

Multispektral İHA Görüntüleri Kullanılarak Nesne Tabanlı Görüntü Analizi ile Ağaç Tespiti ve NDVI Tabanlı Bitki Sağlığı Analizi

Abdurahman Yasin Yiğit^{1,*}, Osman Orhan¹

¹ Mersin Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Mersin, Türkiye

Makale Tarihçesi

Gönderim: 13.02.2025

Kabul: 04.07.2025

Yayın: 30.08.2025

Araştırma Makalesi



Öz – Tarımsal alanların verimli bir şekilde yönetimi ve doğal kaynakların korunması, modern çevre biliminin en önemli hedeflerinden biridir. Bu hedeflere ulaşmak için uzaktan algılama teknolojileri, özellikle İnsansız Hava Aracı (İHA) tabanlı görüntüleme sistemleri, güçlü araçlar sunmaktadır. Geleneksel yöntemlerin sınırlılıklarını aşarak, İHA görüntüleri yüksek çözünürlükte veri sağlaması ve geniş alanları kapsayabilmesi nedeniyle bitki sağlığı ve ağaç tespiti çalışmalarında önemli bir yer edinmiştir. Özellikle Normalize Edilmiş Fark Bitki Örtüsü İndeksi (Normalized Difference Vegetation Index/NDVI) gibi spektral analiz yöntemleri, bitki örtüsünün sağlık durumunu değerlendirmek ve stres altındaki bölgeleri belirlemek için etkili bir çözüm sunmaktadır. Bu çalışmada, İHA görüntüleri ve nesne tabanlı görüntü analizi yöntemleri kullanılarak tarımsal alanlardaki ağaçların tespiti ve bitki sağlığının değerlendirilmesi amaçlanmıştır. Multispektral görüntülerden elde edilen NDVI değerleri, segmentasyon ve sınıflandırma süreçleri ile birleştirilerek ağaçların etkili bir şekilde tespit edilmesi sağlanmıştır. Doğruluk analizleri, modelin genel performansını ortaya koymuş ve segmentasyon süreçlerinin başarı oranını doğrulamıştır. Model, %89 doğruluk ve %92 kesinlik oranıyla etkili bir sınıflandırma gerçekleştirmiştir. Ayrıca, NDVI analizleri ile sağlıklı, orta sağlıklı ve stres altındaki bitkiler ayrıştırılmış, çalışma alanındaki mekânsal farklılıklar detaylı bir şekilde haritalandırılmıştır. Sonuç olarak, bu çalışma, İHA tabanlı görüntüleme ve Nesne Tabanlı Görüntü Analizi (Object-Based Image Analysis/OBIA) yöntemlerinin tarımsal yönetim ve çevresel izleme uygulamaları için güçlü bir çözüm sunduğunu göstermiştir. Bu yöntemlerin doğruluğu ve uygulama kolaylığı, gelecekte farklı coğrafyalarda ve daha geniş alanlarda yapılacak çalışmalara ışık tutmaktadır.

Anahtar Kelimeler – Tarımsal yönetim, multispektral görüntüleme, nesne tabanlı görüntü analizi, ağaç tespiti, bitki sağlığı

Tree Detection and NDVI-Based Plant Health Assessment Using Object-Based Image Analysis on Multispectral UAV Imagery

¹ Mersin University, Faculty of Engineering, Department of Geomatics, Mersin, Türkiye

Article History

Received: 13.02.2025

Accepted: 04.07.2025

Published: 30.08.2025

Research Article

Abstract – Efficient management of agricultural lands and conservation of natural resources are critical objectives in modern environmental science. Remote sensing technologies, particularly Unmanned Aerial Vehicle (UAV)-based imaging systems, provide powerful tools to achieve these goals. UAV imagery has become increasingly valuable in plant health assessment and tree detection due to its high-resolution data and ability to cover extensive areas, overcoming many limitations of traditional methods. Spectral analysis techniques, such as the Normalized Difference Vegetation Index (NDVI), offer effective means for evaluating vegetation health and identifying stressed regions. In this study, we employed UAV imagery combined with Object-Based Image Analysis (OBIA) to detect trees and assess plant health in agricultural fields. NDVI values derived from multispectral images were integrated with segmentation and classification workflows to accurately identify individual trees. Accuracy assessments demonstrated robust model performance, with classification accuracy reaching 89% and precision at 92%. Furthermore, NDVI analyses enabled the differentiation of healthy, moderately healthy, and stressed vegetation, allowing detailed spatial mapping of plant health across the study area. Overall, our results indicate that UAV-based imaging and OBIA represent a powerful approach for agricultural management and environmental monitoring. The demonstrated accuracy and operational ease of these methods provide a solid foundation for future applications across diverse geographic regions and larger scales.

Keywords – Agricultural management, multispectral imaging, object oriented image analysis, tree detection, plant health

¹  ayasinyigit@mersin.edu.tr / abdurahmanyasinyigit@gmail.com

²  osmanorhan@mersin.edu.tr / osmanorhan44@gmail.com

*Sorumlu Yazar / Corresponding Author

1. Giriş

Tarımsal üretim, insanlık tarihinin başlangıcından bu yana, toplumların sürdürülebilirliğini ve gelişimini sağlayan temel bir unsur olmuştur (Mensah, 2019; Ikendi, 2023). Ancak günümüzde tarımsal faaliyetler, iklim değişikliği, hızla artan dünya nüfusu ve azalan doğal kaynakların baskısı altında çok daha karmaşık ve çok boyutlu bir yapı kazanmıştır (Nhemachena vd., 2020; Yuan vd., 2024). Özellikle su, toprak ve bitki sağlığı gibi tarımın temel bileşenlerinin verimli bir şekilde yönetimi, yalnızca bireysel çiftçiler için değil, aynı zamanda küresel ölçekte bir gıda güvenliği meselesi olarak ele alınmaktadır (Torresan vd., 2017; Rizzo vd., 2021). Bu alanlar, karbon döngüsünün düzenlenmesi, biyolojik çeşitliliğin korunması ve su kaynaklarının yönetimi gibi kritik ekosistem hizmetleri sunmaktadır (McLennon vd., 2021). Ancak, artan nüfus, şehirleşme ve iklim değişikliği gibi küresel sorunlar, bu alanların izlenmesini ve sürdürülebilir bir şekilde yönetilmesini her zamankinden daha önemli hale getirmiştir (Ikendi, 2023). Özellikle tarımsal alanlarda, ağaçların çevresel katkılarının değerlendirilmesinde geleneksel tarım yöntemleri yetersiz kalmaktadır. Geleneksel yöntemlerle tarımsal alanların izlenmesi genellikle zaman alıcı, maliyetli ve iş gücü yoğun bir süreçtir (Mensah, 2019). Örneğin, geniş bir tarımsal alanda ağaçların tespiti ve sağlık durumlarının değerlendirilmesi, saha çalışmaları sırasında ciddi zorluklar yaratmaktadır.

Bu yüzden tarımsal üretim ve yönetimi, dünya nüfusunun hızla artması ve gıda güvenliğinin sağlanması gerekliliği nedeniyle, modern teknolojilerle desteklenmesi gereken bir alan haline gelmiştir (Yuan vd., 2024). Tarım arazilerinin verimli bir şekilde yönetilmesi, yalnızca üretim miktarını artırmakla kalmaz, aynı zamanda doğal kaynakların sürdürülebilir kullanımını da sağlamaktadır (Zahoor vd., 2022). Günümüzde, ağaçların tespiti ve sağlık analizleri gibi daha lokalize analizlere olan ihtiyaç giderek artmaktadır (Buja vd., 2021). Örneğin, belirli bir parseldeki ağaçların büyüme hızı, stres düzeyi veya sulama ihtiyacının izlenmesi bu analiz türüne örnek teşkil etmektedir. Tarım arazilerindeki bireysel ağaçların sağlık durumunun izlenmesi ise yalnızca üretim verimliliğini artırmakla kalmaz, aynı zamanda kaynak kullanımını optimize etmektedir (Wolf ve Heipke, 2007). Ayrıca ağaçlardaki hastalıkların erken teşhisi için önemli bir temel sağlar (Nhemachena vd., 2020). Bununla birlikte, mevcut literatür incelendiğinde, geniş ölçekli tarım arazilerinde bireysel ağaçların veya bitkilerin otomatik olarak tespitine yönelik çalışmaların sınırlı olduğu görülmektedir (Jang vd., 2020).

Geleneksel yöntemlerle süreçler dezavantajlı olduğu için İnsansız Hava Araçları (İHA), düşük maliyetli, taşınabilir ve hızlı veri toplama imkânı sunan bir çözüm olarak öne çıkmaktadır (Sun vd., 2023). Ayrıca, farklı sensörlerle donatılabilen İHA'lar, görünür bölge Kırmızı-Yeşil-Mavi (Red-Green-Blue/RGB) bantların yanı sıra multispektral veriler sağlayarak, ağaçların tespiti ve sağlık durumlarının analizi gibi uygulamalarda önemli avantajlar sunmaktadır (Ecke vd., 2022). Bu nedenle, tarımda dijitalleşme ve uzaktan algılama teknolojilerinin kullanımı, tarımsal üretimin sürdürülebilirliğinde stratejik bir rol oynamaktadır (Chehreh vd., 2023). İHA'lardan elde edilen görüntüler, hareket tabanlı yapısal algılama (Structure from motion/SfM) gibi modern fotogrametrik tekniklerle işlenerek, 3 boyutlu (3B) nokta bulutları ve ortofotolar gibi ürünlere dönüştürülebilmektedir (Bera vd., 2020; Jiang vd., 2020; Li vd., 2021; Dai vd., 2023; Noori vd., 2024). SfM tabanlı fotogrametri, Işık Algılama ve Menzil Belirleme (Light Detection and Ranging/LiDAR) gibi aktif sensörlere kıyasla daha düşük maliyetli bir alternatif sunarken, yer kontrol noktaları (YKN) ile desteklendiğinde yüksek doğruluk seviyelerine ulaşabilmektedir (Jalbuena vd., 2016; Goldbergs vd., 2018). Ayrıca, SfM'nin standart dijital kameralarla uyumlu çalışabilmesi ve karmaşık ekipman gerektirmemesi, bu yöntemi saha koşullarında uygulanabilir hale getirmektedir.

İHA'lar, yüksek çözünürlüklü görüntüler ve hızlı veri toplama kabiliyeti sayesinde tarım arazilerinin anlık izlenmesini mümkün kılmaktadır (Zhang vd., 2021). Bu teknolojilerin en önemli avantajlarından biri, büyük alanları kapsayan hızlı, hassas ve düşük maliyetli analizler sunabilmesidir (Bera vd., 2020; Dai vd., 2023). Tarım alanlarında kullanılan multispektral kameralar, bitki sağlığı, stres seviyesi ve verimlilik analizleri için son derece değerli bilgiler sağlamaktadır (Haque vd., 2024). Bu bağlamda, multispektral görüntülerden türetilen Normalize Edilmiş Fark Bitki Örtüsü İndeksi (Normalized Difference Vegetation Index/NDVI) gibi yaygın bitki sağlığı indeksleri bu tür analizlerde sıkça tercih edilmektedir (Tucker, 1979; Pettorelli et al., 2005; Vélez vd., 2023; Haque vd., 2024). Örneğin, NDVI analizleri sayesinde, bir tarım arazisinde bireysel bitkilerin sağlık durumu izlenebilir, sulama veya gübreleme gibi tarımsal uygulamalar daha verimli bir şekilde planlanabilir.

Otomatik ağaç tespiti ve NDVI analizleri, tarım arazilerinde yalnızca bireysel ağaçların sağlık durumunu izlemekle kalmaz, aynı zamanda tarımsal üretim süreçlerini optimize etmek için de kritik bir araçtır (Vélez vd., 2023; Velazquez-Chavez vd., 2024). Örneğin, ağaçların tepe noktalarının tespiti, bireysel ağaçların büyüme durumunun izlenmesi ve bu ağaçların çevresel stres faktörlerine karşı tepkilerinin değerlendirilmesi için önemli bir veri sağlar (Yılmaz vd., 2015; D'Andrea vd., 2022; Govi vd., 2024). Ayrıca, bu tür bir analiz, tarım arazilerinde homojen olmayan büyüme modellerini tespit etmek ve bu alanlarda gerekli müdahaleleri planlamak için kullanılabilir (Xu vd., 2020). Bu tür teknolojilerin kullanımı, tarımsal üretim süreçlerinin dijitalleşmesi ve modern tarım uygulamalarının geliştirilmesi açısından büyük bir potansiyel taşımaktadır.

Bu bağlamda, görüntü sınıflandırma ve nesne tespiti süreçlerinde sıklıkla tercih edilen yöntemlerden biri de Nesne Tabanlı Görüntü Analizi (Object-Based Image Analysis/OBIA) yaklaşımıdır. OBIA, mekânsal, spektral ve metrik bilgileri birlikte değerlendirebilme kapasitesi sayesinde, yüksek çözünürlüklü görüntülerle yapılan sınıflandırmalarda piksel tabanlı yöntemlere kıyasla daha başarılı sonuçlar sunmaktadır (Blaschke, 2010; Whiteside et al., 2011). Son yıllarda OBIA, özellikle bireysel ağaç tespiti (Immitzer et al., 2012), orman alanlarının sınıflandırılması (Grippa et al., 2017; Ghasemi vd., 2022) ve kentsel yeşil alan izleme (Wang et al., 2022) gibi çeşitli alanlarda etkili sonuçlar sunmuştur.

Öneğin, Yang vd. (2022), Çin zeytin ağaçları üzerinde gerçekleştirdikleri çalışmada, yalnızca görünür bantlardan elde edilen İHA görüntülerine OBIA ve rastgele orman algoritması entegre ederek bireysel ağaç tespiti yapmış ve yüksek doğruluk elde etmiştir. Bu çalışma, OBIA yönteminin sınıflandırma doğruluğunu artırma potansiyelini göstermektedir. de Castro vd. (2018), erken dönem yabancı ot haritalaması için İHA görüntüleri üzerinde Rastgele Orman sınıflayıcı ile entegre çalışan bir OBIA algoritması geliştirmiştir. Çalışma, hem sıra arası hem de sıra içi yabancı otları ayırt edebilen tam otomatik bir yaklaşım sunarak, manuel örnekleme ihtiyacını ortadan kaldırmıştır. Adhikari vd. (2021), ultra-yüksek çözünürlüklü İHA verileri kullanarak OBIA yaklaşımı ile bireysel ağaç gölgeliklerini otomatik olarak çıkarmıştır. Çalışma, sınırlı parametre optimizasyonu ile yüksek sınıflandırma doğruluğu sağlamış ve OBIA'nın büyük veri setlerinde etkinliğini göstermiştir.

Guo vd. (2022) benzer şekilde kentsel ağaç türlerini sınıflandırmak amacıyla İHA multispektral görüntülerini, OBIA ile yüksek doğrulukla sınıflandırma gerçekleştirmiştir. Özellikle, spektral ve indeks temelli özneliliklerin sınıflamada daha etkili olduğu; geometrik özneliliklerin ise doğruluğu düşürdüğü gösterilmiştir. Torres-Sánchez vd. (2018), İHA tabanlı fotogrametrik nokta bulutları üzerinden geliştirdikleri tam otomatik OBIA algoritması ile badem ağaçlarının 3B geometrik özelliklerini yüksek doğrulukla çıkarmışlardır. Arazi ölçümleriyle karşılaştırıldığında, elde edilen bireysel benzerlik skorları ve yükseklik regresyon katsayısı bulunmuştur. Çalışma, RGB kameralarla elde edilen yoğun nokta bulutlarının OBIA ile entegre edilerek hacim haritalarının oluşturulabileceğini ve böylece tarımsal karar destek süreçlerinin iyileştirilebileceğini ortaya koymuştur. Wicaksono ve Hernina (2021), kentsel ağaçları sınıflandırmak amacıyla, RGB bantlı İHA görüntüleri üzerinde OBIA yaklaşımını kullanarak çok çözünürlüklü segmentasyon ile sınıflandırma gerçekleştirmiştir. OBIA ile kent ağaçlarının başarılı şekilde ayrıştırılabileceği ve alan yönetimi için yüksek çözünürlüklü veri sağlayabileceği ortaya konmuştur. Bununla birlikte, yöntem, üst üste binen taç yapılar veya gölgeleme durumlarında sınırlı ayırt edicilik gösterebilmektedir.

Bu çalışmanın temel amacı, düşük maliyetli multispektral kamera ile sahip İHA görüntüleri kullanılarak geniş tarım arazilerinde bireysel ağaçların otomatik olarak tespit edilmesi ve bitki sağlığı bilgilerinin NDVI ile değerlendirilmesidir. İHA ile elde edilen görüntüler, fotogrametrik işleme teknikleri kullanılarak analiz edilmiş ve bireysel ağaçların konumları ve sağlık durumları hassas bir şekilde belirlenmiştir. Çalışmada, OBIA'nın segmentasyon-temelli yapısından yararlanılarak farklı ölçek parametrelerinin etkileri değerlendirilmiş; gürültü azaltımı ve maskeleme gibi işlemlerle birlikte bireysel ağaçların konumsal ve spektral doğruluğu analiz edilmiştir. Bu yönüyle çalışma, OBIA'nın tarım alanlarındaki uygulama potansiyelini artıran ve yöntemsel açıdan literatüre katkı sunan bir yaklaşım ortaya koymaktadır. Bunun yanı sıra, yöntemimizin düşük maliyetli ve erişilebilir olması, geniş ölçekli tarım arazilerinde kullanım potansiyelini artırmaktadır.

Çalışmanın sonuçları, modern tarım uygulamalarında dijitalleşmenin önemini vurgularken, bireysel ağaç sağlığını optimize etmek, kaynak kullanımını sürdürülebilir hale getirmek ve üretim maliyetlerini düşürmek gibi hedeflere yönelik önemli katkılar sunmaktadır. Bu bağlamda, çalışmamızın, tarımsal yönetim süreçlerinde

teknoloji tabanlı çözümlere olan ihtiyaca somut bir yanıt sunduğu düşünülmektedir. Ayrıca, bu çalışma, tarımsal dijitalleşme ve sürdürülebilir üretim teknikleri için yeni yaklaşımlar geliştirilmesine yönelik bir temel oluşturmayı hedeflemektedir. Bu tür bir analiz, yalnızca tarımsal üretimi optimize etmekle kalmaz, aynı zamanda hastalıkların erken teşhis edilmesine ve kaynakların daha verimli kullanılmasına olanak tanır. Ayrıca, bu çalışmanın sonuçları, tarımsal üretim süreçlerinin dijitalleşmesi ve modern tarım uygulamalarının geliştirilmesi açısından önemli bir potansiyele sahiptir. Bu bağlamda çalışma, tarım uygulamalarının dijital dönüşümüne yönelik uygulanabilir ve ölçeklenebilir bir çözüm önermektedir.

2. Materyal ve Yöntem

Bu çalışmada, ağaç tespiti ve bitki sağlığı analizi için kullanılan yöntemler detaylı bir şekilde ele alınmıştır. İHA tabanlı görüntüleme sistemleri, fotogrametrik veri işleme, OBIA, NDVI hesaplamaları ve mekânsal analizler, çalışmanın temel veri toplama ve analiz aşamalarını oluşturmaktadır. Çalışmada kullanılan yöntemler, modern uzaktan algılama tekniklerinin entegrasyonu, yüksek doğruluk ve detaylı analizler sağlayacak şekilde tasarlanmıştır.


Materyal ve metodolojinin kapsamı, veri toplama süreçlerinden başlayarak, dijital ürünlerin oluşturulması ve analiz aşamalarına kadar tüm süreci kapsamaktadır. Çalışma sürecinde hem görüntü işleme hem de mekânsal analizler için farklı yazılımlar ve algoritmalar kullanılmış, bu süreçler her bir alt başlık altında detaylandırılmıştır. Bu amaç doğrultusunda, OBIA tabanlı bir segmentasyon-sınıflandırma iş akışı tasarlanmış ve NDVI analizi ile entegre edilmiştir. Bu bağlamda, çalışma alanı, kullanılan İHA ve kamera özellikleri, uçuş planlaması, görüntü veri işleme ve sayısal haritaların üretimi, nesne tabanlı görüntü analizi ile ağaç tespiti ve ağaç tepe noktaları NDVI değerleri ve bitki sağlığı analizi başlıkları altında çalışmada izlenen yöntemler açıklanmıştır.

Bu bağlamda, çalışma alanı, kullanılan İHA ve kamera özellikleri, uçuş planlaması, görüntü veri işleme ve sayısal haritaların üretimi, nesne tabanlı görüntü analizi ile ağaç tespiti ve ağaç tepe noktaları NDVI değerleri ve bitki sağlığı analizi başlıkları altında çalışmada izlenen yöntemler açıklanmıştır. Bu bölümler, çalışmanın temel bilimsel altyapısını oluşturmakta ve kullanılan teknolojik araçlar, veri işleme teknikleri ve analiz süreçleri hakkında detaylı bilgi sunmaktadır.

2.1. Çalışma Alanı

Bu çalışma, Türkiye'nin Akdeniz Bölgesi'nin önemli tarım alanlarından biri olan Adana'nın Yüreğir ilçesinde gerçekleştirilmiştir. Tarımsal potansiyeli yüksek olan bölge, doğusunda Osmaniye, Kahramanmaraş, Gaziantep, batısında Mersin, kuzeybatısında Niğde, güneydoğusunda Hatay ile il sınırına sahiptir. Çalışma alanı Adana il merkezinin 96 km batısındadır (Şekil 1). Çalışma alanının bulunduğu İlçe güneyden Yumurtalık ve Karataş, doğudan Ceyhan, kuzeyden Sarıçam, batıdan Seyhan ilçeleri ile çevrilidir. Çalışma alanı, coğrafi olarak 36°54'K ve 35°36'D koordinatlarında yer almakta olup kentsel bir alan da tarım arazisi ekosistemine sahiptir. Kışların sert geçmediği bu ilçede tarımsal ürün üretimi oldukça fazladır. Ayrıca uygun topoğrafya, iklim, toprak ve su koşulları ile ilçede Adana İli'ne paralel olarak tahıl türleri arasında en çok buğday, arpa, yulaf ve pirinç yetiştirilmektedir. Bu alanda Sanayi bitkileri arasında ise pamuk başta gelir. Bunların yanı sıra yağ bitkilerinden pamuk çekirdeği (çiğit) ve yer fıstığı, meyvecilikte turfandalık ve turuncgil yetiştiriciliği bölgede yaygın tarım kollarını oluşturur. Çalışma alanı narenciye üretiminin yapıldığı yaklaşık 6,8 hektarlık tarım arazisidir. Çalışma bölgesi, tarım yönetimi, amacıyla seçilmiştir. Bölgenin seçilmesinde, çalışma alanının da bulunan ağaç yapısı, çevresel sorunlar ve uzaktan algılama tekniklerinin uygulanabilirliği gibi etmenler etkili olmuştur.

Bu çalışma kapsamında, İHA tabanlı veri toplama ve uzaktan algılama analizleri için arazi yapısı, düz bir topoğrafyaya sahiptir ve bitki örtüsü yoğunluğu tekli ağaç yapılarından oluşmaktadır. Çalışma alanında gerçekleştirilen veri toplama sürecinde güneş ışığının yoğun olduğu yaz mevsiminde uygulanmıştır. Bu bölge, doğal yapısı ve çevresel özellikleri ile çalışmanın bilimsel ve teknik hedeflerini destekleyecek ideal bir alan olarak değerlendirilmiştir.




Şekil 1. Çalışma alanı

2.2. Verilerin Elde Edilmesi

Son on yılda hızlı bir gelişim kaydeden İHA teknolojisi, farklı disiplinlerde çeşitli amaçlarla yaygın bir şekilde kullanılmaktadır. Bu araçların büyük bir çoğunluğu RGB sensörlere sahiptir. RGB sensörlü İHA'ların küresel ölçekte daha kolay erişilebilir ve düşük maliyetli olması, bu tür cihazların yaygınlaşmasını sağlamıştır (Akca ve Polat, 2022).

RGB sensörlere sahip İHA'lar ile yapılan çalışmalar, ağaç ve bitki tespiti gibi birçok uygulamada başarılı sonuçlar elde etmiştir. Ancak, özellikle bitki örtüsü bulunmayan alanlar ile bitki örtüsünün karıştığı durumlarda sınırlı ayırım kabiliyeti gösterdikleri gözlemlenmiştir (Han vd., 2022). Bu eksikliklerin giderilmesi amacıyla kırmızı kenar (RedEdge) ve yakın kızılötesi (Near-Infrared/NIR) bantlarının kullanılması, bitki örtüsü ile bitki örtüsü bulunmayan alanlar arasında daha yüksek bir ayırt edicilik sağlamaktadır.

Bu nedenle, bu çalışmada hem RGB hem de G-R-RedEdge-NIR sensörlerine sahip bir İHA tercih edilmiştir. Bu çalışmada, hava görüntülerinin toplanması için Şekil 2'de detaylı olarak gösterilen ve teknik özellikleri ise Tablo 1'de sunulan Parrot Bluegrass marka bir İHA kullanılmıştır.




Şekil 2. Parrot Bluegrass İHA ve Parrot Sequoia+ kamera

Tablo 1

Parrot Bluegrass İHA ve Parrot Sequoia + kamera teknik özellikler (Parrot Bluegrass, 2018)

Özellik	Değer
Ağırlık/Boyut	1850 g / 500x440x120 mm (20x17x5 in)
Seyir hızı/Maksimum uçuş süresi	2-20 m/s / Yaklaşık 25 dakika
Radyo bağlantı mesafesi	2 km
Uydu Konumlandırma Sistemleri	GPS + GLONASS
Kamera modeli	Parrot Sequoia+
Sensör tipi	4 ayrı bant (R-G-Redge-NIR) ve RGB
4 x Sensörlerin Odak Uzaklığı	3.98 mm
4 Global Shutter Tek Bant Kameralar	Çözünürlük: 1.2 Mpx, 1280x960 piksel
RGB Odak Uzaklığı	4.88 mm
RGB Kamera	Çözünürlük: 16 Mpx, 4608x3456 piksel


Çalışmada, veri toplama aşamasında ilk olarak hava görüntülerdeki koordinatların arazi koordinatlarına dönüştürülebilmesi amacıyla, görüntü alımından önce arazi üzerinde jeodezik çalışmalar gerçekleştirilmiştir. Bu kapsamda, arazide koordinatları bilinen noktalar, fotoğraflarda seçilebilecek şekilde YKN olarak işaretlenmiş ve bu noktaların konumları Küresel Navigasyon Uydu Sistemi (Global Navigation Satellite Systems/GNSS) Cors tekniği ile hassas bir şekilde ölçülmüştür. YKN'lerin, proje alanı genelinde mümkün olduğunca homojen bir şekilde dağıtılmasına özen gösterilmiştir. YKN'lerin arazideki konumsal dağılımı Şekil 3'te sunulmuştur. Noktaların homojen şekilde yerleştirilmesi, model referanslandırması ve konumsal hata değerlendirmelerinde güvenilirlik sağlamıştır.



Şekil 3. Çalışma alanında belirlenen 12 adet YKN konumunun ortomozaik görüntü üzerindeki dağılımı.

YKN'lerin arazide belirlenmesinin ardından, çalışma alanından yüksek doğrulukta görüntü verisi elde etmek amacıyla titizlikle hazırlanmış bir uçuş planlaması yapılmıştır. Bu planlama sırasında, İHA rotalarının oluşturulması ve optimize edilmesi için Pix4DCapture yazılımı kullanılmıştır. Bu yazılım, proje alanını kapsayan uçuş rotalarını tasarlamak, bindirme oranlarını belirlemek ve İHA'nın uçuş rotasını hem yatay düzlemde hem de irtifa açısından hassas bir şekilde takip etmesini sağlamak amacıyla tercih edilmiştir."

İHA ile görüntü toplama sürecinde kullanılan otonom uçuş rotası, çalışma alanının tamamını kapsayacak şekilde optimize edilmiştir (Şekil 4). Şekil 4'te, çalışma alanının uçuş planlamasını gösteren şematik grafik (sol) ve planın oluşturulduğu Pix4DCapture mobil uygulaması arayüzü (sağ) birlikte sunulmuştur. Pix4DCapture ekran görüntüsünde, uçuş yüksekliği 60 m olarak belirlenmiş; %70 örtüşme oranı ve 400x170 m görev alanı ile 8 dakikalık uçuş süresi hesaplanmıştır. Bu oranlar, görüntüler arasında yeterli örtüşme sağlayarak 3B veri elde edilmesi ve ortofoto üretimi için temel gereksinimlerdendir. Kullanıcı dostu arayüzdeki bu parametrelerin görsel sunumu, çalışma sürecinin tekrarlanabilirliği açısından önemli bir referans oluşturmaktadır.



Şekil 4. Çalışma alanı üzerinde planlanan İHA uçuş rotalarının şematik gösterimi ile Otonom ızgara uçuş güzergâhı (Sol) ve ve Pix4DCapture mobil uygulamasında oluşturulan görev planı arayüzü (sağ).

Yazılım, bindirme oranlarını dikkate alarak uçuş rotalarını otomatik olarak hesaplamış ve görselleştirmiştir. Ayrıca, uçuş yüksekliği, hız, kamera açısı ve görüntüleme sıklığı gibi parametreler de yazılım aracılığıyla optimize edilmiştir. Uçuş sürecinde, İHA'nın pil ömrü ve dönüş süresi gibi teknik detaylar göz önünde bulundurularak uçuşlar iki ayrı bölüm halinde gerçekleştirilmiştir. Uçuş sırasında, GNSS verileri ile İHA'nın gerçek zamanlı konumu izlenmiş ve yazılımın sağladığı ara yüz üzerinden uçuş verileri anlık olarak takip edilmiştir. Bu süreç, uçuş planlamasının doğruluğunu artırmış ve çalışma alanından elde edilen görüntülerin analiz edilebilirliğini sağlamıştır. Bu planlama yaklaşımı sayesinde, çalışma alanının tüm detaylarını kapsayan yüksek çözünürlüklü görüntüler elde edilmiştir. Elde edilen görüntülerin arazi üzerindeki YKN ile uyumlu olması, jeodezik doğruluğun artırılmasına önemli ölçüde katkı sağlamıştır.

Çalışma kapsamında, otonom uçuşlar yaklaşık 60 m irtifada ve ~ 5.65 cm/piksel yer örnekleme aralığı (YÖA) ile gerçekleştirilmiştir. YÖA, sensörün yere olan uzaklığı ve kamera parametrelerine bağlı olarak, tek bir pikselin arazideki fiziksel karşılığıdır ve fotogrametrik ürünlerde detay seviyesinin belirlenmesinde temel bir ölçüttür. Her bir görüntü, İHA üzerinde bulunan dahili GPS/GLONASS modülü kullanılarak coğrafi koordinatlarla etiketlenmiştir. Görüntüleme süreci, 10 m/s sabit uçuş hızında ve sürekli çekim modunda (saniyede 1 görüntü) tamamlanmıştır.

Uçuş sırasında, nadir bir konumdan (90° görüş açısı) toplamda 320 görüntü toplanmıştır. Bu görüntülerin 256 tanesi dört bantlı multispektral fotoğraf (Red-Green-NIR-RedEdge) ve 64 tanesi RGB fotoğraf olarak kaydedilmiştir. Bu düzen, çalışma alanının multispektral ve RGB verilerle detaylı bir şekilde haritalanmasını sağlamıştır.

2.3. Görüntü Veri İşleme ve Sayısal Haritaların Üretimi

Görüntü veri işleme, mekânsal analizler ve dijital haritaların oluşturulmasında temel bir adımdır. Bu süreç, modern fotogrametrik tekniklerin ve bilgisayarlı görüntüleme algoritmalarının etkin bir şekilde uygulanmasıyla, yüksek doğrulukta sayısal haritalar ve 3B verilerin üretilmesini sağlar (Liv vd., 2021). Özellikle İHA kullanımı, geniş alanlardan veri toplanmasında hız ve maliyet avantajı sunarak bu alanda devrim niteliğinde bir değişim yaratmıştır. Bu çalışma da bu verilerin elde edilmesi için fotogrametri tekniği kullanılmıştır.


Fotogrametri, metrik kameralar veya özel sensör sistemleri ile elde edilen fotoğrafların ya da görüntülerin kaydedilmesi, ölçülmesi ve yorumlanması yoluyla fiziksel nesnelerin güvenilir ölçümlerini ve bilgilerini elde etmeyi sağlayan bir tekniktir (Kraus, 2011; Deliry ve Avdan, 2021). Bu teknik, dijital haritaların üretimi için yaygın olarak kullanılmaktadır. Son yıllarda ihtiyaç duyulan mekânsal verilerin toplanmasında benimsenen yöntemlerden biri de İHA) olmuştur. İHA teknolojisi, geniş alanlardan veri toplama süreçlerini daha hızlı ve düşük maliyetli bir şekilde gerçekleştirme imkânı sunmaktadır.

Teknolojideki ilerlemeler, fotogrametri ile bilgisayarlı görüntüleme teknolojisinin entegrasyonunu sağlamış ve bu durum, 3B veri ile çalışma esnekliğini artırarak dijital haritaların üretim süreçlerinde otomasyonu geliştirmiştir (Fernández-Hernández vd., 2015). Günümüzde, dijital kameralarla elde edilen fotoğraflardan 3B veri üretimini mümkün kılan çeşitli yazılımlar mevcuttur. Bu yazılımların çoğu, SfM gibi özel algoritmalara

dayanmaktadır (Fonstad vd., 2013; Javernick vd., 2014; Westoby vd., 2012; Berra vd., 2020). SfM, sahnenin geometrisini, kamera konumlarını ve yönelimlerini, bilinen 3B konumlara sahip bir hedef ağının önceden tanımlanmasına gerek kalmadan otomatik olarak çözümleyen bir fotogrametrik tekniktir (Snavely vd., 2008; Vasuki vd., 2014; Noori vd., 2024).

SfM, bilgisayarla görselleştirme tabanlı bir ölçüm yöntemi olarak özellikle İHA platformlarında kullanımıyla son yıllarda büyük bir popülerlik kazanmış ve düşük maliyetiyle öne çıkan bir teknoloji haline gelmiştir (Bryson et al., 2013; Gomez, 2015; Berra vd., 2020). Bu avantajları nedeniyle SfM, bilimsel araştırmalarda yaygın olarak kullanılmaktadır (Iglhaut vd., 2019). Düşük maliyet, hızlı sonuç alma ve kolay 3B ölçüm kabiliyeti özellikleri sayesinde SfM, yerbilimleri araştırmalarında dönüştürücü bir etki yaratmıştır.

SfM yönteminde 3B veriler, örtüşen bir dizi fotoğraf çerçevesi kullanılarak oluşturulur. Yöntem, birbiriyle örtüşen fotoğraflar arasında ortak noktaları bulma ve eşleştirme prensibine dayanır. Bu çalışmada, SfM algoritmasına dayalı fotogrametrik iş akışı Şekil 5'te şematik olarak sunulmuştur. Görsel, veri toplama aşamasından ortomozaik üretimine kadar izlenen adımları ve her aşamadaki temel girdileri açık şekilde göstermektedir.



Şekil 5. SfM algoritmasına dayalı fotogrametrik iş akışının şematik gösterimi.

Şekil 5'te de görüldüğü üzere SfM süreci, görüntülerdeki ortak noktaların belirlenmesiyle başlar. Bu aşamada, görüntüler arasında örtüşme sağlayan özellikler algılanır ve bu özellikler üzerinden eşleştirme yapılır. Bu çalışmada SfM tabanlı fotogrametrik süreç Agisoft Metashape yazılımı ile gerçekleştirilmiştir. Görüntüler arasında bağlantılar kurularak, kameraların uzaydaki tahmini konumlarının belirlenmesi için temel bir yapı oluşturulur. Bu adım, görüntülerin hizalanması ve doğru bir temel koordinat sistemine oturtulması için kritik öneme sahiptir.

Görüntüler arasında eşleştirilen ortak noktalar kullanılarak, her bir görüntünün çekildiği kamera konumları hesaplanır. Bu adım hem kamera hareketinin izlenmesini hem de sahnenin 3B yapısının ilk tahmininin elde edilmesini sağlar (Ferro vd., 2024). SfM algoritmasının bu aşaması, herhangi bir önceden tanımlanmış referans ağı olmaksızın geometrik bir çözüm sunar. Blok dengeleme, görüntü eşleştirme sürecinden elde edilen geometrik çözümü optimize eder (Goldbergs vd., 2018). Bu adımda, kameraların konumları ve görüntülerdeki ortak noktaların koordinatları arasındaki hata minimize edilir. Blok dengeleme işlemi, sahnenin daha doğru bir şekilde modellenmesini ve görüntüler arasındaki geometrik uyumun artırılmasını sağlar.

Önceki adımlarda belirlenen ortak noktalar, sahnenin genel geometrisini temsil eden bir seyrek nokta bulutu oluşturmak için kullanılır (Jiang vd., 2020). Bu seyrek nokta bulutu, sahnenin temel yapısının 3B bir taslağını sunar ve daha sonraki aşamalarda yoğunlaştırma işlemi için bir temel oluşturur. Bu aşamada üretilen nokta bulutu ve diğer veriler, YKN verileri kullanılarak coğrafi koordinat sistemine oturtulur (Dai vd., 2023). Bu işlem, modellenen sahnenin dünya koordinatlarında doğru bir şekilde temsil edilmesini sağlar. Referanslandırma, dijital ürünlerin haritalama ve analiz süreçlerinde kullanılabilirliğini artırır.

Seyrek nokta bulutundan elde edilen yapısal bilgi kullanılarak, sahnenin daha detaylı bir modeli oluşturulur. Bu aşamada, görüntülerin tüm piksellerinden alınan bilgilerle yoğun bir nokta bulutu üretilir. Yoğun nokta bulutu, sahnenin yüzey detaylarını ve topografik özelliklerini daha hassas bir şekilde temsil eder (Wallace vd.,

2016). Yoğun nokta bulutundan üretilen veriler, sayısal yükseklik modelleri gibi dijital ürünlerin oluşturulması için kullanılır. Aynı zamanda, görüntüler birleştirilerek ortomozaik haritalar üretilir. Bu ürünler, mekânsal analizlerde ve karar destek sistemlerinde kritik öneme sahiptir.

İHA ile elde edilen yüksek çözünürlüklü görüntüler, SfM algoritması ile işlenmiş ve her bir banta (Red, Green, NIR, RedEdge) ait ortomozaik görüntüler üretilmiştir. Ayrıca, RGB bantların birleştirilmesiyle RGB ortomozaik görüntüleri oluşturulmuştur. Yapılan analizler sonucunda, çalışma bölgesine ait yükseklik bilgilerini içeren sayısal ürünler de elde edilmiştir.

Oluşturulan ortomozaik görüntüler ve sayısal yükseklik modelleri, OBIA için girdi parametreleri olarak kullanılmıştır. Bu ürünler, çalışma alanının mekânsal analizlerinde yüksek doğruluk ve detay sağlamış, araştırmanın temel veri setini oluşturmuştur.

2.3.1. Fotogrametrik Verilerin Doğruluk Araştırılması

Bu çalışmada, fotogrametrik verilerin doğruluğu, YKN referans alınarak değerlendirilmiştir. YKN'ler, çalışma alanında hassas jeodezik yöntemlerle ölçülmüş ve fotogrametrik modelin dünya koordinat sistemine uyumunu sağlamak amacıyla referans olarak kullanılmıştır.

Doğruluk araştırması kapsamında, üretilen dijital veriler (orto-mozaik, 3B yükseklik modelleri) üzerinden alınan konum bilgileri, YKN'lerin gerçek koordinatları ile karşılaştırılmıştır. Bu karşılaştırma, yatay ve düşey doğruluk seviyelerinin değerlendirilmesine olanak tanımıştır. Her bir YKN için ölçülen sapmalar, Kök Ortalama Kare Hatası (Root Mean Squared Error/RMSE) (Hodson, 2022) yöntemi kullanılarak analiz edilmiş ve modelin genel doğruluk düzeyi belirlenmiştir. Bu süreçte doğruluk seviyesi, Denklem 1'de verilen formül ile hesaplanmıştır.

YKN verilerinin kullanımı, fotogrametrik verilerin jeodezik doğruluğunu sağlamak ve üretilen dijital ürünlerin güvenilirliğini artırmak açısından kritik bir öneme sahiptir. Bu süreç, özellikle çalışmanın sonuçlarının doğruluğu ve geçerliliği üzerinde belirleyici bir etki yaratmıştır. Çalışma da toplam 12 YKN kullanılmıştır. Bunlarda altı tanesi referanslandırma için diğer altı tanesi ise doğruluk analizi için kullanılmıştır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (2.1)$$

Burada:

x_i : Gerçek (ölçülen) değer,

$\hat{x}_i$: Model tarafından tahmin edilen değer,

n : Toplam veri noktası sayısını ifade etmektedir.

Bu formül, gerçek değerlerle model tarafından tahmin edilen değerler arasındaki farkların karelerini alır, bu farkların ortalamasını hesaplar ve sonuçta karekök alarak hata değerini sağlar. RMSE, modelin genel doğruluk seviyesi hakkında bilgi verir; düşük RMSE, modelin daha doğru olduğunu gösterir.

2.4. Nesne Tabanlı Görüntü Analizi ile Ağaç tespiti

Geleneksel piksel tabanlı sınıflandırma yöntemleri, her bir pikseli bağımsız olarak değerlendirerek sınıflandırma yaptığı için bu karmaşıklığı tam olarak yansıtamayabilir (Jianget vd., 2008). Bu durum, "tuz ve biber" etkisi olarak bilinen, anlamsız ve dağınık sınıflandırma sonuçlarına yol açabilir. OBIA ise uzaktan algılama verilerinin analizinde son yıllarda sıklıkla tercih edilen bir yöntem haline gelmiştir (Bilgilioglu, 2015; Blaschke vd., 2024). OBIA, pikseller yerine nesne seviyesinde analiz yaparak, mekânsal ve spektral bilgileri birleştirir ve daha hassas sonuçlar sunar (Bergsjö, 2014; Ruess vd., 2024). OBIA, öncelikle benzer spektral ve mekânsal özelliklere sahip pikselleri bir araya getirerek anlamlı nesneler (segmentler) oluşturur (Yiğit ve Uysal 2020). Bu segmentler, tek tek piksellerden daha fazla bilgi içerir ve gerçek dünyadaki nesneleri daha iyi temsil

eder (Baatz vd., 1999; Marino vd., 2024). OBIA, sınıflandırma sürecinde sadece spektral bilgiyi değil, aynı zamanda nesnelerin şeklini, boyutunu, dokusunu, komşuluk ilişkilerini ve bağlamsal bilgilerini de kullanır (Baatz vd., 1999; Mahdy, 2024). Bu bütüncül yaklaşım, özellikle karmaşık kentsel ortamlarda daha doğru ve anlamlı sınıflandırma sonuçları elde edilmesini sağlar (Blaschke, 2010).

Bu çalışmada, İHA ile elde edilen multispektral ve RGB ortomozaik görüntüler, OBIA yöntemine entegre edilerek çalışma alanındaki ağaçların tespiti gerçekleştirilmiştir. OBIA yöntemi, görüntülerin segmentasyon işlemine tabi tutulmasıyla başlayarak, belirli kurallar ve eşik değerler çerçevesinde her bir segmentin sınıflandırılmasını sağlamaktadır. Segmentasyon ve sınıflandırma süreci, spektral özellikler, şekil, doku ve diğer mekânsal parametrelere dayalı olarak gerçekleştirilmiştir.

Ağaç tespiti, özellikle multispektral verilerdeki RedEdge ve NIR bantlarının yüksek ayırt edici özelliklerinden faydalanılarak gerçekleştirilmiştir. Bu bantlar, bitki örtüsünün spektral yanıtını hassas bir şekilde ölçerek, ağaçlar ile bitki örtüsü bulunmayan alanlar arasındaki ayrımı belirgin hale getirmiştir. OBIA yöntemi ile elde edilen sonuçlar, çalışma alanındaki ağaç varlığının hem doğruluk hem de detay bakımından başarılı bir şekilde tespit edilmesini sağlamıştır.

Özellikle bitki örtüsünün yoğunluğunu ve sağlığını değerlendirmede yaygın olarak kullanılan bir uzaktan algılama indeksi olan NDVI, görüntülerindeki Red ve NIR bantlardaki yansıma değerlerinin karşılaştırılması esasına dayanır (Govi vd., 2024). Bitkiler, klorofil pigmentleri sayesinde görünür kırmızı ışığı yoğun bir şekilde emerken, hücresel yapıları nedeniyle NIR ışığı güçlü bir şekilde yansıtırlar (Ferro vd., 2024). Bu spektral özelliklerden yararlanılarak hesaplanan NDVI, bitki örtüsünün varlığı, yoğunluğu ve genel durumu hakkında nicel bir ölçüt sunar.

Bu çalışmada İHA verilerinden NDVI değerlerinin elde edilmesi ve OBIA süreçleri, eCognition Developer ortamında yürütülmüştür. Bu tercih, yazılımın çok çözünürlüklü segmentasyon, sınıflandırma kuralları ve görsel kontrol imkânları gibi OBIA'ya özgü fonksiyonlar sunması nedeniyle yapılmıştır. Ayrıca, kullanıcı dostu arayüzü sayesinde segmentasyon parametrelerinin hızlı optimize edilmesine olanak tanımaktadır.

NDVI değerleri, ortomozaik verilerindeki belirli bantlardaki yansıma değerleri kullanılarak Denklem 2 ile hesaplanmıştır. Temel Prensipte: NDVI, bitki örtüsünün kırmızı ışığı emme ve NIR ışığı yansıtma özelliğine dayanmaktadır. Sağlıklı bitki örtüsü, klorofil nedeniyle kırmızı ışığı yoğun bir şekilde emerken, hücresel yapısı nedeniyle NIR ışığı güçlü bir şekilde yansıtır. Bu fark, NDVI hesaplamasında kullanılır.

$$NDVI = \frac{NIR - R}{NIR + R} \quad (2.2)$$

NDVI hesaplamak için eCognition yazılımı kullanmamız, araştırmamızın hedeflerine ulaşmak ve karmaşık kentsel çevrelerdeki arazi örtüsü değişimlerini doğru bir şekilde analiz etmek için kritik öneme sahiptir. eCognition, OBIA yaklaşımını benimseyen güçlü bir yazılımdır ve geleneksel piksel tabanlı yöntemlere kıyasla çeşitli avantajlar sunmaktadır.

Yazılım, farklı ölçeklerde ve özelliklerde nesneler oluşturmak için çeşitli segmentasyon algoritmaları sunar (Mahdy, 2024). Özellikle çoklu çözünürlüklü segmentasyon algoritması, kullanıcı tanımlı parametreler (ölçek, şekil, kompaktlık) aracılığıyla anlamlı ve homojen nesnelerin oluşturulmasına olanak tanır. Bu, farklı özellikte temsil edilen nesnelerin diğer yüzeylerden ayırmak için kritik öneme sahiptir (Hemmateenejad vd., 2024). Ayrıca nesnelerden çok çeşitli spektral, mekânsal, şekilsel ve bağlamsal özelliklerin çıkarılmasına olanak tanımaktadır (Madhuanand vd., 2024). Bu özellikler, farklı arazi örtüsü sınıflarını ayırt etmek için kullanılır. Örneğin, yeşil bitki örtüsü/vejetasyon genellikle yüksek NDVI değerlerine, belirli bir dokuya ve şekle sahipken, yer yüzeyi farklı spektral özelliklere ve geometrik şekillere sahip olabilir. Bu zengin özellik seti, sınıflandırma doğruluğunu önemli ölçüde artırmaktadır. Kullanılan yazılım Coğrafi Bilgi Sistemleri (CBS) yazılımlarıyla sorunsuz bir şekilde entegre olabilmektedir. Sınıflandırılmış veriler, CBS ortamında daha fazla analiz ve görselleştirme için kolayca aktarılabilir (Sari vd., 2024).

Sonuç olarak, araştırmamızda eCognition yazılımının tercih edilmesinin temel nedenleri, yazılımın OBIA yaklaşımını benimsemesi, gelişmiş segmentasyon algoritmaları, zengin özellik seti, kural tabanlı sınıflandırma

yetenekleri, çeşitli analizi desteği ve CBS entegrasyonudur (Madhuanand vd., 2024). Bu özellikler, karmaşık ortamlardaki bitki örtüsü yüzeylerin doğru ve güvenilir bir şekilde analiz etmemize olanak sağlayarak araştırma hedeflerimize ulaşmamıza önemli katkı sağlamaktadır.

NDVI analizi, öncelikle ilgili görüntülerinin yazılıma aktarılmasıyla başlamaktadır ve bant aritmetiği kullanılarak NDVI değeri piksel düzeyinde hesaplanabilir. Bu işlem için, yeni bir özel özellik oluşturulur ve formül alanına NDVI denklemi girilir. Burada NIR, yakın kızılötesi bandın yansıma değerini, Red ise kırmızı bandın yansıma değerini temsil etmektedir (Sharma vd., 2024). Çalışmanın temel avantajlarından biri olan OBIA yaklaşımı, NDVI analizine farklı bir boyut kazandırmaktadır. Görüntü öncelikle homojen piksel gruplarından oluşan anlamlı nesnelere (segmentlere) ayrılır. Bu segmentasyon süreci, ölçek, şekil ve kompaktlık gibi parametreler aracılığıyla kontrol edilir ve analiz edilecek arazi örtüsü özelliklerine uygun nesnelerin oluşturulması hedeflenir (Tarmizi ve Rizwan, 2024). Segmentasyon parametrelerinin (ölçek, şekil, kompaktlık) belirlenmesinde, eCognition yazılımında bulunan Optimizasyon Segmentasyon Parametreleri (Optimal segmentasyon Parameter/OSP) (Yao ve Wang, 2019) aracı kullanılmıştır. OSP, kullanıcı tarafından tanımlanan bir amaç fonksiyonunu optimize ederek, manuel deneme yanılma yöntemine kıyasla daha objektif ve verimli bir şekilde en uygun parametre kombinasyonunu belirlemeyi sağlamaktadır. Bu yaklaşım, segmentasyon kalitesini artırarak sonraki sınıflandırma adımlarının doğruluğunu olumlu yönde etkilemektedir. Segmentasyonun ardından, her bir nesne için ortalama NDVI değeri veya NDVI istatistikleri (minimum, maksimum, standart sapma vb.) hesaplanabilecektir. Bu yaklaşım, piksel tabanlı analizde ortaya çıkabilecek gürültüyü azaltır ve daha anlamlı sonuçlar elde edilmesini sağlamaktadır. Sonuç olarak, OBIA yaklaşımı ve gelişmiş analiz araçları sayesinde NDVI analizini daha doğru, anlamlı ve bağlamsal hale getirmekte ve kentsel yeşil alan araştırmaları gibi çeşitli uygulamalar için değerli bilgiler sunmaktadır.

2.4.1. Nesne Tabanlı Görüntü Analizi için Doğruluk Araştırması

Uzaktan algılama görüntülerinden elde edilen NDVI değerlerinin güvenilirliği ve doğruluğu, yapılan analizlerin ve çıkarımların geçerliliği açısından kritik öneme sahiptir. Doğruluk analizi, hesaplanan NDVI değerlerinin gerçek dünya koşullarını ne kadar iyi yansıttığını değerlendirme sürecidir. Doğruluk analizi, sınıflandırılmış haritanın gerçek dünya koşullarını ne kadar doğru bir şekilde yansıttığını nicel olarak belirlemeyi amaçlar. Harici doğrulama verilerinin temininde zorluklar yaşandığı durumlarda uygulanan Eğitim ve Test Alanları (Training and Test Area/TTA) maskesi yöntemi, sınıflandırma doğruluğunun içsel bir değerlendirmesini sağlamak için etkili bir alternatif (Jalbuena vd., 2016) olmaktadır. Bu yaklaşım, sınıflandırma sürecinde kullanılan eğitim verileri ile sınıflandırma sonuçlarının değerlendirilmesinde kullanılacak bağımsız test verilerinin aynı veri seti içerisinde belirlenmesine dayanmaktadır (Kampouri vd., 2019). TTA maskesi oluşturma süreci, öncelikle sınıflandırılacak her bir arazi örtüsü sınıfını temsilen, uydu görüntüsü üzerinde homojen ve karakteristik alanların uzman bilgisi ve görsel yorumlama yoluyla belirlenmesini içermektedir. Bu alanlar, yazılımının sunduğu vektör tabanlı çizim araçları kullanılarak manuel olarak işaretlenir ve her bir alan ilgili sınıf etiketiyle ilişkilendirilir. Belirlenen bu alanlar daha sonra iki alt kümeye ayrılır (Dwikarsa ve Basith, 2021). Bunlar sınıflandırma algoritmasının eğitimi için kullanılan eğitim alanları ve oluşturulan sınıflandırma modelinin performansını değerlendirmek amacıyla kullanılan test alanlarıdır. Test alanlarının, eğitim alanlarından mekânsal olarak bağımsız olması ve sınıflandırılan bölgenin genelindeki sınıf dağılımını temsil etmesi, doğruluk analizinin güvenilirliği açısından kritik öneme sahiptir (Aguilar vd., 2021). Eğitim ve test alanlarının ayrılma oranı, genellikle veri setinin büyüklüğüne ve sınıf çeşitliliğine bağlı olarak değişmekle birlikte, yaygın olarak kullanılan oranlar %70-80 eğitim ve %20-30 test şeklindedir. Oluşturulan ve etiketlenen bu eğitim ve test alanları yazılımında bir TTA maskesi olarak kaydedilir. Bu analizde, TTA maskesindeki test alanları referans veri olarak kabul edilir ve sınıflandırma sonuçları bu referans verilerle piksel veya nesne bazında karşılaştırılır. Bu karşılaştırma sonucunda bir karmaşıklık matrisi (confusion matrix) oluşturulacaktır. Karmaşıklık matrisi, her bir sınıf için doğru sınıflandırılan (Doğru Pozitifler-DP), doğru bir şekilde tanımlanan ama NDVI olmayanlar (Doğru negatif-DN), yanlış sınıflandırılan (Yanlış Pozitifler- YP ve Yanlış Negatifler- YN) örnek sayılarını özetlemektedir. Bu matris üzerinden çeşitli doğruluk metrikleri hesaplanır. Bunlar Denklem 3, 4, 5,6, 7 ve 8’de verilmiştir.

Doğruluk: Toplam doğru sınıflandırılan örnek sayısının toplam örnek sayısına oranıdır ve sınıflandırma performansının genel bir ölçüsünü sunar ve Denklem 3 ile hesaplanır.

$$\text{Doğruluk} = \frac{YN + DP}{DN + DP + YN + YP} \quad (2.3)$$

Kesinlik: pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu ölçer. Başka bir deyişle, sınıflandırıcının "evet" dediği durumlardan kaç tanesinin gerçekten "evet" olduğunu gösterir ve Denklem 4 ile hesaplanır.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (2.4)$$

Geri Çağırma: Gerçekte pozitif olan sınıfların ne kadarının doğru bir şekilde pozitif olarak sınıflandırıldığını gösterir ve Denklem 5 ile hesaplanır.

$$\text{Geri Çağırma} = \frac{DP}{DP + YN} \quad (2.5)$$

Belirlilik: Gerçekte negatif olan sınıfların ne kadarının doğru bir şekilde negatif olarak sınıflandırıldığını gösterir ve Denklem 6 ile hesaplanır.

$$\text{Belirlilik} = \frac{DN}{DN + YP} \quad (2.6)$$

F-skör: Kesinlik ve Geri Çağırma'nın harmonik ortalamasıdır ve sınıflandırma modelinin hem pozitif tahminlerdeki doğruluğunu hem de gerçek pozitifleri yakalama yeteneğini dengeler ve Denklem 7 ile hesaplanır.

$$F - \text{skör} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.7)$$

Kappa Katsayısı: Şans eseri gerçekleşen sınıflandırmayı hesaba katan bir doğruluk ölçüsüdür. Sınıflandırma sonuçları ile referans veriler arasındaki uyumu değerlendirir. Kappa katsayısı, genel doğruluğa göre daha sağlam bir ölçüt olarak kabul edilir çünkü şans faktörünü elimine eder. 0 ile 1 arasında değer alır, 1 mükemmel uyumu gösterir ve Denklem 8 ile hesaplanır.

$$\begin{aligned} &\text{Kappa Katsayısı} \\ &= \frac{(DP + DN) - [(DP + YN)(DP + YP) + (YP + DN)(YN + DN)] / (DP + YP + YN + DN)}{(DP + YP + YN + DN) - [(DP + YN)(DP + YP) + (YP + DN)(YN + DN)] / (DP + YP + YN + DN)} \quad (2.8) \end{aligned}$$

Hesaplanan doğruluk metrikleri, sınıflandırma sonuçlarının kalitesi hakkında önemli bilgiler sunar. Yüksek doğruluk değeri, sınıflandırmanın genel olarak iyi performans gösterdiğini işaret ederken, duyarlılık ve özgüllük değerleri, sınıflandırıcının belirli sınıfları doğru bir şekilde tanımlama ve yanlış sınıflandırmalardan kaçınma yeteneği hakkında detaylı bilgi verir. F-ölçütü, kesinlik ve duyarlılık arasında bir denge kurarak sınıflandırma performansının daha bütüncül bir değerlendirmesini sağlar. Kappa katsayısı ise, şans faktörünü göz önünde bulundurarak sınıflandırma sonuçlarının güvenilirliğini değerlendirmede kritik bir rol oynar. Bu istatistiksel göstergelerin kesin tanımları, Chen vd. (2018) ve Orhan vd. (2022) tarafından yapılanlar da dahil olmak üzere çok sayıda yayında açıklanmıştır. Gerekli hesaplamalar aşağıdaki denklemlerin uygulanması yoluyla elde edilebilir. P değişkeni NDVI olarak sınıflandırılan piksellerin toplam sayısını temsil ederken, N değişkeni NDVI değeri olarak sınıflandırılmayan piksellerin toplam sayısını temsil etmektedir. YP, yanlış sınıflandırılan piksellerin sayısını gösterirken; YN, NDVI olmayan olarak tanımlanan piksellerin sayısını

temsil eder. Doğru sınıflandırılan piksellerin sayısı DP ile temsil edilirken, DN ise NDVI olmayan olarak doğru sınıflandırılan piksellerin sayısını temsil eder (Chen vd., 2017).

2.5. Ağaç Tepe Noktaları NDVI Değerleri ve Bitki Sağlığı Analizi

Bu çalışmada, İHA ile elde edilen multispektral görüntüler OBIA yöntemiyle işlenmiş ve segmentasyon işlemi gerçekleştirilmiştir. Segmentasyon sonucunda her bir ağaç bireysel bir nesne olarak tanımlanmış ve bu nesnelerin NDVI değerleri hesaplanmıştır. Hesaplanan NDVI değerleri ve segmentasyon sonuçları, analizlerin devamında kullanılmak mekânsal analiz süreçlerinde CBS yazılımı olan ArcGIS Pro yazılımı tercih edilmiştir. Bu tercih, yazılımın yaygın akademik kullanımının yanı sıra, raster tabanlı eşikleme ve zonal istatistik gibi analizleri entegre biçimde gerçekleştirme yeteneğine dayanmaktadır.

CBS yazılımında, segmentasyon sonuçları mekânsal veri katmanlarıyla birleştirilmiş ve her bir ağaç nesnesi için NDVI tabanlı analizler gerçekleştirilmiştir. Ağaç tepe noktalarının belirlenmesi için yerel maksimum algoritmaları uygulanmış ve her bir ağacın tepe koordinatları belirlenmiştir. Bu süreçte, NDVI değerleri, ağaçların sağlık durumlarını belirlemek için temel bir ölçüt olarak kullanılmıştır.

Ağaçların sağlık durumları, NDVI değerlerine göre üç ana kategoriye ayrılmıştır:

- Sağlıklı ağaçlar: $NDVI > 0.6$
- Orta sağlıkta ağaçlar: $0.4 \leq NDVI \leq 0.6$
- Stres altındaki ağaçlar: $NDVI < 0.4$

Analizin yapıldığı yazılımda, NDVI değerlerinin dağılımı mekânsal olarak analiz edilmiş ve sağlık durumlarına göre ağaçların çalışma alanındaki dağılımları haritalanmıştır. Bu süreçte, NDVI değerlerine dayalı renk kodlu haritalar oluşturularak, çalışma alanındaki sağlıklı ve stres altındaki ağaçların mekânsal düzeni görselleştirilmiştir. Ayrıca, her bir ağaç için tepe noktaları ve sağlık durumları veritabanına kaydedilmiştir.


Bu analizler sonucunda, çalışma alanındaki bireysel ağaçların tepe noktaları ve sağlık durumları detaylı bir şekilde değerlendirilmiş, özellikle stres altındaki ağaçların bulunduğu bölgelerdeki potansiyel çevresel faktörler üzerine çıkarımlarda bulunulmuştur. ArcGIS Pro'nun sunduğu mekânsal analiz araçları, segmentasyon sonuçlarının daha ileri düzeyde analiz edilmesine olanak sağlamış ve çalışma alanının genel bitki sağlığı hakkında detaylı bilgiler sunmuştur.

3. Bulgular

3.1. Fotogrametri Yöntemi ile Ortomozaik Harita Analizi

Çalışma alanında, İHA ile toplanan multispektral görüntüler, fotogrametrik işleme süreci sonucunda yüksek çözünürlüklü ortomozaik haritalara dönüştürülmüştür. Fotogrametrik işlem için SfM algoritması kullanılmış, görüntülerin hizalanması ve 3B nokta bulutlarının oluşturulması sağlanmıştır. SfM algoritması, görüntüler arasındaki örtüşen bölgelerdeki ortak noktaları tespit ederek, her bir görüntünün uzaydaki konumunu ve yönelimini belirlemiştir. Bu süreç, YKN ile desteklenmiş ve coğrafi doğruluğun artırılması sağlanmıştır.

Üretilen ortomozaik harita, yaklaşık 5.65 cm/piksel mekânsal çözünürlük değerine sahiptir ve görüntüler arasında %70 boyuna ve %70 enine bindirme oranları sağlanmıştır. Bindirme oranlarının yüksek tutulması, 3B veriler ve ortomozaik üretimi sırasında yüksek doğruluk elde edilmesine katkıda bulunmuştur. Haritanın mekânsal detayları, çalışma alanının topografik yapısını ve ağaç örtüsünü detaylı bir şekilde temsil etmiştir. Fotogrametrik iş akışı sonucunda elde edilen yüksek çözünürlüklü ortomozaik görüntü Şekil 6'da sunulmuştur. Bu ortomozaik, segmentasyon, NDVI hesaplamaları ve doğruluk analizleri gibi birçok mekânsal işlem için temel veri setini oluşturmuştur.



Şekil 6. Çalışma alanına ait RGB ve multispektral bantların entegrasyonu ile üretilen yüksek çözünürlüklü ortomozaik görüntü

Doğruluk analizi, haritanın YKN'ler ile karşılaştırılması sonucunda gerçekleştirilmiştir. Analizler sonucunda, yatay doğruluk için RMSE değeri X, Y ve Z için sırasıyla 0.38 cm, 0.35 cm, 0.42 cm olarak hesaplanmıştır. Bu değerler, üretilen ortomozaik haritanın yüksek doğruluk düzeyinde olduğunu ve mekânsal analizlerde güvenilir bir veri seti sağladığını göstermektedir. Doğruluk analizi 6 YKN ile gerçekleştirilmiştir. Detaylı analiz Tablo 2'de verilmiştir.

Tablo 2

Fotogrametrik ürünlerin doğruluk analizi

YKN No	Sapma (X) (cm)	Sapma (Y) (cm)	Sapma (Z) (cm)
1	0.47	0.39	0.40
2	0.23	0.45	0.67
3	0.47	0.25	0.36
4	0.50	0.29	0.29
5	0.22	0.18	0.18
6	0.31	0.43	0.44
RMSE	0.38	0.35	0.42

Ortomosaik harita, çalışma alanındaki ağaç tepe noktalarının belirlenmesi, NDVI analizi ve diğer mekânsal çalışmalar için temel bir veri seti olarak kullanılmıştır. Harita üzerinde yapılan analizler, bitki örtüsünün yoğunluğunu, arazi kullanımı detaylarını ve topografik özellikleri detaylı bir şekilde ortaya koymuştur. Ayrıca, haritanın koordinat sistemi olarak WGS 84 UTM Zonu 36N kullanılmış ve çalışma alanının gerçek dünya koordinatlarıyla uyumlu hale getirilmesi sağlanmıştır.

Sonuç olarak, fotogrametrik yöntemler ile üretilen ortomozaik harita hem çözünürlük hem de doğruluk açısından başarılı bir performans sergilemiş ve çalışmanın ilerleyen aşamalarında kullanılacak verilerin temelini oluşturmuştur. Ortomozaik haritanın detaylı yapısı, mekânsal analizlerin ve ağaç tespiti gibi uygulamaların yüksek doğrulukla gerçekleştirilmesine olanak tanımıştır. Bu sonuçlar, fotogrametrik yöntemlerin, özellikle İHA tabanlı çalışmalar için etkin bir araç olduğunu bir kez daha kanıtlamaktadır.

3.2. OBIA ile Ağaç Tespiti ve Doğruluk Analizi

Bu çalışmada, segmentasyon işlemi, görüntülerin pikseller yerine OBIA yaklaşımıyla analiz edilmesini sağlamak için gerçekleştirilmiştir. Çalışmada, ağaç tespiti için ilk olarak segmentasyon işlemi gerçekleştirilmiştir. Segmentasyon, görüntülerin pikseller yerine, mekânsal ve spektral özelliklere dayalı olarak oluşturulan nesneler halinde analiz edilmesini sağlar. Segmentasyon işlemi için en uygun parametrelerin belirlenmesi ve sonuçların doğruluk açısından optimize edilmesi amacıyla OSP kullanılmıştır. OSP, OBIA

yönteminde kullanılan en önemli adımlardan biri olan segmentasyon işleminin başarısını artırmak için uygulanır. OSP, segmentasyon sırasında kullanılan parametrelerin (örneğin, ölçek, şekil ve kompaktlık parametreleri) optimize edilmesi yoluyla, analizde doğruluk ve etkinliği artırmayı hedefler.


OSP'nin belirlenmesinde hem yazılım tarafından önerilen başlangıç değerleri hem de deneysel analizler esas alınmıştır. Bu süreçte, segmentasyon parametreleri farklı kombinasyonlarla test edilmiş ve elde edilen sonuçlar görsel değerlendirme ve doğruluk analizi ile karşılaştırılmıştır. Nihai olarak belirlenen parametreler, çalışma alanındaki bireysel ağaçların başarılı bir şekilde tanımlanmasını sağlamıştır.

Bu süreçte, segmentasyon sonuçları görsel değerlendirme ve doğruluk analizleriyle sürekli olarak karşılaştırılmıştır.

- **Ölçek Parametresi:** Ölçek parametresi, segmentlerin boyutunu belirler ve özellikle ağaç tespiti gibi çalışmalarda kritik bir rol oynar. Küçük bir ölçek, segmentlerin aşırı detaylı olmasına ve her bir ağacın birden fazla segmentle temsil edilmesine neden olurken, büyük bir ölçek, birden fazla ağacın tek bir segmentte birleştirilmesine yol açabilir. Bu çalışmada, 20 ile 50 arasında ölçek değerleri test edilmiş ve bireysel ağaçları en iyi şekilde temsil eden 20 değeri seçilmiştir.
- **Şekil Parametresi:** Şekil parametresi, segmentlerin geometrik şekil özelliklerine verilen önemi tanımlar. Bu parametrenin yüksek tutulması, segmentlerin şekil özelliklerine daha fazla odaklanılmasını sağlarken, düşük bir değer, spektral özelliklerin daha fazla önceliklendirilmesini sağlar. Çalışma alanında ağaçların genellikle düzensiz geometrik şekillere sahip olması nedeniyle, spektral bilgiyi önceliklendiren bir yaklaşım benimsenmiş ve 0.3 değeri uygun bulunmuştur.
- **Kompaktlık Parametresi:** Kompaktlık parametresi, segment sınırlarının netliği ve detay seviyesi üzerinde etkilidir. Yüksek bir kompaktlık değeri, segmentlerin sınırlarının belirgin olmasını sağlarken, düşük değerler daha geniş ve daha az ayrıntılı segmentler üretir. Bu çalışmada, sınırların net bir şekilde belirlenmesi için 0.5 değeri kullanılmıştır.


Segmentasyon sürecinde farklı ölçek parametrelerinin nesne oluşumuna etkisi Şekil 7'de karşılaştırmalı olarak gösterilmiştir. Özellikle 20 ölçek değerinde, bireysel ağaç yapılarının daha net ayrıştığı ve sınıflandırma doğruluğunun arttığı gözlemlenmiştir.

Segmentasyon sonuçları Şekil 7'de gösterilmiştir. Görüldüğü üzere, segmentasyon, bireysel ağaçları başarılı bir şekilde ayırmış ve çalışma alanındaki bitki örtüsünün spektral ve mekânsal özelliklerini yansıtmıştır. Segmentasyon sonrası ağaçların doğru bir şekilde tanımlanması, OBIA yönteminin doğruluğunu artıran önemli bir adımdır. OSP'nin belirlenmesi için kullanılan deneysel yöntem, segmentasyon işleminin ağaç tespiti üzerindeki etkisini anlamada önemli bir katkı sağlamıştır. Segmentasyon parametrelerinin optimize edilmesi, bireysel ağaçların doğru bir şekilde temsil edilmesini ve diğer arazi unsurlarından (örneğin, çalılar, çıplak toprak) net bir şekilde ayrılmasını mümkün kılmıştır.




Şekil 7. OBIA kapsamında test edilen farklı segmentasyon ölçek parametrelerine ait görsel karşılaştırmalar. Görseller, sırasıyla 50, 40, 30 ve 20 ölçek değerlerinde elde edilen segmentasyon sonuçlarını göstermektedir.

OBIA temelli segmentasyon sonucunda elde edilen bireysel ağaç tespiti, Şekil 8’de ortomozaik görüntü ile karşılaştırmalı olarak sunulmuştur. Şekil 8’de yer alan NDVI tabanlı ortomozaik görüntü (sol) ve OBIA ile tespit edilen bireysel ağaç segmentasyon çıktısı (sağ), bitki sağlığı ve obje ayrımı açısından yöntemin mekânsal etkinliğini ortaya koymaktadır. Görüntüdeki kırmızı tonlar düşük NDVI değerlerini temsil etmekte olup, bu alanlar çoğunlukla kenar bölgeler ve ağaç dışı unsurlarla örtüşmektedir. Sağ paneldeki segmentasyon çıktısı, bireysel ağaçların yüksek NDVI değerleriyle birlikte tanımlanabilir olduğunu ve OBIA yaklaşımının düzenli tarım yapılarında başarılı şekilde uygulanabildiğini göstermektedir. Ağaçlar arası boşlukların doğru segmentlerle korunmuş olması, sınıflandırma modelinin geometriye duyarlı çalıştığını da desteklemektedir.



Şekil 8. Çalışma alanına ait ortomozaik görüntü (sol) ve OBIA yöntemiyle tespit edilen bireysel ağaçlar (sağ). Ortomozaik görüntü, yeşil (G), kırmızı (R) ve yakın kızılötesi (NIR) bantların birleşimiyle oluşturulmuş olup, bitki örtüsünün spektral özelliklerini yansıtmaktadır. Sağ panelde ise segmentasyon ve sınıflandırma süreci sonrası tespit edilen ağaçlar yeşil simgelerle gösterilmiştir. Görsel karşılaştırma, yöntemle elde edilen bireysel ağaç ayrımının doğruluğunu ve mekânsal bütünlüğünü ortaya koymaktadır.


Ağaç tespiti sürecinde, segmentasyon sonrası uygulanan maskeleme ve gürültü temizleme işlemleri Şekil 9’da görsel olarak sunulmuştur. Şekil 9, segmentasyon sonrası uygulanan gürültü temizleme ve maskeleme sürecini göstermektedir. Sol panelde ham segment maskesi yer almakta olup, düşük spektral tepki veren ve yapısal olarak uygun olmayan birçok küçük segment de görünmektedir. Sağ panelde ise alan, şekil faktörü ve NDVI eşik değerleri ile yapılan filtreleme sonrasında yalnızca bireysel ağaçlara karşılık gelen segmentlerin kaldığı gözlemlenmektedir. Bu filtreleme sayesinde hem yanlış pozitif sınıflandırmalar azaltılmış hem de modelin yalancı örneklerden etkilenme riski minimize edilmiştir. Gürültü azaltımı sonrası mekânsal dağılım daha homojen ve sistematik bir yapı kazanmıştır.



Şekil 9. OBIA süreci sonrası oluşturulan maskeleme uygulamasıyla elde edilen çalışma alanı (sol) ve gürültülerden arındırılmış, nihai tespit edilen bireysel ağaçlar (sağ).

Şekil 10’da ise bireysel ağaç tespit sonuçlarının hem genel dağılımı hem de örnek bir bölgedeki yakınlaştırılmış bir bölümünde bireysel ağaç segmentlerinin detay gösterimi sunulmaktadır. Şekil 10’dan da anlaşılacağı üzere, segment sınırları ile ağaç gövdeleri oldukça iyi örtüşmektedir. Özellikle ağaçlar arası mesafenin düzenli olması, OBIA segmentasyon algoritmasının geometriye duyarlılığını artırmış; fazla bölme veya eksik bölme

gibi yaygın hatalar minimum düzeyde kalmıştır. Bu durum, segmentasyon ölçek parametresinin (30) optimal olarak seçildiğini ve görsel olarak da doğrulandığını göstermektedir. Bu görsel temsil, hem doğruluk analizi hem de spektral sınıflandırma başarısının mekânsal bir kanıtı niteliğindedir.



Şekil 10. Çalışma alanındaki bireysel ağaçların tespitine ilişkin genel görünüm (sol) ve seçilen alanın yakınlştırılmış detay gösterimi (sağ). OBIA yöntemiyle tespit edilen her bir ağaç, yeşil dairesel simgelerle temsil edilmiştir.

Segmentasyon sonucunda çalışma için doğruluk analizi yapılmıştır. Bu çalışmada, ağaç tespiti ve doğruluk analizlerini gerçekleştirmek için TTA yöntemi kullanılmıştır. TTA, analiz edilen çalışma alanının eğitim ve test aşamaları için belirli bölgelere ayrılmasını ifade eder. Bu yöntem, modelin eğitimde gördüğü veri ile test sırasında karşılaşacağı veriyi ayırarak, sınıflandırma sonuçlarının genelleştirilebilirliğini artırmayı hedefler. Çalışmanın güvenilirliğini sağlamak ve doğruluğu değerlendirmek için TTA yöntemi sistematik bir şekilde uygulanmıştır. Çalışma alanı, eğitim (training) ve test bölgeleri olacak şekilde iki ana kategoriye ayrılmıştır. Eğitim alanı, modelin sınıflandırma ve segmentasyon parametrelerini öğrenmesi için kullanılırken, test alanı, modelin bu öğrendiklerini bağımsız bir veri setinde değerlendirmesine olanak tanımıştır.

- Eğitim Alanı: Çalışma alanının yaklaşık %70'i eğitim alanı olarak belirlenmiştir. Bu bölge, farklı arazi tiplerini, bitki örtüsü yoğunluklarını ve spektral varyasyonları içerecek şekilde seçilmiştir.
- Test Alanı: Çalışma alanının kalan %30'u test alanı olarak ayrılmıştır. Test alanı, eğitim sırasında kullanılan verilere benzer olmayan bölgeleri içermesi için özenle seçilmiştir.


Eğitim ve test alanları, CBS tabanlı bir maskeleme işlemi ile ayrılmıştır. Bu işlem sırasında, alanların spektral ve mekânsal çeşitliliği dikkate alınarak, sınıflandırmanın başarısını artıracak bir alan bölünmesi yapılmıştır. Maskeleme işlemi, modelin ağaç ve ağaç olmayan unsurları tespit ederken hem doğruluğunu hem de genelleştirme kapasitesini artırmıştır. Eğitim ve test alanlarının ayrılması, modelin öğrenme aşamasında görülen verilere bağımlı kalmasını engelleyerek genelleştirme yeteneğini artırmıştır. Test alanı, eğitim sırasında kullanılmayan bir veri seti ile değerlendirildiği için sonuçların doğruluğu bağımsız bir şekilde ölçülmüştür. Bu amaçla analiz de Doğruluk, Kesinlik, Geri Çağırma, Belirlilik, F-Skor ve Kappa Katsayısı ölçülmüştür. Sonuçlar Tablo 3'te verilmiştir.

Tablo 3
OBIA doğruluk analizi

Kategori	GP	YP	GN	YN	Doğruluk	Kesinlik	Geri Çağırma	Belirlilik	F-Skor	Kappa Katsayısı
Ağaç	120	10	80	15	0.89	0.92	0.89	0.89	0.90	0.77
Ağaç Olmayan	85	15	120	10	0.89	0.85	0.89	0.89	0.87	0.78

Sınıflandırma performansına ilişkin ayrıntılı metrikler hem sayısal hem de görsel olarak sunulmuştur. Tablo 3'te görüldüğü üzere, ağaç kategorisinde modelin doğruluk değeri %89, kesinlik oranı %92 ve F1-Skor değeri

%90 olarak hesaplanmıştır. Ağaç olmayan kategorisinde ise doğruluk %89, kesinlik %85 ve F1-Skor %87 olarak belirlenmiştir. Ayrıca, Kappa katsayısı ağaç ve ağaç olmayan kategorileri için sırasıyla 0.77 ve 0.78 olarak bulunmuştur. Bu sonuçlar, modelin her iki kategori için de yüksek bir sınıflandırma performansı sergilediğini göstermektedir. Şekil 11'de sunulan ısı haritası ise bu sayısal değerlerin görsel olarak karşılaştırılmasına olanak tanımaktadır.



Şekil 11. OBIA doğruluk analizine ilişkin sınıflandırma metriklerinin kategori bazında görsel karşılaştırması.

Şekil 11'de ağaç kategorisinde F-Skor (0.90) ve kesinlik (0.92) değerlerinin yüksekliği, modelin özellikle ağaç tespiti konusunda güçlü bir ayırım kabiliyetine sahip olduğunu göstermektedir. Buna karşın, ağaç olmayan sınıfta daha düşük kesinlik (0.85) değeri, spektral benzerlik veya arazi örtüsü kaynaklı bazı karışıklıkların yaşandığına işaret etmektedir. Her iki sınıf için benzer doğruluk (%89) ve geri çağırma değerlerinin elde edilmesi, segmentasyon algoritmasının dengeli bir şekilde çalıştığını göstermektedir. Ayrıca, Kappa katsayılarının 0.77 ve 0.78 düzeyinde olması, sınıflandırma sonucunun tesadüfi dağılımdan anlamlı biçimde ayrıldığını ortaya koymaktadır. Tablo 3'teki yüksek F-skor ve kesinlik değerleri, özellikle ağaç sınıfının ayırt edilmesinde modelin kararlılığını ortaya koymaktadır. Buna karşılık, ağaç olmayan sınıftaki daha düşük kesinlik değeri, karışıklık ihtimalinin görece daha yüksek olduğunu göstermektedir.

TTA yöntemi, modelin performansını artırmak ve analizlerin güvenilirliğini sağlamak açısından etkili bir araç olmuştur. Eğitim ve test alanlarının dikkatli bir şekilde ayrılması, modelin doğruluk seviyesini artırmış ve sınıflandırma sonuçlarının genelleştirilebilirliğini sağlamıştır. Özellikle, farklı spektral ve mekânsal özelliklere sahip alanlardan elde edilen sonuçlar, modelin farklı koşullara uyum sağlayabildiğini ve genelleştirme kabiliyetinin yüksek olduğunu ortaya koymuştur.

Bu yöntemin uygulanmasıyla, çalışma alanındaki ağaçların ve ağaç olmayan unsurların başarılı bir şekilde tespit ve sınıflandırıldığı görülmüştür. TTA yöntemi, özellikle mekânsal çeşitliliğin yüksek olduğu bölgelerde uzaktan algılama tabanlı analizlerde güçlü bir temel sağlamış ve sınıflandırma sürecinin doğruluğunu artırmıştır. Sonuç olarak, TTA'nın hem modelin performansı hem de elde edilen sonuçların güvenilirliği üzerinde olumlu bir etkisi olduğu tespit edilmiştir.


Model tarafından yapılan YP sınıflandırmaların büyük bir kısmı, ağaç gölgeleri ve çalı benzeri nesnelerin ağaç olarak algılanmasından kaynaklanmıştır. Gölgeleme nedeniyle spektral yansımanın değişmesi, özellikle NDVI değerlerinde düşüşe yol açarak modelin bazı bölgeleri stresli veya cansız bitki örtüsü olarak değerlendirmesine neden olmuştur. Ayrıca, sık bitkili ve örtüşen taç yapılarının bulunduğu alanlarda segmentasyon hataları görülmüş, bu durum bazı ağaçların tekil nesne yerine birleşik bir yapı olarak algılanmasına neden olmuştur. Bu, özellikle tepe örtüsünün homojen olmadığı bölgelerde model performansını sınırlamıştır.

3.3. NDVI Analizi Sonuçları ve Bitki Sağlığı

Bu çalışmada, bitki sağlığını değerlendirmek ve ağaç tepe noktalarını analiz etmek için NDVI değerleri kullanılmıştır. İHA ile elde edilen multispektral görüntüler işlenmiş ve ağaçlar OBIA yöntemiyle başarılı bir

şekilde tespit edilmiştir. Segmentasyon ve sınıflandırma işlemlerinin ardından her bir ağaca ait NDVI değerleri, CBS yazılımına aktarılmıştır.


CBS ortamında NDVI değerlerini daha anlamlı ve analiz edilebilir bir hale getirmek için veri üzerinde yumuşatma (smooth) işlemi uygulanmıştır. Bu işlem, her bir ağaca ait NDVI değerlerini mekânsal ve spektral olarak homojenleştirmek ve analizdeki gürültüyü azaltmak amacıyla gerçekleştirilmiştir. Yumuşatma işlemi, çevresel faktörlerin neden olduğu ani değişiklikleri minimize ederek, daha tutarlı bir analiz için sağlam bir temel oluşturmuştur. Bu işleme ait görüntü Şekil 12’de verilmiştir.



Şekil 12. Tespit edilen bireysel ağaçların CBS yazılımında Smooth yapılmamış (sol) ve Smooth yapılmış (sağ) görüntüsü

Smooth işlemi sonrası, her bir ağacın NDVI değerleri daha dengeli bir yapıya kavuşmuş ve çalışma alanındaki ağaçların sağlık durumu daha net bir şekilde değerlendirilmiştir. Bu süreç, özellikle farklı ağaç grupları ve stres altındaki bölgelerin tespiti için kritik bir öneme sahiptir.

Yumuşatma işleminden sonra, her bir ağacın NDVI değeri analiz edilmiştir. NDVI değerleri, bitki sağlığını değerlendirmek için daha önce aktarılan değerlere göre Sağlıklı Ağaçlar, Orta Sağlıkta Ağaçlar ve Stres Altındaki Ağaçlar olmak üzere üç kategoriye ayrılmıştır. Bu kategoriler, her bir ağacın fotosentetik aktivite seviyesini ve genel sağlık durumunu temsil etmektedir. CBS ortamında NDVI değerleri mekânsal olarak analiz edilerek ağaçların sağlık durumu haritalandırılmıştır. Bu süreçte, ağaçların tepe noktalarının koordinatları ve NDVI değerleri, bitki sağlığına dair detaylı bir değerlendirme yapılmasını sağlamıştır. Örnek bir alan Şekil 13’te verilmiştir.



Şekil 13. Bireysel ağaçların tepe merkezlerinin NDVI değerlerinin belirlenmesi

NDVI değerlerinin CBS ortamına aktarımı ve smooth işlemi, analiz sürecinin doğruluğunu artırmış ve ağaçların sağlık durumunun değerlendirilmesinde kritik bir rol oynamıştır. Bu yöntem hem sağlıklı hem de stres altındaki ağaç gruplarını ayırt etmeyi mümkün kılmış ve bitki sağlığı analizi için güçlü bir temel oluşturmuştur.

Şekil 13, çalışma alanında bulunan ağaçların NDVI değerlerine göre mekânsal dağılımını göstermektedir. Görselde, her bir ağacın tepe noktası çevresindeki NDVI değerleri farklı renk kodları ile ifade edilmiştir. NDVI değerleri bitki sağlığı ve fotosentetik aktiviteye dayalı olarak kategorilere ayrılmıştır.

NDVI değerlerinin düşük olduğu 0.40-0.48 aralığı (kırmızı tonlar), stres altındaki bitki örtüsünü veya düşük fotosentetik aktiviteye sahip alanları temsil etmektedir. Bu bölgelerde, bitkilerin su eksikliği, hastalık veya diğer çevresel stres faktörlerinden etkilenmiş olabileceği düşünülmektedir. Orta düzeyde fotosentetik aktiviteye sahip 0.48-0.55 aralığı (turuncu tonlar), kısmen sağlıklı ancak çevresel koşullardan etkilenebilecek bitkileri göstermektedir.

Sağlıklı bitkiler 0.55-0.65 aralığında (yeşil tonlar) yoğunlaşmakta olup, bu kategorideki bitkilerin iyi durumda olduğu görülmektedir. 0.65-0.70 aralığı (açık yeşil tonlar), çok sağlıklı bitki örtüsünü ifade ederken, 0.70 ve üzeri değerler (mavi tonlar) maksimum fotosentetik aktiviteye sahip bitkileri temsil etmektedir.

Harita, bitki sağlığının mekânsal farklılıklarını net bir şekilde ortaya koymuştur. Çalışma alanındaki ağaçların büyük çoğunluğu 0.55 ve üzeri NDVI değerine sahiptir ve bu durum bitki örtüsünün genel olarak sağlıklı olduğunu göstermektedir. Ancak, düşük NDVI değerlerinin belirli bölgelerde yoğunlaşması, bu alanların çevresel stres faktörlerinden etkilendiğini göstermektedir.

Bu analiz, bitki örtüsünün sağlık durumunun mekânsal olarak değerlendirilmesi ve stres altındaki bölgelerin tespit edilmesi açısından önemli bilgiler sağlamıştır. Şekil 13, tarımsal yönetim ve çevresel izleme çalışmaları için kritik bir veri seti sunmaktadır.

3.4. Karşılaştırmalı Doğruluk Analizi

Bu bölümde, çalışma alanındaki toplam ağaç sayısı ile modelin tespit ettiği ağaç sayısı karşılaştırılarak, doğruluk analizine dayalı bir değerlendirme yapılmıştır.

Çalışma alanında toplamda 1126 gerçek ağaç olduğu belirlenmiş ve modelin bu ağaçları tespit etme başarısı doğruluk analiziyle değerlendirilmiştir. Model, bu süreçte toplam 1002 ağacı doğru bir şekilde tespit etmiş, ancak 87 nesneyi yanlış bir şekilde ağaç olarak sınıflandırmıştır. Bu durumda, modelin tahmini tespit ettiği toplam ağaç sayısı 1089 olarak hesaplanmıştır. Gerçek ağaç sayısı ile kıyaslandığında, modelin doğruluk performansı oldukça yüksek olmakla birlikte, bazı eksik tespitler ve yanlış sınıflandırmalar gözlemlenmiştir.

Modelin kesinlik değeri %92 olarak hesaplanmış olup, modelin tespit ettiği ağaçların büyük bir çoğunluğunu doğru sınıflandırdığını göstermektedir. Duyarlılık değeri ise %89 düzeyinde belirlenmiş ve bu oran, gerçek ağaçların büyük bir kısmının doğru bir şekilde tespit edildiğini ifade etmektedir. Bu sonuçlar, modelin genel olarak etkili bir tespit yeteneğine sahip olduğunu ortaya koymaktadır. Ancak, geriye kalan 124 eksik tespit edilen ağaç, modelin bazı durumlarda arazi unsurlarını tespit edemediğini veya sınıflandırmada zorlandığını göstermektedir.

Elde edilen doğruluk analiz sonuçları, modelin ağaç tespiti konusunda başarılı bir performans sergilediğini, ancak bazı yanlış pozitifler ve eksik tespitler nedeniyle iyileştirmeye açık alanların bulunduğunu ortaya koymaktadır. Model, büyük ölçüde doğru sonuçlar üretmiş olsa da doğruluk analizine dayanarak sınıflandırma süreçlerinde daha gelişmiş algoritmaların veya ek veri setlerinin kullanımıyla bu performansın daha da artırılabilmesi değerlendirilmektedir. Karşılaştırmalı doğruluk analizi, bu çalışmanın güçlü yanlarını ve iyileştirilmesi gereken alanlarını net bir şekilde ortaya koyarak, OBIA yönteminin gücünü ve sınırlılıklarını kapsamlı bir şekilde değerlendirmeye olanak tanımıştır.

4. Tartışma

Bu çalışma, uzaktan algılama ve OBIA yöntemlerini kullanarak, ağaç tespiti ve bitki sağlığı değerlendirmelerinde yüksek doğruluk oranları sunan bir yaklaşım ortaya koymuştur. NDVI değerleriyle

desteklenen analiz sonuçları, ağaç ve ağaç olmayan unsurların başarılı bir şekilde ayrımını sağlamış ve çalışma alanındaki bitki örtüsünün genel sağlık durumunu ayrıntılı bir şekilde ortaya koymuştur. Doğruluk analizi sonuçları, modelin genelleştirme kabiliyetini ve sınıflandırma doğruluğunu göstermektedir. Ancak, yöntemle ilgili belirli sınırlılıklar ve iyileştirme alanları da bulunmaktadır.

Benzer çalışmalar incelendiğinde, OBIA tabanlı bireysel ağaç tespiti ve bitki sağlığı analizi üzerine önemli sonuçlar elde edildiği görülmektedir. Örneğin, Torres-Sánchez vd. (2018) çalışmasında, İHA verileriyle elde edilen 3B nokta bulutlarının OBIA yaklaşımıyla entegre edilmesi sayesinde, badem ağaçlarının geometrik özellikleri yüksek doğrulukla belirlenmiştir. Adhikari vd. (2021) ise ultra-yüksek çözünürlüklü görüntülerle bireysel ağaç gölgesi çıkarımında OBIA'nın etkinliğini vurgulamıştır. Bu çalışmada ise, önceki literatürden farklı olarak hem segmentasyon parametrelerinin etkisi test edilmiş hem de NDVI analizleriyle ağaç sağlığı değerlendirilerek OBIA'nın tarım alanlarındaki çok yönlü potansiyeli ortaya konmuştur. Bu yönüyle araştırma, hem sınıflandırma doğruluğu hem de sağlık haritalaması açısından literatüre yeni bir katkı sunmaktadır.

Çalışmada kullanılan OBIA yöntemi, segmentasyon sürecinin başarısına büyük ölçüde bağlıdır. Segmentasyon parametrelerinin optimizasyonu ile yüksek doğruluk oranları elde edilmiş olsa da özellikle karmaşık ve yoğun bitki örtüsüne sahip bölgelerde model performansının bir miktar düştüğü gözlemlenmiştir. Yanlış pozitif sınıflandırmalar, genellikle çalılar, gölgeler veya topografik detayların model tarafından yanlış yorumlanmasından kaynaklanmıştır. Bu durum, daha gelişmiş segmentasyon algoritmaları veya ek spektral bilgilerle azaltılabilir.

Bununla birlikte, OBIA yönteminin belirli sınırlılıkları olduğu da göz ardı edilmemelidir. Özellikle, farklı ağaç türlerinin benzer spektral özelliklere sahip olması, sınıflandırma sürecinde yanlış pozitif ve negatif oranlarını artırabilmektedir. Ayrıca, yoğun gölgeleme etkisi, özellikle taç örtüsünün birbirine yakın veya üst üste bindiği bölgelerde segmentasyon doğruluğunu olumsuz etkileyebilmektedir. Wicaksono ve Hernina (2021) benzeri çalışmalarda da bu tür örtüşmelerin, segmentlerin doğru sınırlarla ayrıştırılmasını zorlaştırdığı belirtilmiştir. Ayrıca, farklı ışık koşullarında elde edilen görüntülerde, spektral yansıma varyasyonları OBIA kurallarının tutarlılığını azaltabilmektedir. Bu sınırlamaların azaltılması için gelecek çalışmalarda, ek spektral bantların kullanımı, gölge maskeleri ile ön işleme uygulanması ya da derin öğrenme tabanlı sınıflandırıcıların OBIA ile hibrit kullanımı değerlendirilebilir.

NDVI analizi, bitki sağlığının değerlendirilmesi için etkili bir yöntem sunmuştur. Ancak, NDVI'nın sadece spektral yansımaya dayalı bir indeks olması, çevresel stres faktörlerinin nedenlerini detaylı bir şekilde açıklamak için yeterli olmamıştır. Özellikle, düşük NDVI değerlerinin stres kaynaklarını (örneğin, su eksikliği, hastalık) net bir şekilde ayırt edemediği durumlarda, ek fizyolojik ölçümlerin (örneğin, klorofil içeriği veya toprak nemi) entegre edilmesi gereklidir. Ayrıca, literatürde Normalized Edilmiş Fark Kırmızı Kenar İndeksi (Normalized Difference Red Edge/NDRE), Yeşil Band Tabanlı NDVI (Green NDVI/GNDVI) ve Görünür Bant Atmosfer Dirençli İndeksi (Visible Atmospherically Resistant Index/VARI) gibi göstergeler de bitki sağlığı izleme çalışmalarında yaygın biçimde kullanılmaktadır. Ancak bu çalışmada, veri setinin bant yapısı ve analiz kapsamı doğrultusunda NDVI kullanımı tercih edilmiştir.

Bir diğer sınırlılık, kullanılan İHA teknolojisinin veri toplama süreçlerine bağlıdır. İHA ile görüntüleme, hava koşullarına ve ışık şartlarına duyarlıdır. Bu çalışmada elde edilen yüksek doğruluk oranlarına rağmen, uygun olmayan çevresel koşullarda toplanan veriler model performansını olumsuz etkileyebilir. Ayrıca, İHA ile elde edilen görüntülerin işlenmesi için yüksek hesaplama gücü gerekmektedir, bu da daha büyük alanlarda analiz yapılmasını sınırlayabilir.

Son olarak, eğitim ve test alanlarının dikkatli bir şekilde seçilmesine rağmen, modelin farklı coğrafi bölgelerdeki genelleştirme performansı test edilmemiştir. Modelin diğer ekosistemlerdeki doğruluğunu değerlendirmek için daha geniş bir veri setine ihtiyaç vardır. Gelecekteki çalışmalar, farklı bölgelerden ve çevresel koşullardan elde edilen verilerle modelin doğruluğunu ve uygulanabilirliğini genişletmeyi hedefleyebilir.

Sonuç olarak, bu çalışma, OBIA ve NDVI tabanlı analizlerin, ağaç tespiti ve bitki sağlığı değerlendirmeleri için etkili bir çözüm sunduğunu göstermiştir. Bununla birlikte, segmentasyon doğruluğunu artıracak yeni algoritmaların entegrasyonu, ek spektral ve fizyolojik verilerin kullanımı ve daha geniş coğrafi testler,

yöntemin doğruluğunu ve uygulama alanını daha da geliştirebilir. Bu öneriler, uzaktan algılama tabanlı çevresel analizlerin gelecekteki yönünü belirlemek için önemli bir temel sunmaktadır.

Bu çalışmanın ortaya koyduğu yöntemsel çerçeve, yalnızca akademik bağlamda değil, aynı zamanda tarım arazilerinin dijital izlenmesi, hastalıkların erken teşhisi ve kaynak yönetiminin iyileştirilmesi gibi pratik alanlarda da doğrudan uygulama potansiyeline sahiptir. Elde edilen bulgular, tarımda hassas yönetim uygulamalarının yaygınlaşmasına ve mekânsal olarak hedeflenmiş müdahale stratejilerinin geliştirilmesine katkı sağlayabilir. Bu kapsamda, bölgesel tarım politikalarının şekillendirilmesinde ve sürdürülebilir gıda üretimi stratejilerinde, bu tür dijital izleme yöntemlerinin daha fazla entegre edilmesi önerilmektedir.

5. Sonuçlar

Bu çalışma, ağaç tespiti ve bitki sağlığı değerlendirmesinde uzaktan algılama yöntemlerinin gücünü ortaya koymuştur. OBIA tabanlı segmentasyon ve NDVI analizleri, ağaçların ve genel bitki örtüsünün sağlık durumunu anlamak için etkili bir yaklaşım sunmuştur. Model, genel olarak başarılı sonuçlar üretmiş ve çalışma alanındaki ağaçların büyük bir kısmını doğru bir şekilde tespit etmiştir. NDVI değerlerine dayalı olarak sağlıklı ve stres altındaki ağaçlar arasındaki ayrımların net bir şekilde belirlenmesi, çevresel izleme ve tarımsal yönetim uygulamaları için önemli bir katkı sağlamıştır. Ancak, model performansı üzerinde belirli sınırlılıkların olduğu ve gelecekteki çalışmalarla iyileştirilebileceği de gözlemlenmiştir.

Çalışmada, segmentasyon ve sınıflandırma süreçleri optimize edilerek, modelin ağaç tespitindeki doğruluk oranı %89, kesinlik oranı %92 olarak hesaplanmıştır. NDVI analizleri, bitki sağlığı ile ilgili mekânsal farklılıkları etkili bir şekilde ortaya koymuş ve stres altındaki bitkilerin belirlenmesinde önemli bir araç olmuştur. Bu bulgular hem bireysel ağaçların hem de genel bitki örtüsünün değerlendirilmesi için OBIA ve NDVI yöntemlerinin uygulanabilirliğini göstermiştir.

Segmentasyon süreçlerinin doğruluğu, tespit edilen ağaçların çoğunluğunun doğru bir şekilde sınıflandırılmasını sağlamış ancak özellikle yoğun bitki örtüsü veya karmaşık alanlarda yanlış pozitif ve eksik tespit oranları gözlemlenmiştir. Ayrıca, NDVI analizlerinin yalnızca spektral yansımalarla dayanması, çevresel stres faktörlerinin nedenlerini detaylandırmada yetersiz kalmıştır. Bu bağlamda, ek veri kaynaklarının entegrasyonu ve daha gelişmiş analiz yöntemleriyle mevcut modelin performansı artırılabilir.

Gelecekteki çalışmalar, farklı coğrafi bölgelerdeki veri setlerini kapsayacak şekilde genişletilmeli ve modelin genelleştirme yeteneği daha kapsamlı bir şekilde test edilmelidir. Bunun yanı sıra, daha yüksek çözünürlüklü görüntüler ve çoklu spektral sensörlerin kullanımı, sınıflandırma ve bitki sağlığı değerlendirmelerinde daha yüksek doğruluk oranlarına ulaşılmasını sağlayabilir. Ayrıca, çevresel faktörlerin veri toplama süreçleri üzerindeki etkilerini azaltmak için daha uygun stratejiler geliştirilmesi gereklidir.

Çalışmanın sonuçları, yalnızca akademik katkılarla sınırlı kalmayıp, pratik tarımsal uygulamalara da yol gösterici niteliktedir. Geliştirilen yöntem, hassas tarım uygulamalarında bireysel ağaç sağlığının izlenmesi, su ve gübre kullanımı gibi kaynak yönetiminin optimize edilmesi ve hastalıkların erken teşhisi gibi konularda doğrudan uygulama potansiyeline sahiptir. Ayrıca, yerel ve bölgesel düzeyde tarımsal karar destek sistemlerinin iyileştirilmesi amacıyla, bu tür uzaktan algılama tabanlı otomatik analizlerin yaygınlaştırılması önerilmektedir. Özellikle düşük maliyetli ve hızlı uygulanabilir yapısı sayesinde, bu yöntemin küçük ölçekli üreticiler için de erişilebilir bir çözüm sunabileceği değerlendirilmektedir.

Sonuç olarak, bu çalışma, ağaç tespiti ve bitki sağlığı değerlendirmesi için OBIA ve NDVI yöntemlerinin güçlü bir temel sunduğunu göstermiştir. Ancak, daha gelişmiş algoritmalar, ek veri setleri ve genişletilmiş coğrafi testler ile bu yöntemlerin çevresel yönetim ve sürdürülebilir tarım uygulamaları için daha genelleştirilebilir ve etkili sonuçlar üretmesi sağlanabilir. Bu tür iyileştirmeler, uzaktan algılama tabanlı analizlerin çevresel ve tarımsal karar alma süreçlerinde daha yaygın bir şekilde kullanılmasını mümkün kılacaktır.

Teşekkür

Bu çalışmanın ofis işlemlerinde ve çeşitli destek süreçlerinde gösterdiği değerli katkılarından dolayı Harita Mühendisi Mert Anıl Ateş'e teşekkür ederiz.

Yazar Katkıları

Yazarların makaleye katkıları eşittir. Tüm yazarlar; analizi planlamış ve tasarlamıştır, veri toplamış ve analizini yapmıştır, çalışmanın istatistiksel analizlerini yapmış ve makaleyi yazmıştır.

Çıkar Çatışması

Yazarlar arasında herhangi bir çıkar çatışması yoktur.

Kaynaklar

- Adhikari, A., Kumar, M., Agrawal, S., & Raghavendra, S. (2021). An integrated object and machine learning approach for tree canopy extraction from UAV datasets. *Journal of the Indian Society of Remote Sensing*, 49(3), 471–478. <https://doi.org/10.1007/s12524-020-01240-2>
- Aguilar, M. A., Jiménez-Lao, R., & Aguilar, F. J. (2021). Evaluation of object-based greenhouse mapping using WorldView-3 VNIR and SWIR data: A case study from Almeria (Spain). *Remote Sensing*, 13(11), 2133.
- Akca, S., & Polat, N. (2022). Semantic segmentation and quantification of trees in an orchard using UAV orthophoto. *Earth Science Informatics*, 15(4), 2265–2274.
- Baatz, M., & Schäpe, A. (1999). Object-oriented and multiscale image analysis in semantic networks. In *Proceedings of the 2nd International Symposium on Operationalization of Remote Sensing* (pp. xx–xx). Enschede: ITC.
- Bergsjö, J. (2014). Object-based change detection in urban areas using KTH-SEG. *Bachelor Thesis, KTH Royal Institute of Technology*, Stockholm.
- Berra, E. F., & Peppas, M. V. (2020, March). Advances and challenges of UAV SfM MVS photogrammetry and remote sensing: Short review. In *2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)* (pp. 533–538). IEEE.
- Bilgilioglu, B. B. (2015). Uzaktan algılanmış görüntülerden faydalanılarak nesne tabanlı sınıflandırma yöntemi ile kent merkezlerindeki detayların çıkarımı ve yorumlanması. *Yüksek Lisans Tezi*, Aksaray Üniversitesi, Fen Bilimleri Enstitüsü, Aksaray.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2–16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Blaschke, T. (2010). Object-based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2–16.
- Blaschke, T., Kelly, M., & Merschdorf, H. (2024). Object-based image analysis. In *Remote Sensing Handbook, Volume II: Image Processing, Change Detection, GIS, and Spatial Data Analysis* (pp. 145–xx). Springer.
- Bryson, M., Johnson-Roberson, M., Murphy, R., & Bongiorno, J. (2013). Kite aerial photography for low-cost, ultra-high spatial resolution multi-spectral mapping of intertidal landscapes. *PLoS ONE*, 8(9), e73550. <https://doi.org/10.1371/journal.pone.0073550>
- Buja, I., Sabella, E., Monteduro, A. G., Chiriaco, M. S., De Bellis, L., Luvisi, A., & Maruccio, G. (2021). Advances in plant disease detection and monitoring: From traditional assays to in-field diagnostics. *Sensors*, 21(6), 2129.
- Chehreh, B., Moutinho, A., & Viegas, C. (2023). Latest trends on tree classification and segmentation using UAV data—A review of agroforestry applications. *Remote Sensing*, 15(9), 2263.
- Chen, W., Xie, X., Peng, J., Shahabi, H., Hong, H., Bui, D. T., ... & Zhu, A. X. (2018). GIS-based landslide susceptibility evaluation using a novel hybrid integration approach of bivariate statistical-based random forest method. *Catena*, 164, 135–149.
- Chen, W., Xie, X., Peng, J., Wang, J., Duan, Z., & Hong, H. (2017). GIS-based landslide susceptibility modelling: A comparative assessment of kernel logistic regression, Naïve-Bayes tree, and alternating decision tree models. *Geomatics, Natural Hazards and Risk*, 8(2), 950–973.
- D’Andrea, G., Šimunek, V., Castellaneta, M., Vacek, Z., Vacek, S., Pericolo, O., ... & Ripullone, F. (2022). Mismatch between annual tree-ring width growth and NDVI index in Norway spruce stands of Central Europe. *Forests*, 13(9), 1417.

- Dai, W., Qiu, R., Wang, B., Lu, W., Zheng, G., Amankwah, S. O. Y., & Wang, G. (2023). Enhancing UAV-SfM photogrammetry for terrain modeling from the perspective of spatial structure of errors. *Remote Sensing*, 15(17), 4305.
- de Castro, A. I., Torres-Sánchez, J., Peña, J. M., Jiménez-Brenes, F. M., Csillik, O., & López-Granados, F. (2018). An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV imagery. *Remote Sensing*, 10(2), 285. <https://doi.org/10.3390/rs10020285>
- Deliry, S. I., & Avdan, U. (2021). Accuracy of unmanned aerial systems photogrammetry and structure from motion in surveying and mapping: A review. *Journal of the Indian Society of Remote Sensing*, 49(8), 1997–2017.
- Dwikarsa, Y., & Basith, A. (2021). Benthic habitat classification using multiscale GEOBIA on orthophoto images of Karimunjawa waters. *Communications in Science and Technology*, 6(1), 55–59.
- Ecke, S., Dempewolf, J., Frey, J., Schwaller, A., Endres, E., Klemmt, H. J., ... & Seifert, T. (2022). UAV-based forest health monitoring: A systematic review. *Remote Sensing*, 14(13), 3205.
- Fernández-Hernandez, J., González-Aguilera, D., Rodríguez-Gonzálvez, P., & Mancera-Taboada, J. (2015). Image-based modelling from unmanned aerial vehicle (UAV) photogrammetry: An effective, low-cost tool for archaeological applications. *Archaeometry*, 57, 128–145. <https://doi.org/10.1111/arcm.12078>
- Ferro, M. V., Sørensen, C. G., & Catania, P. (2024). Comparison of different computer vision methods for vineyard canopy detection using UAV multispectral images. *Computers and Electronics in Agriculture*, 225, 109277.
- Fonstad, M. A., Dietrich, J. T., Courville, B. C., Jensen, J. L., & Carbonneau, P. E. (2013). Topographic structure from motion: A new development in photogrammetric measurement. *Earth Surface Processes and Landforms*, 38, 421–430. <https://doi.org/10.1002/esp.3366>
- Ghasemi, M., Latifi, H., & Pourhashemi, M. (2022). A novel method for detecting and delineating coppice trees in UAV images to monitor tree decline. *Remote Sensing*, 14(23), 5910. <https://doi.org/10.3390/rs14235910>
- Goldbergs, G., Maier, S. W., Levick, S. R., & Edwards, A. (2018). Efficiency of individual tree detection approaches based on lightweight and low-cost UAS imagery in Australian Savannas. *Remote Sensing*, 10(2), 161.
- Gomez, C., Hayakawa, Y., & Obanawa, H. (2015). A study of Japanese landscapes using structure-from-motion derived DSMs and DEMs based on historical aerial photographs: New opportunities for vegetation monitoring and diachronic geomorphology. *Geomorphology*, 242, 11–20. <https://doi.org/10.1016/j.geomorph.2015.02.021>
- Govi, D., Pappalardo, S. E., De Marchi, M., & Meggio, F. (2024). From space to field: Combining satellite, UAV and agronomic data in an open-source methodology for the validation of NDVI maps in precision viticulture. *Remote Sensing*, 16(5), 735.
- Grippa, T., Lennert, M., Beaumont, B., Vanhuyse, S., Stephenne, N., & Bontemps, S. (2017). An open-source semi-automated processing chain for urban object-based classification. *Remote Sensing*, 9(4), 358. <https://doi.org/10.3390/rs9040358>
- Guo, Q., Zhang, J., Guo, S., Ye, Z., Deng, H., Hou, X., & Zhang, H. (2022). Urban tree classification based on object-oriented approach and random forest algorithm using unmanned aerial vehicle (UAV) multispectral imagery. *Remote Sensing*, 14(16), 3885. <https://doi.org/10.3390/rs14163885>
- Han, P., Ma, C., Chen, J., Chen, L., Bu, S., Xu, S., ... & Hagino, T. (2022). Fast tree detection and counting on UAVs for sequential aerial images with generating orthophoto mosaicing. *Remote Sensing*, 14(16), 4113.
- Haque, M. A., Reza, M. N., Ali, M., Karim, M. R., Ahmed, S., Lee, K. D., ... & Chung, S. O. (2024). Effects of environmental conditions on vegetation indices from multispectral images: A review. *Korean Journal of Remote Sensing*, 40(4), 319–341.
- Hemmateenejad, F., Fallati, L., Panieri, G., Ribeiro, P. A., Fusca, C., Ferré, B., & Savini, A. (2024). The role of substrate attributes as a driver for benthic epifaunal communities investigated applying OBIA techniques and image analysis on the Norskebanken cold seep site (Arctic Ocean). *Copernicus Meetings*.
- Hodson, T. O. (2022). Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development Discussions*, 2022, 1–10.
- Iglhaut, J., Cabo, C., Puliti, S., Piermattei, L., O'Connor, J., & Rosette, J. (2019). Structure from motion

- photogrammetry in forestry: A review. *Current Forestry Reports*, 5, 155–168.
- Ikendi, S. (2023). Ecological conservation, biodiversity, and agricultural education as integrated approaches for envisioning the future of sustainable agriculture in North America. *International Journal of Sustainable Development & World Ecology*, 30(2), 152–163.
- Immitzer, M., Atzberger, C., & Koukal, T. (2012). Tree species classification with random forest using very high spatial resolution 8-band WorldView-2 satellite data. *Remote sensing*, 4(9), 2661–2693.
- Jalbuena, R. L., Peralta, R. V., & Tamondong, A. M. (2016, October). Mangrove classification through the use of object-oriented classification and support vector machine of LiDAR datasets: A case study in Naawan and Manticao, Misamis Oriental, Philippines. In *Earth Resources and Environmental Remote Sensing/GIS Applications VII* (Vol. 10005, pp. 367–375). SPIE.
- Jang, G., Kim, J., Yu, J. K., Kim, H. J., Kim, Y., Kim, D. W., ... & Chung, Y. S. (2020). Cost-effective unmanned aerial vehicle (UAV) platform for field plant breeding application. *Remote Sensing*, 12(6), 998.
- Javernick, L., Brasington, J., & Caruso, B. (2014). Modeling the topography of shallow braided rivers using structure-from-motion photogrammetry. *Geomorphology*, 213, 166–182. <https://doi.org/10.1016/j.geomorph.2014.01.006>
- Jiang, N., Zhang, J. X., Li, H. T., & Lin, X. G. (2008). Object-oriented building extraction by DSM and very high-resolution orthoimages. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37, 441–446.
- 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.
- Kampouri, M., Kolokoussis, P., Argialas, D., & Karathanassi, V. (2019). Mapping of forest tree distribution and estimation of forest biodiversity using Sentinel-2 imagery in the University Research Forest Taxiarchis in Chalkidiki, Greece. *Geocarto International*, 34(12), 1273–1285.
- Kraus, K. (2011). *Photogrammetry: Geometry from images and laser scans*. Walter de Gruyter.
- Lang, S., Kienberger, S., & Hagenlocher, M. (2024). Object-based regionalization. In *Remote Sensing Handbook, Volume II: Image Processing, Change Detection, GIS, and Spatial Data Analysis* (pp. 385–xx). Springer.
- Li, X., Xiong, B., Yuan, Z., He, K., Liu, X., Liu, Z., & Shen, Z. (2021). Evaluating the potentiality of using control-free images from a mini Unmanned Aerial Vehicle (UAV) and Structure-from-Motion (SfM) photogrammetry to measure paleoseismic offsets. *International Journal of Remote Sensing*, 42(7), 2417–2439.
- Madhuanand, L., Philippart, C. J., Nijland, W., de Jong, S. M., Bijleveld, A. I., & Addink, E. A. (2024). Optimizing predictions of environmental variables and species distributions on tidal flats by combining Sentinel-2 images and their deep-learning features with OBIA. *International Journal of Remote Sensing*, 1–24.
- Mahdy, M. (2024). Developing a transferable object-based image analysis (OBIA) approach for the detection and classification of urban features. *Master's thesis, Universidade NOVA de Lisboa*.
- Marino, L., Fallati, L., Varzi, A., Fersini, G., Piazzolla, D., Scanu, S., ... & Savini, A. (2024). Object-based image analysis on acoustic remote sensing data to support restoration actions on a *Posidonia oceanica* meadow offshore Civitavecchia (Eastern Tyrrhenian margin, Mediterranean Sea). *Applied Sciences*, 14(8), 3264.
- McLennon, E., Dari, B., Jha, G., Sihi, D., & Kankarla, V. (2021). Regenerative agriculture and integrative permaculture for sustainable and technology-driven global food production and security. *Agronomy Journal*, 113(6), 4541–4559.
- Mensah, J. (2019). Sustainable development: Meaning, history, principles, pillars, and implications for human action: Literature review. *Cogent Social Sciences*, 5(1), 1653531.
- Nhemachena, C., Nhamo, L., Matchaya, G., Nhemachena, C. R., Muchara, B., Karuaihe, S. T., & Mpandeli, S. (2020). Climate change impacts on water and agriculture sectors in Southern Africa: Threats and opportunities for sustainable development. *Water*, 12(10), 2673.
- Noori, A. M., Al-Saedi, A. S. J., & Abed, F. M. (2024). Optimizing application of UAV-based SfM photogrammetric 3D mapping in urban areas. *Iraqi Journal of Science*, 65(5).
- Orhan, O., Bilgilioglu, S. S., Kaya, Z., Ozcan, A. K., & Bilgilioglu, H. (2022). Assessing and mapping

- landslide susceptibility using different machine learning methods. *Geocarto International*, 37(10), 2795–2820.
- Parrot Bluegrass. (2018). Parrot Bluegrass specification. *The Drone Pro Shop*. <https://www.thedroneproshop.com/blogs/product-info/parrot-bluegrass-specification> [Erişim tarihi: 29.12.2024]
- Rizzo, D. M., Lichtveld, M., Mazet, J. A., Togami, E., & Miller, S. A. (2021). Plant health and its effects on food safety and security in a One Health framework: Four case studies. *One Health Outlook*, 3(1), 6.
- Ruess, S., Paulus, G., & Lang, S. (2024). Automated derivation of vine objects and ecosystem structures using UAS-based data acquisition, 3D point cloud analysis, and OBIA. *Applied Sciences*, 14(8), 3264.
- Sari, A. K., Priyono, K. D., & Rosyadi, Y. (2024, June). Estimation of oil palm tree quantity using oil palm Ecognition and SAGA GIS based on UAV imagery (Case Study: Dumai, Riau). In *IOP Conference Series: Earth and Environmental Science* (Vol. 1357, No. 1, p. 012028). IOP Publishing.
- Sharma, S., Beslity, J. O., Rustad, L., Shelby, L. J., Manos, P. T., Khanal, P., ... & Khanal, C. (2024). Remote sensing and GIS in natural resource management: Comparing tools and emphasizing the importance of in-situ data. *Remote Sensing*, 16(22), 4161.
- Snaveley, N., Seitz, S. M., & Szeliski, R. (2008). Modeling the world from internet photo collections. *International Journal of Computer Vision*, 80(2), 189–210. <https://doi.org/10.1007/s11263-007-0107-3>
- Sun, H., Yan, H., Hassanalian, M., Zhang, J., & Abdelkefi, A. (2023). UAV platforms for data acquisition and intervention practices in forestry: Towards more intelligent applications. *Aerospace*, 10(3), 317.
- Tarmizi, N. M., & Rizwan, N. I. (2024). Integrated supervised classification of LULC in identifying Musang King Durian illegal farming location. *Jurnal Sylva Lestari*, 12(2), 459–479.
- Torresan, C., Berton, A., Carotenuto, F., Di Gennaro, S. F., Gioli, B., Matese, A., Miglietta, F., Vagnoli, C., Zaldei, A., & Wallace, L. (2017). Forestry applications of UAVs in Europe: A review. *International Journal of Remote Sensing*, 38(10), 2427–2447.
- Torres-Sánchez, J., de Castro, A. I., Peña, J. M., Jiménez-Brenes, F. M., Arquero, O., Lovera, M., & López-Granados, F. (2018). Mapping the 3D structure of almond trees using UAV-acquired photogrammetric point clouds and object-based image analysis. *Biosystems Engineering*, 176, 172–184. <https://doi.org/10.1016/j.biosystemseng.2018.10.018>
- Vasuki, Y., Holden, E. J., Kovesi, P., & Micklethwaite, S. (2014). Semi-automatic mapping of geological structures using UAV-based photogrammetric data: An image analysis approach. *Computers & Geosciences*, 69, 22–32. <https://doi.org/10.1016/j.cageo.2014.04.012>
- Velazquez-Chavez, L. J., Daccache, A., Mohamed, A. Z., & Centritto, M. (2024). Plant-based and remote sensing for water status monitoring of orchard crops: Systematic review and meta-analysis. *Agricultural Water Management*, 303, 109051.
- Vélez, S., Martínez-Peña, R., & Castrillo, D. (2023). Beyond vegetation: A review unveiling additional insights into agriculture and forestry through the application of vegetation indices. *J*, 6(3), 421–436.
- Wallace, L., Lucieer, A., Malenovsky, Z., Turner, D., & Vopěnka, P. (2016). Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. *Forests*, 7(6), 62.
- Wang, X., Zhang, J., Xun, L., Wang, J., Wu, Z., Hanchiri, M., ... & Yu, X. (2022). Evaluating the effectiveness of machine learning and deep learning models combined time-series satellite data for multiple crop types classification over a large-scale region. *Remote Sensing*, 14(10), 2341.
- Westoby, M. J., Brasington, J., Glasser, N. F., Hambrey, M. J., & Reynolds, J. M. (2012). Structure-from-motion photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, 300–314. <https://doi.org/10.1016/j.geomorph.2012.08.021>
- Whiteside, T. G., Boggs, G. S., & Maier, S. W. (2011). Comparing object-based and pixel-based classifications for mapping savannas. *International Journal of Applied Earth Observation and Geoinformation*, 13(6), 884–893. <https://doi.org/10.1016/j.jag.2011.06.008>
- Wicaksono, A., & Hernina, R. (2021). Urban tree analysis using unmanned aerial vehicle (UAV) images and object-based classification (Case study: University of Indonesia campus). *IOP Conference Series: Earth and Environmental Science*, 683(1), 012105. <https://doi.org/10.1088/1755-1315/683/1/012105>
- Wolf, B. M., & Heipke, C. (2007). Automatic extraction and delineation of single trees from remote sensing data. *Machine Vision and Applications*, 18(5), 317–330.

- Xu, Z., Shen, X., Cao, L., Coops, N. C., Goodbody, T. R., Zhong, T., ... & Wu, X. (2020). Tree species classification using UAS-based digital aerial photogrammetry point clouds and multispectral imageries in subtropical natural forests. *International Journal of Applied Earth Observation and Geoinformation*, 92, 102173.
- Yang, K., Zhang, H., Wang, F., & Lai, R. (2022). Extraction of broad-leaved tree crown based on UAV visible images and OBIA-RF model: A case study for Chinese olive trees. *Remote Sensing*, 14(10), 2469. <https://doi.org/10.3390/rs14102469>
- Yao, Y., & Wang, S. (2019). Evaluating the effects of image texture analysis on plastic greenhouse segments via recognition of the OSI-USI-ETA-CEI pattern. *Remote Sensing*, 11(3), 231.
- Yılmaz, V., Güngör, O., & Kadioğulları, A. İ. (2015). Görüntü işleme teknikleri ile ağaçların boy, tepe çapı ve tepe hacimlerinin belirlenmesi. In *TUFUAB VIII. Teknik Sempozyumu*.
- Yiğit, A. Y., & Uysal, M. (2020). Automatic road detection from orthophoto images. *Mersin Photogrammetry Journal*, 2(1), 10–17.
- Yuan, X., Li, S., Chen, J., Yu, H., Yang, T., Wang, C., ... & Ao, X. (2024). Impacts of global climate change on agricultural production: A comprehensive review. *Agronomy*, 14(7), 1360.
- Zahoor, Z., Latif, M. I., Khan, I., & Hou, F. (2022). Abundance of natural resources and environmental sustainability: The roles of manufacturing value-added, urbanization, and permanent cropland. *Environmental Science and Pollution Research*, 29(54), 82365–82378.
- Zhang, H., Wang, L., Tian, T., & Yin, J. (2021). A review of unmanned aerial vehicle low-altitude remote sensing (UAV-LARS) use in agricultural monitoring in China. *Remote Sensing*, 13(6), 1221.