

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**İYİLEŞTİRİLMİŞ LOKAL MAKSİMUM YÖNTEMİ İLE NOKTA BULUTLARINDAN AĞAÇ TAÇ
SEGMENTASYONU VE METRİKLERİNİN TAHMİNİ**

YÜKSEK LİSANS TEZİ

Murat BAHADIR

**HAZİRAN 2023
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**İYİLEŞTİRİLMİŞ LOKAL MAKSİMUM YÖNTEMİ İLE NOKTA BULUTLARINDAN
AĞAÇ TAÇ SEGMENTASYONU VE METRİKLERİNİN TAHMİNİ**

Murat BAHADIR

ORCID : - - -

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"HARİTA YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 07 / 06 / 2023

Tezin Savunma Tarihi : 23 / 06 / 2023

Tez Danışmanı : Prof. Dr. Fevzi KARSLI
ORCID : - - -

Trabzon 2023

ÖNSÖZ

“İyileştirilmiş Lokal Maksimum Yöntemi ile Nokta Bulutlarından Ağaç Taç Segmentasyonu ve Metriklerinin Tahmini” adlı bu çalışma Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak hazırlanmıştır.

Tez danışmanlığımı üstlenerek çalışma süresince değerli fikirleriyle çalışmalarına yön veren, bilimsel açıdan farklı platformlarda aktif bir şekilde yer almamı sağlayarak akademik çalışma hayatında bana örnek olan ve her türlü desteğini bir an olsun esirgemeyen hocam Prof. Dr. Sayın Fevzi KARSLI’ya sonsuz teşekkürlerimi sunarım.

Tez çalışması süresince matematiksel modelin geliştirilmesi konusunda değerli fikir ve önerileri ile manevi desteğini esirgemeyen saygı değer çalışma arkadaşlarım Harita Mühendisi Sayın Feride Seçil YILDIRIM’a ve Öğr. Gör. Sayın Emirhan ÖZDEMİR’e teşekkürü borç bilirim.

Tez jürimde yer alan Prof. Dr. Sayın Taşkın KAVZOĞLU’na ve Prof. Dr. Sayın Mehmet MISIR’a yapmış oldukları değerlendirmelerden ve katkılarından dolayı teşekkürlerimi sunarım.

Tez çalışmam boyunca Karadeniz Teknik Üniversitesi, Harita Mühendisliği, Fotogrametri ve Uzaktan Algılama Laboratuvarında birlikte çalıştığım, manevi desteklerini benden esirgemeyen Harita Yüksek Mühendisi Sayın Merve YILDIRIM’a, Harita Mühendisi Sayın Cebail KILINÇ’a, Harita Yüksek Mühendisi Sayın Ahmad Shakib SAHAK’a ve Harita Mühendisi Sayın Batuhan GÜMRÜKÇÜ’ye teşekkür ederim. Ayrıca Lisans eğitim hayatımın başlangıcından itibaren desteğini benden esirgemeyerek gelişimimi yakından takip eden değerli hocam Prof. Dr. Sayın Hüsnüye Ebru ÇOLAK’a sonsuz teşekkür ederim.

Son olarak hayatımın her anında maddi ve manevi olarak yanımda durarak sevgi ve desteklerini hissettiren, bugünlere gelmemde bana destek olan, değerli annem Ayşe BAHADIR, babam Turan BAHADIR, kardeşlerim Harita Mühendisi Burak BAHADIR’a ve Engin BAHADIR’a sonsuz teşekkürlerimi sunarım.

Murat BAHADIR
Trabzon 2023

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “İyileştirilmiş Lokal Maksimum Yöntemi ile Nokta Bulutlarından Ağaç Taç Segmentasyonu ve Metriklerinin Tahmini” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Fevzi KARSLI’nın sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 23/06/2023

Murat BAHADIR

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.2. Tezin Amacı.....	7
1.3. Tezin Kapsam ve Organizasyonu	8
1.4. Literatür Araştırması.....	9
1.5. Temel Kavramlar	19
1.5.1. Fotogrametri	19
1.5.1.1. Fotogrametrinin Matematiksel Modeli	21
1.5.2. Lazer Tarama Teknolojisi (LiDAR)	23
1.5.3. Nokta Bulutları	26
1.5.3.1. LiDAR Nokta Bulutu.....	27
1.5.3.2. Fotogrametrik Nokta Bulutu.....	30
1.5.4. Ağaç Metrikleri.....	33
1.5.5. Allometrik Denklemler	35
1.5.6. Zemin Filtreleme (SMRF)	36
1.5.7. Octree (Sekiz dal) Veri Organizasyonu	37
1.5.8. DBSCAN Kümeleme Algoritması	40
1.5.9. Bézier Eğrileri.....	42
1.5.10. Geleneksel Ağaç Taç Segmentasyon Yöntemleri.....	44
1.5.11. Doğruluk Değerlendirmesi	47
1.5.11.1. Piksel Bazlı Doğruluk Analizi	47
1.5.11.2. Nesne Tabanlı Doğruluk Analizi	50

2.	YAPILAN ÇALIŞMALAR.....	52
2.1.	Çalışma Alanları	53
2.2.	Alan Verileri/ Arazi Ölçüleri.....	56
2.3.	Uzaktan Algılama Verileri.....	57
2.3.1.	Nokta Bulutu Verileri	58
2.4.	Ön Hazırlık Aşaması.....	59
2.5.	Orman Metriklerinin Çıkarımı.....	59
2.6.	Kanopi Yükseklik Modeli Oluşturma ve Ağaç Taç Segmentasyonu	61
2.7.	Octree Yöntemi ile Düşey Yönde Ağaç Segmentasyonu	62
2.8.	Gürültü Özellikli Noktaların Temizlenmesi	63
2.9.	Geliştirilmiş Lokal Maksimum Yöntemi.....	66
2.10.	Alan Bazlı İstatistiksel Ölçütler ile Hatalı Ağaç Kümelerinin Tespiti	69
2.11.	Nihai Ağaç Taç Segmentasyonu.....	71
2.12.	Yeni Ağaç Eşleştirme Modeli.....	72
2.13.	Nesne Tabanlı Doğruluk Analizi.....	74
2.14.	Ağaç Metriklerinin Tahmini	74
3.	BULGULAR.....	76
3.1.	Akdeniz Üniversitesi Bireysel Ağaç Taç Segmentasyon Sonuçları.....	76
3.2.	Maçka (Pilav Dağı) Bireysel Ağaç Taç Segmentasyon Sonuçları	82
3.3.	Cenevre Bireysel Ağaç Taç Segmentasyon Sonuçları.....	87
4.	TARTIŞMA.....	91
4.1.	Akdeniz Üniversitesi Ağaçlık Alanın İrdelenmesi	92
4.2.	Maçka (Pilav Dağı) Ağaçlık Alanın İrdelenmesi	97
4.3.	İsviçre/Cenevre Ağaçlık Alanın İrdelenmesi.....	105
4.4.	Bireysel Ağaç Taç Segmentasyonunu Etkileyen Faktörlerin İrdelenmesi	108
4.5.	Bireysel Ağaç Taç Segmentasyon Doğruluğunun İrdelenmesi	109
4.6.	Ağaç Metrik Tahminlerinin İrdelenmesi	110
4.7.	Nokta Bulutlarının Segmentasyon ve Metrik Tahmini Üzerine Etkileri.....	111
5.	SONUÇLAR VE ÖNERİLER.....	112
6.	KAYNAKLAR.....	114
	ÖZGEÇMİŞ	

ÖZET

İYİLEŞTİRİLMİŞ LOKAL MAKSİMUM YÖNTEMİ İLE NOKTA BULUTLARINDAN AĞAÇ
TAÇ SEGMENTASYONU VE METRİKLERİNİN TAHMİNİ

Murat BAHADIR

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Fevzi KARSLI
2023, 121 Sayfa

Yeryüzünde bulunan doğal ve beşerî unsurların konumsal bilgisi ve hacmi, ekonomik, ekolojik ve sosyokültürel açıdan ülkelerin yönetim politikası için büyük önem arz etmektedir. Bu unsurların kontrolü ve analizi için üç boyutlu konum bilgisine ihtiyaç duyulmaktadır. LiDAR ve fotogrametrik nokta bulutları kentsel modelleme, afet yönetimi ve ormanlık alanların kontrolü gibi birçok uygulamada kullanılmaktadır. Son yıllarda ortaya çıkan iklim değişikliği ve küresel ısınma gibi sorunların önlenmesi için kilit roldeki ağaçların, korunması ve güncel durumlarının kayıt altına alınması gerekmektedir. Ancak özellikle yoğun kapalılıktaki ağaçlık alanlarda GPS, sürekli sinyal alamadığından bu bölgelerde yersel ölçüm teknikleri ile arazi çalışması gerçekleştirmek zaman alıcı ve pahalı bir uğraştır. Ülkelerin benimsedikleri ormancılık ilkeleri gereğince ağaçların minimum insan gücü ile envanter bilgisine işlenmesi sürdürülebilir kalkınma açısından büyük önem arz etmektedir. Bu tez çalışmasında, nokta bulutlarından iki aşamalı olarak geliştirilmiş lokal maksimum yönteme dayalı bireysel ağaç taç segmentasyonu ve dört farklı ağaç metriğinin (ağaç boyu, taç genişliği, göğüs çapı, taç taban yüksekliği) tahmini için yeni bir yaklaşım geliştirilmiştir. Çalışmada veri seti olarak sırasıyla Akdeniz Üniversitesi'ndeki Fıstık Çamı (*Pinus pinea*), Maçka'daki (Trabzon) Ladin (*Picea orientalis*) ve Cenevre'deki (İsviçre) Meşe (*Quercus alba- L.*) ile kaplı ağaçlık alanların hava LiDAR ve fotogrametrik nokta bulutları kullanılmıştır. Önerilen akış şeması, MATLAB yazılım ortamında mevcut Kanopi Yükseklik Modelini kullanarak bireysel ağaçları tespit ettikten sonra, bitişik ağaçlarda ortaya çıkan hatalı ağaç kümelenmelerinin iyileştirilmesi için iki farklı düzlemde Bézier eğrileriyle desteklenen geliştirilmiş lokal maksimum yöntemi ile alternatif bir çözümden oluşmaktadır. Elde edilen ağaç kümelerinin metrik tahmini için mevcut ve geliştirilmiş allometrik denklemler kullanılmıştır. Nesne tabanlı doğruluk analizine göre segmentasyon doğruluğu ortalama %79, ağaç merkezlerindeki konumsal hata ise ± 0.785 m olarak hesaplanmıştır.

Anahtar Kelimeler: Nokta Bulutu, Ağaç Taç Segmentasyonu, Geliştirilmiş Lokal Maksimum Yöntemi, Bézier Eğrisi, Ağaç Metrik Tahmini

Master Thesis

SUMMARY

TREE CROWN SEGMENTATION AND ESTIMATION OF METRICS FROM POINT CLOUDS WITH IMPROVED LOCAL MAXIMUM METHOD

Murat BAHADIR

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Department of Geomatics Engineering
Supervisor: Prof Dr. Fevzi KARSLI
2023, 121 Pages

On the Earth's surface, spatial information and volume of natural and human-made elements are importance for countries' governance policies in terms of economic, ecological, and sociocultural aspects. 3D spatial information is needed for control and analysis of these elements. LiDAR and photogrammetric point clouds are used in many applications such as urban modeling, disaster management, and monitoring forested areas. In recent years, to prevent problems like climate change and global warming, key role of trees needs to be preserved and their current status needs to be recorded. However, since GPS cannot receive a continuous signal, especially in densely forested areas, it is time-consuming and expensive to do field studies with terrestrial measurement techniques in these regions. In accordance with forestry principles adopted by countries' it is of great importance for sustainable development to process tree inventory information with minimal manpower. In this thesis study, a novel approach based on a two-stage developed local maxima method for individual tree crown segmentation from point clouds and the estimation of four different tree metrics (tree height, crown width, breast diameter, crown base height) is proposed. The study utilizes aerial LiDAR and/or photogrammetric point clouds of forested areas covered with Stone Pine (*Pinus pinea*) at the Mediterranean University, Larch (*Picea orientalis*) in Maçka, and Oak (*Quercus alba- L.*) in Geneva as the dataset. The proposed workflow consists of detecting individual trees using the existing Canopy Height Model in the MATLAB software and then providing an alternative solution by improving the erroneous tree clusters that occur in adjacent trees using a two-plane approach supported by Bézier Curves. Existing and improved allometric equations were used for the metric estimation of the obtained tree clusters. According to the object-based accuracy analysis, the segmentation accuracy was calculated as an average of 79%, and the positional error in tree centers was ± 0.785 m.

Keywords: Point Cloud, Tree Crown Segmentation, Improved Local Maximum Method, Bézier Curve, Tree Metric Estimation

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Makale istatistiği: a) yıllara göre, b) konulara göre, c) veri setine göre.....	10
Şekil 2. Bindirmeli hava görüntüsü alımı	20
Şekil 3. Fotogrametrik veri alım geometrisi ve matematiksel modeli.....	21
Şekil 4. Hava LiDAR veri toplama sistemi	24
Şekil 5. Doğrusal (linear) LiDAR ile detay noktalarının üretilmesi.....	24
Şekil 6. Hava LiDAR nokta bulutu; a) RGB görüntüye sahip nokta bulutu, b) sınıflandırılmış veri seti, c) yoğunluğa göre renklendirilmiş, d) yüksekliğe göre renklendirilmiş nokta bulutu.....	28
Şekil 7. TLS nokta bulutu; a) huş ağacı (Betula pendula) (URL-1, 2023), b).....	29
Şekil 8. Mobil LiDAR (MLS) nokta bulutu (URL-3, 2023)	30
Şekil 9. Epipolar eşleştirme (Sao Paulo / Brezilya).....	31
Şekil 10. SGM sekiz yönlü eşleme modeli (Hirschmüller, 2011)	31
Şekil 11. Epipolar geometri (Gonzalez-Aguilera vd., 2010).....	32
Şekil 12. Fotogrametrik nokta bulutu (Of/Türkiye)	33
Şekil 13. Ağaç parametrelerinin şeması (Herrero-Huerta vd., 2018).....	34
Şekil 14. SMRF ile zemin ve zemin üstü noktaların filtrelenmesi	37
Şekil 15. Octree hiyerarşik yapısı.....	38
Şekil 16. Octree veri organizasyonu uygulaması	39
Şekil 17. DBSCAN algoritmasının kümeleme modeli (URL-4, 2023).....	41
Şekil 18. Bézier eğrilerinin şematik gösterimi	43
Şekil 19. KYM oluşturulması (Meddens vd., 2018).....	45
Şekil 20. Ağaç taç segmentasyonu için dijital yüzey modelinde su genişlemesi	46
Şekil 21. Ortalama kaydırma algoritması; a) ortofoto üzerinde, b) grid yapıda gösterim (Hu vd., 2017).....	47
Şekil 22. Piksel bazlı metriklerin belirlenmesi	49
Şekil 23. Ağaç taç segmentasyonu ve metrik tahmini genel iş akışı	52
Şekil 24. Çalışma alanı-1 (Akdeniz Üniversitesi)	54
Şekil 25. Çalışma alanı-2 (Pilav Dağı, Maçka)	55
Şekil 26. Çalışma alanı-3 (Cenevre/İsviçre).....	55

Şekil 27. Ağaçlık alan LiDAR nokta bulutu (Akdeniz Üniversitesi): a) 2B, b)3B görüntüsü	58
Şekil 28. Filtreleme işlemi: a) Maçka veriseti, b) Akdeniz Üniversitesi.....	59
Şekil 29. Orman metriklerinin çıkarımı.....	60
Şekil 30. Ağaç tepelerini belirleme: a) LiDAR nokta bulutu, b) fotogrametrik nokta bulutu	61
Şekil 31. Mevcut uygulama sonucu bireysel ağaç segmentasyonu	62
Şekil 32. Düşey yönde segmentasyon: a) basamak oluşumu, b) test alanına uygulanması	63
Şekil 33. İki farklı düzlem üzerinden gürültü içerikli noktaların tespiti.....	64
Şekil 34. Farklı düzlemlerden ağaç profillerinin görünümü.....	65
Şekil 35. Ağaç profillerinden sınır geçirme.....	66
Şekil 36. Bézier eğrileri ile ağaç profillerini çizdirme	67
Şekil 37. Hatalı ağaç kümelerinin bölütlenmesi: (a) üç tepeli ağaç, (b) iki tepeli ağaç.	68
Şekil 38. Yeni segmentasyon sonucu oluşan ağaç kümeleri	69
Şekil 39. Beşli ağaç komşuluk modeli: a) veri setine uygulanması, b) topolojik model....	70
Şekil 40. İstatistiksel ölçütler ile hatalı segmente edilen ağaç kümelerinin tespiti	71
Şekil 41. Ağaç taç sınırlarının çember şeklinde temsil edilmesi	72
Şekil 42. Ağaç merkez noktalarını eşleştirme modeli	73
Şekil 43. TTY metriği için allometrik denklemin oluşturulması.....	75
Şekil 44. 3B bireysel ağaç taç segmentasyonu (Akdeniz Üniversitesi): a) fotogrametrik, b) LiDAR nokta bulutu	77
Şekil 45. Nesne tabanlı doğruluk analizi (Akdeniz Üniversitesi): a) fotogrametrik, b) LiDAR	77
Şekil 46. LiDAR nokta bulutu aşamalı segmentasyon sonuçları (Akdeniz Üniversitesi)	80
Şekil 47. Fotogrametrik nokta bulutu aşamalı segmentasyon sonucu (Akdeniz Üniversitesi)	81
Şekil 48. 3B bireysel ağaç taç segmentasyonu (Pilav Dağı): a) alan 1, b) alan 2.....	82
Şekil 49. Nesne tabanlı doğruluk analizi (Maçka/Pilav Dağı): a) alan 1, b) alan 2.....	83
Şekil 50. Maçka-1 aşamalı segmentasyon sonucu.....	86
Şekil 51. Maçka-2 aşamalı segmentasyon sonucu.....	86
Şekil 52. 3B bireysel ağaç taç segmentasyonu (Cenevre/İsviçre)	88
Şekil 53. Aşamalı segmentasyon görselleri (İsviçre/Cenevre)	89
Şekil 54. İstatistiksel olarak hatalı tespit edilen ağaçlar: a) fotogrametrik, b) LiDAR	92
Şekil 55. KYM ile önerilen yöntemin kıyaslanması (Akdeniz, LiDAR)	93
Şekil 56. KYM ile önerilen yöntemin kıyaslanması (Akdeniz, fotogrametrik)	93

Şekil 57. Akdeniz Üniversitesi regresyon analizi (LiDAR nokta bulutu)	94
Şekil 58. Akdeniz Üniversitesi regresyon analizi (Fotogrametrik nokta bulutu)	94
Şekil 59. İstatistiksel olarak hatalı tespit edilen ağaçlar: a) denek alan 1, b) denek alan 2	97
Şekil 60. KYM ile önerilen yöntemin kıyaslanması (Maçka-1, LiDAR).....	98
Şekil 61. KYM ile önerilen yöntemin kıyaslanması (Maçka-2, LiDAR).....	98
Şekil 62. Maçka-1 regresyon analizi: a) x koordinatı, b) y koordinatı, c) TTY metriği, d) TG metriği, e) GYÇ metriği ve f) AB metriği regresyon analizi	99
Şekil 63. Maçka-2 regresyon analizi: a) x koordinatı, b) y koordinatı, c) TTY metriği, d) TG metriği, e) GYÇ metriği ve f) AB metriği regresyon analizi	100
Şekil 64. İstatistiksel olarak hatalı tespit edilen ağaçlar (Cenevre)	105
Şekil 65. KYM ile önerilen yöntemin kıyaslanması (Cenevre, LiDAR).....	106



TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Zenmuse L1 ve P1 kamera özellikleri	57
Tablo 2. Akdeniz Üniversitesi geliştirilen ağaç sayıları	78
Tablo 3. Akdeniz Üniversitesi doğruluk değerlendirmesi	79
Tablo 4. Maçka/Pilav Dağı geliştirilen ağaç sayıları	83
Tablo 5. Maçka (Pilav Dağı) doğruluk değerlendirmesi	84
Tablo 6. Akdeniz Üniversitesi regresyon analizi ve hata değerleri	95
Tablo 7. Akdeniz Üniversitesi ağaç metrik tahmini	96
Tablo 8. Maçka-1 regresyon analizi ve hata değerleri	100
Tablo 9. Maçka-2 regresyon analizi ve hata değerleri	102
Tablo 10. Maçka-1 ağaç metrik tahmini	103
Tablo 11. Maçka-2 ağaç metrik tahmini	104
Tablo 12. İsviçre/Cenevre ağaç metrik tahmini	107

SEMBOLLER DİZİNİ

2B/3B	: İki/Üç Boyutlu
AB/TH	: Ağaç Boyu (Tree Height)
ALS	: Hava LiDAR Sistemi (Airborne LiDAR System)
AMS	: Uyarlanabilir Çekirdek Bant Genişliği Ortalama Kaydırma Algoritması
CNN	: Evrişimli Sinir Ağı
CR	: Taç Çapı
DBSCAN	: Gürültülü Uygulamaların Yoğunluk Tabanlı Uzamsal Kümelenmesi
GYÇ/DBH	: Göğüs Yüksekliğindeki Çap (Diameter Breast Height)
KH/CV	: Kanopi/Taç Hacmi (Canopy Volume)
KYM/CHM	: Kanopi Yükseklik Modeli (Canopy Height Model)
LiDAR	: Işık Algılama ve Mesafe Belirleme (Light Detection and Ranging)
LM	: Lokal/Yerel Maksimum
MCWS	: İşaretçi Kontrollü Havza Segmentasyonu
MLP	: Çok Katmanlı Algılayıcı
MLS	: Mobil LiDAR Sistemi (Mobile LiDAR System)
MNF	: Minimum Gürültü Fraksiyonu (Minimum Noise Fraction)
MSS	: Ortalama Kaydırma Segmentasyonu (Mean Shift Segmentation)
RANSAC	: Rastgele Örneklem Konsensüsü (Random Sample Consensus)
RF	: Rastgele Orman Sınıflandırıcısı
SGM	: Yarı Global Eşleme (Semi-Global Matching)
SMRF	: Basit Morfolojik Filtre (Simple Morphological Filter)
SYM	: Sayısal Yüzey Modeli
TG/CW	: Taç Genişliği (Crown Width)
TLS	: Karasal/Yersel LiDAR Sistemi (Terrain LiDAR System)
TTH/BCV	: Taç Taban Hacmi (Base Crown Volume)
TTY/CBH	: Taç Taban Yüksekliği (Crown Base Height)
WS	: Havza Bölütleme/Segmentasyonu (Watershed Segmentation)

1. GENEL BİLGİLER

1.1. Giriş

İnsan yaşamındaki en temel doğal unsurlardan biri olan ağaçlar, atmosferdeki karbon dioksit (CO₂), sülfür dioksit (SO₂), nitrojen dioksit (NO₂), amonyak (NH₃) gibi zararlı gazları filtreleyerek oksijen üretimini sağlaması, köklerinin toprağa uzanmasından dolayı erozyonu önlemesi ve depremin hasarını azaltan önemli bir unsur olması, fosil yakıt sonucunda ortaya çıkan sera gazlarına ve küresel ısınmaya karşı direnç sağlaması, şehir ve kent alanlarında ısı dengesini oluşturabilmesi, ultraviyole ışınlarla karşı canlıları koruyabilmesi, canlılara temiz su kaynağı sağlaması, zengin bir gıda kaynağı olması ve ekonomik açıdan getirisi olması gibi birçok özelliğinden dolayı ülkelerin sürdürülebilir yaşamı sağlayabilmesi adına önem arz etmektedir. İlave olarak ülkelerin sürdürülebilir çevre politikası kapsamında ağaçlık alanlar, yenilenebilir enerji olan biyokütle enerjisi olarak kullanılmaktadır.

Ormanlar belirli bir kapalılık düzeyinde ağaçların bulunduğu içerisinde çeşitli bitki, hayvan ve organizmaların denge içerisinde yaşadığı canlı bir ekosistem olarak nitelendirilmektedir (Türkiye Orman Varlığı, 2020). Günümüzde zengin biyolojik çeşitliliği sebebiyle orman ekosistemi küresel bir nitelik kazanmış olup korunması ve sürdürülebilirliği için dünya üzerinde birçok ülke yoğun çaba vermektedir. Ormanlar insanlar için gıda, biyoyakıt, barınak, temiz hava ve su temini, erozyon kontrolü, ilaç, gelir kaynağı, istihdam ve dinlenme gibi birçok uzun vadeli ekonomik, ekolojik ve sosyokültürel faydalar sunan doğal bir kaynaktır (Hyypä vd., 2022). AB'nin orman sektöründe ürettiği karbon, küresel yıllık karbon stoklarının %10'unu oluşturmakla birlikte bölgedeki karasal biyolojik çeşitliliğinde %80'inden fazlasına ev sahipliği yapmaktadır (AB komisyonu, 2021) (IUCN, 2021) (Hyypä vd., 2022). Ayrıca, AB'nin orman sektörü 22 milyon kişiyi istihdam etmekte ve biyoekonomide yıllık 2 trilyon avroluk bir ciro oluşturmaktadır (Future of the European Forest-Based Sector, 2018; Hyypä vd., 2022). Orman ekosistemleri, dünyanın karasal alanının yaklaşık %32'si olan 4,06 milyar hektarı kapsayan karasal biyosferin ana gövdesini oluşturmaktadır (Food and Agriculture Organization of the United Nations, 2015) (Hyypä vd., 2022). Birçok ülkede sera gazı emisyonlarını dengelemek için kapsamlı ağaç dikme programları düzenlemesinin yanında genç ormanların yönetimini sağlayabilmek ve doğru

ağaç bilgi ve parametrelerini sağlayabilen yeni yöntemler geliştirmek kritik bir öneme sahiptir (Pearse vd., 2020).

Ülkemizde ormanlık alanların tamamına yakın kısmı Orman Genel Müdürlüğü'nün hüküm ve tasarrufu altında olup yönetimi kanunlar yardımıyla korunmaktadır. Türkiye ormanları orman işletme şefliği bazında, 10-20 yıllık dönüş süreleri ile hazırlanan orman amenajman planlarına bağlı olarak işletilmektedir. Ormanlar ile ilgili bütün çalışmaların temelini orman amenajman planları oluşturmaktadır. Amenajman planlaması için saha içerisinde mevcut denek/deney alanlarında alan, servet, ağaç türü, verimlilik ve kapalılık durumlarını belirten envanter çalışmaları yapılarak bunların dijital ortama geçişi sağlanmaktadır. Ülkemizde sürdürülebilir orman yönetimi için fonksiyonel planlanmayı esas alan “Ekosistem Tabanlı Fonksiyonel Orman Amenajman Yönetmeliği” 05.02.2008 tarih ve 26778 sayılı Resmî Gazetede yayımlanarak yürürlüğe konmuştur (Türkiye Orman Varlığı, 2020).

2020 yılı sonu itibarıyla Türkiye ormanlarında tutulan karbon miktarı yaklaşık 2 milyar ton olarak hesaplanmıştır. Yapılan hesaplamalara göre ülkemiz ormanları yıllık 43 milyon ton oksijen üretmektedir. Ormanlık alanların asli ağaç türlerine göre dağılımı incelendiğinde ise %29,42 (6,8 milyon ha) ile meşe (*Quercus L.*) birinci, %22,74 (5,3 milyon ha) ile kızılçam (*Pinus brutia*) ikinci ve %18,31(4,2 milyon ha) ile karaçam (*Pinus nigra*) ağacı üçüncü sırada yer almaktadır. Türkiye Coğrafi Bölgelerine göre orman varlığı kapsamında %24,4 (5.593.342 ha) ile Karadeniz Bölgesi birinci sırada yer alırken, %5,8 (1.339.133 ha) ile Güneydoğu Anadolu Bölgesi son sırada yer almaktadır (Türkiye Orman Varlığı, 2020). FRA (Küresel Orman Kaynakları Değerlendirmesi) 2020 raporuna göre ülkeler bazında ormanlık alan sıralamasında 236 ülke arasında Türkiye 27.sırada, 2010-2020 yılları arasında ormanlık alanda yıllık net kazanç bakımından 6. sırada, 2015-2020 yılları arasında orman dışı ağaçlandırmasında 4. sırada ve yeniden ağaçlandırma çalışmaları kapsamında ise 12. sırada yer almıştır (Türkiye Orman Varlığı, 2020).

Ağaç envanter bilgileri, ağaç değişikliklerinin izlenmesi, ekosistem hizmetleri, karbon stoğu ve zemin üstü biyokütle tahmini için önemli girdi verilerini oluşturmaktadır (Herrero-Huerta vd., 2018). Envanter bilgileri şehir ve çevre planlanmasında, kentsel kirlilik ve sıcaklıklarının modellenmesinde, tehlikeli ağaçların tespit edilmesi ve biyolojik çeşitliliğin izlenmesinde kullanılmaktadır (Herrero-Huerta vd., 2018; URL-8). Orman ekosistemlerinin sürdürülebilir olması için orman yapısının hassas ormancılık kapsamı altında izlenmesi gerekmektedir (Tockner vd., 2022). Hassas ormancılık, modern teknolojik araçlar

vasıtasıyla optimum verim ile çevreye en az zararı vermeyi amaçlayan bir yönetim sistemidir (Gülci vd., 2015; Arslan vd., 2022). Ormanların izlenimi için ağaç sayısı, göğüs yüksekliğindeki çap (dbh), ağaç boyu, taç taban yüksekliği, taç genişliği, taç taban hacmi, kanopi hacmi ve taç projeksiyon alanı en yaygın parametreler olarak kullanılmaktadır. İlgili parametreler ağacın metrik özelliklerini yansıtacak şekilde kimlik bilgilerini oluşturmaktadır. Ağaç metriklerinin belirlenmesi için doğrudan saha ölçüsü gerekmesine rağmen parametrelerin kendi arasındaki allometrik ilişkisinden türetilen denklemler aracılığıyla da parametre tahmini gerçekleştirilebilmektedir. Allometrik denklemler kullanılarak pratik/saha koşulları altında ölçülmesi zor olan parametrelerin kestiriminin yapılması sağlanmaktadır (Arslan vd., 2022).

Orman ekosistemlerindeki ağaçların, orman kaynaklarının yönetimi, silvikültürel sistemlerin seçimi, envanter bilgilerinin kayıt altına alınması ve hassas orman yönetimi için bireysel ağaç ölçeğinde segmentasyonunun yapılması gerekmektedir (Yun vd., 2021). Bireysel ağaç taçlarının saptanması ve haritalanması, ormanın büyüme durumunu, yenilenmesini ve yoğunluğunu değerlendirmeye yardımcı olmaktadır (Yu vd., 2022). Orman yapısının karmaşıklığı, işçilik maliyeti, erişilebilirlik ve zaman sorunu, istihdam problemi ve topoğrafyanın ortaya çıkaracağı zorluklardan dolayı klasik/yersel ölçümler ile envanter bilgilerinin oluşturulması sınırlı kalmaktadır. İlave olarak orman envanter bilgisi için ölçülecek ağaç metriklerinin doğruluğu saha görevlisinin manuel biçimde ölçebileceği hassasiyet ile sınırlıdır (Panagiotidis vd., 2022). Bu nedenle, doğru orman envanter bilgisini minimum insan gücü, hız ve maliyet ile elde edilmesi, karbon depolama miktarlarının tespiti ve hassas ormancılığın gelişimi için uzaktan algılama araçları/verilerine ihtiyaç duyulmaktadır. Fotogrametrik ve uzaktan algılama verileri ile meşcere yapısı, orman hasar tespiti, kereste hacmi değerlendirilmesi, ağaç taç segmentasyonu ve metriklerinin çıkarılması, orman amenajman planlarının yüksek korelasyon ve doğruluk düzeyinde yapılması sağlanmaktadır.

Son yıllarda İnsansız Hava Araçları (İHA) alçak irtifada uçuş yapabilme özelliği ve geleneksel yöntemlere göre daha az maliyet gerektirmesi, gerçek zamanlı veri işleme ve analizini gerçekleştirebilmesi, yüksek çözünürlükte hava görüntüleri elde etme ve doğrudan arazi hakkında üç boyutlu konum bilgisi sağlaması gibi birçok yeteneğe sahip olmasından dolayı ormancılık alanında yaygın olarak kullanılmaya başlanmıştır (Yu vd., 2022). İHA ile elde edilen dijital görüntüler iki boyutlu (x, y) konum bilgisinin yanında renk bilgisine de sahiptir. Ancak yükseklik bilgisinin (z) eksikliğinden dolayı üç boyutlu bir analiz

gerçekleştirilemeyeceği için ağaç taç segmentasyonu yalnızca iki boyutta yapılır ve en yaygın ağaç metriklerinin tahmini gerçekleştirilemez. Özellikle görüntü üzerinden ağaç boyu ve göğüs yüksekliğindeki çap (dbh) bilgilerinin üç boyutlu konum bilgisi olmadan doğrudan tahmini veya dolaylı yoldan allometrik ilişkiden türetilen denklemler vasıtasıyla elde edilmesi mümkün değildir. Fotogrametrik yöntem ile elde edilen enine ve boyuna bindirilmiş İHA tabanlı hava görüntüleri çeşitli eşleştirme algoritmaları yardımıyla üç boyutlu RGB nokta bulutunu oluşturabilmektedir. Geleneksel İHA tabanlı düşey fotogrametri ile elde edilen fotogrametrik nokta bulutu, ağaç taçları hakkında yükseklik bilgisi bulundurmasına rağmen ağaç gölgelik büyümesinin heterojenliği, ağaç gölgelik yüksekliği ile korelasyonları tasvir etme (Lei vd., 2022) ve eşleştirme algoritmasının nokta bulutunu düzensiz şekilde oluşturmasından kaynaklı bireysel ağaç taç segmentasyonunda sorunlar oluşturabilmektedir. Hava fotogrametrisinde kullanılan optik kameralar çoklu geri dönüş özelliğine sahip olmadığı için yalnızca ağaç taçlarının tepesi hakkında bilgi sağlamaktadır (Mohan vd., 2017; Pearse vd., 2018). Fotogrametrik nokta bulutları, rüzgârda dalların ve yaprakların dinamizmi ve hareketi sebebiyle görüntü eşleştirme aşamasında eşlenik nokta bulmada başarısız olabilmektedir. (Belcore ve Latella, 2022). Bu yönüyle yüksek kapalılık düzeyindeki ormanlık alanlarda fotogrametrik nokta bulutu çok fazla gürültü içerebilmektedir.

Ağaç taç segmentasyonu ve metriklerinin tahmin edilmesi için en yaygın olarak LiDAR (Light Detection and Ranging) teknolojisi kullanılmaktadır. LiDAR, arazi üzerindeki nesnelerin yüksek hassasiyetli yükseklik bilgisi ile üç boyutlu konum bilgisini hızlı ve eşleştirme algoritmalarına gerek kalmadan doğrudan elde edebilen gelişmiş bir aktif uzaktan algılama teknolojisidir. LiDAR güçlü anti-parazit yeteneği, gece-gündüz ölçüm yapabilme, alçak irtifada uçuş gerçekleştirebilme ve nesnelerin üç boyutlu nokta bulutlarını oluştururken gölgelik gibi durumlardan etkilenmeme özelliğinden dolayı bitki örtüsü, ağaç vb. nesnelerin sınıflandırılması, çıkarılması, metriklerinin tahmini gibi birçok uygulamada güçlü bir teknik destek sağlamaktadır (Liu vd., 2021). Özellikle İHA tabanlı Havadan Lazer Tarama Sistemleri (ALS), lazer sinyalinin bitki örtüsü ve yeşillik alanlardaki boşluklara nüfuz edebilmesinden dolayı ağaçların zemin ve iç yapısının ölçümünü de sağlayabilmektedir. Ormancılık disiplinde Işık Algılama ve Mesafe Belirleme (LiDAR) teknolojisinin yaygınlaşmasıyla bireysel ağaç taçlarının segmentasyonu ve parametrelerinin çıkarılması hız kazanmıştır. Örneğin İskandinav ülkelerinde hem büyük ölçekteki ormanlık alanları hem de meşcere düzeyindeki orman kaynakları hakkında bilgi sağlayabilmek için

Havadan Lazer Tarama (ALS) ölçümlerini kullanarak ulusal ölçekte orman envanteri sağlanmaktadır (Kangas vd., 2018; Næsset vd., 2004).

Ormanlık alanlarda Yersel Lazer Tarama (TLS) sistemi ile (360°) tekli ve çoklu tarama modlarında gövde, dallar ve yapraklar gibi ağacın temel unsurlarını detaylı bir şekilde kaydederek veri toplama işlemi gerçekleştirilmektedir (Harikumar vd., 2022). Tek tarama modu, basit veri toplama ayarına sahipken, çoklu tarama modu ise tekli taramalardan toplanan verileri yakalar ve ortak kayıtlar yaparak gövdenin geometrik özelliklerini daha iyi yakalama imkânı sunmaktadır. TLS gürültü ve tıkanmalara karşı dirençli olmakla birlikte üç boyutlu ağaç gövde modelleme alanında hızlı ve doğru bir şekilde metrik çıkarımını sağlamaktadır (Harikumar vd., 2022). TLS nokta bulutları çok istasyonlu taranma gerektirdiği için zaman alıcı bir işlemdir ve analizi için yüksek donanımsal özellik gerekmektedir. Özellikle gövdeye ait göğüs yüksekliğindeki çap (dbh), taç taban yüksekliği ve taç taban hacmi parametrelerinin tahmini için yaygın olarak kullanılmaktadır.

Son yıllarda Mobil Lazer Tarama (MLS) sistemi, ormanlık alanlarda ulaşılması zor alanlara erişilebilirliği artırması yönüyle TLS'ye göre avantaj sağlamakla birlikte orman/ağaç metriklerinin çıkarılması için popüler hale gelmiştir. Mobil LiDAR Sistemi, kentsel ağaç parametrelerinin dağılımını değerlendirmek için yüksek uzamsal hassasiyete sahip olmakla birlikte üç boyutlu verilerin hızlı ve doğru bir şekilde üretilmesini sağlamaktadır (Herrero-Huerta vd., 2018). Veri hacmi TLS'ye benzer şekilde büyüktür ve analiz süreçlerini uzatmaktadır. Tarama işlemi boyunca saha görevlisinin hem konumu hem de perspektifi kalıcı olarak değiştiği için gölgeleme etkilerini ortadan kaldırır ve ağaç gövdesinin merkez konumunu daha yüksek oranda tespit etmesini sağlamaktadır (Bienert vd., 2018; Gollob vd., 2020). Ayrıca orman envanterine kaydedilecek ağaç metriklerinin tahmini için daha ayrıntılı üç boyutlu nokta bulutu sağlamaktadır. Tarama esnasında hareket konumlandırma hataları nedeniyle MLS nokta bulutları TLS nokta bulutlarına göre daha fazla gürültü içermektedir (Bauwens vd., 2016; Liang vd., 2014).

Ağaç taç segmentasyonu için kullanılan en yaygın algoritmalar Kanopi Yükseklik Modeli (KYM/CHM), MCWS (Marker-Controlled Watershed Segmentation), Lokal Maksimum (LM) ve derin öğrenme tabanlı algoritmalar. Mevcut algoritmalar, düşük kapalılık düzeyindeki ağaçlık alanlarda etkili olsa da ormanlık alan gibi yoğunluğun arttığı bölgelerde bireysel ağaç taç segmentasyon doğruluğunu azaltmaktadır. Özellikle ormanlık alanlardaki arazinin topoğrafyası ve ağaçların birbirlerine karşı baskınlık kurmasından dolayı (Hao vd., 2022) farklı yüksekliklerdeki ağaçların bitişik bir ağaç kümesi olarak tespit

edilmesi kaçınılmaz bir sorundur. Kapalılık etkisi yoğun olan bölgelerde ağaç taçlarının karışık bir düzende olmasından dolayı yanlış segmentasyon gerçekleştirilmektedir. Bu yüzden orman envanteri için gereken ağaç metriklerinin bu algoritmalar yardımıyla %100 doğru bir şekilde tespit edilmesi mümkün değildir. Son yıllarda KYM'nin ağaç taçlarını doğru bir şekilde temsil edemediği durumlar için nokta bulutlarından ağaçları yukarıdan aşağıya doğru analiz etmek amacıyla profil ve yerel yoğunluğa dayalı yöntemler geliştirmeye çalışılmaktadır (Hao vd., 2022). Lokal maksimum algoritması görüntüyü filtrelemek için hareketli bir pencere kullanılarak tanımlanabilen, hava görüntülerinde en parlak piksellere ve KYM'deki en yüksek değerlere sahip ağaç tepelerine dayanmaktadır (Yu vd., 2022). Genel olarak Lokal Maksimum algoritması, tek tip orman meşcerelerinde iğne yapraklı ağaçlarda avantaj sağlarken geniş yapraklı ağaçlarda dezavantaj olarak görülmektedir (Belcore ve Latella, 2022). İşaretçi Kontrollü Havza Segmentasyonu (MCWS) ise ağaç tepelerinin en düşük kotlar olarak ters çevrilmiş olması ve her ağaç tepesinin etrafında bir su toplama alanı olarak kabul edilmesi ilkesine dayanmaktadır. Her bir ağaç tepesinin sınırı, su havzasının yüzeyinin su bastığı yerde oluşmaktadır (Yun vd., 2021). Derin öğrenmeye dayalı yöntemler ise voksel tabanlı (VoxNet, 3DShapeNets, O-CNN vb.), nokta bulutunu görüntüye dönüştüren (MVCNN, FPNN, DeepPano vb.) ve nokta tabanlı yöntem (PointNet, PointNet++, PointCNN vb.) olarak üç sınıfta incelenmektedir (M. Liu vd., 2021). İlave olarak ağaç taçlarının algılanması için Mask R-CNN ve Faster R-CNN en yaygın derin öğrenme algoritmaları arasında yer almaktadır (Yu vd., 2022).

Ağaç metriklerinin tahmin edilmesi için bireysel ağaç taç segmentasyonunun doğru bir şekilde yapılması gerekmektedir. Mevcut algoritmalar özellikle ağaç taçlarının bitişik olarak bulunabileceği yoğun kapalılıktaki alanlarda segmentasyonu doğru bir şekilde yapamamaktadır. Özellikle Hava LiDAR ve fotogrametrik nokta bulutu verilerinde gövdeye ait detay noktaları yersel veya mobil LiDAR verilerine göre daha az olacağı için gövde bölgesinde tahmin edilecek ağaç metrikleri (göğüs yüksekliğindeki çap, taç taban yüksekliği ve taç taban hacmi) daha düşük korelasyona sahip olacaktır. Fakat hava ölçümleri ile elde edilecek nokta bulutları yersel ölçümlere göre hız, maliyet ve süre açısından avantaj sağlamaktadır. Ayrıca derin öğrenme ile yapılacak bireysel ağaç taç segmentasyonu süre ve donanım açısından sorun oluşturmaktadır.

Bu tez çalışmasında, LiDAR ve fotogrametrik nokta bulutundan bireysel ağaç taç segmentasyonu için Bézier eğrileri ile desteklenen yeni bir lokal maksimum yaklaşımı geliştirilmiştir. Oluşturulan bireysel ağaç kümelerini kullanarak orman envanterine katkı

sağlayacak ağaç boyu (AB), göğüs yüksekliğindeki çap (GYÇ), taç genişliği (TG) ve taç taban yüksekliği (TTY) ağaç metriklerinin tahmin edilmesi sağlanmıştır. Çalışma kapsamında test verisi olarak Akdeniz Üniversitesi içerisindeki ağaçlık alanın fotogrametrik ve LiDAR nokta bulutu, Trabzon İl'inin Maçka İlçesi'nde bulunan Pilav Dağına ait iki adet denek alanın LiDAR nokta bulutu ve İsviçre'nin Cenevre şehrine ait ormanlık alanın LiDAR nokta bulutu kullanılmıştır. Önerilen yaklaşımın başlangıçtaki bireysel ağaç taç segmentasyonunu gerçekleştirebilmek için MATLAB yazılımında mevcut Kanopi Yükseklik Modeli tabanlı uygulaması kullanılmıştır. Elde edilen ağaç kümeleri düşey yönde yukarıdan aşağı yöntemle segmentasyonunu gerçekleştirebilmek için Octree (Sekiz Dal Veri Organizasyonu) yöntemi ile voksellere ve basamaklara ayrılmıştır. Ardından yanlış segmentasyon yapılarak birden fazla ağaç tepesi oluşturan kümeleri algılayabilmek için Octree sonucu oluşturulan birinci basamaktaki noktaların iki farklı düzlemde (X-Z ve Y-Z) ağaç profil durumları incelenmiştir. Profillerdeki nokta bulutu içerisinde bulunan mevcut gürültüler DBSCAN (Density-Based Spatial Clustering of Applications with Noise) kümeleme algoritması yardımıyla temizlenmiştir. Daha sonra her iki düzlem üzerinden Bézier eğrileri geçirilerek, bu eğri üzerindeki lokal maksimum nokta sayısına göre otomatik bir şekilde hatalı ağaç kümeleri tespit edilerek yeni ağaç kümeleri oluşturulmuştur. Oluşturulan ağaç kümeleri arasında hâlen hatalı bir ağaç kümesi bulunabilme ihtimaline karşın istatistiksel bazda ağaç taç alanları karşılaştırılarak ikinci kez segmentasyon gerçekleştirilmiştir. Elde edilen nihai ağaç kümeleri için geliştirilen ağaç eşleştirme modeli kullanılarak ilgili referans ağaç merkezleri ile bulunan ağaç merkezleri otomatik bir şekilde bire bir eşleştirilmesi sağlanmıştır. Segmentasyon doğruluğunu belirleyebilmek için nesne tabanlı doğruluk analizi kullanılmıştır. Ağaç metriklerinin tahmin edilmesi için AB ve TG doğrudan segmentasyon sonucu oluşan nokta bulutundan hesaplanmıştır. GYÇ metriği için literatürdeki hazır, TTY metriği için ise geliştirilmiş allometrik denklemler ile metrik tahminleri gerçekleştirilmiştir.

1.2. Tezin Amacı

Bu tez çalışmasındaki ana amaç, yoğun kapalılık düzeyindeki ağaçlık alanların görüntü eşleştirme tabanlı fotogrametrik nokta bulutu ve LiDAR nokta bulutundan bireysel ağaç taç segmentasyonunun iyileştirilmesini ve orman envanter bilgisi için gereken ağaç boyu (AB), göğüs yüksekliğindeki çap (GYÇ), taç genişliği (TG) ve taç taban yüksekliği

(TTY) ağaç metriklerinin yüksek korelasyon ile tahmin edilmesini sağlamaktır. Aynı zamanda orman disiplini içerisindeki mevcut arazi çalışmalarında ortaya çıkabilecek olan topoğrafya etkisi, zaman, maliyet, erişilebilirlik ve işgücü sorunlarını otomatik bir şekilde çözmeyi amaçlayan alternatif yeni bir yaklaşım vasıtasıyla nokta bulutlarından doğrudan ve geliştirilmiş olan allometrik denklemler ile dolaylı yoldan çıkarılacak olan ağaç metriklerinin tahmin edilerek envanter bilgilerinin oluşturulmasında hız ve ekonomik kazanç sağlanması hedeflenmektedir.

1.3. Tezin Kapsam ve Organizasyonu

Genel bilgiler bölümünün giriş kısmında, orman envanteri için gerekli olan ağacın sürdürülebilir hassas orman politikasına olan katkıları, Türkiye’deki orman envanteri hakkında kısa bilgi, ağaç taç segmentasyonu ve ağaç metriklerinin tahmin edilmesinin orman disiplini kapsamında oluşturabileceği faydalar, ağaç çalışmaları için en yaygın olarak kullanılan uzaktan algılama araçları ve verileri, bireysel ağaç taç segmentasyonu için en popüler algoritmalar ve tezin amacı açıklanmıştır. Literatür araştırması bölümünde ağaç taç segmentasyonu, metrik çıkarımı ve ağaç türlerinin sınıflandırılmasına yönelik mevcut araştırmaların özetleri sunulmuştur. Temel kavramlar kısmında, tezin ana amacına yönelik kullanılan sistemler (Fotogrametri, lazer tarama teknolojileri, nokta bulutları, ağaç metrikleri, allometrik denklemler), algoritmalar (SMRF, Octree, DBSCAN, Bézier eğrisi, geleneksel ağaç taç segmentasyon yöntemleri) ve literatürdeki doğruluk analizi yöntemleri hakkında detaylı bir açıklama verilmiştir. Yapılan çalışmalar bölümünde öncelikle çalışma alanları, alan verileri/arazi ölçüleri, kullanılan uzaktan algılama verileri hakkında açıklama yapılmıştır. Ardından tez çalışmasında önerilen geliştirilmiş lokal maksimum yaklaşımı detaylı bir şekilde açıklanmıştır. Son olarak geliştirilen ağaç eşleştirme modeli ile obje tabanlı doğruluk analizi ve ağaç metriklerinin tahmin yöntemleri açıklanmıştır. Bulgular bölüm başlığı altında önerilen ağaç taç segmentasyon iyileştirme yöntemine ait nitel ve nicel sonuçlar şekil ve tablo bilgileri olarak ayrıntılı bir şekilde sunulularak yorumlanmıştır. Tartışma bölümünde önerilen yaklaşımın Kanopi Yükseklik Modeli ile karşılaştırılması ve doğru segmentasyon ve ağaç metrik tahminini etkileyebilecek unsurların nesnel bir şekilde yorumlanması sağlanmıştır.

Sonuçlar kısmında ise yapılan çalışmanın alternatif bir iyileştirme yaklaşımı olduğu ve orman envanter bilgisinin oluşturulmasındaki katkıları nitel ve nicel olarak sunulmuştur. Bu bölümün ardından kaynaklar ve özgeçmiş ile tez tamamlanmıştır.

1.4. Literatür Araştırması


Tez kapsamı boyunca bireysel ağaç taç segmentasyonu, ağaç/orman metrikleri çıkarılması ve ağaç türlerinin sınıflandırılması konu başlıkları altında 2018 ile 2022 yılları arasında yayımlanan 34 adet makale incelenmiştir. Araştırmalar sonucunda 2018-2022 yılları arasında incelenen makale sayılarının dağılımı sırasıyla 1 (2018), 1 (2020), 5 (2021) ve 27 (2022) adet ile sınırlandırılmıştır (Şekil 1a). İncelenen makalelerde ağaç taç segmentasyonu, metrik çıkarımı ve ağaç türünün sınıflandırılması için veri seti olarak hava LiDAR (ALS), yersel LiDAR (TLS), mobil LiDAR (MLS), fotogrametrik nokta bulutu (FPC), RGB görüntü, uydu görüntüsü ve hiperspektral görüntüler kullanılmaktadır. Veri setlerine göre makale sayılarının dağılımı detaylı bir şekilde Şekil 1c’de gösterilmiştir.

Literatür hakkında kolayca bilgi edinebilmek için ele alınan 34 makale, konularına göre beş ana grupta sınıflandırılmaktadır (Şekil 1b). Gruplandırılan makalelerin konuları şunlardır:

- Yalnızca bireysel ağaç taç segmentasyonu (A)
- Yalnızca ağaç metrik çıkarımı (B)
- Ağaç taç segmentasyonu ve metrik çıkarımı (C)
- Ağaç taç segmentasyonu ve türlerinin sınıflandırılması (D)
- Ağaç taç segmentasyonu, metrik çıkarımı ve sınıflandırılması (E)

Yalnızca bireysel ağaç taç segmentasyonu için yapılan çalışmalar;

Yu vd. (2022), düşük yoğunluğa sahip Çin göknarı (*Cunninghamia*) bulunan ağaçlık alana ait tek ve çok bantlı görüntüler kullanarak Yerel Maksimum algoritması (LM), İşaretçi Kontrollü Havza Segmentasyonu (MCWS) ve Mask R-CNN kullanarak bireysel ağaç taç segmentasyon doğruluğunu değerlendirmektedir. Yapılan doğruluk analizi sonucuna göre çok bantlı görüntüyle birlikte kullanılan Mask R-CNN ağında %94,68 (F-skor) ile en yüksek segmentasyon doğruluğuna ulaşmaktadır.



Şekil 1. Makale istatistiği: a) yıllara göre, b) konulara göre, c) veri setine göre

Hershey vd. (2022), hava LiDAR nokta bulutu kullanarak Amerika Birleşik Devletlerindeki 17’den fazla sert ağaç türlerinin bulunduğu 10.000 m²’lik ormanlık alanda (16 parsel) tek tek ağaç segmentasyonunu gerçekleştirebilmek için voksellerin sütun tabanlı algoritma önermektedir. Ayrıca ağaç merkez noktalarının referans ağaç merkezi ile eşleştirilmesi için “*TreeMatch*” uygulaması gerçekleştirir. Ancak geliştirilen eşleştirme modeli bütün ağaçlar için 3 m’lik sabit bir çember ile temsil edildiği için komisyon ve ihmal hatalarında eksik yönler mevcuttur. Önerdikleri yöntem tüm alandaki ağaçların %68’ini doğru tespit etmektedir.

Yun vd. (2021), Çin'deki tropikal ormanların bulunduğu ve içerisinde Okaliptüs/ Sıtma ağacı (*Eucalyptus globulus Labill.*), Çin göknarı (*Abies chensiensis*) ve orman parkı olan üç farklı bölgenin Hava LiDAR nokta bulutunu kullanarak doğru bireysel ağaç taç segmentasyonu için bilgisayarla görme teorisine dayanan yeni bir yöntem önermektedir. Çalışmada ilk olarak Sayısal Yüzey Modeli (SYM) içinde tespit edilen hatalı ağaç tepelerini ayırt etmek için açılış eğimine dayalı tarama stratejisine sahip Gauss filtresi kullanır. Ağaç taç segmentasyonunun uygulanması için ise bir enerji kontrol fonksiyonuna dayalı olarak Marker-Controlled Watershed Segmentation (MCWS) algoritması kullanmaktadır. Önerdikleri yöntemin ağaç tespit oranı yaklaşık %80-85 seviyesindedir.

Holmgren vd. (2022), alçak ve yüksek irtifadan gerçekleştirilen iki uçuş sonucu elde ettikleri LiDAR nokta bulutunu kullanarak İsveç'in güneyinde yer alan Remningstorp'taki yarı boreal orman içerisinde bulunan Norveç ladini (*Picea abies*), Sarıçam (*Pinus sylvestris*), Huş (*Betula sp.*) ve Meşe (*Quercus robur*) ağaçlarının iki boyutlu (2B) ve üç boyutlu (3B) segmentasyon yöntemleri ile taçlarını çıkarmaktadır. 2B ağaç taç segmentasyonu için Kanopi Yükseklik Modeli ve havza bölütleme (Watershed Segmentation) algoritmasını, 3B ağaç taç segmentasyonu için ise Ortalama Kayma (Mean Shift) algoritmasını kullanmaktadır. 2B ve 3B segmentasyon yöntemleri ile elde edilen doğruluklar, yüksek irtifadaki nokta bulutunda sırasıyla %87 ve %92 olarak hesaplanırken, alçak irtifadaki nokta bulutunda ise bu değerler sırasıyla %91 ve %99 olarak değerlendirilmektedir.

Lei vd. (2022), fotogrametrik ve LiDAR nokta bulutunun birleştirilmesiyle elde edilen veriyi kullanarak Güney Çin'in Guangxi eyaletinde yer alan Gaofeng orman çiftliğindeki Okaliptüs (*Eucalyptus robusta smith*), Spingbract Chinkapin (*Castanopsis hystrix*) ve Çin göknarı (*Cunninghamia lanceolata (Lamb.) hook.*) dahil olmak üzere karmaşık ağaç türünün baskın olduğu test alanında, ağaç taç segmentasyonunu gerçekleştirebilmek için 3B gölgelik niteliklerini dikkate alan Uyarlanabilir Çekirdek Bant Genişliği Ortalama Kaydırma Algoritmasını (AMS- adaptive-kernel bandwidth mean-shift algorithm) önermektedir. Segmentasyon başarı oranı %83 olarak değerlendirilmektedir.

Ozdarici-Ok vd. (2022), Türkiye'nin Antalya ilinde, Aksu ilçesine bağlı Kumköy kasabası yakınlarındaki test alanı içerisinde yer alan Fıstık çamı (*Pinus pinea L.*) ağaç türlerinin İHA tabanlı Sayısal Yüzey Modellerinden tek tek çıkarılması için yerel maksimumların gelişmiş bir olasılık haritasını oluşturarak oryantasyon simetrisi ve Chan-Vese aktif kontur modelini kullanmaktadır. Referans noktalarını El Tipi Mobil Lazer

Tarayıcı ile elde ettikten sonra önerilen yaklaşımın piksel tabanlı ve nesne tabanlı F1 puanlarını sırasıyla %88,3 ve %97,7 düzeyinde ortaya çıktığı gözlemlenmektedir.

Hao vd. (2022), farklı yoğunluklara sahip iğne ve geniş yapraklı karışık meşcere bölgesinde aşırı ağaç bölümlenmesi karşı 3B segmentasyon yapabilen yeni bir hiyerarşik bölge büyütme algoritması önermektedir. Veri seti olarak hava LiDAR nokta bulutlarını kullanmaktadır. Önerilen yöntemin bireysel ağaç taç segmentasyon doğruluğu ortalama %86 seviyesindedir.

Freudenberg vd. (2022), hava ve uydu görüntülerinden 2B bireysel ağaç taç tasvirini sağlayabilmek için Mask R-CNN'in genellikle ayrı ağaç taçlarıyla birlikte büyük miktarlarda etiketlenmiş eğitim verilerine ihtiyaç duymasından dolayı U-Net ağını önermektedir. Veri seti olarak Hindistan, Bengaluru'daki bir kentsel bölgeden 30 cm çözünürlükte WorldView-3 uydu görüntüsünü ve Almanya, Gartow yakınlarındaki yoğun ormanlık bir alanın 5 cm çözünürlüklü hava görüntüsünü kullanmaktadır. Uydu görüntülerinden elde edilen segmentasyon doğruluğu %71 iken hava görüntülerinde bu değer %82 seviyesindedir.

Zhou vd. (2022), ağaç gövdesine ait LiDAR noktalarının yerel bir mahallede büyük yükseklik farklılıkları gösterdiği hipotezine bağlı olarak, yükseklik farkına dayalı yeni bir ağaç gövdesi algılama ve yerelleştirme yaklaşımı önermektedir. Ayrıca yöntemin performansını DBSCAN ve yükseklik/yoğunluk tabanlı yaklaşımlar ile karşılaştırmaktadır. Test bölgesi olarak ABD'deki Purdue Üniversitesinin sorumluluğunda bulunan Martell Ormanındaki Çapaklı meşe (*Q. macrocarpa*) ile Kuzey kızıl meşesi (*Quercus rubra*) ağaçları ele alınmaktadır. Kıyaslama sonucunda önerilen yükseklik farkına dayalı yaklaşım, en yüksek F1 puanı ile sonuçlanmaktadır.

Belcore ve Latella (2022), fotogrametrik nokta bulutundan bireysel ağaç taç segmentasyonu gerçekleştirmek için yoğunluk, doku ve lokal maksimum algoritması tabanlı yaklaşımları karşılaştırmaktadır. Nehir kıyısına yakın yerde seçilen test bölgesi içerisinde yapılan analizler sonucunda fotogrametrik nokta bulutu ile yapılan segmentasyon doğruluğu yaklaşık %76 seviyesinde gözlemlenmektedir.

Fu vd. (2022), Çin'deki yapay ve Almanya'daki karışık orman bölgelerinin yersel LiDAR nokta bulutlarından 3B segmentasyon gerçekleştirebilmek amacıyla optimum küme sayısını ve gereken giriş parametrelerini (epsilon ve minpts) otomatik ve uyarlamalı olarak belirleyebilen, mesafe dağıtım matrisine (DDM) dayalı geliştirilmiş DBSCAN algoritmasını önermektedir. Gövde algılama sonuçlarını değiştirmek için Hough çemberi uydurma

yöntemi kullanmaktadır. Önerilen segmentasyon yönteminin genel doğruluk değeri %93 olarak değerlendirilmektedir.

Tienaho vd. (2022), Finlandiya’da Sarıçam (*Pinus sylvestris*) ağaçlarının baskın olarak bulunduğu ormanlık alana ait yersel LiDAR ve fotogrametrik nokta bulutları kullanarak fraktal tabanlı kutu (D_b) ile bireysel ağaçların yapısal karmaşıklığını bütüncül bir şekilde ölçmeyi sağlamaktadır. D_b , bitki materyalinin yoğunluğunu ve dağılımını ölçer ve aynı zamanda ağacın yapısal özelliğini yansıtmaktadır. Ayrıca ağaç segmentasyonu için Kanopi Yükseklik Modeli ve Havza Bölütleme algoritmasını kullanmaktadır.

Yalnızca ağaç metrik çıkarımı için yapılan çalışmalar;

Sumnall vd. (2022), Rastgele Orman sınıflandırıcı ve otomatikleştirilmiş değişken seçimi (Boruta) yaklaşımı kullanarak tam dalga formundaki hava LiDAR nokta bulutu verilerinden 27 adet orman ölçüsünü tahmin etmektedir. Ormanın elverişli koruma durumunu değerlendirmek için ele alınan 17 orman ölçüsünün %73 ile %98 arasında başarı sağladığı gözlemlenmektedir.

Harikumar vd. (2022), yersel LiDAR nokta bulutlarından Çam (*Pinus pinea*), Ladin (*Picea*), ve Huş ağacı (*Betula pendula roth*) türleri için üç boyutlu boşluk hacim tabanlı gövde modelleme ve dal-düğüm lokalizasyon yaklaşımını önermektedir. Gövde tasviri için (x, y) düzleminde oluşturulan ızgaradaki en düşük kotlu nokta belirlenir ve bu noktalardan elde edilecek düzensiz üçgen ağı (TIN) modelini kullanmaktadır. Dal düğüm lokalizasyonu için Gradient Vector Flow Snake (GVF-Snake) 3-D Active Contour algoritmasını kullanmaktadır. Ayrıca göğüs yüksekliğindeki çap (dbh) metriğinin tahmini için ortalama 5,25 mm’lik RMSE hata değeri hesaplamaktadır.

Ağaç taç segmentasyonu ve metrik çıkarımı için yapılan çalışmalar;

Herrero-Huerta vd. (2018), kentsel ağaçların en önemli ağaç parametrelerini (DBH, CBH, CV) otomatik olarak tahmin etmek için yenilikçi bir yaklaşım önermektedir. Göğüs Yüksekliğindeki Çap (DBH) parametresini Rastgele Örneklem Konsensüsü (RANSAC) kullanarak farklı yükseklikteki kutulara ait noktaların daireye yerleştirilmesiyle, Taç Taban Yüksekliğini (CBH) vokselizasyon teknikleri ile ve Kanopi Hacmini (CV) ağ oluşturma prosedürleri ve α -şekil yöntemleri uygulayarak tahmin etmektedir. Ağaç

parametre/metrikleri için %90'ın üzerinde bir R^2 korelasyon değeri hesaplamaktadır. Yapılan araştırma, kentsel alandaki düşük kapalılığa sahip ağaçlar üzerinde test edildiği için genelleyici bir yaklaşım olarak görülmemektedir.

Tockner vd. (2022), GeoSLAM teknolojisi ile elde ettikleri Kişisel Lazer Tarama (PLS) nokta bulutundan bireysel ağaç segmentasyonunu gerçekleştirebilmek için otomatik vokseller tabanlı bölge büyütme taç segmentasyon algoritmasını önermektedir. Segmentasyon sonucunda göğüs yüksekliğindeki çap (dbh), ağaç boyu (th), taç taban yüksekliği (cbh), taç projeksiyon alanı (cpa) ve kanopi/taç hacmi (cv) metriklerini çıkarmaktadır. Veri seti olarak orta kapalılık düzeyinde Avrupa kayını (*Fagus sylvatica* L.), Norveç ladini (*Picea abies*), Avrupa karaçam (*Larix decidua* Mill.), Gümüş göknar (*Abies alba* Mill.), Sarıçam (*Pinus sylvestris* L.) ve Sapsız Meşe (*Quercus petraea*.) ağaçlarının bulunduğu 6 adet parselin nokta bulutlarını kullanarak %87,02 segmentasyon doğruluğu sağlamaktadır. Ağaç metrik tahminlerinde ise cbh metriğinin tahmininde zorlanmaktadır.

Huo vd. (2022), İsveç'in kuzeyinde Sarıçam (*Pinus sylvestris*), Norveç Ladini (*Picea abies*) ve Huş (*Betula pendula* ve *Betula pubescens*) türlerin yer aldığı boreal orman içerisindeki ağaçların, bireysel ağaç taç segmentasyonunu gerçekleştirmek için hem hava (ALS) hem de yersel LiDAR (TLS) nokta bulutlarını kullanmaktadır. Ağaçların simetrik yapısını tespit ederek üç boyutlu ağaç taç segmentasyonunu gerçekleştirmek amacıyla eşit açılı sektörel vokselizasyon yöntemini açıklayan SSD algoritmasını önermektedirler. Baskın ağaç noktalarını ve düşük seviyedeki bitki örtüsünü Ortalama Kayma (Mean Shift) kümelemesi ile ortadan kaldırmaktadır. ALS ve TLS nokta bulutlarını Yinelemeli En Yakın Nokta (ICP- Iterative Closest Point) algoritması ile birleştirmektedir. Segmentasyon doğruluğu yalnızca ALS kullanıldığında %76, yalnızca TLS kullanıldığında %86 ve ALS ve TLS birleştirilmesi sonucunda ise %87 olarak tespit edilmektedir. Ayrıca çalışma kapsamında taç çapı (CR-crown radius) ve taç taban yüksekliği (CBH- crown base height) metrikleri tahmin edilmektedir.

Arslan vd. (2022), göğüs yüksekliğindeki çap (dbh) ve ağaç boyu (th) metriklerinin tahmin edilebilmesi için hava LiDAR, yersel LiDAR ve fotogrametrik nokta bulutlarını kullanarak veri karşılaştırmasını yapmaktadır. Çalışma bölgesi olarak İstanbul Orman Bölge Müdürlüğü'ne ait saf Meşe (*Quercus sp.*) ağaçların bulunduğu meşcereyi kullanmakta ve ağaç taç segmentasyonu için Kanopi Yükseklik Modelini uygulamaktadır. Dbh metriğinin yersel nokta bulutu ile referans veri arasındaki Pearson korelasyon değerinin %97'nin üzerinde bir performans sağladığı gözlemlenmektedir.

Chen vd. (2022), Çin'in Hebei Eyaleti, Zhangjiakou Şehri'ndeki %70'i Beyaz Huş (*Betula Pendula*) ve %30'u Karaçam (*Pinus nigra*) olmak üzere iki ağaç türüne sahip Laohugou ormanlık alanında ağaç boyu tahmini için hava LiDAR nokta bulutu, göğüs yüksekliğindeki çapın (dbh) tahmini için ise yersel LiDAR nokta bulutunu kullanmaktadır. Ağaç taç segmentasyonunu Kanopi Yükseklik Modeli ile gerçekleştirmektedir. Dbh parametresinin belirlenmesi için nokta yoğunluk analizine dayanan daire uydurma yöntemi önermektedir. Dbh için yapılan analizler sonucunda ortalama R^2 değeri 0,99 ve RMSE değeri 0,54 cm olarak hesaplanmaktadır.

Hyypä vd. (2022), yüksek yoğunluklu hava LiDAR nokta bulutundan göğüs yüksekliğindeki çapı (dbh) ve gövde eğrilerini otomatik bir şekilde tahmin etmeye çalışmaktadır. Test alanı olarak Finlandiya'nın Güneydoğu kesiminde Lappeenranta bölgesinde Norveç Ladini (*Picea abies*) bulunan bir orman bölgesini kullanmaktadır. Havza bölütleme (Watershed segmentation) ile ağaç taç segmentasyonunu, DBSCAN ve RANSAC algoritmalarıyla da gövde eğrilerinin çıkarılmasını sağlamaktadır. Önerdikleri yöntemin ağaç tespit oranı, üç adet denek alanın yoğunluğuna bağlı olarak %42 ile %71 arasında değişkenlik göstermektedir. Ayrıca dbh parametresi için ortalama R^2 değeri 0,78, RMSE değeri ise 2,5 cm olarak hesaplanmaktadır.

Xu vd. (2022), Nanjing Ormancılık Üniversitesi'nin Baima Kampüsü'ndeki Kiraz (*Prunus avium*) ve Begonya'nın (*Begoniaceae*) olduğu bir test bölgesinde, yersel LiDAR (TLS) nokta bulutu kullanarak, ağacın gövde ve dal iskeletini 3B olarak çıkarabilmek için DBSCAN kümeleme algoritması ile geliştirilmiş Uzay Kolonizasyon algoritması önermektedir. Oluşturulan ağaç iskeletlerinin dal açısı, gövde uzunluğu ve dal uzunluğu için ortalama karekök hatası (RMSE) sırasıyla 3,309 derece, 0,069 m, 0,051 m olarak tespit edilmektedir.

Feng vd. (2022), hava LiDAR nokta bulutundan göğüs yüksekliğindeki çapın (dbh) doğrudan ölçümü için öncelikle çok ölçekli silindirik algılama yöntemiyle üç boyutlu ağaç taç segmentasyonu uygulamaktadır. DBH parametresinin segmente edilmiş ana nokta bulutundan doğrudan ölçümünü sağlamak için çok ölçekli halka uydurma yöntemini kullanmaktadır. Önerilen yaklaşım sonucunda dbh parametresi gerçek LiDAR nokta bulutunda 0,708 (R^2), simüle edilmiş nokta bulutunda ise 0,882 (R^2) olarak tahmin edilmektedir.

Panagiotidis vd. (2022), yersel ve hava LiDAR verilerinin füzyonu ile üretilecek üç boyutlu nokta bulutunun, göğüs yüksekliğindeki çapı (dbh), ağaç boyu (th), taç projeksiyon

alanı, taç genişliği, taç uzunluğu, taç/kanopi yüzeyi ve taç/kanopi hacmi üzerindeki etkisini incelemektedir. Çalışmada tür olarak Avrupa Meşesi (*Quercus robur L.*) ve Norveç Ladini (*Picea abies L.*) kullanılmaktadır. Ele alınan ağaç türleri üzerinde dbh ve th metriğinin yaklaşık %98 seviyesinde doğru tahmin edildiği gözlemlenmektedir.

Rudge vd. (2021), Kuzey Avustralya'daki savana ağaçlarının bulunduğu ormanlık alana ait hava LiDAR nokta bulutundan ağaç taç segmentasyonu ve allometrik ölçeklendirme denklemleri ile göğüs yüksekliğindeki çap (dbh) metriğinin tahmini üzerine çalışmaktadır. Ağaç taç segmentasyonu için Adaptive Mean Shift 3D (AMS3D) algoritmasını önermektedir. DBH metriğinin allometrik denklemler ile tahmini için ortalama 5,28 cm'lik bir RMSE hata değeri elde etmektedir.

Pires vd. (2022), İsveç'te orman yolları üzerinde Norveç Ladini (*Picea abies*), Sarıçam (*Pinus sylvestris*) ve Huş ağacı (*Betula spp.*) ile kaplı alana ait mobil (arabaya monte edilmiş) LiDAR nokta bulutundan bireysel ağaç taç segmentasyonunu ve gövde özelliklerini belirlemektedir. Taç segmentasyonu için nokta bulutundaki enine kesitleri tanımlayan bir gövde segmentasyon yöntemi önermektedir. Yapılan analizler sonucunda ortalama %85 segmentasyon doğruluğu ve sırasıyla 3,3 cm, 0,135 m³ dbh ve gövde hacmi RMSE hatası elde etmektedir.

Ağaç taç segmentasyonu ve türlerinin sınıflandırılması için yapılan çalışmalar;

Chen vd. (2021), nokta bulutlarından derin öğrenme yöntemleri ile ağaç türlerini sınıflandırmak için Point Cloud Tree Species Classification Network (PCTSCN) ağını önermektedir. Önerdikleri ağ, örnekleme ve özellik çıkarma bileşeni olarak iki ana aşamadan oluşmaktadır. Veri seti olarak Yersel Lazer Tarama (TLS) ve İHA Lazer Tarama (UAVLS) kullanarak Beyaz Huş (*Betula pendula roth*) ve Karaçam (*Pinus nigra*) ağaç türlerini iki farklı model hiperparametreleri ile %92 ve %96 doğrulukla sınıflandırmaktadır.

Natesan vd. (2020), insansız hava araçlarından alınan yüksek çözünürlüklü RGB görüntüleri kullanarak orman ağacı türleri ve bireysel ağaç düzeyinde sınıflandırma için Evrişimli Sinir Ağı'na (CNN) dayanan DenseNet ağını önermektedir. Çalışmada beş baskın iğne yapraklı Kızılçam (*Pinus resinosa*), Doğu Beyaz Çamı (*Pinus strobus*), Balzam Göknarı (*Abies balsamea*), Beyaz Ladin (*Picea glauca*) ve Doğu Beyaz Sediri (*Mazı occidentalis*) ağaç türünde %84'ün üzerinde sınıflandırma doğruluğu elde etmektedir.

Guo vd. (2022), 12 yaygın subtropikal kentsel çok yıllık odunsu bitki türünü tanımlamak için eksenel simetrik ve eksenel olmayan gölgelik tabanlı LiDAR morfolojik özelliklerini geliştirerek uyarlanabilir elipsoid yöntemini önermektedir. Test alanı, Kraliyet palmyesi (*Roystonea regia*), Dağ inciri (*Ficus altissima*) ve Cajuput/Beyaz Samet (*Melaleuca cajuputi*) gibi yaygın subtropikal kentsel ağaç türlerinin hakimiyetindedir. Segmentasyon işlemi için Kanopi Yüksekli Modeli ve Havza Bölütleme (Watershed Segmentation) algoritmasını kullanmaktadır. Ayrıca ağaç türlerini sınıflandırmak için Rastgele Orman Sınıflandırıcı (Random Forest) ve Destek Vektör Makinesi (Support Vector Machine) uygulamaktadır. Ağaç türünü belirlemede %88 doğruluk değeri elde etmektedir.

Qin vd. (2022), hava LiDAR nokta bulutu, hiperspektral ve yüksek çözünürlüklü RGB görüntüler kullanarak subtropikal geniş yapraklı ormanlarda 18 adet bireysel ağaç türlerinin segmentasyonu için Havza Spektral Dokusal Kontrollü Normalleştirilmiş Kesim (WST-Ncut) algoritması önermektedir. Ağaç türlerini sınıflandırmak için Rastgele Orman Sınıflandırıcısı (RF) kullanmaktadır. Önerilen yaklaşımda yapısal, spektral ve dokusal özelliklerin birleştirilmesinden dolayı tek tek ağaçları tanımlama başarısı yaklaşık %90 seviyesine ulaşmaktadır.

Banerjee ve Raval (2022), İHA-LiDAR nokta bulutlarını kullanarak kömür madeni sahalarındaki bitki örtüsünün haritalanması için Kanopi Yükseklik Modeli ile segmentasyon gerçekleştirdikten sonra çeşitli sınıflandırma algoritmalarını kullanarak sınıflandırma performanslarını değerlendirmektedir. Yapılan araştırmada test verisi olarak Avustralya'nın Sidney şehrinin güneybatısındaki Wollongong yakınlarında bulunan 5 bataklık bitki örtüsü ve 3 bataklık dışı bitki örtüsü sınıfı olmak üzere toplam 8 bitki örtüsü sınıfı kullanmaktadır.

Yadav vd. (2021), Okalıptüs (*Eucalyptus globulus Labill.*) ağacının baskın olduğu yoğun ve ıslak ormanda bireysel ağaç taç segmentasyonu ve tür sınıflandırması için havadaki hiperspektral ve LiDAR verilerinin kapasitesini değerlendirmektedir. Segmentasyon işlemi için Kanopi Yükseklik Modelini (KYM) ele almaktadır. Ağaç türü sınıflandırmada ise Rastgele Orman ile nesne tabanlı bir sınıflandırma gerçekleştirmektedir. KYM ile hiperspektral ve minimum gürültü fraksiyonu (MNF-Minimum Noise Fraction) görüntüleri birlikte kullanarak performans değerlendirmesi yapmaktadır. En iyi segmentasyon doğruluğunu (%88) hiperspektral görüntülerin bulunduğu kombinasyonlardan elde etmektedir.

Liu vd. (2022), çok katmanlı algılayıcı (MLP) tabanlı derin öğrenme yöntemleri (PointNet, PointNet++ ve PointMLP) ile bireysel ağaç kümelerini yersel LiDAR nokta

bulutu kullanarak sınıflandırmak için Kayın (*Fagus*), Douglas Göknarı (*Pseudotsuga menziesii*), Ladin (*Picea*), Kızıl Meşe (*Quercus rubra*), Meşe (*Quercus alba*- L.), Dişbudak (*Fraxinus excelsior*) ve Çam (*Pinus pinea*) ağaçlarının olduğu bölgede test yapmaktadır. 2048 nokta ile yapılan eğitim sürecinde en yüksek doğruluğu elde etmektedir. Sınıflandırmada PointMLP'nin eğitilmesi daha hızlıdır ve daha iyi performans göstermektedir. Genel sınıflandırma doğruluğu ise yaklaşık %94 seviyesindedir.

Liu vd. (2021), Saihanba Ulusal Orman Parkı'nda Beyaz Huş (*Betula pendula*) ve Karaçam (*Pinus Nigra*) ağacının yer aldığı bir test alanına ait yersel ve hava LiDAR nokta bulutlarını kullanarak ağaçların üç boyutlu yapısal özelliklerini elde etmek için LayerNET adlı nokta tabanlı bir derin sinir ağı önermektedir. LayerNET, nokta kümelerini doğrudan işleyerek düşey yönde ayırt edici özellik temsilini katmanlı öğrenen ağaç yapılı bir derin sinir ağı modelidir. Önerilen yöntemin ortalama sınıflandırma doğruluğu ise %90 olarak tespit edilmektedir.

Ağaç taç segmentasyonu, metrik çıkarımı ve sınıflandırılması için yapılan çalışmalar;

Bennett vd. (2022), orman yangın yönetimi için yüksek çözünürlüklü RGB görüntüleri kullanarak DeepForest'a dayanan iki aşamalı bir algılama ve tanımlama evrişimli sinir ağı önermektedir. İlave olarak ağaç türünü, yüksekliğini, konumunu ve boyutunu otomatik olarak hesaplar ve sınıflandırma yapabilmek için VGG19 ağını eğitir. Önerilen ağın genel ortalama ağaç tespit oranı %92, sınıflandırma oranı ise %65 olarak hesaplanmaktadır.

Literatür araştırması sonucunda farklı veri setleri ile yapılan bireysel ağaç taç segmentasyonu işlemleri için bitişik ağaç kümelerinde hatalı segmentasyon gerçekleştirildiği ve bu yüzden çoğunlukla düşük veya orta yoğunluğa sahip ağaçlık alanların test verisi olarak tercih edildiği gözlemlenmiştir. Yapılan çalışmalarda ağaç taç segmentasyonu için genellikle Kanopi Yükseklik Modeli ve Havza Bölütleme algoritması tercih edilse de ormanlık alanlarda ağaç taçlarının karışık bir düzende olmasından dolayı bu algoritmalar ağaç tepelerini algılamakta zorlanmaktadır. Ağaç metriklerinin çıkarılması için bazı çalışmalar doğrudan veri seti üzerinden tahmin edilirken bazı çalışmalarda geliştirilmiş allometrik denklemler ile kestirim yapılmaktadır. Sınıflandırma aşamalarında ise özellikle Rastgele Orman Sınıflandırıcı, Destek Vektör Makineleri ve derin öğrenme tabanlı yöntemler tercih edilmektedir. Veri setleri incelendiğinde ise tekil veri kullanılan çalışmalar bütünleşik veri kullanan çalışmalara göre daha düşük doğrulukta sonuçlar üretmektedir.

Hava LiDAR nokta bulutu verilerini kullanan çalışmalar yoğun kapalılıktaki ağaçlık alanlarda, gövde hakkında çok fazla bilgi toplayamadığı için gövde üzerindeki ağaç metrik hesapları düşük korelasyon ile tahmin edilmektedir. Yersel LiDAR nokta bulutu tercih eden çalışmalar ise zamandan ve işgücünden kayıp vermekte ancak ağaç gövdesi üzerinde yoğun nokta bulutu oluşturabilmesinden dolayı metrik çıkarım çalışmalarında büyük avantajlar sağlamaktadır. Mobil LiDAR tercih eden çalışmalar ise yersel LiDAR'a göre ormanlık alan içerisine erişilebilirliği daha kolay hale getirmekte, ancak daha fazla gürültü içermektedir. Fotogrametrik nokta bulutu kullanan çalışmalar ise yaprak ve dalların hareketleri sebebiyle görüntü eşleştirme aşamasında gürültüler ile karşılaşmaktadır. Görüntü tabanlı çalışmalar ise özellikle derin öğrenme modellerine dayanarak gerçekleştirilmektedir. Ayrıca derin öğrenme tabanlı 2B ve 3B segmentasyon işlemleri eğitim veri seti ihtiyacı ve eğitim süresi açısından negatif bir etki oluşturmaktadır. Bu tez çalışmasında literatürdeki çalışmalardan farklı olarak Kanopi Yükseklik Modeli'ndeki segmente edilen ağaçların tekrar segmente edilmesini sağlamak için Bézier eğrisi ile geliştirilmiş lokal maksimum yaklaşımı önerilmiştir. Önerilen yaklaşımın hatalı segmentasyon yapabilme ihtimaline karşın ağaç taçlarının alanlarını istatistiksel bazda karşılaştırarak ikinci kez düzeltme getirmektedir. Segmentasyon doğruluğunu hesaplamak için ağaç taçlarının sınırları üzerinden geçirilecek değişken yarıçaptaki çemberler ile referans ve bulunan ağaçların birebir eşleştirilmesi sağlanmaktadır. Son olarak ağaç metriklerinin tahmin edilmesi için geliştirilmiş allometrik denklemler kullanılmaktadır.

1.5. Temel Kavramlar


1.5.1. Fotogrametri

Fotogrametri, photos (ışık), grama (çizim) ve metron (ölçme) sözcüklerinden oluşmakla birlikte iki veya üç boyutlu nesnelerin fotoğraflar üzerinden ölçülerek metrik bir şekilde yorumlanması olarak tanımlanmaktadır. Uluslararası Fotogrametri ve Uzaktan Algılama Topluluğunun (ISPRS) tanımına göre; fotogrametri, nesnelere ve yakın çevresine temas etmeksizin, yayılan elektro manyetik enerjinin algılanması, değerlendirilmesi ve yorumlanmasıyla nesne ve çevresi hakkında güvenilir bilgiler elde etme sanatı, bilimi ve teknolojisidir. Konecny (2002)'nin tanımına göre fotogrametri, görüntülerden yayılan

elektromanyetik enerjilerin elde edilmesi ile yeryüzündeki cisimler ve çevre hakkında dijital ortamda doğruluğu yüksek sayısal bilgiler sunan bir bilim dalıdır.

Fotogrametri ile nesnelerin radyometrik ve geometrik özellikleri fotoğraflar yardımıyla tespit edilerek yorumlanması ve analizi sağlanmaktadır. Ayrıca araziye ait ölçümler ve veri toplama işlemleri doğrudan gerçek yeryüzü yerine fotoğraf üzerinden yapıldığı için dolaylı bir ölçme ve veri toplama yöntemi olarak değerlendirilmektedir. Fotogrametri kısacası, cisimler hakkında iki boyuta sahip görüntülerden üç boyutlu bilginin oluşmasını sağlayan bir teknolojidir. Cisim uzayında üç boyutlu koordinat bilgisi elde etmek için özel durumlar haricinde genellikle tek bir fotoğraf yeterli olmamaktadır. Üç boyutlu veriyi/bilgiyi üretebilmek için en az bindirmeli iki adet görüntü alımının gerçekleştirilmesi gerekir. Bu durum insanların yeryüzündeki cisimleri üç boyutlu olarak algılayabilmesi için sağ ve sol gözden gelen sinyallerin beyinde derinlik algısı olarak değerlendirilmesine benzemektedir (Karslı, 2022; Linder, 2016). İnsan beyni de aynı fotogrametri bilimindeki gibi nesneye herhangi bir temas etmeksizin farklı konumlardan bindirmeli olarak görüntüleri ele alarak üçüncü boyutu hissetmemizi sağlar. Bindirmeli çekilen hava fotoğraflarına ilişkin görsel Şekil 2’de sunulmaktadır.

Fotogrametri, kamera konumu ve değerlendirme yöntemlerine göre hava, yersel ve yakın resim fotogrametrisi olmak üzere üç gruba ayrılmaktadır. Hava fotogrametrisinde hava araçlarına (İnsansız Hava Aracı, fotogrametrik uçak vb.) yerleştirilen dijital kamera ile yeryüzü hakkında hava fotoğrafları ve konumsal bilgiler üretilmektedir. Yersel fotogrametri de ise yeryüzündeki cisimlerin etrafından çekilmiş görüntüler üzerinden işlem yapılmaktadır. Yakın resim fotogrametrisi ise nesne ile kamera arasında en fazla 300 m mesafe olan bir fotogrametri tekniğidir.



Şekil 2. Bindirmeli hava görüntüsü alımı

Model üzerinde gösterilen O, üç boyutlu obje koordinat sisteminin orijinini, $P_i (X, Y, Z)$ nesnenin yeryüzündeki koordinatlarını, O' izdüşüm merkezinin koordinatlarını (X_0, Y_0, Z_0), OP_i iki vektör arasındaki mekansal üçgeni tanımlamaktadır. Resim ve obje koordinat sistemi arasında dönüşüm yapabilmek için ölçek faktörü (λ_i) ve dönüklük matrisinin (R) bilinmesi gerekmektedir. İzdüşüm denklemlerinin genel formatı Denklem 1'de açıkça belirtilmiştir.

$$\begin{pmatrix} X_i \\ Y_i \\ Z_i \end{pmatrix} = \begin{pmatrix} X_0 \\ Y_0 \\ Z_0 \end{pmatrix} + \lambda'_i R \begin{pmatrix} x_i \\ y_i \\ -c \end{pmatrix} \quad (1)$$

Obje koordinat ve görüntü koordinat sistemlerindeki birim vektörler (i, j, k ve a, b, c) ortogonal şekilde birbirlerine dik bir konumda bulunmakla birlikte tüm eksenlerde aynı ölçek faktörü kullanılmaktadır. Arazi koordinatlarından (X_i, Y_i ve Z_i), resim koordinatlarının (x_i, y_i) hesaplanması için kullanılacak izdüşüm denkleminin yeni formu Denklem 2'de gösterilmektedir.

$$\begin{pmatrix} X_i \\ y_i \\ -c \end{pmatrix} = \frac{1}{\lambda'_i} R^T \begin{pmatrix} X_i - X_0 \\ Y_i - Y_0 \\ Z_i - Z_0 \end{pmatrix} \quad (2)$$

(1) ve (2) numaralı denklemde belirtilen dönüklük matrisinin hesaplanması için üç eksenlerdeki dönüklük matrislerinin (R_ω, R_ϕ, R_χ) bilinmesi gerekmektedir. Dönüklük açılarının hesaplanması için ilgili açının kosinüs ve sinüs değerleri hesaplanır. (3), (4) ve (5) numaralı eşitliklerde bulunan X, Y ve Z eksenlerindeki dönüklük matrisleri kullanılarak (6) numaralı denklemdeki genel dönüklük matrisi formülü elde edilmektedir (Karşlı, 2022).

$$R_\omega^T = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \omega & \sin \omega \\ 0 & -\sin \omega & \cos \omega \end{pmatrix} \quad (3)$$

$$R_\phi^T = \begin{pmatrix} \cos \phi & 0 & \sin \phi \\ 0 & 1 & 0 \\ -\sin \phi & 0 & \cos \phi \end{pmatrix} \quad (4)$$

$$R_{\chi}^T = \begin{pmatrix} \cos \chi & \sin \chi & 0 \\ -\sin \chi & \cos \chi & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (5)$$

$$R^T = R_{\omega}^T R_{\phi}^T R_{\chi}^T = \begin{pmatrix} r_{11} & r_{21} & r_{31} \\ r_{12} & r_{22} & r_{32} \\ r_{13} & r_{23} & r_{33} \end{pmatrix} \quad (6)$$

(2) numaralı denklemde R^T matrisi yerine yazıldıktan sonra resim koordinatlarının (x_i , y_i) hesaplanması için (7) ve (8) numaralı eşitliklerde belirtilen izdüşüm denklemleri elde edilmektedir. Ölçek faktörü (λ) sadeleştirmeden dolayı genel izdüşüm denklemlerinde yer almamaktadır. Özetle izdüşüm denklemlerinin oluşumu görüntü, izdüşüm merkezi ve arazi noktalarının doğrusal düz bir hat üzerinde yer alma ilkesine dayanmaktadır.


$$x_i = -C \frac{r_{11}(X_i - X_0) + r_{12}(Y_i - Y_0) + r_{13}(Z_i - Z_0)}{r_{31}(X_i - X_0) + r_{32}(Y_i - Y_0) + r_{33}(Z_i - Z_0)} \quad (7)$$

$$y_i = -C \frac{r_{21}(X_i - X_0) + r_{22}(Y_i - Y_0) + r_{23}(Z_i - Z_0)}{r_{31}(X_i - X_0) + r_{32}(Y_i - Y_0) + r_{33}(Z_i - Z_0)} \quad (8)$$

1.5.2. Lazer Tarama Teknolojisi (LiDAR)

LiDAR (Işık Algılama ve Mesafe Belirleme), sensör tarafından cisim yüzeylerine gönderilen lazer ışınlarının geri yansyarak sensöre ulaşmasına kadar geçen sürenin hesaplanması ile hedef nesnenin lazer tarayıcı ile arasındaki mesafenin ölçümü olarak tanımlanmaktadır. LiDAR ölçüm prensibi yeryüzündeki hedef nesne ile tarayıcı arasındaki eğik mesafenin belirlenmesine dayanmaktadır. Bu ilkeye göre ışık hızı ve sinyalin gidiş-geliş süresi ile mesafe hesap edilmektedir (Denklem 9). Ölçüm esnasında lazer ışınlarının isabet ettiği nesnelere ait konumsal bilgilerin (X , Y , Z) elde edilebilmesi için tarayıcının konumu ve dönüklük açılarının bilinmesi gerekmektedir. Tarayıcının konumu (X_0 , Y_0 , Z_0) Global Konumlandırma Sistemi (GPS) ile dönüklük açıları (ω , ϕ , χ) ise İnertiyel Ölçme Aleti (IMU) yardımıyla elde edilmektedir. Ayrıca LiDAR ile ölçüm yapılırken veri toplama zamanı, uçuş hızı ve yüksekliği, tarama açısı, bindirme oranları, lazer dalga boyu gibi

parametreler dikkate alınmalıdır. LiDAR ile veri toplama işlemi Şekil 4’te detaylı bir şekilde gösterilmektedir. LiDAR ile arazideki detay noktaların üretilmesi Şekil 5’te verilmiştir.



Şekil 4. Hava LiDAR veri toplama sistemi


$$\rho = \frac{t \times V}{2}$$

(9)

ρ : mesafe,

t: zaman,

V: lazer ışınının hızını temsil etmektedir.



Şekil 5. Doğrusal (lineer) LiDAR ile detay noktalarının üretilmesi

Tarayıcı tarafından gönderilen lazer ışınları bazı hedeflerden geçerek ulaşabildiği son noktadan sensöre geri yansımaktadır. Lazer tarayıcılar cisimlerden yansıyan ışınları yansıma sırasına göre kaydetmektedir. Nesnelerden geri yansıyan ışınlar bakıldığında ilk yansıma değerleri yüksek detayların bulunduğu bina, ağaç, direk vb. detaylardan gerçekleşirken, son yansımalar ise zemin üzerindeki noktalardan olduğu bilinmektedir. Bundan dolayı yansıma sırasına göre detayların cinsine ilişkin tahminler geliştirilebilmektedir. Lazer tarayıcılardan gönderilen ışınlar detayların cinsine göre farklı yansımalar meydana getirmektedir. Yansıyan ışınların mesafesi çok büyük olursa kaba hatalı bir ölçüm gerçekleşir (Karşlı, 2022). Deniz, göl, akarsu gibi sıvı yüzeylerde ise tarayıcıdan gönderilen ışınlar genellikle yutulur ve geri dönen ışın miktarı çok az olmaktadır (Karşlı, 2022). Bu yüzden sulak alanlarda daha çok suyun sığ olduğu bölgelerde yoğun bir şekilde ışınlar geri yansır (Acar, 2018).

Günümüzde en çok tek veya çok darbe özelliğine sahip tek dalga boylu ve darbeli doğrusal (lineer) mod LiDAR teknolojisi kullanılmaktadır. Bu tür lazer tarayıcılarda tek bir lazer darbesi gönderilir ve geri yansdıktan sonra sensör tarafından kaydedilir (Şekil 5). Dolayısıyla nesnelere gelen lazer ışınının darbesi bir önceki darbe alındıktan sonra gerçekleşir ve bu da iki ardışık darbenin belirli bir zaman aralığı ile birbirinden ayrılmasını sağlamaktadır. Sözü geçen zaman aralığı ifadesi Darbe Tekrarlama Frekansı (PRF) ile ilişkilidir. Doğrusal LiDAR sensörlerinin tarama modları genellikle zikzak veya paralel çizgiler şeklindedir.

Hava LiDAR sensörlerinde önceki ışın darbesinin dönüş dalga biçimini almadan ikinci bir lazer ışınının gönderilmesine imkân sağlayan çoklu darbe özelliğine sahip lazer tarayıcılarda bulunmaktadır. Bu sensörler herhangi bir uçuş yüksekliğinde darbe hızının iki katına çıkmasını sağladığı için çalışma alanı içerisinde doğrusal LiDAR'a göre daha fazla detay noktası üretebilecektir. Tam dalga biçiminde (FWD) ise tekli veya çoklu dönüş sinyallerinin aksine kısa zaman diliminde bir ayak izinin tüm derinliğinde geri saçılan yüzeylerin özelliğini tam dalga formunda kaydeder (Karşlı, 2022).

Çok spektral LiDAR (MSL) tarayıcılar verilerin sınıflandırılmasına yardımcı olabilen dönüş darbesinin (yansıyan ışınların) yoğunluk bilgilerini kaydetmektedir. Mevcut literatürde kullanılan dalga boyları genellikle 532 nm, 1064 nm ve 1550 nm şeklinde üç bağımsız darbe yayılımına sahiptir.

Son zamanlarda gelişen Geiger Mod LiDAR (GML) ve Tek Foton LiDAR (SPL) teknolojileri diğer sistemlerden farklı olarak dönüş lazerlerinin birkaç fotonunu bile

algılayarak mesafeyi ölçebilmektedir (Karslı, 2022). Bahsi geçen iki sistem bir lazer darbesini birden fazla darbeye bölebildikleri için yüksek detayların çevresinde tam kapsama sağlayarak gölge etkisini minimum seviyeye indirebilmektedir. Ayrıca değişken uçuş yüksekliklerinde gerçekleştirilen detay ölçümünde diğer sistemlere göre kullanıcıya daha yoğun bir veri seti sunmaktadır.

LiDAR genel olarak arazi üzerindeki çeşitli detayların (zemin, bina, bitki örtüsü, araba, elektrik direği vb.) 3B nokta bulutlarını yoğun ve doğru bir şekilde temsil edebilmesi için çalışma alanı içerisindeki nesnelerin koordinatlarını (X, Y, Z), yoğunluk bilgisini ve renk bilgisi (R, G, B ve IR) elde etmektedir. İlave olarak dönüş sayısı, tarama açısı, arazi örtüsü sınıfı gibi çeşitli bilgiler sunabilir. LiDAR sistemleri tarafından üretilen nokta bulutları özellikle yüksek kotlu detayların (ağaç, bina, elektrik direği vb.) bulunduğu bölgelerde lazer ışınının küçük boşluklardan geçerek zemine isabet etmesinden dolayı üstünlük sağlamaktadır. Ancak lazer ışınları her zaman kenar boyunca bir nesneye tam olarak isabet etmediği için keskin kenarları temsil etmede optik veriye (hava görüntüsü) göre kısıtlamaları bulunmaktadır. Aktif bir sistem olan LiDAR, gece-gündüz ölçüm yapabilmesi ve gölgelerden etkilenmemesinden dolayı üretilen 3B nokta bulutları, topoğrafya üzerindeki doğal veya beşerî unsurları analiz etme aşamasında önemli derecede zengin geometrik bilgi sağlamaktadır (Vosselman vd., 2005).

LiDAR verileri hava, yersel, mobil (El tipi, GeoSLAM, araca monteli) olmak üzere üç ana sınıfa ayrılmaktadır. Hava LiDAR (ALS) geniş ölçekte detay ölçümü gerçekleştirme aşamasında diğer yöntemlere göre avantaj sağlamaktadır. Havadan yapılan ölçümde uçuş yüksekliğine bağlı olarak oluşturulan veri setinin yoğunluğu daha düşük çıkar. Yersel LiDAR (TLS) ise daha çok küçük çalışma bölgelerinde nokta bulutu üretim aşamalarında kullanılmaktadır. TLS ile üretilen veri seti ALS'ye göre çok daha yoğun olmakta ancak istasyon gerektirdiği için zamanı ve iş gücünü artırmaktadır. Mobil LiDAR (MLS) ise TLS gibi küçük çalışma bölgelerinde tercih edilmektedir. Veri setinin yoğunluğu yüksek olmasına rağmen hareket halinde ölçüm yapıldığından nokta bulutu üzerinde çok fazla gürültü özellikli noktalar bulunmaktadır.

1.5.3. Nokta Bulutları

Nokta bulutları, yeryüzündeki nesnelerin (doğal veya yapay) dış yüzeyini üç boyutlu koordinat sisteminde (X, Y, Z) temsil etmek için kullanılan bir veri kümesidir. Coğrafi

olarak kullanılan nokta bulutları genellikle Dijital/Sayısal Yükseklik Modelinin üretimi, kentsel alanlarda bina, köprü, yol, ağaç gibi kent unsurlarının modellenmesi, harita üzerinde mevcut detayların çıkarılması ve analizi, hacim hesabı ve hasar tespiti gibi birçok harita faaliyetlerinin hızlı ve etkin bir şekilde uygulanabilmesi için tercih edilmektedir. Mevcut literatürde yaygın olarak kullanılan nokta bulutları, LiDAR sistemleri ile doğrudan, fotogrametrik görüntü eşleştirme yöntemleriyle ise dolaylı yoldan elde edilmektedir.


1.5.3.1. LiDAR Nokta Bulutu

LiDAR teknolojisi ile tarayıcı tarafından gönderilen lazer sinyali yeryüzündeki hedef nesneye isabet ettikten sonra alıcı sensöre tekrar geri yansyarak sinyalin detaya temas ettiği noktanın konum (X, Y, Z), yoğunluk (intensity) ve renk bilgisi (R, G, B, IR) gibi geometrik ve spektral özelliklerini kaydetmektedir. Lazer tarayıcılar gönderilen lazer ışınının seyahat süresini hassas bir şekilde ölçtüktan sonra öncül bilgi olarak kullanılan ışık hızı bilgisiyle nesne ile alıcı arasındaki eğik mesafeyi hesaplamaktadır. Mesafe, lazer tarayıcının anlık konumunun GPS ile belirlenmesi ve dönüklük parametrelerinin (ω , ϕ , χ) IMU ile hesaplanmasının ardından her bir lazer sinyalinin hedef nesneye temas ettiği noktanın X, Y, Z koordinatları doğru bir şekilde üretilmektedir. Üretilen nokta bulutları uçuş yüksekliğine, kameranın hassasiyetine, tarama moduna ve yöntemine göre değişken yoğunluklara sahip olabilmektedir. Nokta bulutunda detay noktalarının yeryüzündeki gibi gerçek rengi ile temsil edilebilmesi için kullanılan LiDAR kamerasında RGB bant desteği bulunmalıdır. Ham LiDAR nokta bulutları içerisinde yer alan gürültü özellikli noktalarında filtrelenmesi veya ayıklanması gerekmektedir.


LiDAR teknolojisi ile üretilecek nokta bulutları hava (ALS), yersel (TLS) ve mobil LiDAR (MLS) sistemleri ile farklı yoğunluk ve düzeyde oluşturulmaktadır. Hava LiDAR nokta bulutları hava araçlarına (İHA, drone, uçak vb.) monte edilmiş LiDAR kameraları kullanılarak üretilmektedir. İHA ve drone kullanarak yapılan ölçümler genellikle düşük veya orta irtifada gerçekleştirildiği için uçak ile elde edilen hava LiDAR nokta bulutuna göre daha yoğun bir nokta bulutu sağlamaktadır. Hava LiDAR nokta bulutu genellikle geniş alanlarda hızlı ve etkili bir şekilde kullanılmasına rağmen yoğun yerleşik kesimlerde veya ormanlık alanlarda bina veya ağaçların alt kısımlarına ait detaylara kısmen nüfuz edebilirler. Bu durum hava ölçümünün tarama açısına ve topoğrafya üzerindeki detayların karmaşıklığına bağlı olarak değişkenlik gösterebilmektedir. Ayrıca hava ölçümlerinde tarayıcı tarafından

gönderilen sinyal havada uçuşan nesnelere denk geldiği zaman lazer ışınları arazi üzerindeki detaylara isabet etmeden sensöre geri yansıyorak gürültülü nokta üretebilir. Gelişen teknoloji ile birlikte son zamanlarda hava araçları ile elde edilen LiDAR nokta bulutlarının yoğunlukları 1000-3000 nokta/m² seviyelerine çıkmaktadır. Hava LiDAR nokta bulutlarına ilişkin örnekler Şekil 6’da gösterilmektedir.

Yersel LiDAR nokta bulutları özellikle küçük çalışma bölgelerinde nesnelerin 3B modellerini üretmede üstün yeteneğe sahiptir. Hava LiDAR ölçümünde yapılanın aksine yersel lazer tarama işlemi statik yöntemle birlikte arazide istasyonlar yardımıyla gerçekleştirilmektedir. (Şekil 7). Çalışma prensibi yine hava LiDAR’da olduğu gibi lazer tarayıcıdan hedef nesne üzerine gönderilen lazer sinyalinin seyahat süresinden faydalanarak bölgedeki tüm detayların (X, Y, Z) koordinatlarını üretmektedir. ALS veri setine göre oldukça yüksek bir yoğunluğa sahip olmakla birlikte özellikle nesnelerin gövde kısmına ilişkin detay noktalarını yüksek doğrulukta sağlamaktadır.



Şekil 6. Hava LiDAR nokta bulutu; a) RGB görüntüye sahip nokta bulutu, b) sınıflandırılmış veri seti, c) yoğunluğa göre renklendirilmiş, d) yüksekliğe göre renklendirilmiş nokta bulutu



Şekil 7. TLS nokta bulutu; a) huş ağacı (*Betula pendula*) (URL-1, 2023), b) meşe (*Quercus alba*- L.) (URL-2, 2023).


Mobil LiDAR nokta bulutları, hareketli platformlar (GeoSLAM, Sırt LiDAR, mobil cihaza ve araca entegre LiDAR vb.) üzerine entegre edilerek çevredeki nesnelerin lazer tarama ölçümü ile elde edilmektedir. Üretilen veri seti nokta yoğunluğu bakımından yersel lazer tarayıcılara benzemektedir. Hareketli bir mekanizmaya sahip olduğu için çalışma alanı içerisinde ulaşılabilirlik sorununa çözüm getirebilmektedir. Lazer sensörü ile hedef nesne arasındaki mesafe çok düşük olduğu için detay noktaları hava LiDAR nokta bulutuna göre çok daha hassas bir şekilde ölçülür. Hareketli mekanizma sonucunda üretilen nokta bulutları yersel LiDAR nokta bulutuna göre daha fazla gürültü içermektedir. Bu veri seti ile analiz veya modelleme yapılabilmesi için gürültü içerikli noktaların arındırılması veya filtrelenmesi gerekmektedir. Mobil lazer tarama sonucu üretilen nokta bulutuna ilişkin görsel Şekil 8’de yer almaktadır.



Şekil 8. Mobil LiDAR (MLS) nokta bulutu (URL-3, 2023).


1.5.3.2. Fotogrametrik Nokta Bulutu

Fotogrametrik nokta bulutları görüntü eşleştirme algoritmaları yardımıyla üretildikleri için dolaylı yoldan üretilen veri kümesi olarak LiDAR nokta bulutlarından ayrılmaktadır. Dijital görüntülerde nesnelerin konumları stereo görüntü çiftleri ile otomatik olarak tespit edilebilmektedir. Fotogrametride iki resim ele alınarak yapılan stereo değerlendirme ile 3B konum bilgisi üretilmesi aşamasında görüntü eşleştirme işlemi gerçekleştirilmektedir (Şekil 9). Eşleştirme aşamasında stereo (bindirmeli) görüntüler üzerinde detayların nokta olarak seçilmesi ve diğer resimde karşılık gelen eşlenik noktaların da optimum düzeyde işaretlenmesi gerekmektedir (Karşlı, 2022). Mevcut literatürde fotogrametrik nokta bulutu üretimi için kullanılan ticari programlar veya akademik yazılımlar ile eşlenik noktalar belirlenebilir. Programların arka planında kullanılan algoritmalar otomatik olarak seçilen noktaların eşleniklerini diğer resimlerde tespit edebilmek için görüntü üzerinde Temel Dönüşüm Matrisi (Fundamental Matrix) ile normalizasyon işlemi gerçekleştirerek, her bir görüntünün aynı eksene paralel duruma getirilmesini sağlamaktadır (Karşlı, 2022). Yapılan bu işlem ile birlikte epipolar çizgiler oluşmaktadır. Algoritmalar epipolar geometri ile yanlış eşleştirilen noktaları giderebilmek için gerçek eşlenik noktaları, epipolar düzlem üzerinden tespit etmektedir.




Şekil 9. Epipolar eşleştirme (Sao Paulo / Brezilya)

Fotogrametrik nokta bulutlarının üretilmesi için en yaygın kullanılan eşleştirme algoritması Yarı Global Eşleme (SGM), iç ve dış yöneltme elemanları bilinen dijital resim çiftlerinin, epipolar geometri ile piksel tabanlı olarak eşlenik noktalarını tespit ederek 3B koordinatların üçgenleme ile hesaplanmasını sağlamaktadır (Hirschmuller, 2008; Huang vd., 2020). SGM algoritması, radyometrik farklılıkları modellemek için maliyet fonksiyonu kullanır ve tek boyutta optimizasyon gerçekleştirerek maliyet fonksiyonunu minimum değere indirgemeyi amaçlamaktadır (Hirschmuller, 2008). SGM yaklaşımının en önemli avantajlarından biri her piksel için eşleme işlemini ilgili piksele komşu olan 8 yön ile yaparak eşleştirme aşamasında en doğru konumu belirleyebilmesidir (Yastıklı ve Bayraktar, 2014). Özetle her bir piksel ve eşleşme durumu için 8 farklı yoldan elde edilen maliyetlerden, en düşük maliyetli olan yol tercih edilerek eşleştirmede optimum kararı vermeyi sağlamaktadır (Şekil 10).



Şekil 10. SGM sekiz yönlü eşleme modeli (Hirschmüller, 2011).

Yaklaşımın dezavantajı ise piksel bazlı bir işlem yaptığı için bellek gereksinimi ve zaman problemi açığa çıkarabilmesidir (H. Hirschmüller vd., 2012). SGM ile yüksek yoğunluklu ve kaliteli fotogrametrik nokta bulutu üretebilmek için yüksek çözünürlüğe ve bindirme oranına sahip görüntülere ihtiyaç vardır (Navarro vd., 2018). SGM algoritmasında resim çiftleri arasında eşlenik noktaların bulunabilmesi için kullanılan epipolar geometri Şekil 11’de gösterilmektedir.



Şekil 11. Epipolar geometri (Gonzalez-Aguilera vd., 2010).

Görüntü eşleştirme ile üretilen nokta bulutları genellikle LiDAR ile üretilen nokta bulutlarına göre nokta yoğunluğu daha yüksek olmasına rağmen gölgelik alanlarda ve hareketli nesneleri eşleştirmedeki problemlerden dolayı çok sayıda gürültülü nokta içermektedir. Nokta dağılımı açısından değerlendirildiğinde fotogrametrik nokta bulutları LiDAR nokta bulutlarına göre daha düzensiz bir veri seti oluşturmaktadır. Fotogrametrik nokta bulutuna ilişkin örnek veri seti Şekil 12’de gösterilmektedir.




Şekil 12. Fotogrametrik nokta bulutu (Of/Türkiye)

1.5.4. Ağaç Metrikleri

Ağaç envanter bilgileri, ekosistem hizmetlerinin gerçekleştirilmesi, ağaç değişikliklerin izlenmesi, ağaç yönetim sistemlerinin oluşturulması, çevre planlanması, biyolojik çeşitliliğin izlenmesi ve yer üstü biyokütle tahmini için kritik bir öneme sahiptir (Herrero-Huerta vd., 2018). Ormanlık alanlarda meşcere parametrelerinin belirlenmesi ile orman amenajman planları hazırlanmaktadır. Literatürde önemli olan mevcut ağaç metrikleri/parametreleri şu şekildedir:

- Göğüs yüksekliğindeki çap (GYÇ-DBH)
- Ağaç boyu (AB-TH)
- Taç genişliği (TG-CW)
- Taç taban yüksekliği (TTY-CBH)
- Taç taban hacmi (TTH-CBV)
- Kanopi/taç hacmi (KH-CV)

Bu metriklerin dışında ağaç sayısı ve ağaç merkezinin konumu da envanter bilgisi için önemli girdi verileridir. Orman envanter bilgisi için gereken bu parametreler Şekil 13’de detaylı bir şekilde sunulmaktadır.



Şekil 13. Ağaç parametrelerinin şeması (Herrero-Huerta vd., 2018).

Göğüs yüksekliğindeki çap (GYÇ) metriği ağacın hacminin belirlemek için orman envanter parametreleri arasında en önemli metrik olarak görülmektedir. Ağaç gövde çapının ölçümü zeminden 1,3 m yükseklikten (göğüs hizası) kumpas veya çap ölçer aletler ile cm mertebesinde gerçekleştirilmektedir. GYÇ parametresi gövdenin şişkinliği, ağacın çatallanma durumu ve arazinin eğimine göre farklı yöntem ve yükseklikte ölçülmesi gerekebilir.

Ağaç boyu (AB), hacim ve biyokütle gibi önemli bilgilerin hesaplanması için gereken bir metriktir. AB, ağacın düşey yöndeki maksimum ve minimum kotlu noktaların arasındaki mesafenin ölçülmesi ile elde edilir. Arazi çalışmalarında ise boy ölçer aletler ile ağaç boylarının ölçümü gerçekleştirilmektedir.

Taç genişliği (TG), fotosentez ve enerji transferi ile ilgili bitki fizyolojisi ve sağlığının izlenmesi için önemli bir metriktir (Herrero-Huerta vd., 2018). Ağaç tepelerinin izdüşürülmesi ile elde edilecek alanın, çapının ölçülmesi ile belirlenir. Taç genişliği diğer

bir ifadeyle ta apı doęu-batı ve kuzey-doęu ynlerinden llen mesafe deęerlerinin ortalaması alınarak hesaplanmaktadır.

Ta taban ykseklięi (TTY), zeminden bařlayarak aęacın dallanma yaptığı yere kadar olan dřey yndeki mesafe olarak tanımlanmaktadır. TTY parametresi, gvde ile aęacın ta yapısını birbirinden ayırır ve aęacın gvde hacminin belirlenebilmesi iin girdi verisi olarak kullanılır.

Ta taban hacmi (TTH), bitki fizyolojisinin izlenmesi ve analiz edilmesi iin yaygın olarak kullanılan bir aęa metrięidir. TTH metrięi aęa gvdesinin hacmini (m^3) temsil eder ve hesaplanması iin gęs ykseklięindeki ap (GY) ve ta taban ykseklięinin (TTY) bilinmesi gerekmektedir.

Kanopi hacmi (KH), aęacın ta yapısının hacimsel (m^3) olarak kapladığı alanı ifade etmektedir. Kanopi hacminin hesaplanması iin gvde ve ta yapısını dřey ynde birbirinden ayıran ta taban ykseklięi (TTH) ve ta geniřlięi (TG) metriklerinin bilinmesi gerekir.

1.5.5. Allometrik Denklemler

Aęa metrikleri genellikle arazi alıřmaları ile doęrudan llerek orman envanterine kaydedilir. Son yıllarda Uzaktan Algılama ve Fotogrametri bilim dallarındaki geliřmeler ile arazi lsne gerek kalmadan hızlı ve etkili bir řekilde aęa metrik ıkarımı yapılmaya bařlanmıřtır. Genellikle kullanılan  boyutlu (X, Y, Z) veri setleri analiz edilerek aęa metriklerinin doęrudan ham veri zerinden lm saęlanabilmesine raęmen topoęrafyanın getirdięi zorluklar veya alıřma alanlarının kapalılık seviyelerinin ok yksek olmasından dolayı zellikle aęacın bazı kısımlarına ait detay noktalarının llemedięi durumlar gzlemlenebilmektedir. Bu yzden bazı aęa parametrelerinin doęrudan tespiti mmkn olmayabilir. Doęrudan ham veri zerinden llemeyen aęa metrikleri ise bilinen metriklerden kestirim yapılmak suretiyle allometrik denklemler yardımıyla tahmin edilebilirler.

Allometrik denklemler, orman biyoktlesini ve karbon stoęunu tahmin etmek iin yaygın bir řekilde kullanılmaktadır (Basuki vd., 2009; Novotný vd., 2020). Allometrik denklemler, aęacın fiziksel geliřimini inceleyerek bilinmeyen metriklerin bilinen parametreler yardımıyla tahmin edilmesine olanak saęlamaktadır. zellikle aęa metrikleri arasından en nemli olan gęs ykseklięindeki ap (GY) metrięinin belirlenebilmesi iin

birçok çalışmada allometrik denklemler geliştirilmektedir. Bu denklemler ağacın büyüme oranına ve türüne göre farklı şekillerde formülize edilebilirler.

GYÇ ve TG metriğinin tahmin edilebilmesi için literatürde geliştirilen en yaygın formüller incelendiğinde genellikle bu iki metriğin ağaç boyu (AB) ile ilişkilendirildiği gözlemlenmektedir. GYÇ ve TG için ağaç boyu ile ilişkilerinden türetilen en yaygın allometrik denklemler (10), (11) ve (12) numaralı eşitliklerde görülmektedir (Novotný vd., 2020). Denklemlerde bahsedilen R değişkeni taç genişliğini, H ağaç boyunu, DBH göğüs yüksekliğindeki çapı, a ve b ise ağaç türüne göre lokal veya global katsayıları ifade etmektedir.

$$R = aH + b \quad (10)$$

$$DBH = \exp(aH + b) \quad (11)$$

$$DBH = aH^b \quad (12)$$


1.5.6. Zemin Filtreleme (SMRF)

Nokta bulutlarında yer alan zemin ve zemin dışı noktaların birbirinden ayrılması için kullanılan SMRF (Simple Morphological Filter- Basit Morfolojik Filtre) algoritması dört ana aşamadan oluşmaktadır. Birinci aşamada, minimum yüzey (ZI_{min}) oluşturularak veri setindeki en düşük kotlu noktalar korunur. İkinci aşamada belirlenecek maksimum değere göre bir arama penceresi oluşturularak, ızgara/grid hücrelerinin zemin veya zemin dışı nesne olduğunu algılayabilmek için minimum yüzey, morfolojik operasyonlar ile işlenir. Üçüncü aşamada ise gridlenmiş nokta bulutundan bir SYM/DEM oluşturulur ve son aşamada ise ham veri setindeki noktaların SYM/DEM ile arasındaki ilişkisi incelenerek zemin noktalarının filtrelenmesi sağlanır (Pingel vd., 2013).

SMRF algoritmasında üretilen minimum yüzey (ZI_{min}) alanından sonra nokta bulutu gridlere bölünerek bir raster veri elde edilmektedir. Ardından minimum yüzey (ZI_{min}) gridine açma (aşınma + genişleme) ile aşamalı bir morfolojik işlem uygulanır. Görüntü üzerinde açma işlemi için genişleme filtresinin ardından bir erozyon filtresi uygulanır. Yinelemeli filtreleme sonucunda her bir hücre zemin veya zemin üstü olarak sınıflandırılmış yapıda ikili bir maske oluşturur. Algoritma daha sonra bu ikili maskeyi, zemin olmayan hücreleri ortadan

kaldırmak için başlangıçtaki minimum yüzeye uygulayarak geçici bir DEM üretir. Algoritmanın son adımında, zemin ve zemin üstü noktalar belirlenir. Bunu gerçekleştirmek için her nokta ile geçici DEM arasındaki dikey mesafe ölçülür ve bir eşik değeri hesaplanır. Orijinal noktaların, dikey mesafe ve isteğe bağlı ölçeklendirme parametrelerine göre zemin sınıfında olup olmadıklarına karar verilir (Pingel vd., 2013).

SMRF algoritması ile zemin ve zemin üstü noktaların filtrelenmesi için arazinin eğimi ve topoğrafyanın yapısına göre maksimum arama penceresi (yapılandırma elemanı) yarı çapı, eğim eşiği, yükseklik eşiği ve yükseklik eşiği ölçeklendirme faktörü parametrelerinin belirlenmesi gerekmektedir. Yapılandırma elemanı genişleme ve aşınma gibi morfolojik işlemlerde hücre boyutunu belirleyen parametredir. Eğim eşiği minimum yüzey haritasındaki (ZI_{min}) gridlerden zemin ve zemin dışı noktaların ayırt edilmesi için eğime bağlı bir değerlendirme parametresi olarak kullanılmaktadır. Yükseklik eşiği, geçici DEM üzerinden zemin ve zemin dışı noktaları ayırt etmek için kullanılan düşey yönde bir kriterdir. Yükseklik eşiği ölçeklendirme faktörü ise eğimi fazla olan arazi yüzeyinin filtrelenmesi için kullanılmaktadır. SMRF filtreleme algoritmasına ilişkin örnek Şekil 14’te verilmektedir.




Şekil 14. SMRF ile zemin ve zemin üstü noktaların filtrelenmesi

1.5.7. Octree (Sekiz dal) Veri Organizasyonu

Octree yöntemi, girdi olarak kullanılan nokta bulutunun sekize bölünerek indeksli düzende oluşmasını ve uzamsal bölümlenmesini sağlayan bir vokselleme tekniğidir. Octree yöntemi, başlangıçta kullanılan üç boyutlu veriyi hacimsel olarak sınırlandıran kök hücre


adı verilen tek bir dikdörtgen/kare prizmatik şekil ile temsil etmektedir ve bölümlenme işlemi başlamadığı için bu aşama Seviye 0 olarak tanımlanmaktadır. Seviye 0’da üretilen prizmatik sınır daha sonra 8 eşit parçaya bölünerek Seviye 1’deki voksel gruplarını oluşturmaktadır. Elde edilen son voksel grupları aşamalı bir şekilde 8 adet eş voksellere bölünerek nokta bulutlarının 3B uzamsal bölümlenmesini sağlamaktadır. Her bölümlenme sonrasında oluşan 8 adet voksel bir oktan yapısını oluşturur. Bölümlenme seviyesi derinlik sayısına bağlı olarak değişkenlik göstermektedir ve bölümlenme sonucu oluşan en son seviyedeki küçük prizmalar voksel yapısını temsil etmektedir (Dybedal vd., 2019). Octree veri organizasyonunun hiyerarşik yapısı Şekil 15’te gösterilmektedir.



Şekil 15. Octree hiyerarşik yapısı

Şekil 15’te görüldüğü üzere başlangıçta kullanılan ham veri, seviye 0 olarak kök hücre niteliğine sahiptir. Seviye 0’da tek bir veri kümesi mevcut iken Seviye 1’de ilgili veri 8 adet eş parçaya bölünerek 1 oktan grubunu oluşturmaktadır. Seviye 2’de ise Seviye 1’deki bütün veriler 8 adet eş parçaya ayrılacağı için en alt grupta toplam 64 eşit voksel ve 8 adet oktan grubu bulunur. Bölümlenme sayısına bağlı olarak ilgili veri kümesi, indeksli bir düzende eşit boyutlu vokseller şeklinde parçalanmaya devam etmektedir. Octree veri organizasyonunun bölümlenme koşulu, seçilecek maksimum derinlik (*max depth*) değişkenine bağlıdır.

Hiyerarşik yapı üzerinde eğer Seviye 2'ye kadar bir bölümlenme istenirse maksimum derinliği 3 olarak girilmesi gerekir. Sözü edilen sekizdal veri organizasyon yönteminin nokta bulutu üzerinde uygulanması Şekil 16'da sunulmaktadır.



Şekil 16. Octree veri organizasyonu uygulaması

Şekil 16'da görüldüğü üzere Seviye 0'da yer alan ham nokta bulutu her seviyede eş prizmalara/voksellere bölünerek ilgili veri kümesinin noktalarını 3B sınırlayıcı bir dörtgen ile sınırlandırarak içinde kalan noktaları aynı renk ile temsil etmektedir. Özetle voksel sınırları içinde kalan noktalar ayrı bir şekilde depolanmaktadır. Seviye 0, 1 ve 2'deki bölümlenmelerde yer alan voksel sınırları sırasıyla siyah, kırmızı ve mavi renk ile temsil edilmektedir. Seviyeye göre voksel sayıları incelendiğinde ise sırasıyla 1, 8, 64 şeklinde bir örüntü oluşmaktadır. Bu yüzden her seviyede oluşacak voksel sayısı 8^n (n: seviye numarası) formülü ile belirlenebilmektedir.

1.5.8. DBSCAN Kümeleme Algoritması


Yoğunluk tabanlı bir kümeleme tekniği olan DBSCAN (Density-Based Spatial Clustering of Applications with Noise) algoritması, ön bilgi (küme sayısı) gerektirmeden farklı boyut ve yoğunluktaki veri kümelerini başarılı bir şekilde ayırabildiği için bilimsel alanda yapılan analizlerde, literatürdeki diğer kümeleme yöntemlerine göre daha çok tercih edilmektedir. DBSCAN algoritmasının temel mantığı, veri kümesindeki noktaların 2B öklid mesafelerine dayalı bir yakınlık analizi gerçekleştirilerek hangi kümeye ait olabileceğini otomatik bir şekilde tahmin etmektir (Ester vd., 1996).

DBSCAN veri seti içerisinde muhtemel oluşabilecek kümeler hakkında ön bilgi gerektirmeksizin yoğunluğa dayalı bir yaklaşım ile kümeleme işlemini gerçekleştirdiği için K-means (K-ortalama) kümeleme algoritmasına göre daha avantajlı bir yapıya sahiptir (Tran vd., 2013). Yöntemin dezavantajı ise üç boyutlu uzamsal verilerde farklı nesnelerin bitişik veya birbirine çok yakın olmasından dolayı detay noktalarının hangi kümeye ait olabileceğini belirlerken algoritma kararsız hale gelebilmektedir. Ester vd. (1996), bunun bir dezavantaj olduğunu kabul etmektedir ve bu yüzden araştırmacılar DBSCAN kümeleme algoritmasını geliştirmeye yönelik çalışmalar yapmaktadır (Tran vd., 2013). DBSCAN kümeleme algoritmasının matematiksel modeli Şekil 17’de açıklayıcı bir şekilde gösterilmektedir.

Kümeleme işleminin yapılması için *Epsilon* (ϵ) ve *Minpts* isimli kullanıcı girişi iki temel parametresi bulunmaktadır. *Epsilon*, bir nesnenin yer alabileceği kümeye ait komşu noktalarını belirlemek için gerekli olan yakınlık mesafesi olarak tanımlanmaktadır. Diğer bir ifadeyle kümeleri birbirinden ayıran yarı çap mesafesidir. *Minpts* ise bir bölgenin yoğun olarak adlandırılabilmesi için epsilon komşuluğunda bulunması gereken minimum nokta sayısıdır. Kısacası, bir alanı küme olarak nitelendirebilmek için komşuluk sınırları içerisinde bulunması gereken minimum düzeydeki nokta sayısını ifade etmektedir. DBSCAN kümeleme algoritması komşuluk ilişkilerini çember içerisinde ortak nokta bulunmasına göre oluşturmaktadır.

Epsilon ve *Minpts* parametreleri bir kümeyi oluşturabilecek geometrik koşulları veya sınırları ifade etmektedir. Veri seti içerisindeki noktaların hangi küme sınırına ait olduğunu tespit edebilmek için tüm noktaların çekirdek, sınır veya gürültü noktası olarak etiketlenmesi gerekmektedir.

Çekirdek nokta, *Epsilon* yarı çapı içerisinde noktanın kendisi dahil olmak suretiyle en az *MinPts* kadar nokta bulunan çemberin merkez noktasını temsil etmektedir. Sınır nokta, çekirdek nokta özelliği bulunmayan ancak rastgele bir çekirdek noktaya erişim sağlayabilen noktadır. Gürültü noktası ise çekirdek nokta özelliği bulunmayan ve herhangi bir çekirdek noktaya erişim sağlayamayan noktaları ifade etmektedir. Gürültü noktaları kendi içerisinde bir küme oluşturmaktadır. *Epsilon*, *Minpts*, çekirdek nokta, sınır nokta ve gürültü noktalarının veri kümesindeki oluşumu Şekil 17’de betimlenmektedir.



Şekil 17. DBSCAN algoritmasının kümeleme modeli (URL-4, 2023).

Şekil 17’de görüldüğü üzere başlangıçta bütün noktalardan *Epsilon* yarıçapında çemberler geçirilmektedir. Daha sonra bir küme oluşturabilmesi için gereken minimum nokta sayısına (*MinPts*) göre noktaların etiketlenmesi gerçekleştirilir. Etiketleme işlemine öncelikle çekirdek noktaların tespiti ile başlanılır. Şekil üzerinde bulunan 6 adet kırmızı noktaya bakıldığında *Epsilon* yarı çapı içerisinde noktanın kendisi dahil olmak suretiyle en az 4 nokta mevcut olduğu için ilgili noktalar çekirdek nokta olarak etiketlenir. Yeşil noktalarda ise *Epsilon* yarı çapı içerisinde, noktanın kendisi dahil 4’ten daha az nokta bulunmakta ancak rastgele başka bir çekirdek noktaya erişim sağlayabildiği için sınır noktası olarak kabul edilmektedir. Mavi işaretli noktalar ise epsilon yarı çapı içerisinde sadece ilgili noktanın kendisi bulunduğu için çekirdek veya sınır nokta özelliği taşımamakla birlikte gürültü noktası olarak etiketlenir. DBSCAN algoritması ile etiketlemeler tamamlandıktan

sonra çekirdek ve sınır noktaları sağladıkları komşuluk ilişkisine göre yani erişilebilirliklerine göre farklı kümelere ayrılmaktadır. Gürültü noktaları ise aykırı değer olarak kendi başlarına bir küme olarak değerlendirilmektedir. Şekil 17’de gösterilen şemada N noktası gürültü noktası olarak bir küme belirtirken geriye kalan 6 çekirdek nokta ve 2 sınır noktası birbirlerine erişim sağladıkları için bu noktalar (8 adet) tek bir küme olarak belirlenmektedir.

DBSCAN yoğunluk tabanlı parametrik olmayan bir kümeleme tekniği olduğu için mesafeye dayalı komşuluk ilişkilerine göre nokta bulutlarını kümeleyebilmektedir. Algoritmada yer alan *Minpts* ve *Epsilon* parametreleri komşuluk ilişkisini doğrudan etkileyeceği için bu değerlerin seçiminde dikkat edilmesi gerekmektedir.

1.5.9. Bézier Eğrileri

Bézier eğrileri, animasyon, demiryolu güzergahı, otoyol tasarımı, çevre tasarımı, CAD sistemi, modelleme ve bilim, iletişim ve teknoloji alanlarını kapsayan birçok mühendislik uygulamalarında serbest biçimli eğri ve yüzeyleri oluşturmak için etkin bir şekilde kullanılan güçlü bir fonksiyondur (Maqsood vd., 2021). Adını Fransız mühendis Pierre Bézier’den alan bézier eğrileri genellikle matematiksel temsili bilinmeyen şekillerin 2B veya 3B olarak modellenmesini sağlayarak gerçek sınıra veya yüzeye en iyi şekilde uyan eğrileri oluşturmaktadır. Matematik Ansiklopedisi (Hazewinkel, 1997) kitabına göre bézier eğrileri ilk olarak 1960’lı yıllarda marka bir aracın kaportasını ve gövdesini 3B modelleyebilmek için kullanılmıştır (URL-5, 2023). Bézier eğrilerinin temeli 1912 yılında oluşturulan Bernstein polinomlarına dayanmaktadır.

Bézier eğrileri başlangıç, bitiş ve ara noktalar (kontrol noktaları) olmak üzere en az 3 nokta ile tanımlanır. Bu eğriler ilk ve son noktalar arasındaki kontrol noktalarıyla enterpolasyon yapılarak belirlendiğinden dolayı bézier eğrisinin şekli, kontrol noktaların hareketiyle değişkenlik gösterebilir (Hussain vd., 2014). Bézier eğrilerini esas alan eğrilerin temelinde Bernstein polinomu yer almaktadır. Bu polinomun katsayıları, Bézier eğrilerinin kontrol noktalarını oluşturmaktadır. Bernstein polinomu (13), (14), (15), (16) ve (17) numaralı eşitliklerde gösterildiği gibi hesaplanmaktadır.

$$b_0^n(t) = (1 - t)^n(1 - \lambda_1 t) \quad (13)$$


$$b_i^n(t) = t^i(1-t)^{n-i} \left(\binom{n}{i} + \lambda_i - \lambda_i t - \lambda_{i+1} t \right), \quad i = 1, \dots, \left\lfloor \frac{n}{2} \right\rfloor - 1 \quad (14)$$

$$b_{\left\lfloor \frac{n}{2} \right\rfloor}^n(t) = t^{\left\lfloor \frac{n}{2} \right\rfloor} (1-t)^{n-\left\lfloor \frac{n}{2} \right\rfloor} \left(\binom{n}{\left\lfloor \frac{n}{2} \right\rfloor} + \lambda_{\left\lfloor \frac{n}{2} \right\rfloor} - \lambda_{\left\lfloor \frac{n}{2} \right\rfloor} t + \lambda_{\left\lfloor \frac{n}{2} \right\rfloor+1} t \right) \quad (15)$$

$$b_i^n(t) = t^i(1-t)^{n-i} \left(\binom{n}{i} + \lambda_{\left\lfloor \frac{n}{2} \right\rfloor} - \lambda_{\left\lfloor \frac{n}{2} \right\rfloor} t + \lambda_{\left\lfloor \frac{n}{2} \right\rfloor+1} t \right), \quad i = \left\lfloor \frac{n}{2} \right\rfloor + 1, \dots, n-1 \quad (16)$$

$$b_n^n(t) = t^n(1 - \lambda_n + \lambda_n) \quad (17)$$

Denklemlerde yer alan n ifadesi ($n \geq 2, n \in \mathbb{N}$), Bernstein polinomunun derecesini, λ_i ($i=1, 2, \dots, n$) ise şekil parametresini temsil etmektedir. Bir eğri üzerinde sonsuz adet nokta bulunduğundan dolayı b zier eğrisinin  zidirilebilmesi i in ka  adet nokta ile eğri olu turulacađının belirlenmesi gerekir. Bernstein polinomunun derecesi (n) ile ba langı  ve bitiş noktası arasından ge irilecek eğrinin nokta sayısını belirlemek i in, $\lambda_i (\{\lambda_i\}_{i=1}^n)$ şekil parametresini polinomun derecesine g re ayarlayarak bu noktalardan ge ebilen en uygun eğrinin hesaplanması sađlanılır (Han vd., 2008).  zet olarak bernstein polinomunun derecesine g re ba langı  ve bitiş noktası arasında ge irilecek eğrinin nokta sayısı tanımlanmaktadır ( ekil 18).




 ekil 18. B zier eğrilerinin şematik g sterimi

Şekil 18’de görüldüğü üzere bernstein polinomunun derecesi 3 olarak seçildiği için başlangıç ve bitiş noktaları arasında 3 adet noktadan geçirilecek olan en uygun eğri tespit edilmeye çalışılmaktadır. Geçirilen eğriler polinomun derecesine bağlı olarak λ_i şekil parametresi $\lambda_1, \lambda_2, \lambda_3$ değerleri ile sınırlandırılmaktadır. Şekil 18’deki geçirilen eğrilerde λ_1 ve λ_2 değerleri 0, λ_3 değerleri ise sırasıyla -1 (kesik kırmızı renkli eğri), -2 (kesik mavi renkli eğri) ve 1 (kesikli yeşil renkli eğri) olarak değerlendirilmektedir. Seçilen farklı λ_i şekil parametresine göre ara noktalardan enterpolasyonla geçirilen bu eğriler değişkenlik göstermektedir. Sonuç olarak başlangıç, bitiş ve ara noktaları belli olan eğriler oluşturulmaktadır. İlave olarak Bézier eğrileri, geçirilecek en uygun eğrinin derecesine otomatik karar verebilme yeteneğine sahip hızlı ve pratik bir eğri geçirme yaklaşımı olarak görülmektedir.

1.5.10. Geleneksel Ağaç Taç Segmentasyon Yöntemleri

Ağaç taç segmentasyonu için kullanılan en yaygın model olan Kanopi Yükseklik Modeli (KYM), Sayısal Yüzey Modelinden Sayısal Arazi Modelinin çıkarılması sonucu ağaç taçlarının yüksekliklerini elde etmektedir (Şekil 19). KYM topoğrafya üzerinde bulunan ağaçların gerçek yüksekliğinden arazi yüksekliğini çıkarmasıyla ağaçlık alanda zemin taç yapısını ortaya çıkarmaktadır (URL-6, 2023). Kanopi yükseklik modellerinin diğer bir ifadeyle ağaçların zemin topoğrafyası üzerindeki yüksekliklerinin raster temsilleri olarak tanımlanmaktadır. KYM, düşük yükseklik değerleri veya bir ağaç tepesindeki eksik veriler (komisyon hatası olabilecek durumlar) dışında kanopinin (taç yapısının) en üst kısmını tanımlamalıdır (Sassu vd., 2021). KYM’nin en önemli parametresi grid boyutudur. Eğer grid boyutu yüksek seçilirse daha büyük bir arama penceresi oluşacağından dolayı kanopi yüksekliğindeki varyasyon/çeşitlilik azalacak ve tepe ve çukur noktalarının ayırt edilmesi zorlaşacaktır (Chen vd., 2006).




Şekil 19. KYM oluşturulması (Meddens vd., 2018).

Ağaç taçların belirlenmesi için öncelikle gölgelik yüksekliğine bağlı olarak yumuşatma derecesi seçimi ile KYM geliştirildikten sonra model üzerinde yerel maksimumlar ile ağaç taç tepelerinin tespiti gerçekleştirilmektedir (Pitkänen vd., 2004). İkinci yöntem olarak KYM’de bitişik ağaç kümelerinin birbirinden ayrılması için yerel maksimumlar ile birlikte taç merkezi alanı içindeki eğime dayalı yöntemlerde geliştirilmiştir (Pitkänen vd., 2004). Ayrıca KYM üzerine yapılacak olan Gauss filtresi segmentasyon yöntemini güçlendirmektedir (Chen vd., 2006).

Ağaç taçlarını elde etmek için KYM üzerine MSS (Mean Shift Segmentation), MPBS (Morphological Profiles Based Segmentation), MRS, SRGS (Seeded Region Growing Segmentation) ve WS (Watershed Segmentation) teknikleri kullanılmaktadır (Yılmaz, 2017).

Ağaç taç segmentasyonu için en yaygın yöntem İşaretleyici Kontrollü Su Havza Bölütlemesi (MCWS) konseptine dayanan dökme su simülasyon algoritmasıdır. MCWS yöntemi, ters ağaç taç profilleri ile temsil edilen çukurlara su dökme ve her çukura akan suyun ağaç yüksekliklerine göre kontrol edilmesi işlemine dayanmaktadır (Şekil 20).



Şekil 20. Ağaç taç segmentasyonu için dijital yüzey modelinde su genişlemesi (Yun vd., 2021).


MCWS algoritması ağaçlık alan içerisinde ters Sayısal Yüzey Modeli (SYM/DSM) belirlenecek olan dikey yöndeki yükseklik aralığına ($H_{aralık}$) göre su doldurma stratejisi ile çalışmaktadır (Yun vd., 2021). Su doldurma stratejisi gereği öncelikle ağaç tepe noktalarının olduğu bölge su ile dolduktan sonra su seviyesi arttıkça üst katmanlara doğru bir dolum gözlemlenmektedir (Yun vd., 2021).

Şekil 20a ters çevrilmiş ağaç taç profiline dökülen su kavramını temsil eder ve su dökümü ilk olarak ağaç taç tepelerinden başlayarak dolmaktadır. Şekil 20b su genişlemesinin belirlenen $H_{aralık}$ mesafesine göre düşey yönde yukarıdan aşağıya doğru her aralıkta etkilediği bölmeleri göstermektedir. Şekil 20c'de ise Havza bölütleme (Watershed segmentation) ile ağaç taç sınırları elde edilmektedir.

MCWS algoritması ile LiDAR verilerinden ağaç taç segmentasyonunu gerçekleştirebilmek için öncelikle Kanopi Yükseklik Modeline Gauss filtresi uygulanarak ağaç tepeleri algılanır. Daha sonra KYM içindeki hücreler yükseklik aralığına ve komşu hücre bağlantısına göre ağaç tepe bağlantılarının kurulabilmesi için parçalara bölünür. Son

olarak ağaç taç segmentasyonunu gerçekleştirebilmek için belirlenecek yükseklik aralığına göre havza bölütleme (MCWS) algoritması uygulanır (Yun vd., 2021).

Ağaç taç segmentasyonu için yaygın olarak kullanılan diğer bir yöntem ise DBSCAN ve Mean Shift (Ortalama Kaydırma) algoritmasının birlikte kullanılmasıyla yapılmaktadır. DBSCAN ile segmentasyon gerçekleştirildiğinde yoğun kapalılık düzeyindeki ormanlık alanlarda sorunlar yaşanmaktadır. Ortalama Kaydırma kümelemesi Şekil 21’de gösterilmektedir.



Şekil 21. Ortalama kaydırma algoritması; a) ortofoto üzerinde, b) grid yapıda gösterim (Hu vd., 2017).

Ortalama Kaydırma algoritması, veri集中的 noktalarından belirli bir yarıçap içindeki noktaların dağılım moduna doğru kaydırma işlemini gerçekleştirmektedir. Ortalama Kaydırma algoritması yoğunluğa dayalı bir yöntem olduğu için noktalar yoğunluk fonksiyonunun yerel bir maksimumuna yakınsayana kadar yinelemeli bir şekilde kayma/kaydırma işlemi ile kümeleme gerçekleştirir (URL-7, 2023).

1.5.11. Doğruluk Değerlendirmesi

1.5.11.1. Piksel Bazlı Doğruluk Analizi


Doğruluk analizi, üretilen sonuç çıktı ile referans (gerçek) verinin karşılaştırılması üzerine elde edilen başarı düzeyi olarak tanımlanmaktadır. Literatürde geliştirilen modelin

veya yapılan analiz işlemlerinin ne derecede doğru yapılabildiğinin test edilebilmesi için en yaygın kullanılan yöntem piksel bazlı doğruluk analizi yöntemidir. Piksel bazlı yöntemde, elde edilen çıktı ve referans verilerin raster formatlı yapıya dönüştürülmesinden sonra karşılıklı piksellerin bire bir karşılaştırılması ile dört temel metriğin (DP, DN, YP, YN) elde edilmesi gerekmektedir. Ayrıca bu aşamada sonuç ve referans verilerin raster görüntüsünün satır ve sütun piksel sayılarının birbirine eşit olmasına dikkat edilmelidir. Doğruluk analizi için Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) metriklerine ait piksel sayıları elde edilmektedir. Genel olarak yapılacak olan değerlendirme ile sonuç (tahmin/bulunan) verisindeki her bir piksel için bu dört temel metriğin etiketlenmesi gerçekleştirilerek bu metriklerin kaç adet piksel ile temsil edildiği belirlenir.

Doğruluk analizi için sonuç (tahmin) ve referans verilere ait raster görüntüler binary (ikili) formatlı bir yapıya sahip olmakla beraber doğruluğu test edilecek olan nesne siyah, arka plan ise beyaz renkli piksel ile temsil edilmektedir (Şekil 22).

Doğru Pozitif (DP), referans (gerçek) görüntü üzerinde nesneye ait olan pikselin (siyah renkli) tahmin görüntüsü üzerinde de nesneye karşılık geldiği belirlenen piksellerin etiketlerini gösterir. Doğru Negatif (DN), referans görüntü üzerinde nesne dışındaki arka plana ait olan pikselin (beyaz renkli) tahmin görüntüsü üzerinde de nesne dışındaki arka plan bölgesine karşılık geldiği belirlenen piksellerin etiketlerini tanımlamaktadır. Yanlış Pozitif (YP), referans veride nesne dışı bölgeye ait olan pikselin, tahmin görüntüsü üzerinde nesneye karşılık geldiği belirlenen piksellerin etiketlerini temsil etmektedir. Yanlış Negatif (YN) ise referans görüntüde nesneye ait olan bir pikselin tahmin görüntüsünde nesne dışı bölgeye karşılık geldiği belirlenen piksellerin etiketlerini göstermektedir.

Raster görüntü üzerinden dört temel metriğin etiketlenmesi Şekil 22’de ayrıntılı bir şekilde gösterilmektedir. Örnek olarak sekiz satır, sekiz sütundan oluşan tahmin ve referans verinin binary görüntüsü kullanılmaktadır. Piksel bazlı doğruluk analizinde her bir piksel yalnızca tek bir metrik ile etiketlenir ve tüm metriklerin toplamı görüntü boyutuna (toplam piksel sayısına) eşit olmak zorundadır.



Şekil 22. Piksel bazlı metriklerin belirlenmesi

Şekil 22’de görüldüğü üzere 8×8 boyutlarındaki referans ve tahmini görüntü matrisleri eşit boyutta olmakla birlikte referans veride her bir piksel tahmin verisinde karşılık gelen piksel ile kıyaslanarak dört temel metriğin etiketlenme işlemi gerçekleştirilmektedir. Görsel üzerinde DP değerleri ele alınan nesnenin (siyah piksel) gerçek veriye göre doğru tahmin edildiği pikselleri özetlemektedir. DN, nesne dışı (beyaz piksel) bölgenin doğru tahmin edildiği bölgeyi göstermektedir. YP, gerçek veride nesne olarak bulunmayan fakat tahmin görüntüsünde nesne olarak tanımlanan pikselleri temsil eder. YN ise gerçek veri üzerinde var olan nesne piksellerinin tahmin görüntüsü üzerinde bulunmama durumunu açıklamaktadır. Şekilde gösterilen örnek nesne için 12 adet DP, 2 adet YN, 1 adet YP ve 49 adet DN metriği hesaplanmaktadır.

Dört temel metriğin etiketlenmesinin ardından literatürde yaygın olarak kullanılan doğruluk değerlendirme ölçütlerine ilgili metriklerin piksel adetleri yazılarak doğruluk oranları hesaplanmaktadır. Piksel bazlı doğruluk analizi için en yaygın olarak kullanılan değerlendirme ölçütleri tamlık (Cp-Completeness), doğruluk (Cr-Correctness), kalite (Q-Quality), birleşim üzerinden kesişim (IoU-Intersection over Union), F1-skor ve genel doğruluk (OA-Overall Accuracy) metrikleridir. Literatürde kalite metriği IoU metriği ile aynı denkleme sahip olduğundan dolayı tekrarı önlemek adına yalnızca kalite metriği paylaşılmaktadır. Değerlendirme ölçütlerinin denklemleri (18), (19), (20), (21) ve (22) numaralı eşitliklerde ayrıntılı bir şekilde verilmektedir. Cp, referans görüntüde nesne olarak bulunan piksellerin kaç tanesinin doğru pozitif olarak tahmin edildiğinin oranını göstermektedir. Cr, tahmin görüntüsü üzerinde nesne olarak bulunan piksellerin kaç tanesinin doğru pozitif olarak tahmin edildiğinin oranını vermektedir. Q, referans ve tahmini raster görüntüsünün üst üste bindirilmesi sonucu nesne olarak tanımlanan piksellerin kaç tanesinin doğru pozitif olarak nitelendirildiğinin oranını belirtir. OA, tüm pikseller içerisinde

kaç tanesinin doğru bir şekilde nesne veya nesne dışı piksel olarak etiketlendiğinin oranını hesaplamaktadır. F1 denklemi ise tamlik ve doğruluk metriklerinin harmonik ortalaması olarak hesaplanmaktadır.

$$C_p = \frac{DP}{DP + YN} \quad (18)$$

$$C_r = \frac{DP}{DP + YP} \quad (19)$$

$$Q = \frac{DP}{DP + YN + YP} \quad (20)$$

$$OA = \frac{DP + DN}{DP + YN + YP + DN} \quad (21)$$

$$F - \text{skor (F1)} = \frac{2 \times C_p \times C_r}{C_p + C_r} \quad (22)$$

Şekil 22’de örnek olarak verilen nesne için belirlenen piksel adetleri ilgili denklemlere uygulandığında C_p , C_r , Q , OA ve $F1$ ölçütleri için doğruluk oranları sırasıyla %85,7, %92,3, %80, %95,3 ve %88,8 olarak hesaplanmaktadır.

1.5.11.2. Nesne Tabanlı Doğruluk Analizi


Literatürde yapılan bir diğer doğruluk analizi yöntemi ise nesne/obje tabanlı olarak gerçekleştirilmektedir. Piksel tabanlı analizde referans ve tahmini görüntülerin bire bir pikselleri karşılaştırılarak bir doğruluk oranı hesaplanırken nesne tabanlı doğruluk analizinde ise objelerin direkt olarak karşılaştırılması ile analiz yapılmaktadır. Nesne tabanlı doğruluk analizinde Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Negatif (YN) ve Yanlış Pozitif (YP) metrikleri obje bazında değerlendirilir ve aynı piksel bazlı doğruluk analizindeki gibi değerlendirme ölçütlerine ilgili metriklerin obje sayıları girilerek doğruluk oranları hesaplanır. Örneğin referansta bulunan bir ağaç, sonuç çıktıda ağaç olarak tahmin ediliyorsa nesne tabanlı doğruluk analizine göre ilgili obje DP olarak etiketlenmektedir. Eğer

rastgele bir ağaç objesinin türü kızılcım olarak belirlendiyse ve bu obje gerçekte sarıçam olarak referansa etiketlendiyse bu nesne YN metriğine ait olmaktadır. Eğer gerçekte ilgili konumda bulunmayan bir ağaç, sonuç çıktıda sarıçam olarak tahmin edilirse ilgili obje YP olarak işaretlenmektedir. Son olarak eğer gerçekte ağaç bulunmayan bir noktada, sonuç veride de ağaç yok olarak tahmin edilirse ilgili nokta (obje) DN olarak sayılmaktadır. İlgili metriklerin sayıları piksel bazlı analizde bulunan (Cp, Cr, Q, OA ve F1) değerlendirme ölçütlerindeki denklemlerde girdi olarak kullanılır ve doğruluk oranları hesaplanır.

Piksel bazlı doğruluk analizinde mevcut 4 metriğin (DP, DN, FN ve FP) toplamı görüntüdeki toplam piksel sayısını vermektedir. Ancak obje bazlı doğruluk değerlendirmesinde piksellerin birebir kıyaslanması yerine objelerin karşılaştırılması yapıldığından ilgili metriklerin sayıları toplamı, referans obje sayısını geçebilmektedir. Her iki doğruluk analizinde de insan müdahalesi gerektiren bir işlem sonucu elde edilen sonuç verisi olacağı için doğruluk oranlarının %100 olması mümkün olmamaktadır.

2. YAPILAN ÇALIŞMALAR

Bu tez çalışmasında, LiDAR ve fotogrametrik nokta bulutlarından bireysel ağaç taç segmentasyonunu gerçekleştirebilmek için Bézier eğrileri ile geliştirilmiş lokal maksimum yaklaşımı önerilmiştir. Segmentasyon aşamasından sonra bireysel ağaçlar üzerinden orman envanter bilgisi için gerekli olan ağaç metrikleri tahmin edilmiştir. Tez çalışması kapsamında, önerilen yöntemin genel iş akışı Şekil 23'te detaylı bir şekilde sunulmaktadır.



Şekil 23. Ağaç taç segmentasyonu ve metrik tahmini genel iş akışı

Gerçekleştirilen çalışma mevcut uygulama, geliştirilmiş segmentasyon yöntemi, ikinci düzenleme ve doğruluk analizi ve ağaç metrik tahmini olmak üzere dört temel başlıktan oluşmaktadır (Şekil 23). Mevcut uygulama aşamasında, girdi olarak kullanılan nokta bulutlarından ağaç tepelerini tespit etmek için Kanopi Yükseklik Modeli (KYM) kullanılır ve segmentasyon için Watershed Segmentation (Havza bölütleme) algoritmasıyla birlikte bireysel ağaç taçlarının segmentasyonu gerçekleştirilir. Geliştirilmiş segmentasyon yöntemi aşamasında ise mevcut uygulama sonucu oluşan ağaç kümelerinin düşey yönde analizini gerçekleştirebilmek için Octree (Sekiz dal Veri Organizasyonu) uygulanmıştır. Octree sonucu dört basamağa ayrılan ağaç noktalarından ağaç taç yapısını en iyi temsil eden 1. basamaktaki noktalar iki farklı düzlem/ağaç profili üzerinden (XZ ve YZ) ele alınarak gürültü içerikli kısımları ise DBSCAN kümeleme algoritması ile giderilmiştir. Farklı ağaç profilleri üzerinden Bézier eğrileri geçirilerek Havza Bölütleme algoritmasının bitişik ağaç kümelerinde hatalı segmentasyon yapılmasına yeni bir çözüm olanağı sunulmuştur. İkinci düzenleme aşamasında, önerilen segmentasyon yaklaşımı ile elde edilen ağaç kümelerinin hata içerebileceği ihtimaline karşın ağaç taç alanlarını ele alan istatistiksel karşılaştırma yöntemi geliştirilmiştir. Hatalı ağaç kümelerinin algılanabilmesi için 5'li komşuluk modeli kullanılmıştır. İstatistiksel koşullar yardımıyla tespit edilen yanlış ağaç kümeleri yeniden segmente edildikten sonra nihai ağaç kümeleri elde edilmektedir. Son aşamada ise önerilen yaklaşımın bireysel ağaç taç segmentasyonundaki doğruluğu için geliştirilen ağaç eşleştirme modeli yardımıyla nesne tabanlı bir doğruluk analizi gerçekleştirilmiştir. Segmentasyon aşaması sonlandıktan sonra elde edilen bireysel ağaç kümelerinin metrikleri, doğrudan veya allometrik yöntemler vasıtasıyla dolaylı olarak tahmin edilmesi sağlanmıştır. Metrik tahmini için değerlendirmeler regresyon analizi ile kontrol edilmektedir.

2.1. Çalışma Alanları

Tez çalışması kapsamında farklı kapalılık düzeyine sahip 3 adet ağaçlık alan ele alınmıştır. Birinci çalışma alanı olarak Antalya İli, Akdeniz Üniversitesi, Mühendislik Fakültesi kuzey batı bölümünde yer alan mevcut ağaçlık alan (36°53'50,97" Kuzey enlemi 30°38'52,02" Doğu boylamı) kullanılmıştır (Şekil 24). Çalışma bölgesinin denizden yüksekliği ortalama 30 m'dir. Test bölgesinde Akdeniz iklim koşulları etkin olmakla birlikte yazları sıcak ve kurak, kışları ılık ve yağışlı geçmektedir. Yaz mevsiminde ortalama hava sıcaklığı 28-36 °C, kış mevsiminde ise 10-20 °C arasında değişkenlik gösterir ve yıllık nem

oranı yaklaşık %64 seviyelerindedir. Antalya ili 18,7 °C yıllık sıcaklık ortalaması ile birlikte turizm açısından önemli bir şehirdir. Ayrıca kıyı bölgelerinden uzaklaştıkça birçok ağaç türünün varlığından söz edilebilmektedir.




Şekil 24. Çalışma alanı-1 (Akdeniz Üniversitesi)


İkinci çalışma alanı olarak Trabzon İl'i, Maçka İlçesi'nde yer alan Pilav Dağı'ndaki iki adet denek alanı seçilmiştir. Çalışma bölgeleri 40°48'27,07" Kuzey enlemi ile 39°38'22,47" Doğu boylamı arasında yer almakla birlikte denizden ortalama 1100 m yükseklikte konumlanmaktadır (Şekil 25). Trabzon nemli bir iklime sahip olduğu için her mevsim yağış görülmekte ve genel olarak yazları sıcak ve kışları ılık geçmektedir. Yaz aylarında ortalama hava sıcaklığı 32 °C, kışın ise en soğuk günlerinde ortalama -5 °C ile -8 °C arasında değişkenlik göstermektedir. Yıllık ortalama yağış miktarı 800-850 kg/m²'dir. İl topraklarının %45'i orman alanları ile çevrelenmektedir. Bölgede geniş yapraklı ve iğne yapraklı birçok türde ağaç bulunmakla birlikte zengin bir ekolojik yapıya sahiptir.

Üçüncü çalışma alanı olarak Cenevre/İsviçre karışık orman arazi örtüsüne sahip ağaçlık alan seçilmiştir (Şekil 26). Çalışma bölgesi 46°17'23,09" Kuzey enlemleri ile 6° 8'15,53" Doğu boylamları arasında yer almaktadır. İsviçre'nin Zürih şehrinden sonra en yüksek nüfuslu ikinci şehri olarak bilinmektedir. Cenevre şehrinin rakımı deniz seviyesinden 373,6 m yüksektir. İklim olarak karasal iklime bağlı olduğu için kış mevsiminde sıcaklık 0 °C ile -10 °C arasında değişiklik göstermektedir. Yaz mevsiminde sıcak ve nem etkili

olmakla birlikte yağın yağmurun şiddeti zaman zaman şiddetlenmektedir. Bölgenin yıllık ortalama sıcaklığı 10 °C ve yıllık ortalama yağış miktarı ise 1468 mm'dir.



Şekil 25. Çalışma alanı-2 (Pilav Dağı, Maçka)



Şekil 26. Çalışma alanı-3 (Cenevre/İsviçre)

2.2. Alan Verileri/ Arazi Ölçüleri

Tez kapsamında ele alınan Akdeniz Üniversitesi içinde bulunan ağaçlık alan, Fıstık çamı (*Pinus pinea*) ağaçları ile kaplı 3.348,25 m²'lik alanda çevrelenmektedir. Arazinin eğimi ise yaklaşık %5,45 olarak hesaplanmaktadır. Alan içerisinde yatay olarak yaklaşık %70'den fazla ağaç taç yapısı bulunduğu için kapalılık düzeyi 3 olarak belirlenmiştir. Seçilen test bölgesindeki ağaçlar hem bitişik hem de seyrek dağılımda olup önerilen yaklaşımın bitişik ağaçlar üzerinde de çalışabilmesi için iyi bir örnek teşkil etmektedir. Kapalılık açısından değerlendirildiğinde ise yoğun sıklıkta bir çalışma alanı olarak değerlendirilebilmektedir. Arazi üzerinde yersel olarak herhangi bir çalışma yapılmamıştır. Ağaç merkezlerinin konumları ise ortofoto üzerinden manuel sağlanmaktadır. Ağaç metriklerinin tahmini aşamasında, referans veri eksikliğinden dolayı doğrulama imkânı oluşmamaktadır.

Seçilen ikinci test bölgesi olan Pilav Dağı (Maçka) alanı Ladin (*Picea orientalis*) ağaç türü ile kaplı olmakla birlikte birinci test bölgesinden daha sık ağaç yapısına sahiptir. Çalışma bölgesi içerisinde iki adet alt çalışma alanı, denek alanı olarak seçilmiştir. Ormanlık alanlarda ağaçların çok yoğun ve sık bir yapıda olmasından dolayı yersel olarak tüm ağaçlar üzerinde ölçüm yapılarak referans verilerin tek tek toplanması imkansızdır. Bu yüzden çalışmanın kalitesini belirlemek için orman disiplini gereği arazi üzerinde yaklaşık 20×20 m boyutlarında kapalılık düzeyi 3 olan iki adet denek alanı seçilmiştir. Denek alanlarının eğimleri sırasıyla %23,36 ve %18,33 olarak hesaplanmaktadır. Bölge içerisinde özellikle arazi eğimlerinin çeşitlilik göstermesi, yapılacak bireysel ağaç segmentasyon uygulaması ve metrik tahmini için etkili bir unsur olup olmadığı test edilebilecektir. Alan içerisinde harita mühendisleri tarafından klasik/yersel ölçüm yöntemleri ile ağaç merkez konumları ölçülmüştür. Orman envanter bilgisi için gerekli olan ağaç metrikleri ise (göğüs yüksekliğindeki çap, ağaç boyu, taç genişliği ve taç taban yüksekliği) orman mühendisleri tarafından çalışma sahası üzerinden doğrudan ölçülmüştür.

Üçüncü test alanı olan Cenevre/İsviçre, 9.262,99 m²'lik bir alanda Meşe (*Quercus alba- L.*) türündeki ağaçlar ile çevrelenmektedir. Çalışma bölgesinin eğimi %2,73 olarak hesaplanmıştır. İlk iki çalışma alanında olduğu gibi bitişik ağaç kümelerinin yoğun olarak bulunabileceği bir alan seçilmiştir. Yurtdışına ait bir çalışma alanı olduğu için ağaç metrik çıkarımı ve merkez konum ölçümleri için herhangi bir ölçüm gerçekleştirilememiştir. Doğrulama verisi ve ortofoto olmamasından dolayı bu çalışma alanı, önerilen yaklaşımın

çok geniş ve yoğun bir ağaçlık alanda bitişik ağaç kümelerini algılayabilecek seviyede olup olmadığı test etmek için özellikle ele alınmaktadır.

2.3. Uzaktan Algılama Verileri

Bireysel ağaç taç segmentasyonu ve ağaç metrik tahminleri için veri seti olarak fotogrametrik ve LiDAR nokta bulutları kullanılmıştır. Birinci çalışma alanında hem fotogrametrik hem de LiDAR nokta bulutları üzerinden test gerçekleştirilmiştir. 24 Aralık 2021 tarihinde DJI M300 RTK ile yaklaşık 80 m irtifadan test bölgesinin alımı yapılmıştır. LiDAR nokta bulutunu oluşturmak için Zenmuse L1 LiDAR kamerası; fotogrametrik nokta bulutu için Zenmuse P1 kamerası kullanılmıştır. Kamera bilgileri detaylı bir şekilde Tablo 1’de sunulmaktadır. Zenmuse L1 LiDAR kamerası RGB haritalama kamerasına sahip olduğu için doğru renkte nokta bulutu üretebilmektedir. Seçilen test alanı içinde LiDAR nokta bulutunda 2.497.425 nokta; fotogrametrik nokta bulutunda ise 1.193.240 nokta yer almaktadır. Veri setlerinin ortalama yoğunlukları ise LiDAR nokta bulutu için 745,89 nokta/m²; fotogrametrik nokta bulutu için 356,38 nokta/m² olarak hesaplanmıştır.

Tablo 1. Zenmuse L1 ve P1 kamera özellikleri

Zenmuse L1		Zenmuse P1	
Algılama aralığı	450 nm	Piksel boyutu	4.4 µm
Etkin nokta hızı (tek dönüş)	240.000 pts/sn	Mutlak doğruluk (yatay)	3 cm
Çoklu dönüş	480.000 pts/sn	Mutlak doğruluk (dikey)	5 cm
Yatay hassasiyet	10 cm (irtifa: 50 m)	Sensör boyutu	35,9 × 24 mm
Dikey hassasiyet	5 cm (irtifa: 50 m)	Çözünürlük	45 MP
FOV (Görüş alanı)	95 °	Minimum fotoğraf aralığı	0,7 saniye
IMU Güncelleme Sıklığı	200 Hz	Lens boyutu	35 mm
Açısal Hız Ölçer Aralığı	± 2000 dps		
RGB Haritalama Kamerası			
Sensör boyutu	1 inch		
Çözünürlük	20 MP		
Odak uzaklığı	8,8 mm		

İkinci bölge için kullanılan uzaktan algılama verisi yalnızca LiDAR nokta bulutunu içermektedir. Maçka İlçesi’ndeki test bölgesinin 16 Ağustos 2022 tarihinde DJI M300 RTK ile araziden yaklaşık 100 m irtifadan alımı gerçekleştirilmiştir. LiDAR nokta bulutunu üretmek için Zenmuse L1 LiDAR kamerası kullanılmıştır. Üretilen nokta bulutu birinci ve ikinci alt çalışma bölgesi olarak sırasıyla 447.785 ve 601.622 nokta ile çalışma alanını temsil

etmektedir. Veri setlerinin nokta yoğunluğu ise sırasıyla 902,774 ve 1.504,05 nokta/m² olarak hesaplanmaktadır.

Üçüncü veri setinde ise Cenevre/İsviçre ormanlık alana ait LiDAR nokta bulutu kullanılmıştır (<https://mparkan.github.io/Digital-Forestry-Toolbox/>). Çalışma bölgesinin alımı 19-20 Şubat 2017 tarihleri arasında Riegl LMS-Q1560 sensörü tarafından 430 m irtifadan yapılmıştır. Test bölgesi içerisinde 559.250 nokta yer almakta ve nokta yoğunluğu 60,374 nokta/m² olarak hesaplanmaktadır.

2.3.1. Nokta Bulutu Verileri

Tez çalışmasında kullanılan fotogrametrik nokta bulutu ve LiDAR nokta bulutları DJI Terra programında *.las veya *.laz formatında üretilmiştir. Ancak üçüncü çalışma alanına ait LiDAR nokta bulutu verisi açık kaynaktan alındığı için ek bilgi mevcut değildir. Matrice 300 RTK ile üretilen nokta bulutları RGB kamera desteği sağlamasından dolayı noktaların gerçek renkleri ile temsil edilmesi sağlanılmıştır. Çalışma alanlarında kullanılan nokta bulutuna ait örnek görsel Şekil 27’de sunulmaktadır.



(a)




(b)

Şekil 27. Ağaçlık alan LiDAR nokta bulutu (Akdeniz Üniversitesi): a) 2B, b)3B görüntüsü

2.4. Ön Hazırlık Aşaması

Önerilen yaklaşım için girdi olarak kullanılan nokta bulutları öncelikle *.laz veya *.las formatlı olarak MATLAB yazılımındaki mevcut uygulamada kullanıldı. Tez kapsamının temel amaçlarından biri olan bireysel ağaç taç segmentasyonu için öncelikle ham nokta bulutu üzerinden zemin ve zemin dışı noktaların filtrelenmesi gerekmektedir. Özellikle zemin noktalarının ham nokta bulutundan ayrılmasıyla beraber ağacın fenotip özelliklerine ait bilgilerin ele alınması sağlanılacaktır. Nokta bulutlarında herhangi bir detayı çıkarmak için geliştirilen yöntemlerde ilk olarak gürültülü veya istenmeyen noktaların veri setinden temizlenmesi istenir (Chen vd., 2021). Çünkü gürültülü veya istenmeyen noktalar, önerilen matematiksel modelin çalışmasını engelleyebilmektedir (Bahadır vd., 2022). Çalışma kapsamında Filtreleme operasyonu için Simple Morphological Filter (SMRF) algoritması kullanılarak zemin üstü noktalar elde edilmiştir (Şekil 28). Filtreleme ile birlikte ağaç noktaları, zemin noktalarından arındırılmış olacaktır.



Şekil 28. Filtreleme işlemi: a) Maçka veriseti, b) Akdeniz Üniversitesi


2.5. Orman Metriklerinin Çıkarımı

Nokta bulutları ile model geliştirilirken arazinin/zeminin bitki örtüsü üzerindeki etkisini ortadan kaldırmak için yükseklik normalleştirilmesine ihtiyaç duyulmaktadır. Yükseklik normalleştirilmesi ile birlikte veri setinin en düşük kotlu noktası 0 m yükseklikten başlayarak en yüksek kotlu noktasına kadar yükseklik değerleri yeniden oluşturulmaktadır. Normalleştirme işleminde enterpolasyonlu zemin yüksekliğinden orijinal zemin yüksekliği

çıkarılarak bütün noktaların yükseklikleri yeniden oluşturulmaktadır. Orman metrikleri ve ağaç özneliklerinin çıkarılması için girdi olarak normalleştirilmiş yükseklikler kullanılmıştır. Mevcut uygulama aşamasında Kanopi Örtüsü (Canopy Cover-CC), Boşluk fraksiyonu (Gap fraction-GF) ve yaprak alan indeksi (Leaf area index-LAI) orman metrikleri oluşturulmuştur (Şekil 29). Kanopi örtüsü, ağaç taçlarının dikey izdüşümüne göre ormanlık alanları belirleyen metriktir (Ma vd., 2017). Boşluk fraksiyonu, ışık huzmesinin ağaçlık alan ile karşılaşmadan kanopiden geçme olasılığıdır (Richardson vd., 2009). Yaprak alan indeksi, birim zemin alanı başına tek taraflı yaprak alanı miktarıdır (Richardson vd., 2009). Yaprak alan indeksi (LAI) denklem ile hesaplanmaktadır (Denklem 23). Orman metriklerinin çıkarılması için çalışma alanının gridlere bölünmesi gerekmektedir bu yüzden uygulamada grid boyutu 10 m olarak seçilmiştir.

$$LAI = - \frac{\cos(\alpha) \times \ln(GF)}{k} \quad (23)$$


Burada α ortalama tarama açısını, k ise yaprak açısı dağılımı ile yakından ilişkili olan sönme/yok olma katsayısını temsil etmektedir.



Şekil 29. Orman metriklerinin çıkarımı

2.6. Kanopi Yükseklik Modeli Oluşturma ve Ağaç Taç Segmentasyonu


Çalışma kapsamında, mevcut uygulama aşamasında ilk segmentasyon işlemi için Kanopi Yükseklik Modeli (KYM) oluşturulmuştur (Şekil 30). KYM, test alanları içerisinde bulunan ağaçlık alanların yüksekliklerine göre raster görüntüsünü temsil etmektedir. Kanopi yükseklik modeli ile kullanılan veri seti üzerinde ağaç tepe noktaları işaretlenerek ağaç merkezleri tespit edilmiştir. KYM raster görüntüsü üzerinden MATLAB yazılımındaki “*helperDetectTreeTops*” fonksiyonu ile değişken pencere boyutlarındaki yerel maksimum noktalar belirlenerek ağaç tepe noktaları elde edilmiştir. Uygulama da minimum ağaç yüksekliği 5 m olarak seçilmiştir ve yükseklik olarak normalize edilmiş yükseklikler kullanılmıştır.



Şekil 30. Ağaç tepelerini belirleme: a) LiDAR nokta bulutu, b) fotogrametrik nokta bulutu

Kanopi Yükseklik Modeli üzerinden tespit edilen ağaç tepe noktalarından sonra bireysel ağaç taç segmentasyonunu gerçekleştirmek için MCWS (İşaretleyici Kontrollü Havza Bölümlemesi) diğer bir ifadeyle havza bölütleme (Watershed Segmentation) algoritması kullanılmıştır. Bireysel ağaç taç segmentasyonu için MATLAB yazılımında mevcut olarak bulunan “*helperSegmentTrees*” fonksiyonu kullanılmıştır. Segmentasyon işlemini gerçekleştirmek için filtrelenmiş KYM ile havza bölütleme algoritması birlikte kullanılmıştır (Şekil 31). Mevcut uygulama aşamasının son adımı olan bireysel ağaç segmentasyonu, özellikle bitişik ağaç kümelerini tek bir ağaç kümesi olarak hatalı bir şekilde

tespit etmektedir. Bu yüzden segmentasyon sonucu elde edilen bireysel ağaç kümelerinin yeniden analiz edilmesine ihtiyaç duyulmaktadır.




Şekil 31. Mevcut uygulama sonucu bireysel ağaç segmentasyonu

2.7. Octree Yöntemi ile Düşey Yönde Ağaç Segmentasyonu

Mevcut uygulama içerisinde bulunan algoritma veya matematiksel modeller kapalılık seviyesi yüksek olan ağaçlık alanlarda tam anlamıyla doğru segmentasyon yapamamaktadır. Bu yüzden bundan sonraki bölümlerde bitişik ağaç kümelerinden bireysel ağaçların daha iyi bir şekilde çıkarılabilmesi için mevcut algoritmanın iyileştirilmesine yönelik detaylar anlatılacaktır. Tez kapsamında önerilen geliştirilmiş segmentasyon yöntemi için öncelikle Octree (Sekizdal Veri Organizasyonu) yöntemi kullanılarak mevcut ağaç kümeleri düşey yönde segmente edilmiştir. Çalışmada Octree yönteminin uygulanması esnasında derinlik (depth) sayısı 3 olarak seçildiği için oluşan vokseller 4 basamak ve her bir basamakta 16 eşit vokselin bulunduğu bir yapıda olmaktadır (Şekil 32a). MATLAB ortamında yapılan işlemler ile tüm ağaç kümeleri için otomatik bir şekilde vokselizasyon işlemi gerçekleştirilmiş ve her voksel veya basamak içinde kalan nokta bulutu verilerinin ayrı ayrı depolanması sağlanmıştır. Çalışma kapsamında, vokselizasyon sonucu oluşturulan basamaklara göre ağaç

kümeleri üzerinde analiz işlemi gerçekleştirilecektir. Önerilen yaklaşım ağaç profillerini inceleyerek fazladan ağaç tepesi oluşturabilecek hatalı ağaç kümelerini, otomatik bir şekilde tespit etmeyi amaçlamaktadır. Bu sebeple ağaç profilini yansıtacak en iyi basamağın birinci basamak olacağına karar verilerek iş yükünün hafiflemesi sağlanmıştır. İlerleyen aşamalarda yalnızca birinci basamaktaki noktalar üzerinden geliştirilen yaklaşım anlatılacaktır.



Şekil 32. Düşey yönde segmentasyon: a) basamak oluşumu, b) test alanına uygulanması


Test verisi içerisinde yer alan bütün ağaç kümeleri için ilk basamağın otomatik olarak segmente edilmesi Şekil 32b’de gösterilmektedir. Kırmızı renkli noktalar 1 numaralı basamağın içindeki noktaları; yeşil renkli noktalar ise 2, 3 ve 4 numaralı basamakların içindeki noktaları temsil etmektedir (Bahadır vd., 2022). Her basamak ve her voksel ayrı ayrı segmente edildiği için nokta bulutu üzerinden yapılan analiz işlemlerinde iş gücü hafiflemektedir.

2.8. Gürültü Özellikli Noktaların Temizlenmesi

Hatalı segmente edilen ağaç kümelerini tespit etmek için Octree yöntemi ile oluşturulan birinci basamak noktalarının profillerini incelemek için ağaç geometrisini temsil edemeyecek gürültü içerikli noktaların temizlenmesi gerekmektedir. Gürültülerin temizlenmesi için yoğunluk tabanlı parametrik olmayan DBSCAN kümeleme algoritması kullanılmıştır (Şekil 33). DBSCAN algoritması için gerekli olan *Epsilon* ve *Minpts* parametreleri sırasıyla 0,25 ve 5 olarak seçilmiştir. Ağaç profillerini incelemek için tek bir düzlemde doğru sonuca ulaşamayacağı için iki farklı düzlem (X-Z ve Y-Z) üzerinden eş


zamanlı işlemler gerçekleştirilmektedir (Şekil 34). Bu aşamadaki temel amaç herhangi bir düzlem üzerinde ağaç profilinin fazladan bir tepe geometrisi oluşturabileceği ihtimalini gözden geçirmektir. Bu yüzden bu aşamayla birlikte yapılan tüm işlemler iki farklı düzlem üzerinden irdelenecektir.

DBSCAN kümelemesi sonucu oluşan sınıflarda en yüksek nokta sayısına sahip küme, ağaç profilini yansıtabilecek en ideal küme olduğuna karar verilmiştir. Bundan dolayı kalan diğer kümeler gürültü içerikli olarak değerlendirilmiş ve nokta bulutlarından temizlenmesi sağlanılmıştır.



Şekil 33. İki farklı düzlem üzerinden gürültü içerikli noktaların tespiti


Şekil 33’de görüldüğü üzere Y-Z ve X-Z düzlemleri üzerinde sırasıyla yeşil ve mavi renkli sınıflar en fazla nokta sayısına sahip olduğu için profil analizinde ilgili kümeler ele alınacaktır.



Şekil 34. Farklı düzlemlerden ağaç profillerinin görünümü

Şekil 34’te görüldüğü üzere aynı iki ağacın farklı düzlemlerde analizi gerçekleştirildiğinde geometrik yapısından tek veya birden fazla ağaç oluşturulması gerektiği anlaşılmaktadır. Bu tür segmente edilen ağaçlarda iki farklı düzlem üzerinden analiz gerçekleştirilerek yeni oluşturabilecek ağaç kümelerinin tespit edilmesi amaçlanmaktadır. İlk şekil üzerindeki turuncu renkli sınır segmente edilecek ağacın iki adet ağaç olarak bölümlenmesi gerektiğini gösterirken, farklı perspektiften aynı bitişik ağaçlar, tek bir ağaç olarak temsil edilebilmektedir. İlave olarak yapılan işlemler de yalnızca birinci basamakta gerçekleştirilmektedir.

Çalışmada DBSCAN algoritması sonucu en yüksek nokta sayısına sahip olan kümeden MATLAB yazılımındaki “*boundary*” fonksiyonu ile sınır geçirilmiştir (Şekil 35). Ağaç profilini çizdirmek için kullanılan fonksiyon “*alphashape*” algoritmasına dayanmakla birlikte küçültme faktörü (shrink factor) parametresine bağlı olarak (0-1] aralığında sınır dağılımı değişkenlik göstermektedir. Küçültme faktörü 0’a eşit olduğunda maksimum alfa yarıçapı üretilir ve dışbükey bir gövde oluşur. Küçültme faktörü 1 olursa, maksimum küçültme oranı ile minimum alfa yarıçapı üretilir ve içbükey gövdeye benzeyen sınır oluşur (Ozdemir vd., 2022). Tez çalışmasında ağaç profillerinden bir dış sınır geçirebilmek için küçültme faktörü 0,75 olarak seçilmiştir.




Şekil 35. Ağaç profillerinden sınır geçirme

2.9. Geliştirilmiş Lokal Maksimum Yöntemi

Şekil 35'te görüldüğü üzere ağaç profillerini temsil eden sınırlar düzensiz bir poligonal yapıya sahiptir. Çalışma kapsamında önerilen yaklaşım hatalı ağaç kümelerinin tespiti için farklı düzlemlerden ağaç tepe noktalarını lokal maksimum nokta ile tespit etmeyi amaçlamaktadır. Fakat bu aşamada iki temel problem ile karşılaşmıştır. Birincisi ağacın profilini çıkarmak için en altta bulunan yataydaki sınır noktalarının ortadan kaldırılması gerekmektedir. Diğer sorun ise çizdirilen sınırlar, düzensiz bir yapıya sahip olduğu için çok sayıda yerel/lokal minimum ve maksimum nokta üretilebilmektedir. Bu sorunların çözümü için öncelikle her iki düzlemdeki yatay koordinatlara göre minimum ve maksimum sınır koordinatı belirlenmiştir. Eğer birden fazla aynı yatay koordinat değerine sahip nokta varsa ilgili koordinatlar arasından en düşük yükseklik (Z) değerine sahip olan nokta seçilir. Belirlenecek bu iki sınır noktası (min/maks) arasında kalan sınır noktalarından ağaç profilini temsil edebilecek yeni bir sınır oluşturulur. Daha sonra bu noktalardan eğri geçirilerek birden fazla yerel maksimum ve minimum noktaların oluşmasının önüne geçilmiştir (Şekil 36). Eğri üzerindeki noktaların konumsal özelliklerinden yararlanılarak geliştirilen kod ile yerel minimum ve maksimum noktalar otomatik olarak belirlenmiştir.

Eğri geçirme işlemi için temelinde Bernstein polinomları yer alan Bézier eğrilerinden yararlanılmıştır (Şekil 36). Sınır noktalarından geçirilen Bézier eğrileri 500 adet noktanın yumuşatılması ile elde edilmektedir. Bézier eğrileri ile elde edilen sınırlar ağaç profilini ideal düzeyde temsil ettikleri için lokal maksimum noktalarını temsil ederken gereğinden fazla noktanın, lokal maksimum nokta olarak etiketlenmesi sorununa çözüm sağlamaktadır.



Şekil 36. Bézier eğrileri ile ağaç profillerini çizdirme


Şekil 36’da görüldüğü üzere iki farklı düzlem için 500 noktadan oluşan Bézier eğrileri ile ağaç profilleri gerçeğe en yakın düzeyde yaklaşıp çok fazla sayıda lokal maksimum ve minimum nokta üretilmesi sorununa çözüm sağlamaktadır. Şekil üzerinde mavi renkli sınırlar “*boundary*” fonksiyonu ile oluşturulurken, kırmızı renkli eğriler ise ilgili sınır noktalarını en uygun biçimde temsil edebilecek Bézier eğrilerini göstermektedir. Sarı renkli kare Bézier eğrileri üzerinde lokal/yerel maksimum noktaları, siyah renkli kare ise yerel minimum noktaları temsil etmektedir.

Hatalı ağaç kümelerinin tespit edilmesi için Bézier eğrileri üzerinde oluşturulan yerel maksimum noktalar dikkate alınmıştır. Geliştirilen yaklaşım iki düzlem üzerinden eş zamanlı bir işlem yaptığı için hatalı kümeleri çift taraflı kontrol etmektedir. Hem Y-Z hem de X-Z düzlemlerinde yerel maksimum nokta sayısı 1 ise geliştirilen yaklaşım ilgili ağaç kümesini 0 olarak işaretlemektedir. Eğer yerel maksimum nokta sayısı 1’den büyük ise ilgili ağaç kümesini 1 olarak kaydetmektedir.


Çalışmada iki farklı düzlem için eş zamanlı yerel maksimum sayısının kontrolü için ağaç küme sayısı kadar satır, düzlem sayısı (2) kadar sütundan oluşan ve içerisinde 1 ve 0

rakamları bulunan mantıksal bir matris oluşturulmaktadır. Matematiksel olarak “veya” bağlacı tablosu ile mantıksal tablo analiz edilmiştir. Mantık tablosuna göre her iki sütunun 0 olarak işaretlendiği satır hatasız segmente edilen ağaç kümesi olarak belirlenir. Özetle her iki düzlemde de tek bir yerel maksimum nokta bulunan bireysel ağaç kümesini temsil etmekte ve ağacın doğru bir şekilde segmente edildiğini göstermektedir. Bunun dışındaki tüm durumlar hatalı ağaç kümesi olarak işaretlenir. Bu durumda ağaç kümesinin hatalı olarak tespit edilebilmesi için en az bir düzlemde birden fazla yerel maksimum noktaya ihtiyacı olduğu anlaşılmaktadır (Bahadır vd., 2022).

Hatalı şekilde segmente edilen ağaç kümeleri yeniden bölümlenerek birden fazla ağaç kümesinin oluşturulması sağlanmaktadır. Bu aşamaya kadar yapılan analizlerde iki farklı düzlem üzerinden işlemler yapılmıştır. Bundan sonraki işlemlerde bölümlenme gerçekleştirilecek ağaçlar için iki farklı düzlemde yalnızca birinin seçilmesi gerekmektedir. Tez çalışması kapsamında yerel minimum nokta sayısı daha fazla olan düzlem, bölümlenme için kullanılmıştır. Düzlem seçiminden sonra yerel minimum noktaların yatay koordinatına göre mevcut hatalı ağaç kümelerinin bölütlenmesi yapılarak yeni ağaç kümeleri oluşturulmuştur (Şekil 37). Yapılan bölütleme işlemi doğrudan yerel minimum nokta sayısı ile ilişkilidir (Bahadır vd., 2022). Tüm ağaçlar için yapılan yeni segmentasyon sonuçlarına ait örnek Şekil 38’de sunulmaktadır.



Şekil 37. Hatalı ağaç kümelerinin bölütlenmesi: (a) üç tepeli ağaç, (b) iki tepeli ağaç.




Şekil 38. Yeni segmentasyon sonucu oluşan ağaç kümeleri

2.10. Alan Bazlı İstatistiksel Ölçütler ile Hatalı Ağaç Kümelerinin Tespiti

Önerilen segmentasyon yaklaşımı ile havza bölütleme algoritmasının bitişik ağaçlarda hatalı ağaç kümesi oluşturmaya çözüm olanağı sağlanmıştır. Fakat farklı düzlemlerden ağaç profilleri analiz edilerek geliştirilen yöntem bazı bireysel ağaç kümelerini halen doğru bir şekilde temsil edememe durumları gözlemlenmektedir. Bu yüzden havza bölütleme algoritmasına yapılan birinci iyileştirme yöntemi bazı ağaçların segmentasyonunda yetersiz kalmaktadır. Birinci iyileştirme yöntemi sonucunda halen hatalı ağaç kümesi bulunabilme ihtimaline karşın mevcut durumdaki ağaç taç alanlarının birbirleri ile arasındaki geometrik ilişkisi incelenerek yeniden segmente edilmesi gereken bireysel ağaçlar tespit edilmiştir. İkinci kez hatalı ağaç kümesi tespiti için son durumdaki bütün ağaç kümelerini içeren 5’li komşuluk modeli geliştirilmiştir (Şekil 39). Bu aşamadaki temel mantık herhangi bir ağacın oluşturabileceği ağaç taç alanının komşu ağaçlar ile benzerlik gösterebilme ihtimalini göz önünde bulundurmadır. Bu durum esasen ağaçların birbiriyle arasındaki topolojik ilişkisi ile ilgilidir. Ağaç taç alanlarının birbirleri ile arasındaki topolojik ilişkisini değerlendirebilmek için alan bazı istatistiksel ölçütler geliştirilmiştir.


İkinci kez ağaç taç segmentasyonunda hatalı olarak değerlendirilen ağaç kümelerini tespit etmek için öncelikle bütün ağaç kümelerinin taç sınırlarını ele alarak bir alan hesabı yapılmaktadır. Daha sonra bütün ağaç taç alanlarının ortalama alandan büyük olanları tespit edilerek ön değerlendirme yapılmıştır. İkinci aşamada ise ağaç taç sınırlarının merkez

noktası tespit edilip bu noktanın taç sınır noktalarına olan mesafeleri hesaplandıktan sonra mesafeye bağlı standart sapma ve ortalama değerleri belirlenmiştir. Alan koşulunu sağlayan ağaç kümeleri için standart sapma ve ortalama ölçütlerinin ortalaması alınarak hesaplanan bu değerlerden büyük olan bireysel ağaç kümeleri tespit edilmiştir. Bu aşama ile birlikte veri seti içerisindeki ağaç kümelerinden iki adet koşullandırma ile hatalı ağaç kümeleri değerlendirilmiştir. Daha sonra topolojik ilişkiyi modele entegre etmek suretiyle 5’li komşuluk modeli geliştirilmiştir. Her ağaç kümesinin mesafeye dayalı olarak en yakınındaki 5 ağaç ile topoloji oluşturulmuştur. Başlangıçta yapılan iki koşullandırma ile hatalı küme olarak etiketlenen ağaçlar ele alınarak oluşturulan topolojideki ilgili ağacın kendisi dahil olmak üzere toplam 6 ağaç kendi arasında değerlendirilmiştir. Topolojik ilişki için genel olarak taç alanı ve taç alanların standart sapması olmak üzere iki koşul dikkate alınmıştır. Birinci koşulda her 6’lı ağaç kümesi için bir ortalama taç alanı hesaplanır ve topolojik ilişkide yer alan 6 ağacın taç alanları ile arasındaki farklar hesaplanmıştır. Taç alan farkı ortalama farktan büyük olan ağaç kümeleri hatalı ağaç olarak etiketlenir. İkinci koşulda ise topolojik ilişki içerisindeki ağaç taç alanları için alan bazlı standart sapma hesaplanır ve ortalama standart sapma değerinden büyük olanlar ilk koşuldan ayrı bir şekilde hatalı ağaç kümesi olarak tespit edilmektedir. Belirlenen bu iki koşul içerisinde hatalı segmente edilmiş ağaç etiketleri bulunmaktadır. Alan bazlı hatalı segmente edilen bireysel ağaç kümelerini tespit etmek için bu iki koşulun birleşimi alınmaktadır. Her iki koşulu sağlayan ağaç kümeleri için ayrıca mükerrerlik önlenmektedir. Çalışmada kullanılan alan bazlı istatistiksel karşılaştırma ile ilgili örnek görsel Şekil 40’ta sunulmaktadır.



Şekil 39. Beşli ağaç komşuluk modeli: a) veri setine uygulanması, b) topolojik model

Şekil 39’da gösterilen örnek model üzerinde A kümesi, 5’li komşuluk modelinde istatistiksel anlamda topoloji içerisindeki komşu ağaçların taç yapısına benzer özellik gösterebileceğinden dolayı doğru segmente edilmiş bir ağaç kümesi olarak belirlenmektedir. B kümesi ise komşu ağaçlara göre taç alanının daha geniş olmasından dolayı istatistiksel değerlendirmeler sonucunda hatalı segmente edilmiş ağaç kümesi olarak tespit edilmektedir.



Şekil 40. İstatistiksel ölçütler ile hatalı segmente edilen ağaç kümelerinin tespiti

Şekil 40’ta görüldüğü üzere ağaç taç yapıları komşularına göre daha farklı şekilde oluşan bireysel ağaç kümeleri, hatalı olarak işaretlenmiştir. Önerilen alan bazlı istatistiksel ölçütler, topolojisi içerisinde farklı dağılıma sahip olan ağaç kümelerini otomatik bir şekilde tespit edebilmektedir. Literatürdeki bireysel ağaç taç segmentasyonu uygulamalarında genel olarak ikinci bir hatalı ağaç kümesi değerlendirmesi yapılmamaktadır. Fakat matematiksel modeller yoğun kapalılıktaki ormanlık alanlarda ağacın fenotip özelliklerini tam anlamıyla temsil edemeyeceği unutulmamalıdır.


2.11. Nihai Ağaç Taç Segmentasyonu

Ağaç taç sınırlarının komşulukları arasındaki istatistiksel ilişkiler gözlemlendikten sonra ikinci defa düzeltilmesi gereken ağaç kümeleri otomatik olarak belirlenmiştir. Hatalı kümelerin yeniden segmente edilebilmesi için Kanopi Yükseklik Modeli’ndeki grid çözünürlüğü parametresi düşürülerek yeniden havza bölütleme algoritması çalıştırılmıştır.

Yoğun kapalılık düzeyine sahip ormanlık alanlarda grid çözünürlüğünü değiştirmek segmentasyon sonucunu etkilemediği için önceki aşamalarda önerilen Bézier eğrisi ile geliştirilen lokal maksimum algoritması hatalı kümeler için tekrar uygulanmıştır. İkinci segmentasyon aşamasında yalnızca hatalı ağaç kümeleri için uygulama yapılacağı için doğru segmente edilen ağaçlar ile ilgili noktalar, kalan kümelere arındırılmış olacaktır. Dolayısıyla yeni ağaç profillerinin oluşmasına imkân sağlamaktadır.

2.12. Yeni Ağaç Eşleştirme Modeli

Bireysel ağaç taç segmentasyonunun doğruluğunu değerlendirmek için ağaç taç sınırlarının merkez noktası ile referans ağaç merkez noktalarının birbirleriyle eşleştirilmesi gerekmektedir. Eşleştirme işleminin yapılabilmesi için öncelikle her bir taç sınırı için değişken yarıçapta çemberler geçirilmiştir. Her bir ağaç kümesi için taç sınırlarına en iyi uyan çemberleri çizdirebilmek için (24), (25) ve (26) numaralı eşitliklerden yararlanılmıştır. Çemberlerin yarıçaplarını belirlerken ağaç merkezleri ile taç sınır noktaları arasındaki yatay mesafelerin ortalaması alınarak her bir taç sınırı için farklı yarı çap değerleri üretilmiştir (Şekil 41).



Şekil 41. Ağaç taç sınırlarının çember şeklinde temsil edilmesi


$$r = \frac{1}{n} \sum_{i=1}^n (d_i) \quad (24)$$

$$C_x = r \cos \theta + m_x \quad (25)$$

$$C_y = r \sin \theta + m_y \quad (26)$$

Burada n segmentasyon sonucu oluşan ağaç küme sayısını, m_x ve m_y ağaç merkez noktasının koordinatını, d_i ağaç merkez noktasının taç sınır noktalarına olan mesafesini, r oluşturulan çemberin yarı çapını, C_x ve C_y oluşturulan çemberin x ve y koordinatlarını ve θ ise kaç derece aralıklarla $[0-2\pi]$ çember noktalarının oluşturulacağını gösteren açı değerini temsil etmektedir.

Bireysel ağaçlar için çember geçirildikten sonra her bir ağaç merkezinin tek bir referans merkezi ile eşleştirebilmesi sağlanılmıştır (Şekil 42). Eşleştirme modeli ağaç taç sınırını temsil edebilecek çemberin içinde kalan referans noktaların bulunan ağaç merkezine olan mesafelerine göre nokta eşleştirmeyi sağlamaktadır. Çember içerisinde birden fazla referans nokta bulunması durumunda en kısa mesafedeki referans noktası ile eşleştirme yapılmaktadır. Eğer çember içerisinde herhangi bir şekilde referans nokta bulunmaz ise ilgili ağaç kümesi yanlış bir şekilde segmente edildiği anlaşılmaktadır. Temsili çemberlerin kesişimi söz konusu olduğunda referans nokta, en yakındaki bulunan ağaç merkezi ile eşleştirilmiştir.



Şekil 42. Ağaç merkez noktalarını eşleştirme modeli

Koşul 1 ve 2’de gösterilen yeşil çizgiler eşleştirilen merkez noktalarını temsil etmektedir. Koşul 3’te ise ağaç taç sınırları için oluşturulan çemberin içerisinde herhangi bir referans nokta bulunmadığı için eşleştirme yapılamamıştır. Önerilen yaklaşım segmentasyon sonucu üretilen ağaç taç sınırlarına bağlı olarak değişken yarı çapta çemberler kullanarak ağaç merkezinin taç sınırı içerisinde doğru kabul edilebileceğini kanıtlamaktadır.

2.13. Nesne Tabanlı Doğruluk Analizi


Tez kapsamında önerilen bireysel ağaç taç segmentasyon yönteminin doğruluğunu test etmek için nesne tabanlı doğruluk analizi yöntemi kullanılmıştır. Ağaç taç sınırları referans/gerçek verideki karşılıkları bilinemediği için piksel bazlı doğruluk analizi yerine nesne tabanlı bir analiz gerçekleştirilmiştir. Doğruluk değerlendirmesi için ağaç merkez noktaları ele alınmıştır. Nesne tabanlı doğruluk analizi için Doğru Pozitif (DP), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) metrikleri kullanılmıştır.

DP doğru tespit edilen ağaç tepelerinin sayısını, YP sahada mevcut olmayan fazladan ağaç tepelerinin sayısını (komisyon hatası) ve YN ise algılanmayan ağaç tepelerinin sayısını (ihmal hatası) temsil etmektedir. Ağaç eşleştirme modelinde referans ağaç merkezleri ile eşleştirilen bulunan ağaç merkezleri DP olarak etiketlenmektedir. Eşleştirme sağlanamayan ağaç merkez ve referans noktaları ise sırasıyla YP ve YN olarak etiketlenmektedir.

Nesne tabanlı doğruluk değerlendirmesi için tamlık (Cp-Completeness), doğruluk (Cr-Correctness), kalite (Q-Quality), ve F1-skor ölçütleri kullanılmıştır.

2.14. Ağaç Metriklerinin Tahmini

Tez çalışmasının ikinci temel amacı olan ağaç metriklerinin/parametrelerinin tahmini doğrudan veya allometrik denklemler vasıtasıyla dolaylı yoldan elde edilmektedir. Çalışma kapsamında ağaç boyu (AB), taç genişliği (TG), taç taban yüksekliği (TTY), göğüs yüksekliğindeki çap (GYÇ) metrikleri üzerine yoğunlaşmıştır. AB metriği için segmente edilen ağacın maksimum ve minimum yükseklikteki noktaların farkı alınmaktadır. TG metriği için taç sınırlarına çizdirilen çemberlerin çapları kullanılmaktadır. TTY ve GYÇ metrikleri ise allometrik denklemler aracılığıyla tahmin edilmiştir. GYÇ için temel kavramlar bölümünde yer alan (11) ve (12) numaralı eşitliklerdeki allometrik denklemler tercih edilmiştir. Tez çalışması boyunca TTY metriği için yeni bir allometrik denklem geliştirilmiştir (Denklem 27). Allometrik denklem referans olarak ölçülmüş metriklerden türetilmektedir. Geliştirilen allometrik denklem için Şekil 43'ten yararlanılmıştır.



Şekil 43. TTY metriği için allometrik denklemin oluşturulması

TTY metriği için öncelikle referans TTY ile GYÇ metrikleri oranlanarak ortalama bir hata değeri hesaplanmıştır. Daha sonra Kanopi Yüksekliği (KY) ile TTY oranını kullanarak bir katsayı hesaplanmıştır. KY ve TTY yüksekliklerinin toplamı ile ağaç boyu (H) hesaplanabileceği için oranlanan ifadelerle birer katsayı verilmiştir. Bu katsayıların toplamı ağaç boyunu ifade etmektedir. TTY metriğinin hesaplanması için ağaç boyu, toplam katsayıya oranlanmıştır. Son olarak bulunan değerden ortalama hata değeri çıkarılarak nihai TTY yüksekliği hesaplanmıştır.

$$TTY = \frac{H}{1.6066} - 0.4903 \quad (27)$$


Denklem 27’de gösterilen 1.6066 değeri, KY/TTY oranı (0.6066) yapıldıktan sonra bu iki metriğin arasındaki katsayılar sırasıyla 0.6066x ve x şeklinde bilinmeyen olarak değerlendirildiği için yazılmıştır. Ağaç boyu da bu iki metriğin toplamına eşit olacağı için H değeri 1.6066x değerine eşit olmaktadır. Hesaplanması gereken TTY metriği denklemde x olarak tanımlandığı için basit bir oran-orantı hesabı ile yaklaşık bir tahmin yapılmaktadır. GYÇ metriği de hata değeri hesaplanması aşamasında allometrik denklemlere dahil edilmiştir.

3. BULGULAR


Çalışma kapsamında, LiDAR ve fotogrametrik nokta bulutlarından bireysel ağaç taç segmentasyonu için Bézier eğrileri ile geliştirilen lokal maksimum algoritması önerilmektedir. Uygulama aşamasında bireysel ağaç taç segmentasyonu için mevcut Kanopi Yükseklik Modeli (KYM) ve havza bölütleme (Watershed Segmentation) algoritmasına iki aşamalı bir segmentasyon iyileştirmesi yapılarak ideal düzeyde bireysel ağaç taçlarının çıkarılması sağlanmıştır. İlk aşamada hatalı ağaçlar, X-Z ve Y-Z düzlemindeki profiller üzerinden, ikinci aşamada ise 5'li komşuluk modeli içerisindeki ağaçlardan topoloji oluşturularak alan bazlı istatistiksel ölçütler ile karşılaştırma yapılmak suretiyle otomatik bir şekilde tespit edilmiştir. Geliştirilen ağaç eşleştirme modeli ile birlikte segmentasyon sonucu üretilen her bir ağaç kümesinin merkez noktası, referans noktalar ile eşleştirilmiştir. Eşleştirme sonucunda segmentasyon doğruluğunu belirlemek için nesne tabanlı doğruluk analizi yöntemi uygulanmıştır. Tez çalışmasındaki ikinci temel amaç olan ağaç metriklerinin tahmini aşamasında geliştirilen veya mevcut allometrik denklemler kullanılmıştır. Çalışma bölgesi olarak Akdeniz Üniversitesi'ndeki ağaçlık alan, Maçka (Pilav Dağı) ve Cenevre/İsviçre ormanlık alan ele alınmıştır. Seçilen test bölgeleri yoğun kapalılık seviyesinde olmakla birlikte birçok bitişik ağaç kümelerini içermesinden dolayı veri setinin zorluklarına karşı çözüm olanağı sağlamasıyla avantajlı bir konuma sahiptir. Tez kapsamı boyunca Bulgular ana başlığı altında üç çalışma bölgesinin sonuçları nitel ve nicel olarak ayrı ayrı irdelenenerek yorumlanacaktır.

3.1.Akdeniz Üniversitesi Bireysel Ağaç Taç Segmentasyon Sonuçları

Tez çalışmasında Akdeniz Üniversitesi'ndeki ağaçlık alan için veri seti olarak hem fotogrametrik hem de LiDAR nokta bulutu kullanılmıştır. Bireysel ağaç taç segmentasyonu için referans veri olarak ortofoto üzerinden sayısallaştırılan ağaç merkezleri değerlendirilmeye alınmıştır. Hem LiDAR hem de fotogrametrik nokta bulutu üzerindeki nihai ağaç taç segmentasyon sonuçları üç boyutlu olarak Şekil 44'te görülmektedir. Kullanılan veri setlerinin nesne tabanlı segmentasyon doğruluğu ise Şekil 45'te ortofoto üzerinde gösterilmektedir.



Şekil 44. 3B bireysel ağaç taç segmentasyonu (Akdeniz Üniversitesi): a) fotogrametrik, b) LiDAR nokta bulutu



Şekil 45. Nesne tabanlı doğruluk analizi (Akdeniz Üniversitesi): a) fotogrametrik, b) LiDAR

Akdeniz Üniversitesindeki hem fotogrametrik hem de LiDAR nokta bulutu verileri kullanılarak elde edilen ağaç sayılarına ilişkin nicel sonuçlar Tablo 2’de gösterilmektedir. Önerilen segmentasyon yönteminin nesne tabanlı doğruluk analizi sonuçları ise Tablo 3’de sunulmaktadır.

Tablo 2. Akdeniz Üniversitesi geliştirilen ağaç sayıları

Veri türü	KYM	Birinci Hata	1. İyileştirme	İkinci Hata	2. İyileştirme
Fotogrametrik	94	20	115	7	120
LiDAR	89	21	112	9	121

Tablo 2’de görüldüğü üzere başlangıçta mevcut algoritmanın kullandığı Kanopi Yükseklik Modeli üzerinden ağaç tepelerinin sayısı fotogrametrik ve LiDAR nokta bulutu için sırasıyla 94 ve 89 olarak belirlenmiştir. Ağaç profillerinin iki farklı düzlem üzerinden Bézier eğrisi ile analiz edilmesi sonucunda fotogrametrik ve LiDAR nokta bulutu için sırasıyla 20 ve 21 ağacın hatalı segmente edildiği tespit edilmiştir. Hatalı ağaç kümeleri kendi içerisinde ikili veya üçlü ağaç kümesi olabilecek şekilde bitişik bir halde bulunmaktadır. Birinci hatalı ağaç kümelerinin tespiti aşamasında fotogrametrik nokta bulutunda KYM üzerinden üretilen ağaç sayısının yaklaşık %22,22’si, LiDAR nokta bulutunda ise yaklaşık %23,59’unun yeniden segmente edilmesine karar verilmiştir. Yerel minimum nokta sayısına göre bölümlenen ağaç sayıları 2’li veya 3’lü bir şekilde yeni bir küme oluşturabilmektedir. Önerilen yaklaşım fotogrametrik ve LiDAR nokta bulutunda birinci iyileştirme sonucunda sırasıyla 115 ve 112 ağaç tespit etmiştir. Birinci iyileştirme aşaması ile birlikte ağaç sayılarında fotogrametrik ve LiDAR verisi için sırasıyla %22,34 ve %25,84’lük bir artış sağlanmıştır. Ağaç sayısındaki artış ise sırasıyla 21 ve 23 olarak gözlemlenmiştir. Önerilen yaklaşım alan bazlı istatistiksel koşullandırma aşamasında oluşturduğu 5’li komşuluk modeli topolojisi ile fotogrametrik ve LiDAR nokta bulutları için sırasıyla 7 ve 9 ağacın taç yapısının komşu ağaçlardan farklı bir şekilde geliştiğini tespit ederek hatalı ağaç kümesi olarak nitelendirmiştir. İkinci hatalı ağaç kümesi tespitinde bir önceki iyileştirmede elde edilen ağaçların fotogrametrik ve LiDAR verisi için sırasıyla %6,08’i ve %8,03’ü alan bazlı istatistiksel koşullandırma sonucu hatalı segmente edildiği gözlemlenmiştir. Nihai segmentasyon sonucuna bakıldığında ise fotogrametrik ve LiDAR verisi için sırasıyla 5 (%4,34 artış) ve 9 (%9,03 artış) ağacın yeniden oluşturulduğu ve ağaç


sayılarının 120 ve 121'e yükseldiği gözlemlenmektedir. Fotogrametrik nokta bulutunda 2 adet ağacın istatistiksel koşullandırma ile hatalı olarak segmente edildiği tespit edilmesine rağmen ikinci iyileştirme aşamasında herhangi bir değişikliğe uğramamıştır. Bu durum ikinci iyileştirmede grid çözünürlüğünün düşürülerek Kanopi Yükseklik Modeli üzerinden yeniden ağaç tepesi algılama aşamasında ilgili ağaçların bölümlenemeyeceğini göstermektedir. Genel olarak yorumlandığında, önerilen yaklaşımın Akdeniz Üniversitesi'ndeki fotogrametrik ve LiDAR veri seti üzerinde test edildiğinde ağaç sayısının Kanopi Yükseklik Modeli sonuçlarına göre sırasıyla 26 ve 32 ağaç daha fazla ortaya çıkardığı gözlemlenmektedir. Başlangıca göre ağaç sayısındaki yüzdelik artışlar karşılaştırıldığında ise fotogrametrik ve LiDAR verilerinde ağaç sayılarının sırasıyla %27,66'lık ve %35,95'lik bir artış sağladığı görülmektedir.

Tablo 3. Akdeniz Üniversitesi doğruluk değerlendirmesi


Veri Türü	DP	YN	YP	Referans Ağaç
Fotogrametrik	116	9	4	125
LiDAR	107	18	14	125
Veri Türü	Tamlık (%Cp)	Doğruluk (%Cr)	Kalite (%Q)	F-skor (%)
Fotogrametrik	92,80	96,66	89,92	94,69
LiDAR	85,60	88,43	76,98	86,99
Ortalama	89,20	92,54	83,45	90,84

Tablo 3'te görüldüğü üzere Akdeniz Üniversitesi'ndeki test alanında referans olarak 125 ağaç merkezi bulunmasına rağmen önerilen segmentasyon ve ağaç eşleştirme modeli yardımıyla fotogrametrik ve LiDAR nokta bulutlarında sırasıyla 116 ve 107 ağaç doğru bir şekilde tahmin edilmiştir. Fotogrametrik nokta bulutu sonuçlarına göre çalışma sahasında mevcut olan 9 adet ağaç (YN-ihmal hatası) tespit edilememiştir. Ayrıca gerçek test alanı içerisinde ağaç bulunmayan bölgede ise 4 adet (YP-komisyon hatası) hatalı ağaç bulunmaktadır. LiDAR nokta bulutu sonuçlarına bakıldığında ise 18 adet ağaç çalışma alanında (referans veri) bulunmasına rağmen önerilen yaklaşım ile tespit edilememiştir. 14 adet ağaç ise sahada bulunmamasına rağmen fazladan ağaç merkezi olarak etiketlenerek tespit edilmiştir. Doğru pozitif (DP) ağaçların referans ağaç sayısına oranlanması ile yapılan sayı bazlı analizde, fotogrametrik nokta bulutunda %92,8, LiDAR nokta bulutunda ise %85,6'lık bir ağaç segmentasyon doğruluğu elde edilmektedir. Akdeniz Üniversitesi'nde

kullanılan veri setleri karşılaştırıldığında fotogrametrik nokta bulutu ile yapılan değerlendirme LiDAR nokta bulutuna göre daha iyi sonuç vermiştir. LiDAR nokta bulutunun daha yoğun olmasından dolayı hem Kanopi Yükseklik Modeli hem de önerilen Bézier eğrisi ile geliştirilmiş lokal maksimum algoritması kullanılarak bitişik ağaç tepelerini ayırt etmede kısmen yetersiz kaldığı gözlemlenmiştir. Özellikle seçilen test bölgesinin yoğun bir ağaçlık alan ile çevrelenmesinden dolayı yanlış tespit edilen ağaç sayıları makul seviyede görülmektedir. Veri setinin doğruluğunu değerlendirmek için yapılan nesne tabanlı doğruluk analizi sonuçları incelendiğinde tamlık (Cp), doğruluk (Cr), kalite (Q) ve F-skor değerleri fotogrametrik nokta bulutu için sırasıyla %92,80, %96,66, %89,92 ve %94,69, LiDAR nokta bulutunda ise %85,60, %88,43, %76,98 ve %86,99 olarak hesaplanmıştır. Önerilen bireysel ağaç taç segmentasyon yaklaşımı Akdeniz Üniversitesi'ndeki veri setleri için ortalama Cp, Cr, Q ve F-skor değerleri sırasıyla %89,20, %92,54, %83,45 ve %90,84 olarak hesaplanmaktadır. Tez kapsamında Kanopi Yükseklik Modeli üzerinden gerçekleştirilen havza bölütleme (Watershed Segmentation) algoritmasını iyileştirmek için Bézier eğrisi ile geliştirilen lokal maksimum yaklaşımı kullanılarak elde edilen segmentasyon sonuçları aşamalı bir şekilde Şekil 46 ve 47'de paylaşılmaktadır.



Şekil 46. LiDAR nokta bulutu aşamalı segmentasyon sonuçları (Akdeniz Üniversitesi)



Şekil 47. Fotogrametrik nokta bulutu aşamalı segmentasyon sonucu (Akdeniz Üniversitesi)


Şekil 46 ve 47’de a-c görselleri KYM + Havza Bölütleme (WS) ile yapılan mevcut segmentasyon yaklaşımını, d-f görselleri Bézier eğrileri ile geliştirilen lokal maksimum yaklaşımının segmentasyon sonuçlarını, g-i arasındaki görseller ise ikinci iyileştirme sonucu nihai bireysel ağaç taç segmentasyon sonuçlarını temsil etmektedir. Şekilde yer alan a, d ve g görselleri bireysel ağaç taç sınırları ile ağaç merkez noktalarını, b, e ve h görselleri doğruluk analizi öncesi gereken ağaç eşleştirme modeli için bireysel ağaç taç sınırlarına uyan sembolik çemberleri, c, f ve i ise ilk iki aşamadaki görsellerin çakıştırılması ile elde edilen sonuç çıktısını göstermektedir.

Önerilen bireysel ağaç taç segmentasyon yaklaşımı genel anlamıyla Akdeniz Üniversitesi içerisindeki ağaçlık alanda yer alan bitişik ağaç kümelerini segmente edebildiği

görülmektedir. Hatalı tespit edilen ağaçlar, 3 kapalılık düzeyinde yoğun olarak adlandırılan test alanı içerisinde bulunduğu için makul seviyede olduğu gözlemlenebilmektedir.


3.2.Maçka (Pilav Dağı) Bireysel Ağaç Taç Segmentasyon Sonuçları

Tez çalışmasında Trabzon İl'inin Maçka İlçesi'nde bulunan Pilav Dağı'ndaki iki adet denek alan için veri seti olarak LiDAR nokta bulutu kullanılmıştır. Alan verisi olarak arazide ağaç merkez konumları, ağaç boyu, göğüs yüksekliğindeki çap, taç genişliği, taç taban yüksekliği metrikleri uzmanlar tarafından ölçülmüştür. Bireysel ağaç taç segmentasyonunun doğruluğunu test edebilmek için arazide ölçülen ağaç merkezlerinin konumları kullanılmıştır. Denek alanlarına ait nihai ağaç taç segmentasyon sonuçları üç boyutlu olarak Şekil 48'de gösterilmektedir. Önerilen segmentasyon yaklaşımın nesne tabanlı doğruluk analizi ise Şekil 49'da ortofoto üzerinde temsil edilmektedir.



Şekil 48. 3B bireysel ağaç taç segmentasyonu (Pilav Dağı): a) alan 1, b) alan 2

Pilav Dağı'ndaki iki adet denek alanı için LiDAR nokta bulutu verileri kullanılarak elde edilen ağaç sayılarına ilişkin nicel sonuçlar Tablo 4'te gösterilmektedir. Önerilen bireysel ağaç taç segmentasyon yönteminin nesne tabanlı doğruluk analizi sonuçları ise Tablo 5'te sunulmaktadır.



Şekil 49. Nesne tabanlı doğruluk analizi (Maçka/Pilav Dağı): a) alan 1, b) alan 2

Tablo 4. Maçka/Pilav Dağı geliştirilen ağaç sayıları

Veri türü	KYM	Birinci Hata	1. İyileştirme	İkinci Hata	2. İyileştirme
LiDAR (Maçka1)	18	13	32	4	36
LiDAR (Maçka2)	16	7	27	3	29

Tablo 4’te görüldüğü üzere başlangıçta mevcut algoritmanın kullandığı Kanopi Yükseklik Modeli üzerinden ağaç tepelerinin sayısı denek alanı 1 ve 2 için sırasıyla 18 ve 16 olarak belirlenmiştir. Ağaç profillerinin iki farklı düzlem üzerinden Bézier eğrisi ile analiz edilmesi sonucunda denek alanı 1 ve denek alanı 2 için sırasıyla 13 ve 7 ağacın hatalı segmente edildiği tespit edilmiştir. Hatalı ağaç kümeleri Akdeniz Üniversitesi test alanında olduğu gibi kendi içerisinde ikili veya üçlü ağaç kümesi olabilecek şekilde bitişik bir halde bulunmaktadır. Birinci hatalı ağaç kümelerinin tespiti aşamasında denek alanı 1’de KYM üzerinden üretilen ağaç sayısının %72,22’si, denek alanı 2’de ise %43,75’inin yeniden segmente edilmesine karar verilmiştir. Önerilen yaklaşım denek alanlarında birinci iyileştirme sonucunda sırasıyla 32 ve 27 ağaç tespit etmiştir. Birinci iyileştirme aşaması ile birlikte ağaç sayılarında birinci ve ikinci denek alanları için sırasıyla %77,77 ve %68,75’lik bir artış sağlanmıştır. Ağaç sayısındaki artış ise sırasıyla 14 ve 11 olarak gözlemlenmiştir. Önerilen yaklaşım alan bazlı istatistiksel koşullandırma aşamasında oluşturduğu 5’li

komşuluk modeli topolojisi ile denek alanlarında sırasıyla 4 ve 3 ağacın taç yapısının komşu ağaçlardan farklı bir şekilde geliştiğini tespit ederek hatalı ağaç kümesi olarak etiketlenmektedir. İkinci hatalı ağaç kümesi tespitinde bir önceki iyileştirmede elde edilen ağaçların birinci ve ikinci denek alanlarında sırasıyla %12,5'i ve %11,11'i alan bazlı istatistiksel koşullandırma sonucu hatalı segmente edildiği gözlemlenmiştir. Nihai segmentasyon sonucuna bakıldığında ise birinci ve ikinci denek alanı için sırasıyla 4 (%12,5 artış) ve 2 (%7,4 artış) ağacın yeniden oluşturulduğu ve ağaç sayılarının 36 ve 29'a yükseldiği gözlemlenmektedir. İkinci denek alanında 1 adet ağacın istatistiksel koşullandırma ile hatalı olarak segmente edildiği tespit edilmesine rağmen ikinci iyileştirme aşamasında herhangi bir değişikliğe uğramamıştır. Bu durum ikinci iyileştirmede tekrarlanan geliştirilmiş lokal maksimum yaklaşımının her iki düzlemde de fazladan ağaç tepesi oluşturabileceği bir profil algılayamamasından kaynaklanmaktadır.

Genel olarak yorumlandığında önerilen yaklaşımın Pilav Dağı'ndaki LiDAR veri seti üzerinde test edildiğinde ağaç sayısının Kanopi Yükseklik Modeli sonuçlarına göre sırasıyla 18 ve 13 ağaç daha fazla ortaya çıkardığı gözlemlenmektedir. Başlangıca göre ağaç sayısındaki yüzdelik artışlar karşılaştırıldığında ise birinci ve ikinci denek alanlarında ağaç sayılarının sırasıyla %100'lük ve %81,25'lik bir artış sağladığı görülmektedir.

Tablo 5. Maçka (Pilav Dağı) doğruluk değerlendirmesi

Veri Türü	DP	YN	YP	Referans Ağaç
LiDAR (Maçka1)	32	5	4	37
LiDAR (Maçka2)	27	9	2	36
Veri Türü	Tamlık (%Cp)	Doğruluk (%Cr)	Kalite (%Q)	F-skor (%)
LiDAR (Maçka1)	86,48	88,88	78,05	87,67
LiDAR (Maçka2)	75,00	93,10	71,05	83,07
Ortalama	80,74	90,99	74,55	85,37


Tablo 5'te görüldüğü üzere Maçka (Pilav Dağı) iki adet test alanında referans olarak sırasıyla 37 ve 36 ağaç merkezi bulunmasına rağmen önerilen segmentasyon ve ağaç eşleştirme modeli yardımıyla LiDAR nokta bulutlarında sırasıyla 32 ve 27 ağaç doğru bir şekilde tahmin edilmiştir.

Birinci denek alanında çalışma sahasında mevcut olan 5 adet ağaç (YN) tespit edilemeyerek ihmal hatası oluşturmaktadır. İlave olarak denek alanları içerisinde bulunmayan ağaçların yerine fazladan 4 adet ağaç (YP) tespit edildiği için komisyon hatası içermektedir. Pilav Dağı'ndaki ikinci denek alanı incelendiğinde ise 9 adet ağaç referans veride (arazide) bulunmasına rağmen önerilen yaklaşım ile tespit edilemediği için ihmal hatası bulunmaktadır. Ayrıca 2 adet ağaç (komisyon hatası) sahada mevcut olmamasına rağmen fazladan ağaç merkezi olarak etiketlenen ağaçları belirtmektedir. Doğru pozitif (DP) ağaçların referans ağaç sayısına oranlanması ile yapılan sayı bazlı analizde, birinci denek alanı için %86,48, ikinci denek alanı için ise %75'lik bir ağaç taç segmentasyon doğruluğu elde edilmektedir.


Test bölgelerindeki segmentasyon doğrulukları karşılaştırıldığında birinci denek alanı ile yapılan değerlendirme daha iyi sonuç verdiği gözlemlenmektedir. Bu durum arazinin topoğrafyası ve ağaç dalların karmaşık bir yapı içerisinde bitişik bir ağaç kümesi oluşturmasından kaynaklanmaktadır. Özellikle Pilav Dağı'nda seçilen iki denek alanı da çok yüksek yoğunluk düzeyine sahip olduğundan dolayı tespit edilen ağaç sayıları her iki alan için uygun olarak görülmektedir. Çevre şartlarının yapılan segmentasyon işlemini doğrudan etkilediği gözlemlenmektedir.

Veri setinin doğruluğunu değerlendirmek için yapılan nesne tabanlı doğruluk analizi sonuçları incelendiğinde tamlik (Cp), doğruluk (Cr), kalite (Q) ve F-skor değerleri birinci denek alanı için sırasıyla %86,48, %88,88, %78,05 ve %87,67, ikinci denek alanında ise %75,00, %93,10, %71,05 ve %83,07 olarak hesaplanmıştır. Önerilen bireysel ağaç taç segmentasyon yaklaşımı Maçka Pilav Dağı'ndaki denek alanları için ortalama Cp, Cr, Q ve F-skor değerleri sırasıyla %80,74, %90,99, %74,55 ve %85,37 olarak hesaplanmaktadır.

Kanopi Yükseklik Modeli üzerinden gerçekleştirilen havza bölütleme (Watershed Segmentation) algoritmasını iyileştirmek için Bézier eğrisi ile geliştirilen lokal maksimum yaklaşımı kullanılarak elde edilen segmentasyon sonuçları aşamalı bir şekilde Şekil 50 ve 51'de paylaşılmaktadır.



Şekil 50. Maçka-1 aşamalı segmentasyon sonucu




Şekil 51. Maçka-2 aşamalı segmentasyon sonucu

Şekil 51 ve 52’de a-c görselleri KYM + Havza Bölütleme (WS) ile yapılan mevcut segmentasyon yaklaşımını, d-f görselleri Bézier eğrileri ile geliştirilen lokal maksimum yaklaşımının segmentasyon sonuçlarını, g-ı arasındaki görseller ise ikinci iyileştirme sonucu nihai bireysel ağaç taç segmentasyon sonuçlarını temsil etmektedir. Şekilde yer alan a, d ve g görselleri bireysel ağaç taç sınırları ile ağaç merkez noktalarını, b, e ve h görselleri doğruluk analizi öncesi gereken ağaç eşleştirme modeli için bireysel ağaç taç sınırlarına uyan sembolik çemberleri, c, f ve ı ise ilk iki aşamadaki görsellerin karşılaştırılması ile elde edilen sonuç çıktısı göstermektedir.

Önerilen bireysel ağaç taç segmentasyon yaklaşımı genel anlamıyla Maçka Pilav Dağı’ndaki denek alanlarında yoğun kapalılıkta ağaçların bulunmasına rağmen bitişik ağaç kümelerini KYM+ Havza bölütleme algoritmasına göre daha iyi segmente edebilmektedir. Seçilen test alanı birinci test alanına göre daha yoğun olmakla birlikte çevre şartlarının zorlukları göz önünde tutulursa yapılan segmentasyon işlemi makul seviyede gerçekleşmiştir. Ayrıca KYM ve Havza bölütleme algoritmasının ormanlık alanlarda bireysel ağaç taç segmentasyonu için yetersiz kaldığı açıkça görülmektedir.

3.3. Cenevre Bireysel Ağaç Taç Segmentasyon Sonuçları


Tez kapsamında son çalışma alanı olan Cenevre/İsviçre ormanlık alan için veri seti olarak 2017 yılında üretilen LiDAR nokta bulutu kullanılmıştır. Ele alınan çalışma bölgesi yurtdışında bulunduğu için alan verisi olarak herhangi bir ölçüt bulunmamaktadır. Bu yüzden bu çalışma bölgesi için herhangi bir doğruluk analizi veya ağaç metrik tahmini yapılamamıştır. Bu veri seti sadece çok geniş alanda yapraksız ağaçların bulunduğu ve yüksek kapalılık düzeyine sahip ormanlık alanlarda önerilen segmentasyon yaklaşımının ne derecede katkı sağlayabileceğini test etmek için seçilmiştir. Çalışma alanına ait üretilen nihai ağaç taç segmentasyon sonucu 3B olarak Şekil 52’de gösterilmektedir. Çalışma alanında yapraksız ağaçların bulunması ve ağaçların ilgili alanda çok sık bulunmasından kaynaklı seçilen bu test alanı diğer iki çalışma alanına göre daha zorlayıcı bir örnek teşkil etmektedir.



Şekil 52. 3B bireysel ağaç taç segmentasyonu (Cenevre/İsviçre)

Cenevre veri seti için başlangıçta mevcut algoritmanın kullandığı Kanopi Yükseklik Modeli üzerinden ağaç tepelerinin sayısı 216 olarak tespit edilmiştir. Ağaç profillerinin iki farklı düzlem üzerinden Bézier eğrisi ile analiz edilmesi sonucunda ağaç sayısı 324'e ulaşmıştır. Yüzdelik olarak hesaplandığında başlangıçta Kanopi Yükseklik Modeli üzerinden hesaplanan ağaç sayısının %50' lik bir artış yaptığı gözlemlenmektedir. Önerilen segmentasyon yaklaşımı alan bazlı istatistiksel koşullandırma aşamasında oluşturduğu 5'li komşuluk modeli topolojisi ile çalışma bölgesinde 11 adet ağacın taç yapısının komşu ağaçlardan farklı bir şekilde geliştiğini tespit ederek hatalı ağaç kümesi olarak etiketlenmektedir. İkinci hatalı ağaç kümesi tespitinde bir önceki iyileştirmede elde edilen ağaçların %3,39'u alan bazlı istatistiksel koşullandırma sonucu hatalı segmente edildiği gözlemlenmiştir. İkinci iyileştirme ile birlikte nihai segmentasyon sonucu irdelendiğinde 5 (%1,54) ağaçlık bir artış ile toplamda 329 ağaca ulaşılmıştır. İkinci iyileştirme aşamasında 6 adet ağacın hatalı segmente edilmesine rağmen yeniden segmentasyona uğramadığı gözlemlenmiştir. Bu durum ikinci iyileştirmede tekrarlanan geliştirilmiş lokal maksimum yaklaşımının her iki düzlemde de fazladan ağaç tepesi oluşturabileceği bir profil algılayamamasından kaynaklanmaktadır. Genel olarak İsviçre/Cenevre veri seti için önerilen yaklaşım Kanopi Yükseklik Modeli ile elde edilen ağaç sayısına göre 113 adet ağaç daha fazla üretmektedir. Başlangıca göre ağaç sayısındaki yüzdelik artış ise %52,31 olarak hesaplanmıştır. Kanopi Yükseklik Modeli üzerinden gerçekleştirilen havza bölütleme

(Watershed Segmentation) algoritmasını iyileştirmek için Bézier eğrisi ile geliştirilen lokal maksimum yaklaşımı kullanılarak elde edilen segmentasyon sonuçları aşamalı bir şekilde Şekil 53'te paylaşılmaktadır.



Şekil 53. Aşamalı segmentasyon görselleri (İsviçre/Cenevre)

Şekil 53'te a-c görselleri KYM + Havza Bölütleme (WS) ile yapılan mevcut segmentasyon yaklaşımını, d-f görselleri Bézier eğrileri ile geliştirilen lokal maksimum yaklaşımının segmentasyon sonuçlarını, g-i arasındaki görseller ise ikinci iyileştirme sonucu nihai bireysel ağaç taç segmentasyon sonuçlarını temsil etmektedir. Şekilde yer alan a, d ve g görselleri bireysel ağaç taç sınırları ile ağaç merkez noktalarını, b, e ve h görselleri doğruluk analizi öncesi gereken ağaç eşleştirme modeli için bireysel ağaç taç sınırlarına uyan sembolik çemberleri, c, f ve i ise ilk iki aşamadaki görsellerin çakıştırılması ile elde edilen sonuç çıktısını göstermektedir.

Önerilen bireysel ağaç taç segmentasyon yaklaşımı genel anlamıyla Cenevre ormanlık alanda yoğun kapalılıkta ağaçların yapraksız şekilde bulunmasına rağmen bitişik ağaç kümelerini KYM+ Havza bölütleme algoritmasına göre daha iyi segmente edebildiği gözlemlenmektedir. Test alanındaki çevre şartları göz önünde tutulursa önerilen segmentasyon yaklaşımı yapraksız ve yoğun kapalılık düzeyindeki ağaçlarda bölütleme işlemini yapabilmektedir.



4. TARTIŞMA

Tez kapsamında önerilen geliştirilmiş lokal maksimum yaklaşımı, bireysel ağaç taç segmentasyonu için KYM + Havza Bölütleme (Watershed Segmentation) algoritmasına iyileştirme yapılmak suretiyle test edilerek kapalılık düzeyi yüksek ağaçlık alanlarda bitişik ağaç kümelerinin segmente edilebilmesine alternatif bir çözüm olanağı sunmaktadır. Bézier eğrisi ile geliştirilmiş lokal maksimum yaklaşımı ağaç profillerini en iyi şekilde temsil ederek farklı düzlemlerde bitişik ağaç kümelerinin oluşabilme durumlarını otomatik bir şekilde incelemektedir. Bézier eğrisi üzerindeki lokal maksimum noktalar, elde edilecek ağaç kümelerinin sayısını, yerel minimum noktalar ise bölümlenme yapılacak sınırı temsil etmektedir. Profil analiz işlemleri iki farklı perspektif/düzlem üzerinden gerçekleştirildiği için yeniden segmente edilebilme ihtimali bulunan ağaçlar daha doğru bir şekilde tespit edilmiştir. Birinci iyileştirme sonucu ağaç taç yapılarının planimetrik/yatay sınırları, oluşturulan 5'li komşuluk modeli içerisindeki topoloji yardımıyla alan bazlı istatistiksel ölçütler ile kıyaslanarak halen bitişik ağaç kümesi olup tek bir bireysel ağaç olarak segmentasyonu gerçekleştirilen kümeleri, yeniden değerlendirmeye almaktadır. İstatistiksel anlamda komşu ağaçların büyüme veya gelişme durumları birbirine benzer olması beklenildiği için geliştirilen topoloji, ağaç taç yapılarında oluşabilecek büyük sapmaları otomatik bir şekilde tespit ederek ilgili ağacı, hatalı ağaç olarak etiketlemektedir. İkinci kez yapılan hatalı ağaç kümesi tespitinden sonra nihai ağaç taç segmentasyonunu gerçekleştirebilmek için yalnızca hatalı ağaç kümelerini ele alarak ya yeniden profil analizine girdi olarak kullanılmıştır ya da KYM için grid çözünürlüğü düşürülerek ağaçların yeniden segmente edilebilmesi sağlanılmıştır. Son yapılan segmentasyon işlemi yalnızca hatalı ağaç kümelerini işleme aldığı için komşu ağaçların etkisinden arındırılmış olacaktır. Ancak ikinci aşamada grid çözünürlüğünü düşürmek her zaman segmentasyon yapılabileceği anlamına gelmemektedir. Arazinin topoğrafik yapısı ağaçların bitişik bir şekilde çok yoğun olarak bulunması gibi etkenlerden dolayı grid çözünürlüğü düşürmek veya yükseltmek mevcut segmentasyon sonucunu değiştirmeyebilir. Önerilen segmentasyon yaklaşımı KYM + Havza Bölütleme algoritması tarafından hatalı bir şekilde tespit edilen ağaçları iyileştirerek yeniden segmente etmeyi sağlamıştır. Ağaç taç sınırlarının referans verisi bulunmadığı için önerilen yaklaşımın doğruluk analizi nesne tabanlı olarak gerçekleştirilmiştir.

Bulgular ana başlığı altında mevcut doğrulama metrikleri özellikle yüksek kapalılık düzeyine sahip ağaçlık alanlarda umut vadeden sonuçlar üretmektedir. Tez kapsamında ikinci temel aşama olan ağaç metrik tahmini için geliştirilmiş veya mevcut allometrik denklemler kullanılarak kestirim yapılmıştır. Tartışma ana bölüm başlığı altında veri setleri için analiz ve yorumlamalar ayrı başlıklar altında sunulmaktadır.

4.1. Akdeniz Üniversitesi Ağaçlık Alanın İrdelenmesi

Akdeniz Üniversitesi içerisindeki ağaçlık alan için kullanılan fotogrametrik ve LiDAR nokta bulutları ile elde edilen ağaç kümelerinden ikinci kez hatalı tespit edilen ağaçların görselleri Şekil 54’te sunulmaktadır.




Şekil 54. İstatistiksel olarak hatalı tespit edilen ağaçlar: a) fotogrametrik, b) LiDAR


Şekil 54’te görüldüğü üzere Akdeniz Üniversitesi’ndeki mevcut ağaçlık alanın hem LiDAR hem de fotogrametrik nokta bulutu veri seti için istatistiksel anlamda komşu ağaçlara göre sapma yapan ağaçlar otomatik bir şekilde renklendirilmiştir. Renklendirilen hatalı ağaç kümeleri özellikle 5’li komşuluk modeli içerisinde alan bazlı istatistiksel koşullar ile analiz edildiğinde ağaç taç yapısının çok farklı geliştiği açık bir şekilde gösterilmiştir. Hatalı olarak etiketlenen ağaç kümeleri içerisinde birden fazla ağaç bulunduğu görülmektedir. Aynı test alanı için kullanılan farklı veri setleri incelendiğinde genellikle benzer ağaçlarda hatalı

etiketler bulunmaktadır. Önerilen istatistiksel ölçütlerin Akdeniz Üniversitesi'ndeki ağaçlık alan için uygun bir şekilde çalıştığı gözlemlenmektedir.

Çalışma bölgesinde başlangıç aşamasında ağaç tepe noktalarının tespit edilmesi için kullanılan Kanopi Yükseklik Modeli ve nihai ağaç taç segmentasyonu sonucu üretilen ağaç merkezleri Şekil 55 ve 56'da karşılaştırılmıştır. Ayrıca referans ağaç merkez noktaları ortofoto üzerinde gösterilerek gerçek ağaç sayına göre karşılaştırılması da yapılmıştır.




Şekil 55. KYM ile önerilen yöntemin kıyaslanması (Akdeniz, LiDAR)




Şekil 56. KYM ile önerilen yöntemin kıyaslanması (Akdeniz, fotogrametrik)

Şekil 55a ve 56a’da ki görseller incelendiğinde Kanopi Yükseklik Modeli üzerinden birçok ağacın tespit edilemediği açık bir şekilde gösterilmektedir. Şekil 55b ve 56b’de ise referans ağaç noktaları ortofotoya eklendiği zaman önerilen yaklaşım sonucu üretilen ağaç merkez noktalarına daha fazla uyum sağladığı gözlemlenmektedir. Görsel olarak yapılan bu karşılaştırmada önerilen bireysel ağaç taç segmentasyon yönteminin mevcut uygulamaya göre daha başarılı olduğu söylenebilmektedir.

Tez çalışmasında yapılan segmentasyon işlemlerinin doğruluk analizleri nesne tabanlı olarak yapılmıştır. Fakat yapılan doğruluk analizi ne kadarlık bir hata ile bu işlemlerin yapıldığını temsil edememektedir. Bu yüzden önerilen yaklaşım ile elde edilen ağaç merkez noktaları ile referans ağaç merkez noktaları arasında regresyon analizi uygulanarak segmentasyon işleminin tutarlılığı kontrol edilmiştir (Şekil 57 ve 58). Regresyon analizi ile elde edilen nicel sonuçlar Tablo 6’da ayrıntılı bir şekilde paylaşılmaktadır.



Şekil 57. Akdeniz Üniversitesi regresyon analizi (LiDAR nokta bulutu)



Şekil 58. Akdeniz Üniversitesi regresyon analizi (Fotogrametrik nokta bulutu)

Tablo 6. Akdeniz Üniversitesi regresyon analizi ve hata değerleri

Veri türü	N	RMSE(m)	R ²	Adj-R ²
Fotogrametrik (y)	116	1,0087	0,99	0,99
LiDAR (y)	107	0,9846	0,99	0,99
Fotogrametrik (x)	116	0,9607	0,99	0,99
LiDAR (x)	107	1,0682	0,99	0,99

Tablo 6’da yer alan N ifadesi nesne tabanlı doğruluk analizi ile elde edilen Doğru Pozitif (DP) etiketli ağaçların sayısını temsil etmektedir. Regresyon analizi ve hata değerlerinin hesaplanabilmesi için referans noktalarla eşleşme yapabilen ağaçlara ihtiyaç duyulmaktadır. Tablo 6 değerlerinde görüldüğü üzere fotogrametrik nokta bulutu için 116, LiDAR nokta bulutu için 107 adet noktanın x ve y koordinatları için ayrı ayrı RMSE, R² ve Adj-R² değerleri hesaplanmıştır. Fotogrametrik nokta bulutunda ağaç merkez noktaları için y koordinatında yaklaşık 1 m’lik, x koordinatında ise yaklaşık 0,96 m’lik bir RMSE hata değeri elde edilmiştir. LiDAR nokta bulutunda ise bu değerler sırasıyla yaklaşık 0,98 ve 1,06 olarak hesaplanmaktadır. Genel olarak önerilen yaklaşım sonucu üretilen ağaç merkezleri referans noktaya göre ortalama 1 m’lik bir hata içermektedir. R² ve Adj-R² değerlerine bakıldığında ise regresyon analizinde referans ve tahmini değerler arasında yaklaşık %99’luk bir uyumluluk söz konusudur. Önerilen yöntem ile bulunan ağaç merkez noktaları %99 (R²) model doğruluğu sağlamaktadır. Veri setlerinin RMSE değerleri kıyaslandığında fotogrametrik nokta bulutu sonuçları LiDAR nokta bulutuna göre daha düşük hata içermektedir. Fotogrametrik nokta bulutunda daha fazla Doğru Pozitif (N) ağaç nesnesi bulunduğu için hatanın bütün ölçülere yayılması beklenilmektedir. Dolayısıyla yayılan hata, RMSE değerine direkt olarak azaltıcı yönde etki sağlayacaktır. Eşleştirme modelinde bulunan merkez noktalarının en yakın mesafedeki referans noktalarla eşleştirilmesi ile optimum düzeyde hata değeri hesaplanmıştır. Önerilen bireysel ağaç taç segmentasyonu için belirlenen hata değerleri çok yüksek yoğunluklu ve bitişik ağaç kümeleri ile kaplı çalışma alanı için uygun seviyede olduğu düşünülmektedir.

Tez kapsamında, orman envanteri için gerekli olan ağaç metrikleri (Ağaç boyu-AB, göğüs yüksekliğinde çap-GYÇ, taç taban yüksekliği-TTY ve taç genişliği-TG) üzerine tahmin yapılmıştır (Tablo 7). Fotogrametrik ve LiDAR nokta bulutu için yapılan tahmin değerleri alan ölçüsü bulunmadığı için regresyon analizine dahil edilmemiştir.

Tablo 7. Akdeniz Üniversitesi ağaç metrik tahmini

Ağaç Metrikleri	Fotogrametrik Nokta Bulutu			LiDAR Nokta Bulutu		
	Minimum	Maksimum	Ortalama	Minimum	Maksimum	Ortalama
AB (m)	3,34	12,60	9,29	7,61	12,48	10,91
GYÇ (cm)	11,33	29,14	21,70	17,51	28,76	24,20
TTY (m)	1,59	7,35	5,29	4,25	7,27	6,20
TG (m)	1,84	10,95	5,01	1,64	8,94	5,56

Tablo 7’de görüldüğü üzere ağaç boyu, fotogrametrik nokta bulutu için ortalama 9,29 m olarak hesaplanmışken, LiDAR nokta bulutunda ise 10,91 m olarak hesaplanmıştır. Segmentasyon sonucunda Doğru Pozitif etiketli ağaç sayısının veri setlerine göre farklılık göstermesinden dolayı işleme katılan ağaç boyları tamamen aynı olmamaktadır. Dolayısıyla hesaplanan tüm metriklerde bu durum geçerli olacaktır. Göğüs yüksekliğindeki çap (GYÇ) metriğine bakıldığında ise fotogrametrik ve LiDAR nokta bulutunda sırasıyla 21,70 cm ve 24,20 cm’lik bir değer hesaplanmıştır. Özellikle ağaç gövde hacminin hesaplanması için önemli bir metrik/parametre olan GYÇ metriği nokta bulutlarından cm mertebesinde hesaplanabilmesi için mevcut allometrik denklemler (Denklem 11) kullanılmıştır. GYÇ metriğinin hesaplanması için allometrik denklemlerdeki a ve b katsayıları sırasıyla 0,102 ve 2,086 olarak seçilmiştir. Taç taban yüksekliği (TTY) metriği ise fotogrametrik nokta bulutu için ortalama 5,29 m, LiDAR nokta bulutunda ise ortalama 6,20 m olarak tahmin edilmiştir (Denklem 27). Fotogrametrik ve LiDAR nokta bulutu için taç genişliği (TG) metriği ise sırasıyla ortalama 5,01 ve 5,56 m olarak tahmin edilmektedir.


Tablo 7’de yer alan minimum ve maksimum değerlere bakıldığında aralarındaki fark (maks-min = aralık) en düşük olan veri seti metrik tahmini için en tutarlı sonuçları vermektedir. Çünkü aynı çalışma alanı içerisinde bulunan mevcut ağaçlar birbirlerine benzer metrik değerlerine sahip olması gerekmektedir. Bu aralık değerinin fazla olması veri seti içerisindeki çalışma alanını seçerken ağaç ile ilgili noktaların kesilmesinden kaynaklı olabilmektedir. Bu bilgiler doğrultusunda LiDAR nokta bulutundan tahmin edilen metrikler, fotogrametrik nokta bulutundaki tahminlere göre daha tutarlı olduğu söylenebilmektedir.

Akdeniz Üniversitesi için kullanılan veri setlerinde yapılan metrikler nicel olarak kıyaslandığında ise AB, GYÇ, TTY ve TG metriği için fotogrametrik ve LiDAR nokta

bulutu sonuçları arasında sırasıyla 1,62 m, 2,5 cm, 0,91 m ve 0,55 m'lik bir fark bulunmaktadır.

4.2. Maçka (Pilav Dağı) Ağaçlık Alanın İrdelenmesi


Maçka Pilav Dağı'ndaki iki denek alanı için LiDAR nokta bulutları ile elde edilen ağaç kümelerinden ikinci kez hatalı tespit edilen ağaçların görselleri Şekil 59'da sunulmaktadır.




Şekil 59. İstatistiksel olarak hatalı tespit edilen ağaçlar: a) denek alan 1, b) denek alan 2

Şekil 59'da görüldüğü üzere Pilav Dağı'ndaki denek alanlarında kullanılan LiDAR veri seti için istatistiksel anlamda komşu ağaçlara göre sapma yapan ağaçlar otomatik bir şekilde renklendirilmiştir. Renklendirilen hatalı ağaç kümeleri özellikle 5'li komşuluk modeli içerisinde alan bazlı istatistiksel koşullar ile analiz edildiğinde ağaç taç yapısının çok farklı geliştiği açık bir şekilde gösterilmiştir. Hatalı olarak etiketlenen ağaç kümeleri gerçekte birden fazla ağaçtan oluştuğu bilinmektedir. Seçilen test bölgesi ormanlık alan içerisinde bulunduğu için Akdeniz Üniversitesi'ndeki ağaçlık alana göre mevcut ağaçların daha karmaşık olduğu görülmektedir. Buna rağmen önerilen istatistiksel ölçütlerin ormanlık alan için uygun bir şekilde çalıştığı gözlemlenmektedir. Ormanlık alan içerisindeki veri setinin çıkarılması aşamasında ortaya çıkan problemlerin segmentasyonu doğrudan etkilediği görülmektedir.

Çalışma bölgesinde başlangıç aşamasında ağaç tepe noktalarının tespit edilmesi için kullanılan Kanopi Yükseklik Modeli ve nihai ağaç taç segmentasyonu sonucu üretilen ağaç merkezleri Şekil 60 ve 61’de karşılaştırılmıştır. Ayrıca referans ağaç merkez noktaları ortofoto üzerinde gösterilerek gerçek ağaç sayına göre karşılaştırılması da yapılmıştır.




Şekil 60. KYM ile önerilen yöntemin kıyaslanması (Maçka-1, LiDAR)




Şekil 61. KYM ile önerilen yöntemin kıyaslanması (Maçka-2, LiDAR)

Şekil 60a ve 61a’ da ki görseller incelendiğinde Kanopi Yükseklik Modeli üzerinden birçok ağacın tespit edilemediği açık bir şekilde gösterilmektedir. Şekil 60b ve 61b’de ise referans ağaç noktaları ortofotoya eklendiği zaman önerilen yaklaşım sonucu üretilen ağaç merkez noktalarına daha fazla uyum sağladığı gözlemlenmektedir. Görsel olarak yapılan bu karşılaştırmada önerilen bireysel ağaç taç segmentasyon yönteminin mevcut uygulamaya göre daha başarılı olduğu söylenebilmektedir. Görsel üzerinden yapılan analize göre birçok ağaç merkez noktasının Kanopi Yükseklik Modeli üzerinden algılanamadığı fark edilmektedir. Çalışma bölgesi yoğun ve bitişik ağaç kümeleri ile çevrelendiği için Kanopi Yükseklik Modelindeki grid çözünürlüğü parametresi değiştirilmesine rağmen bireysel ağaç sayısında herhangi bir değişiklik sağlanamamıştır. Bu yüzden ikinci iyileştirme aşamasında yeniden Bézier eğrisi ile geliştirilmiş lokal maksimum yaklaşımı kullanılarak ağaç sayısında yüksek oranda artış sağlanmıştır.

Tez çalışmasında Maçka bölgesindeki iki denek alanı için yapılan segmentasyon işlemlerinin doğruluk analizleri nesne tabanlı olarak gerçekleştirilmiştir. Önerilen yaklaşım sonucu elde edilen ağaç merkez noktaları referans noktalar ile karşılaştırılmak suretiyle regresyon analizine tabi tutulmuştur (Şekil 62 ve 63).



Şekil 62. Maçka-1 regresyon analizi: a) x koordinatı, b) y koordinatı, c) TTY metriği, d) TG metriği, e) GYÇ metriği ve f) AB metriği regresyon analizi



Şekil 63. Maçka-2 regresyon analizi: a) x koordinatı, b) y koordinatı, c) TTY metriği, d) TG metriği, e) GYÇ metriği ve f) AB metriği regresyon analizi

Test alanları için uzmanlar tarafından ölçülen ağaç metriklerinin tahmini Tablo 8 ve 9'da detaylı bir şekilde paylaşılmaktadır. Çalışma bölgesinde alan verisi olarak ağaç metrikleri doğrudan ölçüldüğü için regresyon analizine Akdeniz Üniversitesinden farklı olarak ağaç metrik bilgileri de eklenmiştir.

Tablo 8. Maçka-1 regresyon analizi ve hata değerleri

Veri türü	N	RMSE	R^2	Adj- R^2
Y koordinatı (m)	32	0,527	0,994	0,993
X koordinatı (m)	32	0,535	0,996	0,995
TTY (m)	32	0,910	0,674	0,663
TG (m)	32	0,399	0,869	0,864
GYÇ (cm)	32	4,54	0,583	0,569
AB (m)	32	0,542	0,940	0,938

Tablo 8’de Maka birinci denek alanı iin Doėru Pozitif (DP) olarak tahmin edilen aėalar iin regresyon ve hata analizi sonuları grlmektedir. Birinci denek alanında 32 adet aėa iin regresyon analizi uygulanarak tahminlerin tutarlılıėı ve ne kadar hata ile elde edildiėi hesaplanmıřtır. Maka birinci denek alanında aėa merkez noktaları iin y koordinatında yaklařık 0,52 m’lik, x koordinatında ise yaklařık 0,53 m’lik bir RMSE hata deėeri elde edilmiřtir. Genel olarak deėerlendirildiėinde ise bulunan aėa merkezlerinin yaklařık 50 cm’lik bir konumsal hata ierdiėi gzlemlenmektedir.

Aėa merkez noktalarının koordinatlarındaki R^2 ve Adj- R^2 deėerlerine bakıldıėında referans veriye gre yaklařık %99’luk model doėruluėu elde edilmiř ve konum noktalarının tutarlı olduėu anlařılmıřtır. Ta taban yksekliėi (TTY) metriėi, 0,91 m RMSE hata deėerine sahip olmakla birlikte tahmin modelinin doėruluėu yaklařık %65 seviyelerinde grlmektedir. Ta geniřliėi (TG) metriėi, 0,39 m’lik bir hata iermekte ve yaklařık %86 seviyelerinde referans veriye gre tutarlı olduėu sylenebilmektedir. Gės yksekliėindeki ap (GY) metriėi 4,54 cm hatalı tahmin edilmekte ve regresyon analizine gre %58 model doėruluėu saėlamaktadır. Aėa boyu (AB) metriėi iin ise 54 cm’lik RMSE hata deėeri hesaplanmıř ve modelin tutarlılıėı ise yaklařık %94 seviyelerinde gzlemlenmektedir.

Aėa metrikleri iin RMSE deėerleri karřılařtırıldıėında en fazla hata TTY, en az hata ise GY metriėinde ortaya ıkmıřtır. Model doėrulukları karřılařtırıldıėında ise AB metriėi en tutarlı, GY metriėi ise en tutarsız tahminleri oluřturduėu grlmektedir. Fakat GY metriėinin hata ve model doėruluėu cm mertebesinde hesaplandıėı iin diėer metriklere gre hata oranı daha yksek ıkabilmektedir.

TTY metriėi tez kapsamında geliřtirilmiř allometrik denklem aracılıėıyla tahmin edildiėi iin aėacın gvde ve kanopi/ta kısımlarını ayırt ederken yaklařık 90 cm’lik bir hata grlmektedir. Genel olarak Maka birinci denek alanı iin aėa metrik tahminlerine bakıldıėında test alanının zorluklarına raėmen uygun seviyede olduėu sylenebilmektedir.

Tablo 9. Maçka-2 regresyon analizi ve hata değerleri

Veri türü	N	RMSE	R ²	Adj-R ²
Y koordinatı (m)	27	0,601	0,991	0,991
X koordinatı (m)	27	0,611	0,991	0,990
TTY (m)	27	0,381	0,842	0,836
TG (m)	27	0,362	0,910	0,906
GYÇ (cm)	27	1,570	0,913	0,909
AB (m)	27	0,740	0,811	0,803

Tablo 9’da Maçka ikinci denek alanı için Doğru Pozitif (DP) olarak tahmin edilen ağaçlar için regresyon ve hata analizi sonuçları görülmektedir. İkinci denek alanında 27 adet ağaç için regresyon analizi uygulanarak tahminlerin tutarlılığı ve ne kadar hata ile elde edildiği hesaplanmıştır. Denek alanında ağaç merkez noktaları (x, y) için genel olarak 60 cm’lik bir konumsal hata bulunmaktadır. Ağaç merkez noktalarının regresyon analizine göre doğruluğu önceki test alanları gibi %99 seviyelerinde gözlemlenmektedir. Taç taban yüksekliği (TTY) metriği, 0,38 m RMSE hata değerine sahip olmakla birlikte tahmin modelinin doğruluğu yaklaşık %84 seviyelerinde görülmektedir. Taç genişliği (TG) metriği, 0,36 m’lik bir hata içermekte ve yaklaşık %91 seviyelerinde referans veriye göre tutarlı olduğu söylenebilmektedir. Göğüs yüksekliğindeki çap (GYÇ) metriği 1,57 cm hatalı tahmin edilmekte ve regresyon analizine göre %91 model doğruluğu sağlamaktadır. Ağaç boyu (AB) metriği için ise 74 cm’lik RMSE hata değeri hesaplanmış ve modelin tutarlılığı ise yaklaşık %81 seviyelerinde gözlemlenmektedir. Ağaç metrikleri için RMSE değerleri karşılaştırıldığında en fazla hata 74 cm ile TTY, en az hata ise 1,57 cm ile GYÇ metriğinde ortaya çıkmıştır. Model doğrulukları karşılaştırıldığında %91 ile GYÇ metriği en tutarlı, %81 ile AB metriği ise en tutarsız tahminleri oluşturduğu görülmektedir. Genel olarak Maçka ikinci denek alanı için ağaç metrik tahminlerine bakıldığında test alanının zorluklarına rağmen uygun seviyede olduğu söylenebilmektedir.

Tablo 8 ve 9’da ki iki denek alanı için sonuçlar incelendiğinde TTY, TG, GYÇ ve AB metriği için sırasıyla ortalama 64,5 cm, 38,1 cm, 3,1 cm ve 64,1 cm’lik hata değeri hesaplanmıştır. Regresyon analizine göre model doğrulukları kıyaslandığında ise TTY, TG, GYÇ ve AB metriği için sırasıyla ortalama %76, %89, %75 ve %87 ile referans veri arasında tutarlılık sağlandığı gözlemlenmektedir. RMSE hata değerleri analiz edildiğinde TTY, TG,

GYÇ metrikleri ikinci denek alanında, AB metriği ise birinci denek alanında daha doğru tahmin edilmiştir. Maçka Pilav Dağı'ndaki iki denek alanının arazi eğimleri yaklaşık %20 civarında olmakla birlikte test alanlarında çok yoğun kapalılıkta ağaçlar bulunmaktadır. Bu yüzden ağaç gövdesine ait kısıtlı noktalar bulunmasına rağmen orman envanterine katkı sağlayacak ağaç metriklerinin yüksek doğrulukla tahmin edilmesi sağlanmıştır. İlave olarak denek alanları yaklaşık 20×20 m'lik bir alandan oluştuğu için ağaç sayısı çok düşük kalmaktadır ve oluşabilecek hataların miktarı da geniş alana göre daha fazla olması beklenmektedir. Ağaç metriklerinin ormanlık alan içerisinde doğrudan ölçülmesi iş gücü ve maliyet açısından zorlu olacağından yapılan bu tahminler çalışmalara hız kazandıracaktır. Maçka Pilav Dağı'ndaki denek alanlarında orman envanteri için gerekli olan ağaç metrikleri (Ağaç boyu-AB, göğüs yüksekliğinde çap-GYÇ, taç taban yüksekliği-TTY ve taç genişliği-TG) üzerine ayrıntılı bir analiz yapılmıştır (Tablo 10 ve 11).

Tablo 10. Maçka-1 ağaç metrik tahmini

Ağaç Metrikleri	Birinci Denek Alanı			Gerçek (Referans) Değerler		
	Minimum	Maksimum	Ortalama	Minimum	Maksimum	Ortalama
AB (m)	15,47	24,88	20,86	15,30	25,30	20,76
GYÇ (cm)	18,29	44,96	31,62	16,30	43,40	28,96
TTY (m)	10,05	15,73	13,27	9,50	16,40	13,03
TG (m)	1,94	6,72	4,33	2,30	6,33	4,33

Tablo 10'da görüldüğü üzere Maçka birinci denek alanı için ağaç boyu ortalama 20,86 m olarak tahmin edilmiş iken, arazide ise 20,76 m olarak ölçülmektedir. Göğüs yüksekliğindeki çap (GYÇ) metriğine bakıldığında gerçek değerler ortalama 28,96 cm olarak görülürken, model üzerinde ortalama 31,62 cm olarak tahmin edilmektedir. Özellikle ağaç gövde hacminin hesaplanması için önemli bir metrik/parametre olan GYÇ metriği nokta bulutlarından cm mertebesinde hesaplanabilmesi için mevcut allometrik denklemler (Denklem 12) kullanılmıştır. GYÇ metriğinin hesaplanması için allometrik denklemlerdeki a ve b katsayıları sırasıyla 0,050 ve 2,086 olarak seçilmiştir. Taç taban yüksekliği (TTY) metriği, arazi üzerinde ortalama 13,03 m olarak ölçülmüşken, geliştirilen allometrik

denklemler ile ortalama 13,27 m olarak tahmin edilmiştir. Taç genişliği (TG) metriği ise hem ölçü hem de tahmin sonucunda ortalama 4,33 m olarak ortaya çıktığı gözlemlenmektedir.

Tablo 10’da yer alan minimum ve maksimum değerlere bakıldığında aralarındaki farkın (maks-min = aralık) gerçek aralık değerine yakın olması beklenilmektedir. Maçka birinci denek alanı için tahmin edilen metriklerin aralık değerleri referans ile kıyaslandığında ise AB, GYÇ, TTY ve TG metriği için sırasıyla 0,59 m, 0,43 cm, 1,22 m ve 0,75 m fark bulunmaktadır. Genel olarak bakıldığında ormanlık alan için bu hatalar doğal bir sonuç olarak görülmektedir. Ayrıca ağaç parametre/metriklerin arazi üzerinden doğrudan ölçümü esnasında da hata oluşabileceği için referans ölçülerin çok güvenilir bir veri olduğunu söylemek pek doğru olmayacaktır. Özellikle seçilen test alanı yaklaşık %20 arazi eğimine sahip olduğu için nokta bulutu üzerinden hesaplanacak ağaç metrikleri, ölçüm yapılan nokta ile direkt olarak uyuşmayabilir. Örneğin ağaç boyu için seçilecek minimum nokta, arazi eğimine bağlı olarak zeminin üst veya alt bölgesine denk gelebilmektedir. Metrik ölçümleri esnasında ölçüm yapılacak nokta ile model üzerinden hesaplanacak noktanın birbirine yakın olması tahmin doğruluğunu artırıcı yönde etkilemektedir. Kısacası arazi eğimine bağlı olarak yapılan metrik ölçümlerinin gerçek değerden uzaklaşma ihtimali bulunmaktadır.

Tablo 11. Maçka-2 ağaç metrik tahmini

Ağaç Metrikleri	İkinci Denek Alanı			Gerçek (Referans) Değerler		
	Minimum	Maksimum	Ortalama	Minimum	Maksimum	Ortalama
AB (m)	18,06	26,98	22,32	18,0	24,4	21,7
GYÇ (cm)	17,93	40,44	28,55	17,6	43,2	27,9
TTY (m)	8,44	12,81	10,69	8,1	12,1	10,64
TG (m)	1,60	6,61	4,41	2,45	7,03	4,44

Tablo 11’de görüldüğü üzere Maçka ikinci denek alanı için ağaç boyu ortalama 22,32 m olarak tahmin edilmiş iken, arazide ise 21,7 m olarak ölçülmektedir. Göğüs yüksekliğindeki çap (GYÇ) metriğine bakıldığında gerçek değerler ortalama 27,9 cm olarak görülürken, model üzerinde ortalama 28,55 cm olarak tahmin edilmektedir. GYÇ metriğinin nokta bulutlarından cm mertebesinde hesaplanabilmesi için mevcut allometrik denklemler (Denklemler 12) kullanılmıştır. GYÇ metriğinin hesaplanması için allometrik denklemlerdeki

a ve b katsayıları sırasıyla 0,051 ve 2,026 olarak seçilmiştir. Taç taban yüksekliği (TTY) metriği, arazi üzerinde ortalama 10,64 m olarak ölçülmüşken, geliştirilen allometrik denklemler ile ortalama 10,69 m olarak tahmin edilmiştir. Taç genişliği (TG) metriği ise ölçü sonucu 4,44 m, tahmin sonucunda ortalama 4,41 m olarak ortaya çıktığı gözlemlenmektedir.


Maçka ikinci denek alanı için tahmin edilen metriklerin aralık değerleri referans ile kıyaslandığında ise AB, GYÇ, TTY ve TG metriği için sırasıyla 2,52 m, 3,09 cm, 0,37 m ve 0,43 m fark bulunmaktadır.

Genel olarak bakıldığında ormanlık alan için elde edilen hatalar doğal bir sonuç olarak görülmektedir. İkinci test alanı birinci denek alanı gibi yüksek bir eğime sahip olduğu için alan verisi/ölçüsü kaba hata içermekte ve tahmin doğruluğunu negatif yönde etkilemektedir. İlave olarak ağaç boyu metriği uzmanlar tarafından lazer mesafe ölçer ile yapıldığı için lazer ışını yoğun kapalılıktaki ormanlık alanlarda tepe noktasına tam olarak ulaşamadığı zaman kaba hatalı ölçüm gerçekleşecektir.

Allometrik denklemler vasıtasıyla tahmin edilen ağaç metrikleri, ağaç boyuna bağlı olduğu için dolaylı olarak diğer metriklerde kaba hata içerebilmektedir.


4.3. İsviçre/Cenevre Ağaçlık Alanın İrdelenmesi

Cenevre çalışma alanı için LiDAR nokta bulutları ile elde edilen ağaç kümelerinden ikinci kez hatalı tespit edilen ağaçların görselleri Şekil 64'te sunulmaktadır.



Şekil 64. İstatistiksel olarak hatalı tespit edilen ağaçlar (Cenevre)

Şekil 64'te görüldüğü üzere Cenevre ağaçlık alanda kullanılan LiDAR veri seti için istatistiksel anlamda komşu ağaçlara göre sapma yapan ağaçlar otomatik bir şekilde renklendirilmiştir. Renklendirilen hatalı ağaç kümeleri özellikle 5'li komşuluk modeli içerisinde alan bazlı istatistiksel koşullar ile analiz edildiğinde ağaç taç yapısının ilk iki çalışma alanında olduğu gibi çok farklı geliştiği açık bir şekilde görülmektedir. Seçilen test alanı yoğun, geniş ve yapraksız ağaçlardan oluşmasına rağmen önerilen istatistiksel ölçütlerin diğer çalışma alanlarında olduğu gibi uygun bir şekilde çalıştığı gözlemlenmektedir. Ormanlık alan içerisindeki veri setinin çıkarılması aşamasında ortaya çıkan problemler segmentasyonu doğrudan etkilediği görülmektedir. Özellikle orman içerisinde bir çalışma alanı seçildiğinde ayarlanacak veri seti alan dışındaki ağaçların nokta verilerini de içerebileceği için komisyon veya ihmal hatalarına sebep olabilmektedir. Çalışma bölgesinin, başlangıç aşamasında ağaç tepe noktalarının tespit edilmesi için kullanılan Kanopi Yükseklik Modeli ve nihai ağaç taç segmentasyonu sonucu üretilen ağaç merkezleri Şekil 65'te karşılaştırılmıştır. Cenevre ormanlık alanın ortofoto görüntüsü mevcut olmadığı için Google Earth üzerinde ağaç merkez noktalarının konumları gösterilmiştir. LiDAR nokta bulutu üretimi 2017 yılında gerçekleştirilmiş olup ağaçlarda yaprak bulunmamaktadır. Google Earth üzerinde ağaçların yapraksız görüntüsü bulunmadığı için çalışma alanının güncel fotoğrafı eklenmiştir.



Şekil 65. KYM ile önerilen yöntemin kıyaslanması (Cenevre, LiDAR)

Şekil 65'teki görseller incelendiğinde Kanopi Yükseklik Modeli üzerinden birçok ağacın tespit edilemediği açık bir şekilde gösterilmektedir. Referans ağaç noktaları görüntüye eklendiği zaman önerilen yaklaşım sonucu üretilen ağaç merkez noktalarına daha fazla uyum sağladığı gözlemlenmektedir. Görsel olarak yapılan bu karşılaştırmada önerilen bireysel ağaç taç segmentasyon yönteminin mevcut uygulamaya göre daha başarılı olduğu söylenebilmektedir. Görsel üzerinden birçok ağaç merkez noktasının Kanopi Yükseklik Modeli üzerinden algılanamadığı fark edilmektedir.

Tez çalışmasında Cenevre ağaçlık alanı için alan verisi (referans ölçüsü) bulunmadığı için nesne tabanlı doğruluk analizi ve regresyon analizleri yapılamamıştır. Test alanı içerisinde orman envanteri için gerekli olan ağaç metrikleri (Ağaç boyu-AB, göğüs yüksekliğinde çap-GYÇ, taç taban yüksekliği-TTY ve taç genişliği-TG) üzerine geliştirilen tahminler Tablo 12'de sunulmaktadır.

Tablo 12. İsviçre/Cenevre ağaç metrik tahmini

Ağaç Metrikleri	Minimum	Maksimum	Ortalama
AB (m)	8,77	29,76	25,82
GYÇ (cm)	3,39	35,99	27,51
TTY (m)	4,97	18,03	15,58
TG (m)	0,87	15,73	5,22

Tablo 12'de görüldüğü üzere İsviçre/Cenevre için ağaç boyu ortalama 25,82 m olarak tahmin edilmektedir. Göğüs yüksekliğindeki çap (GYÇ) metriğine bakıldığında model üzerinde ortalama 27,51 cm olarak tahmin edildiği görülmektedir. GYÇ metriğinin nokta bulutlarından cm mertebesinde hesaplanabilmesi için mevcut allometrik denklemler (Denklem 12) kullanılmıştır. GYÇ metriğinin hesaplanması için allometrik denklemlerdeki a ve b katsayıları sırasıyla 0,051 ve 1,933 olarak seçilmiştir. Taç taban yüksekliği (TTY) metriği, geliştirilen allometrik denklemler ile ortalama 15,58 m olarak tahmin edilmiştir. Taç genişliği (TG) metriği ise tahmin sonucunda ortalama 5,22 m olarak ortaya çıktığı gözlemlenmektedir.

Tablo 12’de yer alan minimum ve maksimum değerlere bakıldığında aralarındaki farkın (maks-min = aralık) aynı çalışma bölgesi içerisinde çok aşırı olmaması beklenmektedir. Test alanı için tahmin edilen metriklerin aralık değerleri AB, GYÇ, TTY ve TG metriği için sırasıyla 20,99 m, 32,60 cm, 13,06 m ve 14,86 m olarak hesaplanmıştır. Mevcut çalışma sahasına ait referans ölçü bulunmadığı için bu değerlerin kontrolü yapılamamaktadır. Fakat aynı çalışma alanı içerisindeki ağaçların büyüme potansiyeli benzer nitelikte olacağı için aralık değerleri normal tahminlere göre çok aşırı bir şekilde sapmaktadır. Bu hata yanlış segmente edilen veya veri setinin oluşturulması esnasında kenar köşede kalan alan dışı ağaçlara ait noktaların işleme katılmasından kaynaklanmaktadır. Herhangi bir ağaç kümesi yanlış segmente edildiği zaman taç yapısı ve gövde yapısına ait metrikler çok küçük sayılara ulaşacaktır. Aralık değerlerinin diğer iki veri setine göre çok yüksek fark oluşturması da segmentasyon aşamasında oluşabilecek hatalı kümelerden kaynaklanmaktadır. Mevcut GYÇ ve TG metriğinin minimum değerine bakıldığında ise en az bir ağacın mutlak suretle hatalı bir şekilde segmente edildiği anlaşılmaktadır. Mevcut çalışma sahası yaprak olmayan bir alan olduğu için segmentasyon aşamasında zorlayıcı bir etkiye sahiptir.

4.4. Bireysel Ağaç Taç Segmentasyonunu Etkileyen Faktörlerin İrdelenmesi

Nokta bulutlarından (hava LiDAR ve fotogrametrik) bireysel ağaç taç segmentasyonunun gerçekleştirilmesi için en zorlayıcı faktör, yoğunluk seviyesi yüksek alanlarda ağaçların bitişik veya karmaşık yapıda olmasından dolayı ağaç tepelerinin algılanamaması ve tek bir ağaç olarak etiketlenmesidir. Ayrıca yapraksız ağaçlarda taç yapısının algılanması, yapraklı ağaçlara göre daha zordur. Özellikle çalışma alanları seçilirken alan dışındaki ağaçların nokta verilerinin ilgili bölgede bulunmasından dolayı gereğinden fazla ağaç segmente edilir veya yanlış ağaç kümesi oluşturulur. Hatalı segmentasyon, doğruluk analizi aşamasında komisyon ve ihmal hatalarının artmasını sağlayacaktır. Bu durum bireysel ağaç taç segmentasyonun doğruluğunu azaltıcı yönde etkilemektedir.

Tez kapsamında uygulanan ilk aşamada ağaç tepelerinin belirlenebilmesi için Kanopi Yükseklik Modeli (KYM) kullanılmıştır. KYM grid çözünürlüğüne bağlı olarak ağaç tepelerini algılamada farklı sonuçlar üretmesine rağmen yüksek kapalılıktaki yoğun ağaçların bulunduğu çalışma bölgelerinde çözünürlüğün etkisiz kaldığı ve birçok bitişik ağaç

kümesini tek bir bireysel ağaç olarak etiketlediği görülmektedir. Mevcut uygulamadaki Havza Bölütleme (Watershed Segmentation) algoritması KYM modeline bağlı olarak ağaçları segmente etmektedir. Dolayısıyla KYM üzerinden algılanamayan ağaç tepe noktaları yanlış segmentasyona sebep olacaktır. Çalışmada önerilen Bézier eğrisi ile geliştirilmiş lokal maksimum yaklaşımı iki farklı perspektif üzerinden ağaç profillerini inceleyerek hatalı ağaç kümelerini otomatik bir şekilde tespit etmektedir. Kullanılan Bézier eğrisi ağaç profillerinin en ideal düzeyde çizdirilebilmesi için oldukça fayda sağlamaktadır. Birinci iyileştirme aşamasında Bézier eğrisi üzerindeki lokal minimum noktalara göre bölütleme işlemi yapılmaktadır. Fakat bölütleme işleminde bazı ağaç kümelerinin taç yapısının tam olarak temsil edilemediği durumlar da mevcuttur.

Birinci iyileştirme sonucunda bütün çalışma bölgeleri için ağaç sayısında önemli derecede artış sağlanmıştır. Önerilen segmentasyon yaklaşımı özellikle bitişik ağaç kümelerini iyileştirmesine rağmen halen hata oluşturabilecek ağaç taç yapılarını alan bazlı istatistiksel koşullar ile otomatik bir şekilde tespit etmektedir. Çalışmada oluşturulan 5’li komşuluk modeli ile ağaç taç yapıları arasında topolojik bir ilişki kurulmuştur. Geliştirilen bu model tüm çalışma bölgelerinde başarılı bir şekilde sonuçlanmıştır. İkinci hatalı ağaç tespitleri istatistiksel koşullar ile sağlanarak segmentasyonu etkileyebilecek taç yapılarını ortaya çıkarmaktadır. Genel olarak topoloji içerisinde çok büyük taç yapısına sahip ağaç kümesi, hatalı ağaç olarak etiketlenmiştir. İkinci iyileştirme aşamasında tekrardan geliştirilmiş lokal maksimum algoritması veya havza bölütleme algoritması uygulanarak nihai ağaç taç segmentasyonu uygun düzeyde sağlanmıştır.

4.5. Bireysel Ağaç Taç Segmentasyon Doğruluğunun İrdelenmesi

Tez çalışmasında bireysel ağaç taç segmentasyonunun değerlendirilmesi için nesne tabanlı doğruluk analizi uygulanmıştır. Segmentasyon doğruluğunu belirleyebilmek için hesaplanan ağaç merkez noktalarının referans veri ile eşleştirilmesi gerekir. Referans ağaç merkez noktalarının tek bir bulunan ağaç merkez noktası ile eşleştirilmesi için geliştirilmiş ağaç eşleştirme modeli kullanılmıştır. Eşleştirme modeli, segmentasyon sonucu oluşan ağaç taç yapısına göre değişken yarıçaplı sembolik çemberler oluşturarak yakınlık analizi uygulamaktadır. Önerilen model, ağaç taç yapısına bağlı olarak çember oluşturduğu için daha doğru bir şekilde referans ağaç noktaları ile eşleştirme yapabilmektedir. Eğer standart yarıçapta bir çember çizilirse ağaç taç yapısından bağımsız olarak rastgele eşleştirme

yapılmış olunur. Buna rağmen literatürde ağaç eşleştirme modeli için genel olarak standart yarıçaplı (3 m) çemberler kullanıldığı gözlemlenmektedir. Fakat bu durum gereğinden fazla Doğru Pozitif (DP) etiketli nesne ürettiği için doğruluk oranını gerçek değerine göre daha yüksek göstermektedir.

Referans noktaların konumları arazi üzerinden ağaç kökünün herhangi bir bölgesinden ölçüleceği için başlangıçta gövdenin yarıçapı kadar hata direkt olarak oluşmaktadır. Ayrıca konumun ölçüleceği bölge ağaç kökünün etrafında olacağı için ekstra olarak cm mertebesinde kaba hata içerebilmektedir.

4.6. Ağaç Metrik Tahminlerinin İrdelenmesi

Ağaç metriklerinin doğru bir şekilde tahmin edilebilmesi için arazi üzerindeki ölçüm ile geliştirilen model üzerindeki ölçümlerin birbirleri arasında tutarlı olması gerekmektedir. Tez kapsamında ağaç boyu (AB), göğüs yüksekliğindeki çap (GYÇ), taç genişliği (TG) ve taç taban yüksekliği (TTY) olmak üzere dört farklı ağaç metriği/parametresi üzerine tahmin yapılmıştır. AB metriğinin ölçümü arazide lazer boy ölçer alet ile yapılmıştır. Fakat çalışma bölgelerindeki denek alanları çok yoğun kapalılıkta olduğu için ağaç dalları birçok ağacın tepe noktasını göstermesini engelleyebilmektedir. Dolayısıyla ağaç boyunu lazerin ulaşabildiği son noktaya göre hesaplayabilecektir. Nokta bulutundan ölçülen ağaç boyu, arazinin eğimine bağlı olarak cm mertebesinde kaba hatalar içerebilmektedir. GYÇ metriğinin ölçümünde ise zeminden 1,3 m yükseklikten gövde çapı ölçülmektedir. Fakat ağaç gövdelerindeki düzensiz gelişme ve büyümeler ilgili metriğin farklı konumlardan ölçülmesini gerektirmektedir. Ağaç gövdesi geometrik olarak birebir silindir olarak oluşmadığı için alan ölçüleri yine hata içerebilecektir. Nokta bulutlarından gerçekleştirilen GYÇ tahminleri ise ağaç boyu ve katsayılar (a ve b) bağlı allometrik denklemlerden türetilmiştir. Ağaç boyundaki hata ve katsayılardaki anormal değişkenlikler tahmin modelinin doğruluğunu düşürücü etkiye sahiptir. Taç genişliği metriği arazi üzerinde doğu-batı ve kuzey-güney şeklinde ölçülürken, çalışma içerisinde taç yapısına göre değişken yarıçaptaki çemberlerin çapları kullanılarak elde edilmiştir. Genel olarak taç genişliği metriği birkaç cm hata ile yüksek doğrulukta üretilmiştir. TTY metriği ağacın gövdesi ile taç yapısının birbirinden ayrıldığı yerin zemin ile arasındaki yüksekliğini ifade etmektedir. Önerilen yaklaşım üzerinde TTY metriği yeni geliştirilen allometrik denklemler yardımıyla tahmin edilmektedir. Çalışmada, girdi verisi olarak hava LiDAR ve fotogrametrik nokta

bulutları kullanıldığı için yoğun kapalılıktaki ağaçlık alanlarda bazı ağaç gövdeleri tam olarak temsil edilemeyecektir. Bu yüzden nokta bulutlarından doğrudan bir ölçüm ile ormanlık alan içerisinde GYÇ ve TTY metriğinin hesaplanması mümkün değildir. Tahminlerin gerçekleştirilebilmesi için kullanılan allometrik denklemler ağacın türüne veya büyümesine göre ağaç metrikleri arasındaki ilişkilerden yararlanılarak türetilmektedir ve mutlaka içerisinde hata bulunduracaktır.

İlave olarak bireysel ağaç taç segmentasyonu yanlış yapılan ağaç kümeleri, ağaç metrik tahmini doğruluğunu direkt olarak azaltıcı etkiye sahiptir.

4.7. Nokta Bulutlarının Segmentasyon ve Metrik Tahmini Üzerine Etkileri

Tez kapsamında bireysel ağaç taç segmentasyonu ve ağaç metrik tahmini için fotogrametrik ve hava LiDAR nokta bulutları kullanılmıştır. Kullanılan veri setinin nokta yoğunluğu çok düşük olması ağaç taç yapılarındaki tepe noktalarının algılanması aşamasında sorunlar oluşturabilmektedir. Nokta yoğunluğunun mümkün mertebede ağaç yapısını tam olarak temsil edebilecek yoğunlukta olması istenmektedir. Ayrıca nokta bulutları havadan yapılan ölçümlere bağlı olduğu için ormanlık alanlarda ağacın gövdesine ait kısıtlı bir bilgi sunabilmektedir. Dolayısıyla ağaç gövdesine ait ağaç metrikleri (TTY ve GYÇ) tahmini için doğrudan bir ölçüm yerine allometrik denklemler kullanılmaktadır.

Yersel veya mobil LiDAR verileri ağaç yapısını (gövde + taç) daha doğru bir şekilde temsil edebileceğinden dolayı bireysel ağaç taç segmentasyonu ve metrik tahmini işlemleri için daha çok tercih edilmektedir. Fakat nokta bulutu üretim aşamasında zaman ve işgücü maliyetinden dolayı araştırmacılara dezavantaj sağlamaktadır.

Derin öğrenme ve makine öğrenmesi yöntemleri ile yapılan çalışmalar ise eğitim aşamasında yoğun bir veri gereksinimi ve donanım gücü gerektireceği için hem zaman hem de maliyet açısından negatif bir etkisi bulunmasına rağmen yüksek doğrulukta sonuçlar üretebilmektedir.

5. SONUÇLAR VE ÖNERİLER

Tez kapsamında, LiDAR ve fotogrametrik nokta bulutlarından bireysel ağaç taç segmentasyonu gerçekleştirebilmek için Bézier eğrisi ile geliştirilmiş lokal maksimum yaklaşımı önerilmiş ve ağaç metrik tahminleri (AB, GYÇ, TTY ve TG) yapılmıştır. Çalışma bölgesi olarak Akdeniz Üniversitesi'ndeki ağaçlık alan, Maçka Pilav Dağı ve Cenevre/İsviçre ormanlık alanı seçilmiştir. Test alanları yoğun kapalılık düzeyine sahip olmakla birlikte birçok bitişik ağaç kümesi için iyi bir örnek teşkil etmektedir. Bireysel ağaç taç segmentasyonunu gerçekleştirmek için başlangıçta KYM modeli üzerinden ağaç tepeleri algılanmış ve Havza Bölütleme (WS) algoritması ile ilk segmentasyon gerçekleştirilmiştir. Mevcut segmentasyon yönteminin bitişik ağaç kümelerini ayırt edememesinden dolayı geliştirilmiş lokal maksimum yaklaşımı kullanılmıştır. Mevcut segmentasyon yöntemine uygulanan iyileştirme sonucunda halen hatalı segmente edilmiş ağaç kümelerinin bulunabilme ihtimaline karşın 5'li komşuluk modeli içerisinde alan bazlı istatistiksel ölçütler geliştirilmiş ve taç yapısında komşu ağaç kümelerine göre anormal farklılıklar bulunan ağaçlar, hatalı ağaç olarak otomatik bir şekilde etiketlenmiştir. Nihai ağaç taç segmentasyonu ile birlikte KYM+WS algoritmasının gerçekleştirdiği segmentasyon işlemine iki aşamalı bir iyileştirme uygulanmıştır. Bireysel ağaç taç segmentasyonunun doğruluğunu analiz etmek için referans ağaç merkez noktaları ile bulunan ağaç merkez noktaları geliştirilen eşleştirme modeli ile ilişkilendirilmiş ve nesne tabanlı doğruluk analizi uygulanmıştır. Cenevre ormanlık alan için alan ölçüsü bulunmadığından dolayı doğruluk değerlendirmesi yapılamamıştır. Yapılan analizler sonucunda segmentasyon doğruluğu Akdeniz Üniversitesi için ortalama Cp, Cr, Q, F-skor metrikleri sırasıyla %89,20, %92,54, %83,45 ve %90,84; Maçka Pilav Dağı'nda ise ortalama %80,74, %90,99, %74,55 ve %85,37 olarak hesaplanmıştır. Akdeniz Üniversitesi ve Maçka'daki veri setleri için y koordinatında ortalama 0,77 m, x koordinatında ise 0,79 m RMSE hata değeri bulunmaktadır. Ağaç metrik tahmininde Pilav Dağı'nda seçilen iki denek alanı için TTY, TG, GYÇ ve AB metriği sırasıyla 64,5 cm, 38,1 cm, 3,1 cm ve 64,1 cm RMSE hatası içermekte ve tahmin modeli doğrulukları ise sırasıyla ortalama %76, %89, %75 ve %87 olarak hesaplanmıştır. Önerilen yaklaşım bitişik ağaç kümelerinin segmentasyonu için kullanılan KYM+WS algoritmasına alternatif bir çözüm olanağı sağlamaktadır. Segmentasyon sonucunda ağaç sayısında önemli derecede artış sağlandığı görülmektedir.

Gelecekteki alıřmalarda bireysel aėa ta segmentasyonu, aėa trlerinin sınıflandırılması ve aėa hacminin belirlenmesi iin gereken aėa metriklerinin de tahmin edilmesi zerine yoėunlařılacaktır. Bu konu hususunda derin ėrenme yntemleri kullanarak ormanlık alanlarda aėa trnn ve metriklerin ıkarılması zerine alıřmalar yapılması hedeflenmektedir.



6. KAYNAKLAR

- Acar, H., 2018. Bina Çatı Noktalarının Yüksek Çözünürlüklü Görüntülerden Üretilen 3B Nokta Bulutu Verileri ile Otomatik Tespit Edilmesi ve Gerçek Ortofoto Üretimi, Doktora Tezi, K.T.Ü. Fen Bilimleri Enstitüsü, Trabzon.
- Arslan, A. E., İnan, M., Çelik, M. F. ve Erten, E., 2022. Point Cloud Data from Terrestrial Laser Scanning, Unmanned Aerial Vehicle and Aerial LiDAR Data: Estimations of Forest Stand Parameters in Open Forest Stand, European Journal of Forest Engineering, 8, 2, 46-54.
- Bahadır, M., Yıldırım, F. S. ve Karşlı, F., 2022. Görüntü Eşleştirme ve LiDAR Kaynaklı Nokta Bulutundan Orman Metriklerinin Otomatik Belirlenmesi, 8. UZAL-CBS Sempozyumu, Kasım, Ankara, Bildiriler Kitabı: 12831.
- Banerjee, B. P. ve Raval, S., 2022. Mapping Sensitive Vegetation Communities in Mining Eco-Space Using UAV-LiDAR, International Journal of Coal Science and Technology, 9, 1.
- Basuki, T. M., Van Laake, P. E., Skidmore, A. K. ve Hussin, Y. A., 2009. Allometric Equations for Estimating the Above-Ground Biomass in Tropical Lowland Dipterocarp Forests, Forest Ecology and Management, 257, 8, 1684-1694.
- Bauwens, S., Bartholomeus, H., Calders, K. ve Lejeune, P., 2016. Forest Inventory with Terrestrial LiDAR: A Comparison of Static and Hand-Held Mobile Laser Scanning, Forests, 7, 12, 127.
- Belcore, E. ve Latella, M., 2022. Riparian Ecosystems Mapping at Fine Scale: A Density Approach Based on Multi-Temporal UAV Photogrammetric Point Clouds, Remote Sensing in Ecology and Conservation, 8, 5, 644-655.
- Bennett, L., Wilson, B., Selland, S., Qian, L., Wood, M., Zhao, H. ve Boisvert, J., 2022. Image to Attribute Model for Trees (ITAM-T): Individual Tree Detection and Classification in Alberta Boreal Forest for Wildland Fire Fuel Characterization, International Journal of Remote Sensing, 43, 5, 1848-1880.
- Bienert, A., Georgi, L., Kunz, M., Maas, H.-G. ve Von Oheimb, G., 2018. Comparison and Combination of Mobile and Terrestrial Laser Scanning for Natural Forest Inventories, Forests, 9, 7, 395.
- Chen, Q., Baldocchi, D., Gong, P. ve Kelly, M., 2006. Isolating Individual Trees in a Savanna Woodland Using Small Footprint LiDAR Data, Photogrammetric Engineering & Remote Sensing, 72, 8, 923-932.
- Chen, J., Chen, Y. ve Liu, Z., 2021. Classification of Typical Tree Species in Laser Point Cloud Based on Deep Learning, Remote Sensing, 13, 23.

- Chen, J., Chen, Y. ve Liu, Z., 2022. Extraction of Forestry Parameters Based on Multi-Platform LiDAR, IEEE Access, 10, 21077-21094.
- Dybedal, J., Aalerud, A. ve Hovland, G., 2019. Embedded Processing and Compression of 3D Sensor Data for Large Scale Industrial Environments, Sensors, 19, 3, 636.
- Ester, M., Kriegel, H. P., Sander, J. ve Xu, X., 1996. A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise, 96, 34, 226-231.
- Feng, B., Nie, S., Wang, C., Xi, X., Wang, J., Zhou, G. ve Wang, H., 2022. Exploring the Potential of UAV LiDAR Data for Trunk Point Extraction and Direct DBH Measurement, Remote Sensing, 14, 12.
- Freudenberg, M., Magdon, P. ve Nölke, N., 2022. Individual Tree Crown Delineation in High-Resolution Remote Sensing Images Based on U-Net, Neural Computing and Applications, 34, 24, 22197-22207.
- Fu, H., Li, H., Dong, Y., Xu, F. ve Chen, F., 2022. Segmenting Individual Tree from TLS Point Clouds Using Improved DBSCAN, Forests, 13, 4.
- Gollob, C., Ritter, T. ve Nothdurft, A., 2020. Forest Inventory with Long Range and High-Speed Personal Laser Scanning (PLS) and Simultaneous Localization and Mapping (SLAM) Technology, Remote Sensing, 12, 9, 1509.
- Gonzalez-Aguilera, D., Rodriguez-Gonzalvez, P. ve Gomez-Lahoz, J., 2010. Camera and Laser Robust Integration in Engineering and Architecture Applications, Sensor Fusion and its Applications.
- Guo, Y., Zhang, H., Li, Q., Lin, Y. ve Michalski, J., 2022. New Morphological Features for Urban Tree Species Identification Using LiDAR Point Clouds, Urban Forestry and Urban Greening, 71.
- Gülci, N., Akay, A.E., Erdaş, O., Wing, M. ve Session, J., 2015. Planning Optimum Logging Operations Through Precision Forestry Approaches, European Journal of Forest Engineering, 1, 2, 56-60.
- Han, X.-A., Ma, Y. ve Huang, X., 2008. A Novel Generalization of Bézier Curve and Surface, Journal of Computational and Applied Mathematics, 217, 1, 180-193.
- Hao, Y., Widagdo, F. R. A., Liu, X., Liu, Y., Dong, L. ve Li, F., 2022. A Hierarchical Region-Merging Algorithm for 3-D Segmentation of Individual Trees Using UAV-LiDAR Point Clouds, IEEE Transactions on Geoscience and Remote Sensing, 60.
- Harikumar, A., Liang, X., Bovolo, F. ve Bruzzone, L., 2022. Void-Volume-Based Stem Geometric Modeling and Branch-Knot Localization in Terrestrial Laser Scanning Data, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 15, 3024-3040.

- Herrero-Huerta, M., Lindenbergh, R. ve Rodríguez-Gonzálvez, P., 2018. Automatic Tree Parameter Extraction by a Mobile LiDAR System in an Urban Context, Plos One, 13, 4.
- Hershey, J. L., McDill, M. E., Miller, D. A., Holderman, B. ve Michael, J. H., 2022. A Voxel-Based Individual Tree Stem Detection Method Using Airborne LiDAR in Mature Northeastern U.S. Forests, Remote Sensing, 14, 3.
- Hirschmuller, H., 2008. Stereo Processing by Semiglobal Matching and Mutual Information, IEEE Transactions on Pattern Analysis and Machine Intelligence, 30, 2, 328-341.
- Hirschmüller, H., 2011. Semi-Global Matching-Motivation, Developments and Applications, Photogrammetric Week, 11, 173-184.
- Hirschmüller, H., Buder, M. ve Ernst, I., 2012. Memory Efficient Semi-Global Matching, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 3, 371-376.
- Holmgren, J., Lindberg, E., Olofsson, K. ve Persson, H. J., 2022. Tree Crown Segmentation in Three Dimensions Using Density Models Derived from Airborne Laser Scanning, International Journal of Remote Sensing, 43, 1, 299-329.
- Hu, X., Chen, W. ve Xu, W., 2017. Adaptive Mean Shift-Based Identification of Individual Trees Using Airborne LiDAR Data, Remote Sensing, 9, 2, 148.
- Huang, X., Han, Y. ve Hu, K., 2020. An Improved Semi-Global Matching Method with Optimized Matching Aggregation Constraint, IOP Conference Series: Earth and Environmental Science, Eylül, Chengdu/Çin, 569, 1, 012050.
- Huo, L., Lindberg, E. ve Holmgren, J., 2022. Towards Low Vegetation Identification: A New Method for Tree Crown Segmentation from LiDAR Data Based on a Symmetrical Structure Detection Algorithm (SSD), Remote Sensing of Environment, 270.
- Hussain, M. Z., Hussain, M. ve Waseem, A., 2014. Shape-Preserving Trigonometric Functions, Computational and Applied Mathematics, 33, 2, 411-431.
- Hyypä, E., Kukko, A., Kaartinen, H., Yu, X., Muhojoki, J., Hakala, T. ve Hyypä, J., 2022. Direct and Automatic Measurements of Stem Curve and Volume Using a High-Resolution Airborne Laser Scanning System, Science of Remote Sensing, 5, 100050.
- Kangas, A., Astrup, R., Breidenbach, J., Fridman, J., Gobakken, T., Korhonen, K. T. ve Olsson, H., 2018. Remote Sensing and Forest Inventories in Nordic Countries – Roadmap for the Future, Scandinavian Journal of Forest Research, 33, 4, 397-412.
- Karşlı, B., 2022. Fotogrametrik Görüntü Tabanlı Nokta Bulutu Üzerinden Otomatik Bina Çıkarımı ve Sayısallaştırma, Yüksek Lisans Tezi, Aksaray Üniversitesi, Fen Bilimleri Enstitüsü, Aksaray.

- Konecny, G., 2002. Geoinformation, London, 1. Baskı.
- Lei, L., Yin, T., Chai, G., Li, Y., Wang, Y., Jia, X. ve Zhang, X., 2022. "A Novel Algorithm of Individual Tree Crowns Segmentation Considering Three-Dimensional Canopy Attributes Using UAV Oblique Photos, International Journal of Applied Earth Observation and Geoinformation, 112.
- Liang, X., Kukko, A., Kaartinen, H., Hyypä, J., Yu, X., Jaakkola, A. ve Wang, Y., 2014. Possibilities of a Personal Laser Scanning System for Forest Mapping and Ecosystem Services, Sensors, 14, 1, 1228-1248.
- Linder, W., 2016. Digital Photogrammetry: A Practical Course, Springer, Berlin, 4. Baskı.
- Liu, B., Huang, H., Tian, X. ve Ren, M., 2022. Individual Tree Species Classification Using the Pointwise MLP-Based Point Cloud Deep Learning Method, MDPI AG, 19.
- Liu, M., Han, Z., Chen, Y., Liu, Z. ve Han, Y., 2021. Tree Species Classification of LiDAR Data Based On 3D Deep Learning, Measurement, 177, 109301.
- Ma, Q., Su, Y. ve Guo, Q., 2017. Comparison of Canopy Cover Estimations From Airborne LiDAR, Aerial Imagery, and Satellite Imagery, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 10, 9, 4225-4236.
- Maqsood, S., Abbas, M., Miura, K. T., Majeed, A., BiBi, S. ve Nazir, T., 2021. Geometric Modeling of Some Engineering GBT-Bézier Surfaces with Shape Parameters and Their Applications, Advances in Difference Equations, 1, 490.
- Meddens, A. J. H., Vierling, L. A., Eitel, J. U. H., Jennewein, J. S., White, J. C. ve Wulder, M. A., 2018. Developing 5 m Resolution Canopy Height and Digital Terrain Models from WorldView and ArcticDEM Data, Remote Sensing of Environment, 218, 174-188.
- Mohan, M., Silva, C.A., Klauberg, C., Jat, P., Catts, G., Cardil, A., Hudak, A.T. ve Dia, M., 2017. Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest, Forests, 8, 9, 340.
- Næsset, E., Gobakken, T., Holmgren, J., Hyypä, H., Hyypä, J., Maltamo, M., Nilsson, M., Olsson, H., Persson, A. ve Söderman, U., 2004. Laser Scanning of Forest Resources: The Nordic Experience, Scandinavian Journal of Forest Research, 19,6, 482-499.
- Natesan, S., Armenakis, C. ve Vepakomma, U., 2020. Individual Tree Species Identification Using Dense Convolutional Network (Densenet) on Multitemporal RGB Images From UAV, Journal of Unmanned Vehicle Systems, 8, 4, 310-333.
- Navarro, J. A., Fernández-Landa, A., Tomé, J. L., Guillén-Climent, M. L. ve Ojeda, J. C., 2018. Testing The Quality of Forest Variable Estimation Using Dense Image Matching: A Comparison with Airborne Laser Scanning in a Mediterranean Pine Forest, International Journal of Remote Sensing, 39, 14, 4744-4760.

- Novotný, J., Navrátilová, B., Janoutová, R., Oulehle, F. ve Homolová, L., 2020. Influence of Site-Specific Conditions on Estimation of Forest Above Ground Biomass from Airborne Laser Scanning, Forests, 11, 3, 268.
- Ozdarici-Ok, A., Ok, A. O., Zeybek, M. ve Atesoglu, A., 2022. Automated Extraction and Validation of Stone Pine (*Pinus pinea* L.) Trees From UAV-Based Digital Surface Models, Geo-Spatial Information Science, 1-21.
- Ozdemir, E., Karsli, F., Kavzoglu, T., Bahadir, M. ve Yagmahan, A., 2022. A Novel Algorithm for Regularization of Building Footprints Using Raw LiDAR Point Clouds, Geocarto International, 37,25, 7358-7380.
- Panagiotidis, D., Abdollahnejad, A. ve Slavík, M., 2022. 3D Point Cloud Fusion From UAV and TLS to Assess Temperate Managed Forest Structures, International Journal of Applied Earth Observation and Geoinformation, 112.
- Pearse, G. D., Dash, J. P., Persson, H. J. ve Watt, M. S., 2018. Comparison of High-Density LiDAR and Satellite Photogrammetry for Forest Inventory, ISPRS Journal of Photogrammetry and Remote Sensing, 142, 257-267.
- Pingel, T. J., Clarke, K. C. ve McBride, W. A., 2013. An Improved Simple Morphological Filter for The Terrain Classification of Airborne LiDAR Data, ISPRS Journal of Photogrammetry and Remote Sensing, 77, 21-30.
- Pires, R. de P., Olofsson, K., Persson, H. J., Lindberg, E. ve Holmgren, J., 2022. Individual Tree Detection and Estimation of Stem Attributes with Mobile Laser Scanning Along Boreal Forest Roads, ISPRS Journal of Photogrammetry and Remote Sensing, 187, 211-224.
- Pitkänen, J., Maltamo, M., Hyypä, J. ve Yu, X., 2004. Adaptive Methods for Individual Tree Detection on Airborne Laser Based Canopy Height Model, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 36, 8, 187-191.
- Qin, H., Zhou, W., Yao, Y. ve Wang, W., 2022. Individual Tree Segmentation and Tree Species Classification in Subtropical Broadleaf Forests Using UAV-Based LiDAR, Hyperspectral, and Ultrahigh-Resolution RGB Data, Remote Sensing of Environment, 280.
- Richardson, J. J., Moskal, L. M. ve Kim, S. H., 2009. Modeling Approaches To Estimate Effective Leaf Area Index From Aerial Discrete-Return LiDAR, Agricultural and Forest Meteorology, 149, 6-7, 1152-1160.
- Rudge, M. L. M., Levick, S. R., Bartolo, R. E. ve Erskine, P. D., 2021. Modelling The Diameter Distribution of Savanna Trees with Drone-Based LiDAR, Remote Sensing, 13, 7.

- Sassu, A., Ghiani, L., Salvati, L., Mercenaro, L., Deidda, A. ve Gambella, F., 2021. Integrating UAVs and Canopy Height Models in Vineyard Management: A Time-Space Approach, Remote Sensing, 14, 1, 130.
- Sumnall, M. J., Hill, R. A. ve Hinsley, S. A., 2022. Towards Forest Condition Assessment: Evaluating Small-Footprint Full-Waveform Airborne Laser Scanning Data for Deriving Forest Structural and Compositional Metrics, Remote Sensing, 14, 20.
- Tienaho, N., Yrttimaa, T., Kankare, V., Vastaranta, M., Luoma, V., Honkavaara, E., Koivumäki, N., Huuskonen, S., Hynynen, J., Holopainen, M. ve Hyyppä, J., 2022. Assessing Structural Complexity of Individual Scots Pine Trees by Comparing Terrestrial Laser Scanning and Photogrammetric Point Clouds, Forests, 13, 8, 1305.
- Tockner, A., Gollob, C., Kraßnitzer, R., Ritter, T. ve Nothdurft, A., 2022. Automatic Tree Crown Segmentation Using Dense Forest Point Clouds From Personal Laser Scanning (PLS). International Journal of Applied Earth Observation and Geoinformation, 114.
- Tran, T. N., Drab, K. ve Daszykowski, M., 2013. Revised DBSCAN Algorithm to Cluster Data with Dense Adjacent Clusters, Chemometrics and Intelligent Laboratory Systems, 120, 92-96.
- URL-1, <http://www.rslab.se/category/equipment/page/2/>. 10 Mayıs 2023.
- URL-2, <https://www.woodworkingnetwork.com/video/terrestrial-laser-scanners-collect-forest-data-awesome-animation>. 12 Mayıs 2023.
- URL-3, <https://www.businesswire.com/news/home/20200825005078/en/GeoSLAMs-ZEB-Go-Launches-A-New-Era-For-Mobile-SLAM>. 12 Mayıs 2023.
- URL-4, <https://en.wikipedia.org/wiki/DBSCAN>. 12 Mayıs 2023.
- URL-5, https://en.wikipedia.org/wiki/B%C3%A9zier_curve. 15 Mayıs 2023.
- URL-6, <https://www.earthdatascience.org/>. 18 Mayıs 2023.
- URL-7, <https://www.geeksforgeeks.org/ml-mean-shift-clustering/>. 25 Mayıs 2023.
- URL-8, <https://journals.sagepub.com>. 20 Mayıs 2023.
- Vosselman, G., Kessels, P. ve Gorte, B., 2005. The Utilisation of Airborne Laser Scanning for Mapping, International Journal of Applied Earth Observation and Geoinformation, 6, 3-4, 177-186.
- Xu, Y., Hu, C. ve Xie, Y., 2022. An Improved Space Colonization Algorithm With DBSCAN Clustering for a Single Tree Skeleton Extraction, International Journal of Remote Sensing, 43, 10, 3692-3713.

- Yadav, B. K. V., Lucieer, A., Baker, S. C. ve Jordan, G. J., 2021. Tree Crown Segmentation and Species Classification in a Wet Eucalypt Forest From Airborne Hyperspectral and LiDAR Data, International Journal of Remote Sensing, 42, 20, 7952-7977.
- Yastıklı, N. ve Bayraktar, H., 2014. Yoğun Görüntü Eşleme Algoritmaları ile Yüksek Çözünürlüklü Sayısal Yüzey Modeli Üretimi, 5. UZAL-CBS Sempozyumu, Ekim, İstanbul, Bildiriler Kitabı: 40.
- Yılmaz, V., 2017. Estimating Basic Forest Stand Parameters From UAS Images, Doktora Tezi, K.T.Ü, Fen Bilimleri Enstitüsü, Trabzon.
- Yu, K., Hao, Z., Post, C.J., Mikhailova, E.A., Lin, L., Zhao, G., Tian, S. ve Liu, J., 2022. Comparison of Classical Methods and Mask R-CNN for Automatic Tree Detection and Mapping Using UAV Imagery, Remote Sensing, 14, 2, 295.
- Yun, T., Jiang, K., Li, G., Eichhorn, M.P., Fan, J., Liu, F., Chen, B., An, F. ve Cao, L., 2021. Individual Tree Crown Segmentation From Airborne Lidar Data Using a Novel Gaussian Filter and Energy Function Minimization-Based Approach, Remote Sensing of Environment, 256, 112307.
- Zhou, T., dos Santos, R. C., Liu, J., Lin, Y. C., Fei, W. C., Fei, S., ve Habib, A., 2022. Comparative Evaluation of a Newly Developed Trunk-Based Tree Detection/Localization Strategy on Leaf-Off LiDAR Point Clouds with Varying Characteristics, Remote Sensing, 14, 15.

ÖZGEÇMİŞ

İlk ve orta öğrenimini Mehmet Akif Ersoy İlköğretim Okulu'nda, Lise eğitimini ise Mithatpaşa Anadolu Lisesi'nde tamamladı. 2016 yılında Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü'nde lisans eğitimine başlayıp 2020 yılında bölüm birinciliği ile mezun oldu. Yüksek lisans eğitimine 2020 yılında Karadeniz Teknik Üniversitesi'nde başladı. Yabancı dil olarak orta düzeyde (B1-B2) İngilizce bilmektedir.

İş deneyimi olarak Sakarya ilinde yer alan KOTAŞ ve SAKARYA Harita Mühendislik Bürolarında 80 gün, Harita Genel Müdürlüğü'nde ise 30 gün olmak üzere toplam 110 günlük stajyerlik deneyimi bulunmaktadır. 2021 yılında Lisans Bitirme tezini geliştirerek "*A Novel Algorithm for Regularization of Building Footprints Using Raw LiDAR Point Clouds*" isimli ilk SCI Makalesi yayımlanmıştır. Ayrıca Yüksek Lisans eğitimi devam ederken "*MÖ. 401-400 Yılında Onbinler'in ve 1461 Yılında Fatih Sultan Mehmet'in Karadeniz'e Varış Güzergâhlarının Tespit Edilerek Modellendirilip Coğrafi İşaretlerle Belirlenmesi*" adlı TUBİTAK COST projesinde 5 ay bursiyer olarak çalıştı.

Yüksek Lisans tez çalışmasının giriş aşamalarını TUFUAB 2022 Teknik Sempozyumu'nda sundu ve sonrasında tez çalışmasını KTÜ Fotogrametri ve Uzaktan Algılama Laboratuvarı'ndaki ekip arkadaşı ile geliştirerek Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'nın düzenlediği UZAL-CBS 2022 Sempozyumu'nda En İyi Sözlü Sunum alanında ikincilik ödülü kazandı.