetilen göstergelerin kullanılmasının, sonbahar örtüsünün fenolojisini büyük ölçekte etkin bir şekilde izlemede önemli bir potansiyele sahip olduğu iddia edilebilir.

Ancak bilgisayarlı görü teknolojisinin ilerlemesi ve insansız hava araçlarının (İHA) ortaya çıkması, araştırmacıların ağaç taçlarının tespiti ve tanımlanmasına yönelik çalışmalar yapabilmesini kolaylaştırmıştır. Taç genişliği ölçümü alanında, geleneksel manuel ölçüm tekniklerinin kullanılması hem zahmetli hem de maliyetlidir. Bu nedenle, *Metasequoia glyptostroboides*'ten taç genişliğini etkili bir şekilde çıkarmak için rafine edilmiş bir YOLOv7 modeli kullanıldı (Dong ve ark., 2023). Çalışma, Çin'deki Qingshan Gölü Ulusal Orman Parkı'nda bulunan *Metasequoia glyptostroboides* ormanına odaklandı. Bu ormandan toplanan veriler sistemde örnek olarak kullanılmıştır. YOLOv7

modelinin performansını optimize etmek için parametresiz dikkat modeli (SimAM) ve Yapısal Benzerlik İndeksi (SIoUs) adı verilen basit bir dikkat mekanizması kullanıldı.

Deneysel kanıtlar, modelin eğitim aşamasında konu dışı bilgilere odaklanmayı azaltma yeteneğine sahip olduğunu ve böylece genel doğruluğunu artırdığını göstermiştir (Dong ve ark., 2023). Araştırmacılar, SIoU (Segmentation Intersection over Union) kullanımının, tespit prosedüründe tespit çerçevesi ile hedef tacın sınırı arasındaki hizalamayı etkili bir şekilde geliştirebileceğini ve böylece taç genişliği ölçümlerinin kesinliğini iyileştirebileceğini gösterdi. Deneysel bulgular, geliştirilmiş modelin, orijinal modele kıyasla performansta %5'lik bir artış gösterdiğini göstermektedir. Taç genişliğinin orijinal modelden 0,151 kat daha büyük olduğu bulundu, bu da geliştirilmiş algoritmanın etkinliğini doğruladı.

2.4. Benzer Çalışmalar

Pek çok araştırma bu alanda çalışma ve geliştirmeyi içeriyordu ve araştırmalar, ağaçların drone ile çekilmiş resimlerini analiz etme ve inceleme üzerine çalıştığı için araştırmamızın fikrine benziyordu; ancak amaç bakımından farklılık gösterirler. Drone uygulamaları, orman yönetimi ve orman envanteri alanında giderek daha popüler hale geliyor.

Özellikle, bireysel ağaç tespitinde optik olarak türetilmiş drone tabanlı görüntü nokta bulutlarının (DIPC) kullanımı yaygınlaştı. Kotivuori ve ark. (2020), dron görüntülerini kullanan küçük alanlar için Orman envanterleri için bir makale sundu. Küçük arazilerde orman envanteri yapmanın fiyatının, numune arazilerin yerinde saha gözlemleriyle önemli ölçüde arttığını keşfettiler. Bu nedenle, bölgesel saha verilerini kullanmadan küçük ölçekli orman amenajman araştırmaları yapmanın mümkün olup olmadığını araştırdılar.

Tibia'nın boyutu, havadan lazer tarama verileriyle birleştirilmiş ulusal ve bölgesel güdük boyutlarının ABA modellerini kullanan eşleştirme ölçütleri kullanılarak tahmin edildi. Hücre seviyesinde, gövde boyutları tahmin edildi ve kesme testi için düzenlendi. ALS verilerinden elde edilen yükseklik ölçümleri ile DIPC verilerinden elde edilen baskın ağaç katmanının yükseklik ölçümleri arasında güçlü ilişkiler bulundu. İğne yapraklı ve yaprak döken ormanlar, Çoklu Veri Kaynaklarının Ulusal Orman Envanterinden alınan ek veriler kullanılarak stok grupları arasında ayırt edildi. ABA modelinin tüm ülke için eşdeğer kök ortalama kare hatası, fazla tahminle %20.0 idi.

Jintasuttisak ve ark. (2022), insansız hava aracı görüntülerinde derin sinir ağı tabanlı hurma ağacı tespiti üzerine bir araştırma sundu. Palmiye ağaçları, Arap

Yarımadası, Orta Doğu ve Kuzey Afrika bölgelerinde önemli ekonomik değere sahiptir. Palmiye ağacı miktarının ve yerleşiminin kesin olarak belirlenmesi, hurma verimini tahmin etmede ve tarımsal arazileri etkili bir şekilde yönetmede çok önemli bir husustur. Son teknoloji Konvolüsyonel Sinir Ağı (CNN) olan YOLO-V5'in kullanımının, drone monteli bir kamera tarafından elde edilen görüntülerde palmiye ağaçlarının tespitinde başarılı olduğu kanıtlanmıştır.

Veri setinin hazırlanma sürecinde toplam 125 adet görüntü rastgele seçilmiştir. Bu görüntüler daha sonra eğitim seti (%60), doğrulama seti (%20) ve test seti (%20) olmak üzere üç farklı veri setine ayrıldı. Palmiye ağacı görüntülerinin manuel açıklaması hem eğitim hem de doğrulama veri kümeleri için gerçekleştirildi. YOLO-V5 CNN'lerin dört alt versiyonu, eğitim veri setindeki palmiye ağacı görüntüleri kullanılarak eğitildi.

Eğitim sürecinde doğrulama için kullanılan veri seti, eğitim aşaması boyunca ağın performansının etkinliğini değerlendirmek için kullanıldı. Son olarak, eğitilen modeller, test veri setinin görüntüleri kullanılarak etkinlikleri açısından değerlendirildi.

Bu çalışma, YOLO-V3, YOLO-V4, SSD300 ve YOLO-V5 gibi çeşitli Konvolüsyonel Sinir Ağı (CNN) mimarilerinin drone görüntülerinde hurma ağaçlarını tespit etme performansının karşılaştırmalı bir analizini sunmaktadır. YOLO-V5'ten elde edilen sonuçlar, diğer CNN mimarileri ile hem nicel hem de nitel olarak karşılaştırılmıştır. Bulgular, kullanılan eğitim verilerinin miktarına bağlı olarak, YOLO-V5m (ortalama derinlik) modelinin en yüksek doğruluğu sergilediğini ve ortalama %92,34'lük bir ortalama doğruluk sağladığını göstermektedir.

Ek olarak, sıkışık ve kesişen çevrelerde ve hurma ağaçlarının dağılımının az olduğu bölgelerde, farklı boyutlardaki hurma ağaçlarını belirleme ve yerini belirleme yeteneği sağlar. Bu nedenle çalışma, yaklaşımın, hurma üretim hacimlerinin tahminini ve palmiye ağacı koşullarının gözetimini kolaylaştırarak, mekanize bir tarımsal yönetim çerçevesinin değerli bir bileşeni olarak hizmet etme potansiyeline sahip olduğu sonucuna varmıştır.

Ferreira ve ark. (2020), Amazon bölgesindeki palmiye ağaçlarının yeni bir haritasını oluşturmayı amaçlayan bir çalışma yürütmüştür. Palmiye ağaçlarının tropik ormanlardaki mekansal dağılımı, ticari kullanım ve yönetim amaçları için çok önemli bir husustur. Palmiye ağaçlarının varlığına ilişkin bilgilerin geleneksel yöntemlerle elde edilmesi zordur ve mekansal sürekliliği sınırlıdır. Amazon bölgesindeki palmiye türlerinin bireysel ağaç tepesi (ITC) seviyesinde haritalanması amacıyla yeni bir teknik geliştirildi. Bu yöntem, ucuz bir insansız hava aracı aracılığıyla elde edilen RGB

görüntülerin kullanılmasını içerir. (İHA). Metodoloji, tamamen evrişimli bir sinir ağı mimarisinin kullanılmasıyla elde edilen palmiye türleri derecelerinin kartografik temsillerinde yürütülen morfolojik prosedürler üzerine kuruludur.

Araştırmacılar başlangıçta belirlenen bölgeyi bölümlere ayırarak ve 4 cm piksel boyutunda RGB görüntülerde tasvir edilen her bir palmiye ağacını manuel olarak tanımlayarak sınıflandırılmış bir veri seti oluşturdu. *Attalea butyracea*, *Euterpe precatoria* ve *Iriarteia deltoidea* olmak üzere üç palmiye türü tanımlanmıştır. Yirmi iki parsel (%80) eğitim amacıyla rastgele seçilirken, test için altı parsel (%20) seçildi. Araştırmacılar, sınıflandırma doğruluğundaki değişkenliği ve modelin genelleme kapasitesini değerlendirmek için hem eğitim hem de test için kullanılan metodolojileri değiştirdiler. Yaklaşım, geleneksel semantik segmentasyonun ortalama doğruluğuna kıyasla %4,7 oranında üstün performans sergiledi. Ayrıca, yaklaşım, birbirine yakın ağaçları kapsama eğiliminde olan ortalama yüzde 34,7'lik bir noktayı doğru bir şekilde tanımladı.

Yaygın olarak Açai olarak bilinen ve Amazon bölgesinde yaygın olarak ticarileştirilen ve sömürülen bir palmiye türü olan *Euterpe precatoria*'nın taksonomik sınıflandırması, en yüksek hassasiyet düzeyine yükseltildi.

İnsansız hava araçlarında (İHA'lar) ve ilgili sensör sistemlerindeki son gelişmeler, bu platformları uzaktan algılama topluluğu için giderek daha çekici hale getiriyor. Malek ve ark. (2014), palmiye ağacı tespitini belirlemek için bu bileşiklerde kullanılacak yetenekler üzerinde çalıştı. Bu görüntülerde belirgin olan kapsamlı uzamsal çözünürlük, gelişmiş izleme uygulamaları için fırsatlar sunar. SIFT, bir palmiye ağacından elde edilen bir insansız hava aracı görüntüsünden bir dizi kilit noktayı çıkarmak için kullanılır. Daha sonra, yukarıda belirtilen kilit noktalar hem avuç içi hem de avuç içi olmayan anahtar noktalardan oluşan bileşik bir veri kümesi üzerinde önceden eğitilmiş bir Ekstrem Öğrenme Makinesi (ELM) sınıflandırıcı aracılığıyla analize tabi tutulur. ELM sınıflandırıcısı, farklı anahtar noktalara dayalı olarak bireysel palmiye ağaçlarının tanımlanmasını üretecektir. Her bir ağacın şeklini yakalamak için kilit noktaları birleştirmek üzere Düzey Gruplarına dayalı aktif kontur yöntemi kullanılmıştır. (LS'ler). Bu çalışma, LS yoluyla elde edilen bölgelerin dokusunun bir analizini gerçekleştirdi. Bu analiz, palmiye ağaçlarını diğer bitki türlerinden ayırmak amacıyla yerel ikili modeller (LBP'ler) kullanılarak yapılmıştır. Önerilen çerçeve, deneysel sonuçlarla doğrulandığı gibi, iki farklı çiftlikten elde edilen 3,5 cm uzamsal çözünürlüğe sahip İHA görüntülerini analiz etmede umut verici yetenekler göstermiştir.

3. MATERYAL VE METOT

3.1. Çalışma Metodu

Doğal ormanların korunması, küresel ekosistemde çok önemli bir rol oynadıkları için çevre için çok önemlidir. Ne yazık ki, ormanların refahını tehdit eden bir dizi faktör var. Bu programın ilk adımı orman izleme olmalıdır. Orman koruma izlemesinin en etkili yollarından biri, RS verilerinin kullanılmasıdır. Orman izleme verilerinin zamanında analizini yapmak için yöntemlerin seçimi de önemlidir. Orman poligonlarının büyük boyutu ve incelenen ulaşılması zor yerler, elle sayma ve ağaçların tek tek tespiti gibi saf manuel analizlerin kullanılmasına izin vermez. İnsansız hava araçlarının (İHA) seri üretime geçmesinden bu yana, bilim insanlarının çok yüksek uzamsal çözünürlüğe sahip yerel alan görüntüleri toplaması mümkün hale geldi (Jiang ve ark., 2020).

Ancak büyük bilgi dizilerini işleme sorunu devam etti. Özellikle, insansız hava araçlarından elde edilen büyük miktarda sıralanmamış RS verilerinin yoğun kaynak gerektiren işlenmesi, ağaç türü hakkında bir uzman görüşü ve belirli bir taç bütünlüğü durumuna sahip örneklerin manuel olarak sayılmasını içerebilir. Ancak son zamanlarda derin sinir ağlarının [OnIs21, SGMA21, STAR19] kullanımıyla bu tür sorunların etkin bir şekilde çözülebileceği gösterilmiştir (Safonova, 2021).

Hurma ağaçlarının sayılarının tespit edilerek yoğunluk alanlarının keşfedilmesi hurma üretiminin yönetimi açısından önemli bir konudur. Bu ağaçlar, Amazon bölgelerinin yanı sıra Ortadoğu ülkeleri de dahil olmak üzere dünyanın birçok bölgesine dağılmıştır. Ve bu ağacın bilgisini elde etmek için ilkel klasik yöntemleri kullanarak, çok fazla insan gücü tasarrufu ve zaman kaybının yanı sıra elde edilen doğru bilgi yüzdelerinin düşük olması nedeniyle birçok zorlukla karşılaşılıyor (Fernández, 2003). Ve dronlarla görüntüleme yeni teknikler kullanılarak, bir palmye ağacı haritası hazırlanabilir ve daha derin ve daha doğru bir şekilde incelenebilir. Drone aracılığıyla elde edilen ve eğitim ve test için gruplara ayrılan görüntüler sayesinde, bitki yoğunluğu ve ağaçların ve diğer tarım alanlarının bozulma yüzdeleri ışığında palmye ağaçlarının keşfedilmesi ve sayılması için gelişmiş sonuçlar elde etmek mümkündür. Drone'ların sağladığı verilerdeki büyük gelişme ve sensör sistemlerinin geliştirilmesindeki teknolojik ilerleme, palmye ağaçlarının izlenmesi, yönetimi ve keşfi uygulamalarında büyük fırsatlar elde ediyor.

Palmye ağaçlarına dikkat çekmek ve bu karlı sektöre yatırım geliştirmek için çalışan birçok ülke için palmye ağaçları milli bir servettir (El-Juhany, 2010). Çalışmalar

sağlamak ve dronlar tarafından çekilen görüntülerde hurma ağaçlarını keşfetmek için derin sinir ağına güvenmek, hurma üretiminde ilerleme sağlar. Bu nedenle palmye ağaçlarını kapsayan alanlara ve bunların yetiştirildiği alanlara çevre açısından doğru erişim ve gerekli kaynakların mevcudiyeti, üretimin geliştirilmesi ve dolayısıyla elde edilen kazancın yanı sıra birçok farklı türün geliştirilmesinde önemli faktörler arasındadır. Gelişmiş evrişimli sinir ağlarının kullanımı, uçak görüntülerinden palmye ağaçlarının tespitinin başarı oranlarını artırır. İyi gelişmiş bir evrişimli sinir ağı olan YOLO-V5 bu konuda kullanılabilir. Drone'lardan elde edilen görüntü grupları üzerinde bir çalışma yapmak için bu verileri üç bölüme ayırmak gerekir: eğitim bölümü, doğrulama bölümü ve test yapmak için bölüm.

Eğitim operasyonları sırasında bu ağıın kapasitesi ve verimliliği hakkında bir çalışma yapmak için eğitim bölümündeki görüntüler üzerinden eğitim işlemleri yapılırken ve doğrulama için kullanılan verilerin doğrulanması yapılırken. Son aşamada ise test bölümündeki görseller üzerinden eğitilen modellerin etkinliği değerlendirilmektedir. Bu ağ, farklı yerlerdeki belirli ağaçlara ulaşmada ve yüksek bitki ve ağaç yoğunluğunun varlığında ve diğer ağaç türleri ile örtüştüğünde yüksek doğruluk oranları gösterdiğinden, palmye ağaçlarının doğru tespitini gerçekleştirmede başarılı olduğunu kanıtlamıştır (Hu ve ark., 2014).

Bu mimarilerin karşılaştırmasının sonuçlarını sunduk ve enfekte ağaçları tespit etme görevi için en iyi YOLO modelini belirledik. Bu bölümün başlıca katkıları şu şekilde sıralanabilir:

- Ağaçların tespiti için yeni bir veri seti oluşturduk.
- Veri kümemize hızlı bir şekilde açıklama eklemek için yeni bir açıklayıcı oluşturduk.
- Görüntülerin kalitesini iyileştirmek ve dolayısıyla algılama modelinin genelleme kapasitesini artırmak için ön işleme prosedürü uyguladık.

DL kullanarak ERS verileri üzerinde ağaç algılama sorunlarına ayrılmış ilgili çalışmaları göz önünde bulundurarak. Nesne algılama, bir sınıfın belirtilen tüm nesnelere yerleştirme ve her biri için bir sınırlayıcı kutu oluşturma görevidir. Yapay sinir ağlarına dayalı akıllı sistemler, bitki tanıma [BoWL20] problemlerini başarıyla çözebilir. Bu sorunları çözmeye yönelik daha geleneksel başka yaklaşımlar da vardır, ancak bunlar sınırlı koşullar dışında gerekli esnekliğe sahip değildir [OJRJ21, ZTMX17].

Yapay sinir ağları umut verici alternatif çözümler sunar ve birçok uygulama bunların kullanımından yararlanır. Aşağıda ormancılık sektöründeki nesne algılama

görevlerinin problemimize en yakın olan DNN ile ERS verileri üzerinde çözülmesine yönelik çalışmalar yer almaktadır. [XATR20] çalışmasında, önceden eğitilmiş bir YOLO modeli kullanan yazarlar, 91'e kadar ortalama bir doğruluk elde edebildiler. İHA ile elde edilen VHR görüntülerinde etkilenen çam ağaçlarının tespitinde %82. Bu çözüm sayesinde, etkilenen ağacın yerini çeşitli havadan görüntüler üzerinde belirlemek mümkün hale geldi. Başka bir çalışmada [QGWC20], yazarlar benzer bir sorunu, AlexNet ve GoogLeNet'in CNN'lerini kullanarak İHA verilerinde ölü bir çam ağacını maksimum %97,38'e varan doğrulukla tespit etme sorununu ele aldılar.

Tao ve ark. [TLZD20]'de, DJI Mavic 2 pro drone verileri ve CNN'lere dayalı DL tekniği ile böceklerden zarar görmüş ağaç tespiti (ölü köknar, hasta köknar, sağlıklı köknar, yaprak döken ağaçlar, çimen ve açıkta kalan) gerçekleştirdi. Önceki çalışmamızda [STAR19], DL ile İHA görüntülerinde Polygraphus Proximus Blandford kabuk böceği tarafından zarar görmüş dört kategorideki köknar ağaçlarını (Abies Sibirica) tespit edebildik. Bununla birlikte, İHA görüntülerinde tek tek ağaçları tespit etme problemini kendi algoritmamızı kullanarak çözdük ve ardından tespit edilen yamaları üç ağaç kategorisinden birine ait olarak sınıflandırdık: a—tamamen sağlıklı ağaç, b—kolonize edilmiş ağaç, c—yakın zamanda ölü ağaç veya ölü ağaç.

Son adımda, bu sorunu çözmek için özel olarak tasarlanmış yeni bir CNN mimarisi önerdik. Geliştirilen mimarinin VGG, ResNet, Inception-V3, InceptionResNet-V2, Xception ve DenseNet gibi modellerle karşılaştırmasını da sunduk. Veri artırma ile eğitilen modelimizin palmye ağaçları için %98,77'ye varan doğruluk gösterdiğine dikkat etmek önemlidir.

3.2. Veri Seti

Hurma ağacı, insanın yetiştirmekle ilgilendiği en eski ağaçlardan biri olarak kabul edilir (Alawar ve ark., 2009) ve tarihsel kaynaklar bunun itibarının, Mezopotamya Vadisi'ndeki ülkelerde bu ağacı diken ve meyveleri üzerinde yaşayan Sümerlere ait olduğunu ileri sürmektedir. 3000 yıldan fazla bir süre önce M.Ö. O zamandan beri, palmye bahçeleri geniş bir alana yayıldı ve çok sayıda Farklı çeşidi var, ta ki mahsul, nüfus için birincil gıda kaynaklarından biri haline gelene kadar.

Çeşitli yerlerdeki farklı çevresel koşullar nedeniyle, bu ağaçların ekonomik önemi kıtadan kıtaya ve ülkeden ülkeye farklılık gösterir. Şu anda, bu ağaçlardan (100) milyona yakın var (Mathijsen, 2021). O ilk zamanlardan beri hurma yetiştiriciliğinin Basra Körfezi bölgesine yayılması, hurma ağacının bu bölgeden geldiğini göstermektedir. Güney Afrika, Avustralya, Amerika ve güney Avrupa'nın bir kısmı dahil olmak üzere

ekvatorun 10 ve 35 kuzey enlemleri arasındaki tropikal ve subtropikal bölgelerde bazı tarih öncesi palmiye türleri yaşıyordu. Bu bölgeler doğuda Pakistan'daki Vadi'den batıda Atlantik Okyanusu'ndaki Kanarya Adaları'na kadar uzanıyordu. 10. enlem ve 35. enlemin kuzeyi, ancak kıttır ve küçük bir ekonomik etkiye sahiptir.

Bu ağacın önemi ve ekonomik değeri nedeniyle, Şekil 3.1'de gösterilen görüntülere benzer dronlar aracılığıyla elde edilen verileri kullanarak, onu keşfetmenin ve özelliklerini incelemenin yollarına ilişkin bir çalışma ve analiz yapacağız.



Şekil 3.1. Veri kümesi görüntüleri örneği

Palmiye çiftliklerinin farklı alanlarından, farklı yüksekliklerden ve palmiye ağaçları dışında pek çok türün yer aldığı farklı ağaç yoğunluk alanlarından drone ile alınan görüntülerin toplanmasıyla veri seti kullanılmıştır. Palmiye ağaçlarını keşfetmek için önerilen yaklaşımı test etme amacı Hazırlanışını, özelliklerini ve başarılı tarımı yönetmemizi ve iyi sonuçlar almamızı sağlayan birçok avantajı bilmek

3.3. Çalışma Alanı

Çalışma, Irak'ın Salah Al-Din Valiliği'nde gerçekleştirildi. Selahaddin Valiliği, tarımsal zenginliğe dayalı en önemli vilayetlerden biri olarak kabul edilir ve ağaç bakımından zengin olan en büyük vilayetlerden biridir. Palmiye ağaçları başta olmak üzere ağaç dikilmiş geniş alanlar vardır. Bu ildeki yerel nüfus, hurma üretimine ve ticaretine ve bu yerel ürünün büyük ekonomik değerinden yararlanılmasına bağlıdır.



Şekil 3.2. Çalışma alanı-Salahaldeen, Irak (Anonim, 2023)

Bu ağaçların modern teknolojiler kullanılarak korunması ve bakımı, dronlar tarafından ve farklı alanlarda hava fotoğrafları kullanılarak çok gereklidir. Bu görüntüler, ağaçların kalitesi hakkında doğru raporlar sağlamak ve ekili alanları analiz etmek için görüntü işleme sistemlerine girdi olarak kullanılır.

3.4. Veri Bölme

Çoğu durumda, veriler iki farklı alt kümeye ayrılır: eğitim verileri ve test verileri (ve bazen üçe: eğitime, doğrulama ve test etme). Modelin eğitiminde kullanılan gerçek veriler, eğitim veri seti olarak adlandırılır (Sinir Ağı durumunda ağırlıklar ve eğilimler). Bu veriler dikkate alınır ve modelin kararlarını bildirmek için kullanılır. Test veri seti, nihai modelin eğitim veri setindeki verilere ne kadar iyi uyduğunun objektif bir analizini yapmak için kullanılan eğitim veri setinin alt kümesidir. Doğrulama veri kümesi, model hiper parametrelerini değiştirirken bir modelin eğitim veri kümesine uygunluğunun tarafsız bir değerlendirmesini sunmak için kullanılan veri örneği olsa da, burada yapılan değerlendirme sıklıkla yapılan bir değerlendirme değildir.

Toplam örnek sayısının yanı sıra gerçek eğitim modelinin her ikisi de bölme oranını belirlemede rol oynar. Tren/test ayrımı, scikit-model selection learning paketinin train test split sınıfı kullanılarak 75:25 oranında gerçekleştirildi. Verilerin yüzde yetmiş eğitim setine, kalan yüzde otuzu ise doğrulama setine ayrıldı. Aynı mülkte çekilmiş birçok fotoğrafla modeli test edeceğiz. Bu oranın optimum olduğuna inanılmaktadır.

Test veri setinde, sklearn'den cross-Val skor işlevi. Doğruluk puanının analizini yapmak için bir çapraz doğrulama paketi kullanıldı. Verilerin yüzde yetmiş eğitim setine, kalan yüzde otuzu ise doğrulama setine ayrıldı. Aynı mülkte çekilmiş birçok fotoğrafla modeli test edeceğiz. Bu oranın optimum olduğuna inanılmaktadır. Test veri setinde, sklearn'den cross-Val skor işlevi. Doğruluk puanının analizini yapmak için bir çapraz

doğrulama paketi kullanıldı. Verilerin yüzde yetmiş eğitim setine, kalan yüzde otuzu ise doğrulama setine ayrıldı. Aynı mülkte çekilmiş birçok fotoğrafla modeli test edeceğiz. Bu oranın optimum olduğuna inanılmaktadır. Test veri setinde, sklearn'den cross-Val skor işlevi. Doğruluk puanının analizini yapmak için bir çapraz doğrulama paketi kullanıldı.

3.5. Derin Sinir Ağı

Modern veri analizi ve sınıflandırma yöntemlerinde genellikle Derin Sinir Ağları kullanılır. En popüler DNN türlerinden ikisi Konvolüsyonel Sinir Ağı (CNN) ve Tekrarlayan Sinir Ağı'dır (RNN) (Yin ve ark., 2017). Çabaları nedeniyle veri analizi alanında birçok çığır açan ilerleme kaydedildi. Bir sonraki bölüm, Uzun-Kısa-Bellek (LSTM) algoritmasına vurgu yaparak, evrişimli sinir ağlarının (CNN'ler) ve tekrarlayan sinir ağlarının (RNN'ler) nasıl çalıştığını açıklayacaktır. Yöntemler, etiketli verilerin ikili sınıflandırmasına odaklandıkları için model için seçilmiştir. Evrensel olarak uygulanabilir her derde deva bir çözüm olmadığı için Yapay Sinir Ağı ve Konvolüsyonel Sinir Ağı gibi derin öğrenme modelleri de teste tabi tutuldu. Bu özel makine öğrenimi mücadelesi için Rastgele Ormanda (RF) karar kıldık. CNN, Yapay Sinir Ağları (ANN), K-En Yakın Komşular (KNN), Lojistik Regresyon (LR), Gauss Naive Bayes ve Destek Vektör Makinesi (SVM), makine öğrenimi tekniklerine (CNN) örnektir. Algoritmaların tüm çıktıları, görev için en etkili sınıflandırıcıyı bulmak için karşılaştırıldı (Williams ve ark., 2012).

3.5.1. Konvolüsyonel sinir ağı

Bir CNN modeli, standart bir sinir ağına doğrusal dönüşümü ekleyerek, girdiden yerel ve genel özellikleri çıkararak ağı karar verme sürecini geliştirebilir. Evrişimli bir katmanın yanı sıra, işlemi üzerinde ayrıntılı kontrol sağlamak için bir CNN ağına birkaç ara katman dahil edilmiştir. Onlar hakkında daha fazla bilgi aşağıda verilmiştir. Görüntü ve video tanıma, tavsiye sistemleri, görüntü sınıflandırma, tıbbi görüntü analizi ve doğal dil işleme, CNN derin öğrenme modelinin en yaygın uygulamalarından bazılarıdır.

Diğer görüntü sınıflandırma algoritmalarının aksine, CNN'ler kullanıma sunulmadan önce çok az ön işleme ihtiyacı duyar. CNN'ler, diğer sinir ağları türlerinden biraz farklıdır. Başlangıç olarak, katmanlar 3 boyutlu bir yapıya sahiptir, yani bir düzlem üzerinde ve ayrıca dikey ve yatay düzlemlerde düzenlenirler. Ayrıca, farklı katmanlardaki nöronlar arasında sadece sınırlı bir bağlantı vardır. Bu katmanların en yaygın türleri, tüm verilere özgü özellikleri öğrenmek amacıyla girdiyi değiştirmek için işlemler

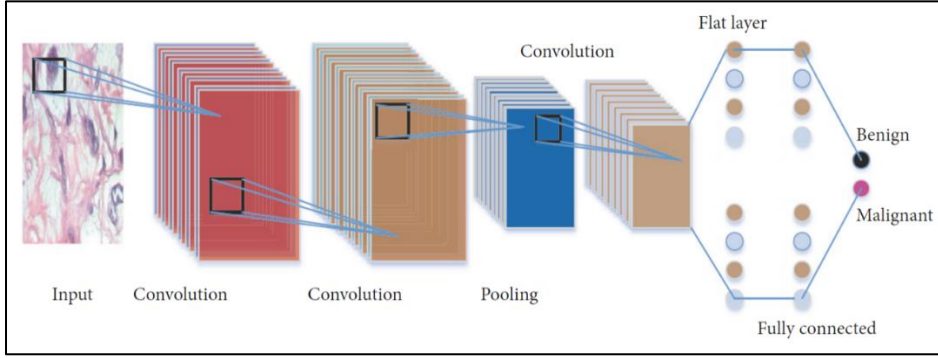
gerçekleştiren evrişim katmanı, aktivasyon veya ReLU katmanı ve havuzlama katmanıdır (Yang ve ark., 2016).

Algoritmanın son çıktısı, görüntüdeki ögenin tahminle eşleşme olasılığına göre basitleştirilecektir. Bu araştırmada, evrişimli bir sinir ağı modeline girdi olarak hizmet etmesi için malzemeyi üç boyuta dönüştürdüm. Küçük örneklem büyüklüğü nedeniyle şüphencilik ortaya çıksa da bulgular aksini kanıtladı (Zhang ve Wu, 2019). Farklı katmanlardaki nöronlar arasında yalnızca sınırlı bir bağlantı vardır. Bu katmanların en yaygın türleri, tümü verilere özgü özellikleri öğrenmek amacıyla girdiyi değiştirmek için işlemler gerçekleştiren evrişim katmanı, aktivasyon veya ReLU katmanı ve havuzlama katmanıdır (Yang ve ark., 2016). Algoritmanın son çıktısı, görüntüdeki ögenin tahminle eşleşme olasılığına göre basitleştirilecektir. Bu araştırmada, evrişimli bir sinir ağı modeline girdi olarak hizmet etmesi için malzemeyi üç boyuta dönüştürdüm. Küçük örneklem büyüklüğü nedeniyle şüphencilik ortaya çıksa da, bulgular aksini kanıtladı (Zhang ve Wu, 2019).

Farklı katmanlardaki nöronlar arasında yalnızca sınırlı bir bağlantı vardır. Bu katmanların en yaygın türleri, tümü verilere özgü özellikleri öğrenmek amacıyla girdiyi değiştirmek için işlemler gerçekleştiren evrişim katmanı, aktivasyon veya ReLU katmanı ve havuzlama katmanıdır (Zhang ve Wu, 2019). Algoritmanın son çıktısı, görüntüdeki ögenin tahminle eşleşme olasılığına göre basitleştirilecektir. Bu araştırmada, evrişimli bir sinir ağı modeline girdi olarak hizmet etmesi için malzemeyi üç boyuta dönüştürdüm. Küçük örneklem büyüklüğü nedeniyle şüphencilik ortaya çıksa da bulgular aksini kanıtladı (Yang ve ark., 2016). Bunların tümü, verilere özgü özellikleri öğrenmek amacıyla girdiyi değiştirmek için işlemler gerçekleştirir. Algoritmanın son çıktısı, görüntüdeki ögenin tahminle eşleşme olasılığına göre basitleştirilecektir.

Bu araştırmada, evrişimli bir sinir ağı modeline girdi olarak hizmet etmesi için malzemeyi üç boyuta dönüştürdüm. Küçük örneklem büyüklüğü nedeniyle şüphencilik ortaya çıksa da bulgular aksini kanıtladı (Zhang ve Wu, 2019). Bunların tümü, verilere özgü özellikleri öğrenmek amacıyla girdiyi değiştirmek için işlemler gerçekleştirir.

Algoritmanın son çıktısı, görüntüdeki ögenin tahminle eşleşme olasılığına göre basitleştirilecektir. Bu araştırmada, evrişimli bir sinir ağı modeline girdi olarak hizmet etmesi için malzemeyi üç boyuta dönüştürdüm. Küçük örneklem büyüklüğü nedeniyle şüphencilik ortaya çıksa da bulgular aksini kanıtladı (Zhang ve Wu, 2019). Şekil 3.3, CNN diyagramını sunar.




Şekil 3.3. Bir konvolüsyonel sinir ağının iş akışı (Prabhu, 2018).

3.5.2. Evrimsel katman

Bu CNN modeli, birincil avantajı olarak görülen A'ya büyük ölçüde güvenmiştir. Çekirdek, evrişim katmanının birincil bileşenidir. Tüm girdi verilerini analiz etmekten ve bunlardan genel özellikler türetmeye çalışmaktan sorumludur. Adım, bir çekirdeğin her yineleme sırasında tamamladığı toplam adım sayısını ifade eder. Hatalı adım adımlarını ve boyutunu seçmemiz durumunda, sınır satır ve sütun konumlarının doğru şekilde bükülmemesi mümkündür.

Tamamen sıfırlarla doldurulmuş ek satırlar ve sütunlar ekleme işlemine sıfır dolgusu denir. Bu, evrişim işleminin tam olarak sınırdaki gerçekleştirilebilmesi için yapılır. Konvolüsyonel model, özelliklerle ilgili önemli miktarda bilgi üretir (Lu ve ark., 2022).

Model yapısı genişledikçe özellik bilgilerinin miktarı da artar, bu da modelin bilgi işlem karmaşıklığını artırır ve onu çok daha hassas hale getirir. BioMed Araştırma Kuruluşu, bir CNN modeli için geliştirilmiş bir havuzlama tekniği örneği Şekil 3.4'te gösterilmektedir.




Şekil 3.4. 2x2 çekirdek tarafından gerçekleştirilen havuzlama işlemi (Green ve ark., 2022)

Dört farklı türde havuzlama işlemi mevcuttur:

- (a) Maksimum Havuzlama
- (b) Ortalama Havuzlama
- (c) Karma maksimum ortalama havuzlama
- (d) Geçitli maksimum ortalama havuzlama.

Yönetilmesi gereken çok sayıda nöronla, bir DNN, birçok farklı öngörüü hesaba katan bir yola yönelebilir. Sonuçlar eğitim setinde mükemmel, ancak bu meydana geldiğinde test setinde sıkıntı yaşıyor. Bu meydana geldiğinde aşırı uyum sorunu söz konusu olabilir. Ayrılma süreci, bu belirli sorunu çözmek için oluşturulmuştur. Şekil 3.5, okulu bırakma hakkında daha fazla bilgi gösterir.



Şekil 3.5. Bırakma şeması (Zeng ve ark., 2017)

Bırakma mekanizmasının temel bir versiyonu Şekil 3.5'te görülmektedir. Sağ taraftaki resimde 1'den 4'e kadar numaralandırılmış dört gizli nöron görünürken, sol taraftaki resimde 2 ve 4. nöronlar ağıın nihai kararına katkıda bulunmamaları için elenmiştir. Sonunda, bir ağdaki nöronların tümü düz ve tekdüze bir şekilde düzenlenecektir. Düz katmanın tüm nöronları, tıpkı normal bir sinir ağıında olduğu gibi birbirleriyle ve üstlerindeki katmanla iletişim kurar. Pek çok tamamen bağlantılı katmanın uygulanması yaygın bir uygulamadır. En son katmanı "son" katman olarak düşünüyorsanız, sonuncusundan önce en az bir düz katmana veya tamamen bağlantılı katmana ihtiyacınız vardır.

3.5.3. Destek vektör makinesi

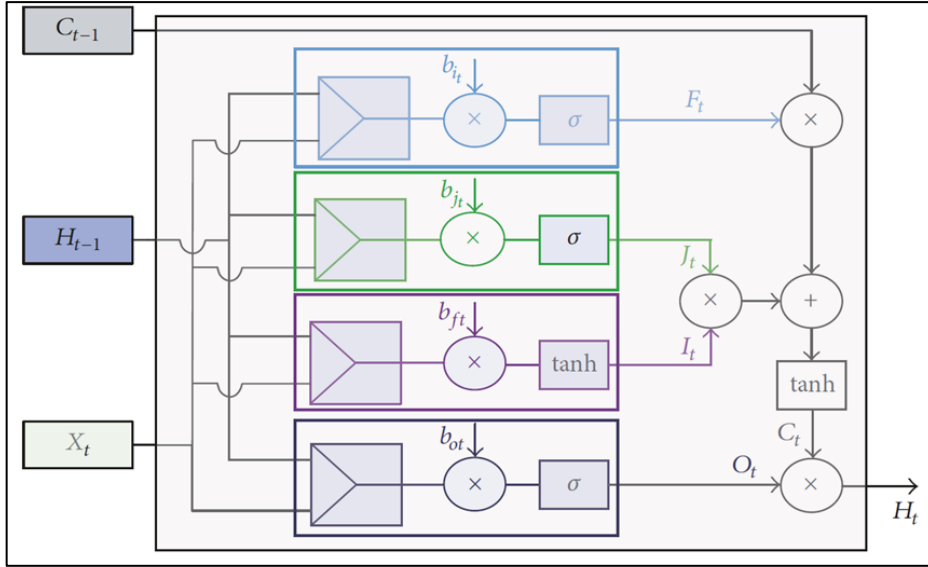
Destek vektör makinesi (SVM), özellikle veri kümesinin yalnızca iki farklı sınıf içerdiği durumlarda, örüntü tanımlama ve sınıflandırma konularında yaygın kullanım bulan denetimli bir makine öğrenme algoritmasıdır (Sonntag ve ark., 2012). SVM'ler,

sınıfları bölen ideal hiperdüzlemi bulma sürecinde kullanılır. Sınıflandırıcı, özellik vektörü olarak da bilinen bir girdi deseni alır ve bunu, desenin hangi sınıfa atanması gerektiğine karar vermek için kullanır. Yalnızca doğrusal olarak ayrılabilen verilerin sınıflandırılmasında etkilidir, ancak pratikte özellik vektörleri doğrusal olarak ayıramaz. Bu sorun çekirdek tekniği kullanılarak çözülebilir. Destek vektör makinesi (SVM), çekirdek tekniklerini kullanarak girdi verilerini daha yüksek boyutlu verilere eşleyen bir makine öğrenme tekniğidir. Aynı zamanda hızlı bir eğitim yaklaşımı sunar.

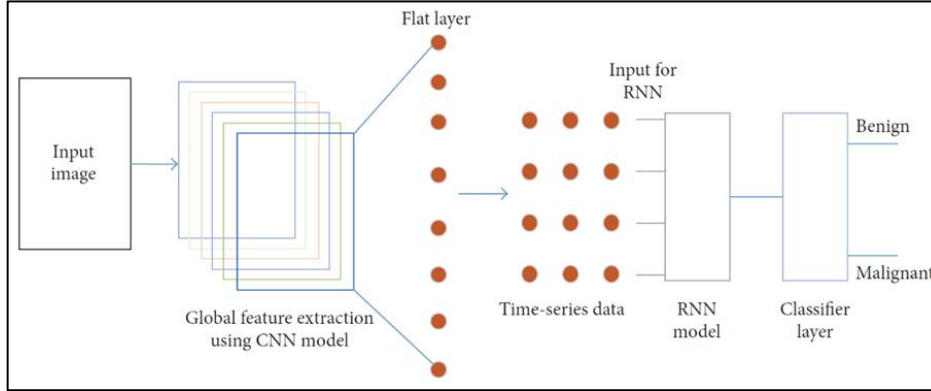
Örüntü sınıflandırması ve regresyon analizi bunun için iki uygulamadır (Hilker ve ark., 2010). Uygun çekirdek işlevinin seçilmesinin, bir SVM sınıflandırıcısının performansı üzerinde önemli bir etkisi olabileceğini not etmek önemlidir. Eldeki sınıflandırma problemine bağlı olarak, uygun çekirdek işlevi seçilecektir. Bu projede SVM'yi uygulamak için Scikit-learn'de bulunan SVC sınıfı kullanılmıştır. Öte yandan, SVM'ler çok fazla belleğe ihtiyaç duyabilir ve anlaşılması ve ayarlanması zor olabilir. Uygun çekirdek işlevi seçilecektir. Bu projede SVM'yi uygulamak için Scikit-learn'de bulunan SVC sınıfı kullanılmıştır.

3.5.4. CNN-LSTM

CNN, dünyanın her yerinden bilgi toplama avantajına sahiptir. Öte yandan, Uzun Kısa Süreli Bellek (LSTM) modeli, veri modellerinde var olan uzun vadeli bağımlılıklardan faydalanabilir. CNN ve LSTM modelleri, sınıflandırma amacıyla birlikte hibritlenmiştir (Schepaschenko ve ark., 2017). Bu, bu faydaların her ikisinin de kullanılabilmesi için yapıldı. Ağın veriler içindeki ilişkileri çıkarabilmesi için gerekli olan bilgiyi zaman serisi formatına dönüştürmek için CNN modelinin çıktısından yönsüz bir grafik oluşturmak zordur. Bunu yapmak için, önce başlangıçta iki boyutlu olan evrişimli çıktıdan verilerin boyutunu küçülttük. LSTM ve CNN modellerinin temel mimarisi aşağıda Şekil 3.6 ve 3.7'de gösterilmiştir (Kwenda ve ark., 2022).



Şekil 3.6. Bir LSTM'nin genelleştirilmiş hücre yapısı.




Şekil 3.7. CNN ve LSTM modelleri birleştirildi

3.6. Sinir Ağı Katmanları

Her ağın yalnızca bir girdi katmanı vardır ve her ağın yalnızca bir çıktı katmanı vardır. İşlenmekte olan verilerdeki giriş değişkenlerinin miktarı, giriş katmanında bulunan nöronların sayısı ile orantılıdır. Her girdi ile bağlantılı çıktuların sayısı, çıktı katmanında bulunan nöronların sayısına eşittir. Ancak zorluk, gizli katmanların ve onları oluşturan nöronların sayısını belirlemektir (Galiatsatos ve ark., 2020). Girdi katmanının yaptığı tek şey, bilgiyi gizli düğümlere iletmektir; kendisi herhangi bir hesaplama yapmaz. Gizli katmanda ise hesaplamalar yapılır ve bilgiler girdi düğümlerinden çıktı düğümlerine taşınır. Bir ağın yalnızca bir girdi katmanı ve bir çıktı katmanı olmasına rağmen, çok sayıda gizli düzeyi olması mümkündür.

Çıktı katmanı, hesaplamaları ve ağdan bu katmandan sorumlu olan dış dünyaya bilgi aktarımını gerçekleştirir. Evrişimli katmanlar, havuzlama katmanları, tamamen

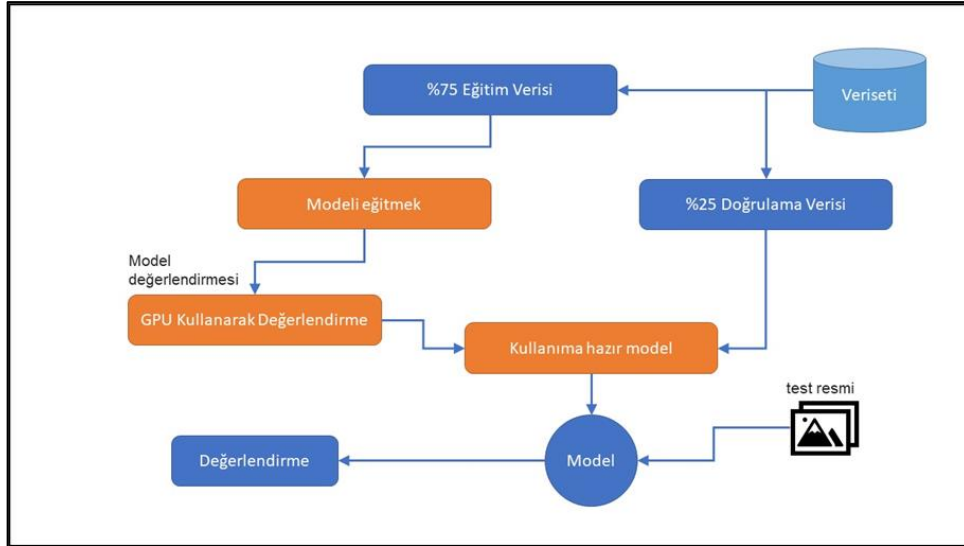
bağlantılı katmanlar ve normalleştirme katmanları tipik olarak bir Evrişimli Sinir Ağı'nın gizli katmanlarını oluşturan bileşenlerdir. Bu çalışmada sunulan CNN ve ANN modellerinin her biri, birkaç gizli katmandan ve ReLU, Sigmoid ve Softmax gibi aktivasyon fonksiyonlarından oluşan kendi benzersiz katman setine sahiptir. Şekil 3.8, değiştirilmiş RNN modelini sunar.



Şekil 3.8. RNN çıktısının üretildiği ve referans verilerinin gizli nöron aracılığıyla beslendiği, RNN modelinin değiştirilmiş bir versiyonu (Islam ve ark., 2018).

3.7. Önerilen Model

Benzer araştırmalardaki önerilere dayanarak ve bu alanda bütünleşik bir model oluşturmak için önerilen modelimizi Şekil 3.9'daki gibi oluşturuyoruz. Veri kümesindeki görüntüleri okuyoruz ve sonraki adımlar görüntüleri ön işlemeyi içeriyor. Drone'lar tarafından çekilen görüntüler genellikle aynı doğrulukta ve verimlilikte değildir. Fotoğrafların bir kısmı aydınlatma, hava koşulları veya hava kirliliği açısından iyi olmayan koşullarda çekilmiş olabilir.



Şekil 3.9. Önerilen model diyagramı

Bir sonraki adımda, veriler daha önce gösterilen oranlarla iki parçaya bölünür. Veri setinin %75'i önerilen modelin eğitimi, %25'i doğrulama ve test amaçlıdır. Bu yöntem, elde edilen oranlarda ve sonuçlarda verimlilik ve yüksek doğruluk ile karakterize edilen modellerde verileri bölmek için kullanılır.

Doğru raporlar elde etmek için kullanılacak akıllı modeller oluşturmak, çok doğru bir model oluşturmayı gerektirir. Önerdiğimiz sistemin doğruluğu, bir havadan görüntü işleme modeli oluşturmayı içeren GPU kullanımı da dahil olmak üzere çeşitli yöntemler kullanılarak ölçülür. Modeli eğitmek için kullanılan görüntüler elde edildikten ve eğitildikten sonra model düzeltme aşamasına girer; bu aşamada veri seti görüntü kısmından yararlanır.

Önerdiğimiz modelin performansını ve gerçek uygulamasını verilerle karşılaştırdığımızda oldukça doğru sonuçlar elde ettiğimiz ortaya çıkıyor. Selahaddin'in çiftliklerinde çekilmiş palmiye ağaçlarının resimleri kullanılmıştır. Her test sürecinde, ağaçların iyi bir tanımı elde edilir, hesaplanır ve bu ağaçların geçerliliği bilinir. Öte yandan, ekilen ve ekilmeyen alanlar, paydaşlar için bir rapor olarak karşılaştırılır. Çiftliklerdeki olasılıkları ve diğer ağaçlara olan ihtiyacın boyutunu bize anlatan modern teknolojileri kullanmak gerekiyor. Bu sonuçlar, ağaçları korumak ve bunlara maruz kalabilecek afetlerde raporlardan yararlanmak için kullanılabilir.

4. BULGULAR VE TARTIŞMA

4.1. Palmiye Veri Tabanı

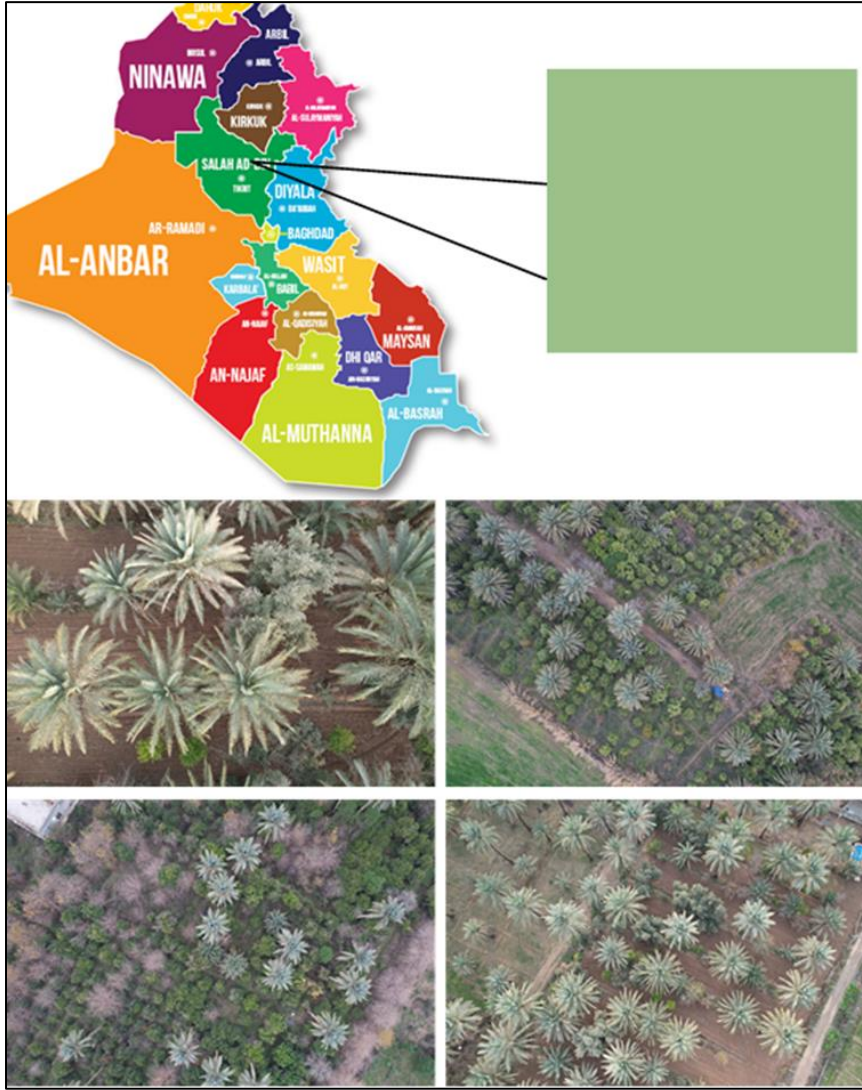
Irak, onlarca yıl önce küresel hurma üreticilerinin ön saflarında yer alıyordu. Ancak, ekonomisi başta petrole bağımlı hale geldikten sonra, bugün bu mahsulün üretimi küresel üretimin %5'ini geçmemektedir (Şekil 4.1).



Şekil 4.1. Irak'ta palmiye ağaçları

Çalışma alanı, Irak'ın merkezindeki Salah al-Din şehrinin yakınında bulunan doğal bir tarım rezervinin topraklarında yer almaktadır. Arazinin büyük bir kısmı (%80) dağ kuşağının ortasında (deniz seviyesinden 300-400 metre yükseklikte) yer alır ve büyük bir kısmı farklı oranlarda yedi ağaç türünden oluşan karma çiftliklerle kaplıdır. Palmiye ağaçlarıdır. Palmiye ağaçları diğer türler arasında baskındır ve özellikle ovalarda olmak üzere toplam ekim alanının %41'ini işgal eder.

Çalışmanın amacı, palmiye ağaçlarını (toplam çiftlik alanının %25'i) korumak ve çeşitlendirmek olduğundan, deney için bu ağaç türünün bulunduğu test parselleri seçilmiştir. Araştırma sahaları için, Temmuz 2021'de bir DJI Phantom 3 Pro quadcopter (standart kamera ile) ile birkaç uçuş sırasında üstün uzamsal çözünürlüğe ($\approx 5-10$ cm/piksel) sahip bir dizi RGB görüntü elde edildi. Araştırma sahaları güneşli havalarda fotoğraflandı 120 m yükseklikte. Tüm fotoğraflar çekilmiştir, Şekil 4.2 konumu ve çekilen bazı fotoğrafları göstermektedir.



Şekil 4.2. Irak'ta alınan palmiye ağaçlarının konumu

IoU metriğinin kullanılması, uzman verileriyle algoritmamız kullanılarak elde edilen ağaç taç konturlarının çakışmasının doğruluğunu hesaba katmamızı sağlar. IoU metriği benzer bir şekilde tanımlanıyor (4.1).

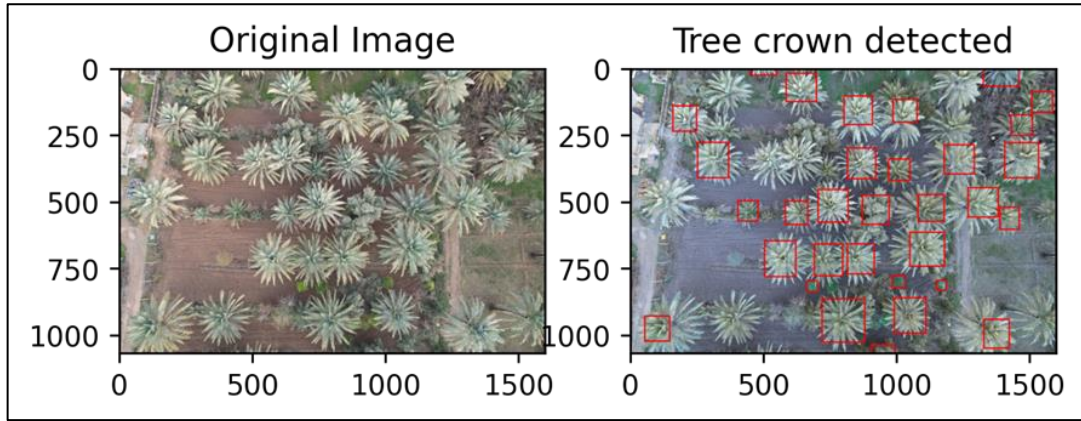
$$IoU(S_A, S_B) = \frac{S_A \cap S_B}{S_A \cup S_B} \quad 4.1.$$

S_A ve S_B sırasıyla algoritma ve uzman tarafından elde edilen ağaç taç konturları içinde bulunan piksel kümeleridir.

4.2. Deneysel Bulgular

Mevcut palmiye ağaçları algılama araçlarının ilk araştırması, en iyi performans gösteren algoritmanın ağaçların %14'ünün taç bölgesini doğru bir şekilde hatırlayabildiğini gösterdi. Zorluklar arasında büyük bireysel ağaçların aşırı

segmentasyonu, zemin modelindeki kusurlara dayalı olarak hatalı tahmin edilen ağaç nesnelere ve ağaç olmayan dikey nesnelere dahil edilmesi yer alıyordu. Tam model, gereksiz kutuları azaltır ve kendinden denetimli ve elle açıklanmalı veri kümelerini birleştirerek büyük ağaçların bölümlenmesini geliştirir. Tam model, iyi aralıklı büyük ağaçların olduğu alanlarda optimum performansa sahiptir, ancak Şekil 4.3'te gösterilen küçük ağaç kümelerini alt bölümlere ayırma eğilimindedir.



Şekil 4.3. Sunulan modelin sonucu

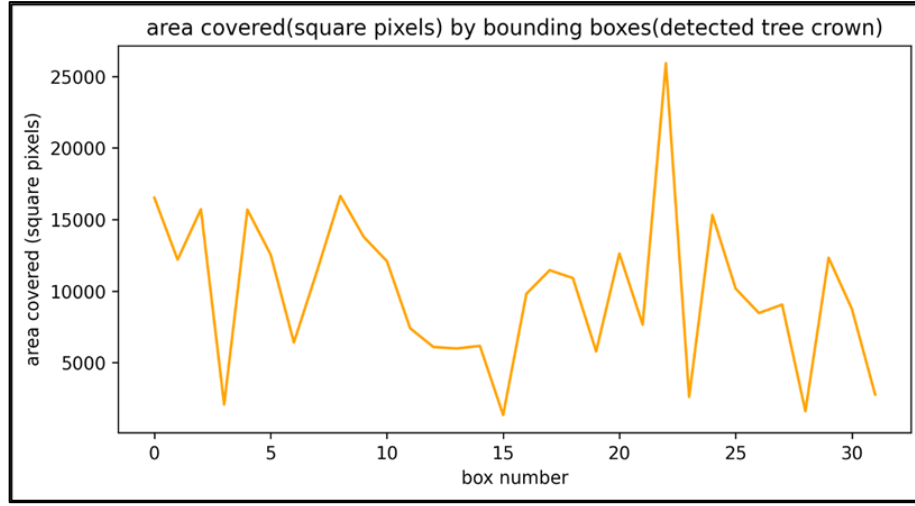
Şekil 4.3 farklı taç boyutlarına sahip palmye ağacı tepesi tespitini göstermektedir, tespit doğruluğu %92 olan 35 taçtan 32'si tespit edilmiştir. Tablo 4.1, tespit edilen palmye ağaçlarının bilgilerini gösterir.

Tablo 4.1. Modelde tespit edilen palmye ağaçlarının bilgileri

#	Algılanan ağaçların bilgileri
1.	Box 1 covering from xmin: 1048 ymin: 614 xmax: 1178 ymax: 741 totaling area of 16510 square pixel
2.	Box 2 covering from xmin: 814 ymin: 299 xmax: 920 ymax: 414 totaling area of 12190 square pixel
3.	Box 3 covering from xmin: 990 ymin: 859 xmax: 1109 ymax: 991 totaling area of 15708 square pixel
4.	Box 4 covering from xmin: 982 ymin: 776 xmax: 1029 ymax: 820 totaling area of 2068 square pixel
5.	Box 5 covering from xmin: 503 ymin: 646 xmax: 620 ymax: 780 totaling area of 15678 square pixel
6.	Box 6 covering from xmin: 1266 ymin: 447 xmax: 1380 ymax: 557 totaling area of 12540 square pixel
7.	Box 7 covering from xmin: 968 ymin: 340 xmax: 1048 ymax: 420 totaling area of 6400 square pixel
8.	Box 8 covering from xmin: 814 ymin: 657 xmax: 915 ymax: 770 totaling area of 11413 square pixel
9.	Box 9 covering from xmin: 1404 ymin: 279 xmax: 1531 ymax: 410 totaling area of 16637 square pixel
10.	Box 10 covering from xmin: 704 ymin: 454 xmax: 817 ymax: 576 totaling area of 13786 square pixel
11.	Box 11 covering from xmin: 584 ymin: 19 xmax: 698 ymax: 125 totaling area of 12084 square pixel

12.	Box 12 covering from xmin: 581 ymin: 497 xmax: 665 ymax: 585 totaling area of 7392 square pixel
13.	Box 13 covering from xmin: 1505 ymin: 88 xmax: 1584 ymax: 165 totaling area of 6083 square pixel
14.	Box 14 covering from xmin: 1386 ymin: 520 xmax: 1458 ymax: 603 totaling area of 5976 square pixel
15.	Box 15 covering from xmin: 1428 ymin: 175 xmax: 1508 ymax: 252 totaling area of 6160 square pixel
16.	Box 16 covering from xmin: 1148 ymin: 794 xmax: 1185 ymax: 830 totaling area of 1332 square pixel
17.	Box 17 covering from xmin: 1079 ymin: 473 xmax: 1177 ymax: 573 totaling area of 9800 square pixel
18.	Box 18 covering from xmin: 801 ymin: 104 xmax: 908 ymax: 211 totaling area of 11449 square pixel
19.	Box 19 covering from xmin: 871 ymin: 475 xmax: 971 ymax: 584 totaling area of 10900 square pixel
20.	Box 20 covering from xmin: 403 ymin: 496 xmax: 479 ymax: 572 totaling area of 5776 square pixel
21.	Box 21 covering from xmin: 690 ymin: 658 xmax: 796 ymax: 777 totaling area of 12614 square pixel
22.	Box 22 covering from xmin: 985 ymin: 117 xmax: 1075 ymax: 202 totaling area of 7650 square pixel
23.	Box 23 covering from xmin: 719 ymin: 863 xmax: 879 ymax: 1025 totaling area of 25920 square pixel
24.	Box 24 covering from xmin: 448 ymin: 0 xmax: 548 ymax: 26 totaling area of 2600 square pixel
25.	Box 25 covering from xmin: 252 ymin: 278 xmax: 368 ymax: 410 totaling area of 15312 square pixel
26.	Box 26 covering from xmin: 1326 ymin: 940 xmax: 1421 ymax: 1047 totaling area of 10165 square pixel
27.	Box 27 covering from xmin: 159 ymin: 141 xmax: 248 ymax: 236 totaling area of 8455 square pixel
28.	Box 28 covering from xmin: 1324 ymin: 0 xmax: 1457 ymax: 68 totaling area of 9044 square pixel
29.	Box 29 covering from xmin: 662 ymin: 796 xmax: 702 ymax: 836 totaling area of 1600 square pixel
30.	Box 30 covering from xmin: 1177 ymin: 287 xmax: 1290 ymax: 396 totaling area of 12317 square pixel
31.	Box 31 covering from xmin: 54 ymin: 927 xmax: 147 ymax: 1021 totaling area of 8742 square pixel
32.	Box 32 covering from xmin: 902 ymin: 1035 xmax: 991 ymax: 1066 totaling area of 2759 square pixel

Bilgiler Tablo 4.3'te sunulmuştur, Ymin ve Xmin'deki kutu konumunu piksel cinsinden boyut ile gösterir. Şekil 4.3 ve Tablo 4.1'den, görüntüdeki tüm alanın %20'sini oluşturan palmye ağaçlarının kullanılan veri tabanında (Şekil 4.4) sınırlayıcı kutuların (algılanan ağaç tacı) kapsadığı alanı (kare pikseller) analiz ediyoruz.




Şekil 4.4. palmye ağacı taçlarının kapladığı alan

Tablo 4.2. Tespit edilen 15 palmye ağacı tepesinin IoU ve F-skoru

S	Tahmin ID	T ID	IoU	Gol	xdk	xmaks	ymin	ymax	öngörülen_etiket	gerçek_etiket	kibrit
1	0	0	0,9581	0,9933	195	238	115	158	Ağaç	Ağaç	*
2	8	3	0,9393	0,9515	165	197	133	170	Ağaç	Ağaç	*
3	13	4	0,9315	0,8517	189	222	74	108	Ağaç	Ağaç	*
4	9	5	0,8911	0,9394	88	127	237	281	Ağaç	Ağaç	*
5	12	6	0,9156	0,8582	125	147	277	302	Ağaç	Ağaç	*
6	7	7	0,8668	0,9625	87	133	354	400	Ağaç	Ağaç	*
7	5	8	0,8824	0,973	22	61	351	392	Ağaç	Ağaç	*
8	1	9	0,939	0,9927	24	73	243	291	Ağaç	Ağaç	*
9	2	10	0,9103	0,9901	33	79	305	352	Ağaç	Ağaç	*
10	6	12	0,9139	0,9698	320	394	0	61	Ağaç	Ağaç	*
11	4	13	0,8626	0,9792	309	354	74	113	Ağaç	Ağaç	*
12	10	14	0,9179	0,92	270	359	285	383	Ağaç	Ağaç	*
13	15	1	0,9214	0,8531	359	400	327	381	Ağaç	Ağaç	*
14	13	4	0,9509	0,8659	83	123	152	192	Ağaç	Ağaç	*
15	2	5	0,9142	0,9861	213	275	135	207	Ağaç	Ağaç	*

* Doğru

Tablo 4.2'den, sunulan tüm görüntülerin eşleşme durumunun doğru olduğu kabul edilebilir. Tespit edilen 15 palmye ağacı tepesinin ortalama IoU tespit oranı %92'dir ve F-skoru %94'tür. Şekil 4.5, geliştirilen modelin deneysel sonuçlarını göstermektedir.



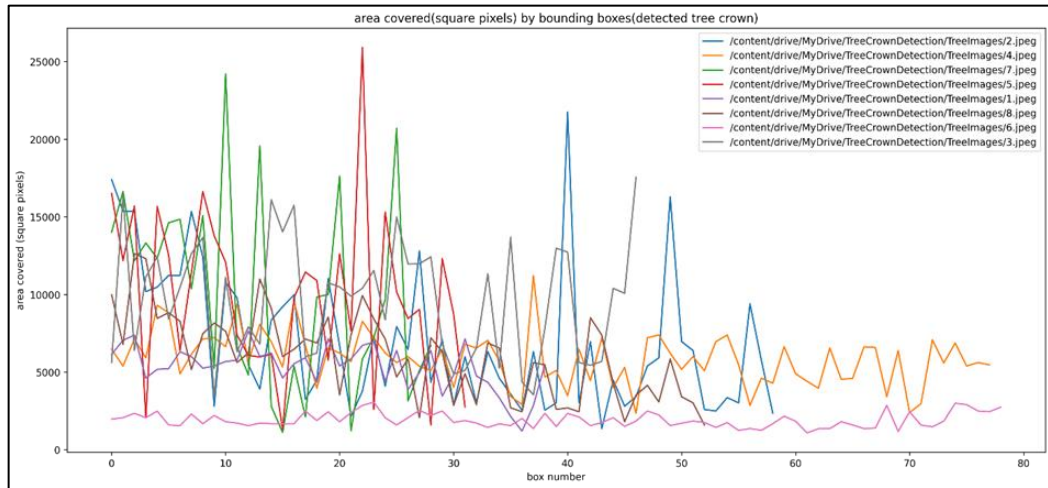
Şekil 4.5. Sunulan modelin deneysel sonuçları

Şekil 4.4'ten, toplanan veritabanının palmye ağacı tepesi tespitini görebiliriz, Tablo 4.3 bölgedeki palmye ağaçlarının kapsadığı alanı gösterir, aynı zamanda yakalanan görüntüdeki toplam palmye ağaçlarının miktarını toplamaya yardımcı olur, çekilen görüntülerin en üstteki uzaklıkları birbirinden farklıdır.

Tablo 4.3. Algılanan palmiye ağaçları, kayıp ve kapalı alan

Kaynak resim	Palmiye ağaçları tespit edildi	Palmiye ağaçları algılanmadı	Kapalı alan
Resim 1	37	4	%13
Resim 2	37	2	%17
Resim 3	49	3	%26
Resim 4	77	4	%31
Resim 5	73	2	%42

Tablo 4.3'te tespit edilen ve kaybolan palmiye ağaçlarını ve kapalı alanı sunarken, Resim-1'de tespit edilen palmiye ağaçlarının 37'si, % 13 kapalı alan ile 41 ağaçtan 37'si ve Resim-2'de % 17 kapalı alan ile 39 ağaçtan 37'si olup, tespit edilen kronların 49'u Şekil 4.4'te sırasıyla resim_3, resim_4 ve resim_6'da 51 ve %26 kapalı alan, 31 kapalı alan ile 81 kurondan 77'sini tespit etti ve %42 kapalı alanla 79 kurondan 73'ünü tespit etti. Şekil 4.5, Tablo 4.3'te test edilen görüntülerde kapsanan alanı göstermektedir.



Şekil 4.6. Tablo 4.3'te test edilen görüntülerin kapsanan alanı

5. SONUÇ VE ÖNERİLER

Irak'ta Konvolüsyonel Sinir Ağları (CNN) kullanılarak bir avuç tacı tespiti için sonuç ve gelecekteki çalışmalar, muhtemelen elde edilen sonuçların bir özetini, bulguların önemini ve daha fazla araştırma ve iyileştirme için potansiyel yönergeleri kapsayacaktır.

Bu çalışmada, Irak'ta avuç içi taç tespiti için Konvolüsyonel Sinir Ağı (CNN) tabanlı bir yaklaşımı başarıyla geliştirdik ve uyguladık. Modelimiz, hava görüntülerinden palmye ağacı taçlarını doğru bir şekilde tanımlama ve yerleştirme konusunda umut verici sonuçlar gösterdi; ortalama IoU algılama oranı %92, F-skoru ise %94'tür. Bu çalışmada elde edilen doğruluk, derin öğrenme tekniklerinin, CNN'lerin avuç içi tepesi algılama zorluğunun üstesinden gelme potansiyelinin %92'sidir. Bu ilerleme, tarım yönetimi, ekolojik çalışmalar ve şehir planlaması gibi çeşitli uygulamaları desteklemede çok önemli bir rol oynayabilir.

Bu çalışma, avuç tacı tespitinde önemli bir başarı elde etmiş olsa da, gelecekteki araştırma ve iyileştirmeler için birkaç yol keşfedilmeyi beklemektedir. Modelin performansı, çeşitli aydınlatma koşullarını, mevsimsel değişiklikleri ve farklı palmye türlerini kapsayan daha geniş ve daha çeşitli bir veri kümesinden yararlanabilir. Bu, modelin genelleştirme yeteneklerini geliştirebilir. ImageNet gibi büyük ölçekli veri kümelerinde eğitilenler gibi önceden eğitilmiş modellerde ince ayar yaparak aktarım öğrenimini araştırmak, modelin avuç tacı algılama görevlerindeki performansını potansiyel olarak artırabilir. Geometrik dönüşümler ve stil aktarımları gibi gelişmiş veri büyütme tekniklerinin uygulanması, modelin farklı görüntü varyasyonlarına karşı daha sağlam olmasına yardımcı olabilir. Gerçek Zamanlı Uygulama: Modeli gerçek zamanlı avuç içi tepesi algılama uygulamalarına uyarlamak, otomatik izleme sistemleri için kapılar açarak çeşitli sektörlerde zamanında müdahaleler sağlayabilir.

Sonuç olarak, Irak'ta avuç tacı tespiti için CNN'lerin başarılı bir şekilde uygulanması, uzaktan algılama ve tarım yönetimi alanında önemli bir ilerleme sunmaktadır. Yukarıda özetlenen önerilen iyileştirmeler ve gelecekteki yönergeler, modelin doğruluğunu, sağlamlığını ve gerçek dünyaya uygulanabilirliğini geliştirmek için bir yol haritası sunar. Teknoloji gelişmeye devam ederken, yapay zekanın tarım ve ekolojik alanlara entegrasyonu, sürdürülebilir kaynak yönetimi ve çevre koruma üzerinde olumlu bir etki yaratma vaadini taşımaktadır.

6. KAYNAKLAR

- Alawar, A., Hamed, A. M., & Al-Kaabi, K. (2009). Characterization of treated date palm tree fiber as composite reinforcement. *Composites Part B: Engineering*, 40(7), 601-606.
- Anonim. (2023). *Iraq: Salah Al-Din - IDP Locations*. <https://reliefweb.int/map/iraq/iraq-salah-al-din-idp-locations-december-2007> Erişim Tarihi: 01.11.2023
- Bohlin, I., Olsson, H., Bohlin, J., & Granström, A. (2017). Quantifying post-fire fallen trees using multi-temporal lidar. *International journal of applied earth observation and geoinformation*, 63, 186-195.
- Bossoukpe, M., Faye, E., Ndiaye, O., Diatta, S., Diatta, O., Diouf, A. A., & Taugourdeau, S. (2021). Low-cost drones help measure tree characteristics in the Sahelian savanna. *Journal of Arid Environments*, 187.
- Castellano, G., Cotardo, E., Mencar, C., & Vessio, G. (2023). Density-based clustering with fully-convolutional networks for crowd flow detection from drones. *Neurocomputing*, 526, 169-179.
- Chen, Q., Song, Z., Dong, J., Huang, Z., Hua, Y., & Yan, S. (2014). Contextualizing object detection and classification. *IEEE transactions on pattern analysis and machine intelligence*, 37(1), 13-27.
- Chowdhury, P. N., Shivakumara, P., Nandanwar, L., Samiron, F., Pal, U., & Lu, T. (2022). Oil palm tree counting in drone images. *Pattern Recognition Letters*, 153, 1-9.
- Church, E.D., Bartlett, A.H., & Jourabchi, M.A. (2013). Raster-to-vector image analysis for fast digitization of historic seismograms. *Seismological Research Letters*, 84(3), 489-494.
- Dang-Nguyen, D. T., Pasquini, C., Conotter, V., & Boato, G. (2015). Raise: A raw images dataset for digital image forensics. *In Proceedings of the 6th ACM multimedia systems conference*, 219-224.
- Dong, C., Cai, C., Chen, S., Xu, H., Yang, L., Ji, J., & Lou, X. (2023). Crown Width Extraction of Metasequoia glyptostroboides Using Improved YOLOv7 Based on UAV Images. *Drones*, 7(6), 336-340.
- El-Juhany, L.I. (2010). Degradation of date palm trees and date production in Arab countries: causes and potential rehabilitation. *Australian Journal of Basic and Applied Sciences*, 4(8), 3998-4010.

- Fernández, E., Junquera, B., & Ordiz, M. (2003). Organizational culture and human resources in the environmental issue: a review of the literature. *International Journal of Human Resource Management*, 14(4), 634-656.
- Ferreira, M.P., de Almeida, D.R.A., de Almeida Papa, D., Minervino, J.B.S., Veras, H.F.P., Formighieri, A. & Ferreira, E.J.L. (2020). Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. *Forest Ecology and Management*, 475.
- Galiatsatos, N., Donoghue, D.N., Watt, P., Bholanath, P., Pickering, J., Hansen, M.C., & Mahmood, A.R. (2020). An assessment of global forest change datasets for national forest monitoring and reporting. *Remote Sensing*, 12(11), 1790.
- Gallardo-Salazar, J. L., Rosas-Chavoya, M., Pompa-García, M., López-Serrano, P. M., García-Montiel, E., Meléndez-Soto, A., & Jiménez-Jiménez, S. I. (2023). Multi-temporal NDVI analysis using UAV images of tree crowns in a northern Mexican pine-oak forest. *Journal of Forestry Research*, 1-13.
- Gan, Y., Wang, Q., & Iio, A. (2023). Tree Crown Detection and Delineation in a Temperate Deciduous Forest from UAV RGB Imagery Using Deep Learning Approaches: Effects of Spatial Resolution and Species Characteristics. *Remote Sensing*, 15(3), 778.
- Ge, W., Li, X., Jing, L., Han, J., & Wang, F. (2023). Monitoring canopy-scale autumn leaf phenology at fine-scale using unmanned aerial vehicle (UAV) photography. *Agricultural and Forest*
- Green, S., McKinney Jr, E., Heppard, K., & Garcia, L. (2018). Big Data, digital demand and decision-making. *International Journal of Accounting & Information Management*, 26(4), 541-555.
- Hilker, T., Nestic, Z., Coops, N. C., & Lessard, D. (2010). A new, automated, multiangular radiometer instrument for tower-based observations of canopy reflectance. *Instrumentation science and Technology*, 38(5), 319-340.
- Holden, P.B., Rebelo, A.J., & New, M.G. (2021). Mapping invasive alien trees in water towers: A combined approach using satellite data fusion, drone technology and expert engagement. *Remote Sensing Applications: Society and Environment*, 21.
- Hu, B., Li, J., Jing, L., & Judah, A. (2014). Improving the efficiency and accuracy of individual tree crown delineation from high-density LiDAR data. *International Journal of Applied Earth Observation and Geoinformation*, 26, 145-155.

- Islam, M.T., Siddique, B. N. K., Rahman, S., & Jabid, T. (2018). Image recognition with deep learning. *In 2018 International conference on intelligent informatics and biomedical sciences (ICIIBMS)*, 3, 106-110).
- Jiang, S., Jiang, C., & Jiang, W. (2020). Efficient structure from motion for large-scale UAV images: A review and a comparison of SfM tools. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167, 230-251.
- Jintasuttisak, T., Edirisinghe, E., & Elbattay, A. (2022). Deep neural network based date palm tree detection in drone imagery. *Computers and Electronics in Agriculture*, 192.
- Khalifa, N.E., Loey, M., & Mirjalili, S. (2022). A comprehensive survey of recent trends in deep learning for digital images augmentation. *Artificial Intelligence Review*, 1-27.
- Kotivuori, E., Kukkonen, M., Mehtätalo, L., Maltamo, M., Korhonen, L., & Packalen, P. (2020). Forest inventories for small areas using drone imagery without in-situ field measurements. *Remote Sensing of Environment*, 237.
- Kwenda, C., Gwetu, M., & Dombeu, J.V.F. (2022). Machine learning methods for forest image analysis and classification: A survey of the state of the art. *IEEE Access*, 10, 45290-45316.
- Lim, S. (2006). Characterization of noise in digital photographs for image processing. *In Digital Photography*, 6069; 219-228. <https://doi.org/10.1117/12.655915>
- Lu, Y., Liu, S., & Bai, Y. (2022). Analysis of Digital Photography Technology in the Era of Big Data. *Mobile Information Systems*, 1-7.
- Magdeev, R.G., & Tashlinskii, A.G. (2019). Efficiency of object identification for binary images. *Computer Optics*, 43(2), 277-281.
- Malek, S., Bazi, Y., Alajlan, N., AlHichri, H. & Melgani, F. (2014). Efficient framework for palm tree detection in UAV images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(12), 4692-4703.
- Manaa, I. E., Benjelloun, F., Sabri, M. A., Yahyaouy, A., & Aarab, A. (2023). Autonomous approach for moving object detection and classification in road applications. *International Journal of Computer Aided Engineering and Technology*, 18(1-3), 211-223
- Mathijssen, D. (2021). The challenging path to add a promising new bio-fiber from an overlooked source to our reinforcement toolbox: Date palm fibers. *Reinforced Plastics*, 65(1), 48-52.

- Oh, S. I., & Kang, H. B. (2017). Object detection and classification by decision-level fusion for intelligent vehicle systems. *Sensors*, 17(1), 207.
- Prabhu, R. (2018). Understanding of convolutional neural network (CNN)-deep learning. *Medium. Com*, 1-11.
- Qi, Y., Coops, N. C., Daniels, L. D. & Butson, C. R. (2022). Comparing tree attributes derived from quantitative structure models based on drone and mobile laser scanning point clouds across varying canopy cover conditions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 192, 49-65.
- Safonova, A. (2021). *Plant species detection in aerial and satellite images using deep learning*. <https://digibug.ugr.es/bitstream/handle/10481/69661/87400%281%29.pdf?sequence=4&isAllowed=y> Erişim Tarihi: 01.11.2023
- Schepaschenko, D., Shvidenko, A., Usoltsev, V., Lakyda, P., Luo, Y., Vasylyshyn, R., & Obersteiner, M. (2017). A dataset of forest biomass structure for Eurasia. *Scientific Data*, 4(1), 1-11.
- Sonnentag, O., Hufkens, K., Teshera-Sterne, C., Young, A. M., Friedl, M., Braswell, B. H., & Richardson, A. D. (2012). Digital repeat photography for phenological research in forest ecosystems. *Agricultural and Forest Meteorology*, 152, 159-177.
- Spencer, S. (2022). *Visual research methods in the social sciences: Awakening visions*. 2. Edt. Taylor & Francis.
- Syifa, M., Park, S. J. & Lee, C. W. (2020). Detection of the pine wilt disease tree candidates for drone remote sensing using artificial intelligence techniques. *Engineering*, 6(8), 919-926.
- Tan, L.K. (2006). Image file formats. *Biomed Imaging Interv Journal*, 2(1), 1-5.
- Tu, Y.H., Phinn, S., Johansen, K., Robson, A., & Wu, D. (2020). Optimising drone flight planning for measuring horticultural tree crop structure. *ISPRS Journal of Photogrammetry and Remote Sensing*, 160, 83-96.
- Valluvan, A.B., Raj, R., Pingale, R., & Jagarlapudi, A. (2023). Canopy height estimation using drone-based RGB images. *Smart Agricultural Technology*, 4.
- Wang, H., Zhao, Z., Liu, P., & Guo, X. (2022). A soft and stretchable electronics using laser-induced graphene on polyimide/PDMS composite substrate. *Flexible Electronics*, 6(26), 1-8. <https://doi.org/10.1038/s41528-022-00161-z>

- Williams, G., Baxter, R., He, H., Hawkins, S., & Gu, L. (2002). A comparative study of RNN for outlier detection in data mining. *In 2002 IEEE International Conference on Data Mining*, 709-712.
- Yang, F., Choi, W., & Lin, Y. (2016). Exploit all the layers: Fast and accurate cnn object detector with scale dependent pooling and cascaded rejection classifiers. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 2129-2137.
- Yin, W., Kann, K., Yu, M., & Schütze, H. (2017). Comparative study of CNN and RNN for natural language processing. *Computer Science*, 1-7. <https://doi.org/10.48550/arXiv.1702.01923>
- Zeng, J., Tan, S., Li, B., & Huang, J. (2017). Large-scale JPEG image steganalysis using hybrid deep-learning framework. *IEEE Transactions on Information Forensics and Security*, 13(5), 1200-1214.
- Zhang, C.L., & Wu, J. (2019). Improving CNN linear layers with power mean non-linearity. *Pattern Recognition*, 89, 12-21.
- Zhang, J., Zhang, Z., Lutz, J.A., Chu, C., Hu, J., Shen, G. & He, F. (2022). Drone-acquired data reveal the importance of forest canopy structure in predicting tree diversity. *Forest Ecology and Management*, 505.
- Zhao, H., Qi, X., Shen, X., Shi, J., & Jia, J. (2018). Icnnet for real-time semantic segmentation on high-resolution images. *In Proceedings of the European conference on computer vision*, 405-420.
- Zhou, J., Chen, X., Li, S., Dong, R., Wang, X., Zhang, C., & Zhang, L. (2023). Multispecies individual tree crown extraction and classification based on BlendMask and high-resolution UAV images. *Journal of Applied Remote Sensing*, 17(1), 016503-016503.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER	
Adı Soyadı:	Hassan Hawas Hameedi AL-HUSSEINI
Uyruğu:	Irak
Orcid Numarası:	0009-0009-5079-9424

EĞİTİM BİLGİLERİ	
Lisans	
Üniversite:	
Bölüm:	
Anabilim Dalı:	
Mezuniyet Yılı:	
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-Husseini, H.H.H., & Sepet, H. (2023) Drone photos process to estimate the common amount of trees in a given area by computer vision technologies. Humanities & Natural Sciences Journal, 4(6): 82-94.