

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

HAVA LİDAR VERİLERİNDEN MEŞÇERE PARAMETRE KESTİRİMİ
VE AĞAÇ TÜRÜ TAHMİNİ

DOKTORA TEZİ

Tolga ODABAŞ

ŞUBAT 2025
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

HAVA LİDAR VERİLERİNDEN MEŞÇERE PARAMETRE KESTİRİMİ
VE AĞAÇ TÜRÜ TAHMİNİ

Tolga ODABAŞ

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (HARİTA MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 11 / 03 / 2025

Tezin Savunma Tarihi : 18 / 04 / 2025

Tez Danışmanı : Prof. Dr. Fevzi KARSLI

Trabzon 2025

ÖNSÖZ

“Hava LiDAR Verilerinden Meşçere Parametre Kestirimi ve Ağaç Türü Tahmini” başlıklı bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Doktora Programı’nda Doktora Tezi olarak hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilim insanı olma yolundaki ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Prof. Dr. Fevzi KARSLI’ya teşekkürü bir borç bilirim. Ayrıca, yapıcı eleştirileri ve önerileri ile tezime büyük katkıları bulunan saygıdeğer hocalarım Sayın Doç. Dr. Uzay KARAHALİL’e ve Sayın Dr. Öğr. Üyesi Hayrettin ACAR’a, eğitim öğretim hayatımda katkısı olan tüm hocalarıma ve ortak olarak çalışmalar yürüttüğümüz ve tez çalışması süresinde de hiçbir yardımdan kaçınmayan arkadaşlarıma teşekkürü borç bilirim. Saha çalışmalarında veri temini konusunda verdikleri destek için Ordu Büyükşehir Belediyesi İmar ve Şehircilik Dairesi Başkanlığı’nda görev yapan Harita Yüksek Mühendisi Murat Aygün Bey’e ve çalışma alanına ait referans verilerinin elde edilmesinde bana eşlik eden öğrencilerime içten teşekkürlerimi sunarım.

Son olarak, doğduğum günden beri elimi hiç bırakmayan, hayatım boyunca aldığım tüm kararlarda bilgi ve tecrübelerinden faydalandığım ve her kararında arkamda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan annem Hayriye ODABAŞ ve babam Kadir ODABAŞ’a, aynı zamanda Mürüvvet AKTAŞ ve Uğur AKTAŞ’a teşekkür eder, minnettarlığımı sunarım. Bu süreçte bana olan desteğini bir an olsun bırakmayan sevgili eşim Açelya AKTAŞ ODABAŞ’a ve moral kaynağım kızım Öykü ODABAŞ’a ne kadar teşekkür etsem azdır.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

“Uygarlığın temelinde ağaç, çiçek ve yeşillik bulunmaktadır. Bunlarsız uygarlığın korunması olası değildir”.

Tolga ODABAŞ

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Hava LiDAR Verilerinden Meşçere Parametre Kestirimi ve Ağaç Türü Tahmini” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Fevzi KARSLI’nın sorumluluğunda tamamladığımı, verilerimi kendim topladığımı, analizleri kendim yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 18/04/2025

Tolga ODABAŞ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XV
SEMBOLLER VE KISALTMALAR DİZİNİ	XVII
1. GENEL BİLGİLER	1
1.1. Problemin Tanımı.....	6
1.2. Çalışmanın Amacı	6
1.3. Tezin Ana Hattı	7
1.3. Literatür Özeti	8
2. TEMEL KAVRAMLAR.....	14
2.1. LiDAR Teknolojisi ve Tarihi Gelişimi	14
2.2. LiDAR Nokta Bulutu Verileri.....	23
2.3. Nokta Bulutu Sınıflandırması.....	27
2.3.1. Model Uyumuna Dayalı Nokta Bulutu Sınıflandırması	27
2.3.2. Bölge Büyümesine Dayalı Nokta Bulutu Sınıflandırması	28
2.3.3. Kümeleme Tabanlı Nokta Bulutu Sınıflandırması.....	30
2.3.4. Hiyerarşik Nokta Bulutu Sınıflandırması	32
2.3.5. Makine Öğrenmesine Dayalı Nokta Bulutu Sınıflandırması	33
2.3.6. Derin Öğrenme Tabanlı Nokta Bulutu Sınıflandırması	34
2.3.7. Zemin Sınıflandırması (PMF ve CSF Algoritmaları)	34
2.4. LiDAR Veri Filtreleme ve Sayısal Yükseklik Modeli Oluşturma	37
2.4.1. Eğim Tabanlı Filtreleme Yöntemleri	39
2.4.2. Morfolojik Filtreleme Yöntemleri	40
2.4.3. Enterpolasyon Tabanlı Filtreleme Algoritmaları	43
2.4.4. Aşamalı Yoğunlaştırma Filtreleme Yöntemleri.....	45
2.4.5. Segmentasyona Dayalı Filtreleme Yöntemleri	47

2.4.6.	Derin Öğrenme Tabanlı Filtreleme Yöntemleri.....	48
2.4.7.	Sayısal Yükseklik Modeli (SYM) Enterpolasyon Yöntemleri	51
2.5.	Orman Yapısal Nitelik Çıkarımı	53
2.5.1.	Meşçere Boyu ve Kapalılık Tespiti.....	53
2.5.2.	Meşçere Boy Profili	55
2.5.3.	Yoğunluk Profili	56
2.5.4.	Regresyon Tabanlı Yapısal Nitelik Çıkarımı.....	57
2.6.	Bireysel Ağaç Segmentasyonu.....	58
2.6.1.	Meşçere Boy Modeli Tabanlı Bireysel Ağaç Segmentasyonu.....	58
2.6.2.	Hava LiDAR Verilerine Dayalı Nokta Bulutu Tabanlı Bireysel Ağaç Segmentasyonu	60
2.6.3.	Nokta Bulutu ve Meşçere Boy Modeli Tabanlı Bireysel Ağaç Segmentasyon Algoritmalarının Karşılaştırılması	62
2.6.4.	Derin Öğrenme Kullanılarak Bireysel Ağaç Segmentasyonu.....	64
2.7.	Ağaç Türü Sınıflandırması	65
2.7.1.	Bireysel Ağaç Düzeyinde Ağaç Türü Sınıflandırması.....	66
2.7.2.	Topluluk Düzeyinde Ağaç Türü Sınıflandırması.....	67
2.8.	Bireysel Ağaç Segmentasyon Algoritmaları	67
2.8.1.	Dalponte2016 Algoritması.....	68
2.8.2.	Silva2016 Algoritması	69
2.8.3.	Watershed Algoritması	70
2.8.4.	Li2012 Algoritması	71
2.8.5.	DBSCAN Algoritması	72
2.8.6.	K-Means Algoritması.....	73
2.8.7.	Gaussian Mixture Models (GMM) Algoritması	73
2.9.	Derin Öğrenme	74
2.9.1.	PointNet	76
2.9.2.	PointNet++	77
2.9.3.	Dinamik Grafik Evrişimsel Sinir Ağı	78
3.	YAPILAN ÇALIŞMALAR.....	80
3.1.	Çalışma Alanı ve Kullanılan Veri	82
3.1.1.	Çalışma Alanı.....	82
3.1.2.	Veri Seti	87
3.2.	Sınıflandırma (Classification)	93
3.3.	Meşçere Boy Modeli (Canopy Height Model).....	102

3.3.1. Nokta Bulutu Tabanlı Meşçere Boy Modeli	104
3.3.2. Raster Tabanlı Meşçere Boy Modeli	110
3.3.3. Çalışma Alanına Ait Meşçere Boy Haritasının Yapay Zekâ ile Üretilmesi.....	115
3.4. Bireysel Ağaç Segmentasyonu (Individual Tree Segmentation)	117
3.4.1. Nokta Bulutu Tabanlı Segmentasyon (Kümeleme)	117
3.4.2. Raster Tabanlı Segmentasyon	122
3.4.3. Referans Verisinin Üretilmesi.....	128
3.4.4. Segmentasyon İyileştirilmesi	131
3.5. Meşçere Parametre (Bileşenlerinin) Kestirimi	133
3.6. Ağaç Türü Tahmini	151
3.6.1. PointNet Mimarisi.....	153
3.6.2. PoinNet++ Mimarisi.....	156
3.6.3. DGCNN Mimarisi.....	159
4. BULGULAR VE İRDELEME	162
4.1. Nokta Bulutu Verilerinin İrdelenmesi	162
4.2. Sınıflandırma Yöntemlerinin İrdelenmesi.....	164
4.3. Meşçere Boy Modelinin İrdelenmesi	166
4.4. Segmentasyon Yöntemlerinin İrdelenmesi	169
4.5. Meşçere Bileşenlerinin İrdelenmesi	172
4.6. Ağaç Türü Tahmini İrdelenmesi.....	174
5. TARTIŞMA	177
6. SONUÇLAR.....	181
7. ÖNERİLER.....	184
8. KAYNAKLAR	186
9. EKLER.....	204
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

HAVA LiDAR VERİLERİNDEN MEŞÇERE PARAMETRE KESTİRİMİ VE AĞAÇ TÜRÜ TAHMİNİ

Tolga ODABAŞ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Fevzi KARSLI
2025, 204 Sayfa

Gelişen uzaktan algılama teknolojileri, orman ekosistemlerinin izlenmesi ve yönetimini daha hassas ve verimli hale getirmiştir. Bu bağlamda, LiDAR teknolojisi, ağaçların üç boyutlu konumunu ve yapısal özelliklerini güvenilir biçimde belirleme olanağı sunmaktadır. Ancak, ağaç türü tespitinde LiDAR verilerinin sınırlı olduğu ve genellikle ek veri ya da yöntemlerle desteklenmesi gerektiği bilinmektedir. Bu çalışmada, hava LiDAR verileri kullanılarak meşçere parametreleri (ağaç boyu, gövde çapı, tepe çapı, tepe alanı, gövde hacmi ve tepe hacmi) belirlenmiş ve optik veri kullanılmadan ağaç türü sınıflandırması gerçekleştirilmiştir. Ladin (*Picea orientalis*), Kayın (*Fagus orientalis*) ve kuru ladin bireyleri üzerinde odaklanılmış; PointNet, PointNet++ ve DGCNN algoritmaları sırasıyla %86, %94 ve %89 doğrulukla tür sınıflandırması yapmıştır. Ayrıca, birinci kapalılık düzeyinden elde edilen referans verilerle kurulan Rastgele Orman ($R^2=0.95$) ve Aşırı Gradyan Artırma ($R^2=0.92$) modelleriyle diğer kapalılık sınıfındaki bireylerin gövde çapları 3–5 cm hata payıyla tahmin edilmiştir. Segmentasyon başarısı ladin bireylerinde yüksek çıkarken, yayvan taç yapısına sahip kayın ağaçlarında daha düşük doğruluk elde edilmiştir. Tepe kapalılığı yüksek alanlarda bireysel ayrıştırma zorlaşsa da, farklı kapalılık sınıfından elde edilen verilerle güvenilir meşçere parametreleri ve ağaç türü tahmini yapılabildiği gösterilmiştir.

Anahtar Kelimeler: Nokta bulutu, Havadan LiDAR, Meşçere parametreleri, Ağaç türü

PhD. Thesis

SUMMARY

ESTIMATION OF STAND PARAMETERS AND TREE SPECIES CLASSIFICATION FROM AIRBORNE LiDAR DATA

Tolga ODABAŞ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Geomatics Engineering Department
Supervisor: Prof. Dr. Fevzi KARSLI
2025, 204 Pages

Developing remote sensing technologies have made the monitoring and management of forest ecosystems more sensitive and efficient. In this context, LiDAR technology offers the opportunity to reliably determine the three-dimensional position and structural properties of trees. However, it is known that LiDAR data is limited in tree species determination and generally needs to be supported by additional data or methods. In this study, stand parameters (tree height, trunk diameter, crown diameter, crown area, trunk volume and crown volume) were determined using airborne LiDAR data and tree species classification was performed without using optical data. Focusing on spruce (*Picea orientalis*), beech (*Fagus orientalis*) and dry spruce individuals; PointNet, PointNet++ and DGCNN algorithms performed species classification with 86%, 94% and 89% accuracy, respectively. In addition, trunk diameters of individuals in other closure classes were estimated with a 3–5 cm error margin using Random Forest ($R^2=0.95$) and Extreme Gradient Boosting ($R^2=0.92$) models established with reference data obtained from the first closure level. While the segmentation success was high in spruce individuals, lower accuracy was obtained in beech trees with a broad crown structure. Although individual separation becomes difficult in areas with high crown closure, it has been shown that reliable stand parameters and tree species estimation can be made with data obtained from different closure classes.

Key Words: Point cloud, Airborne LiDAR, Stand parameters, Tree species

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. LiDAR sisteminin çalışma prensibinin şematik gösterimi (Guo vd., 2023).....	14
Şekil 2. LiDAR gelişiminin kısa geçmişi ve önemli kilometre taşları (Guo vd., 2023).....	16
Şekil 3. Çeşitli platformlara monte edilmiş farklı LiDAR sensörleri (Guo vd., 2023).....	22
Şekil 4. Bitki örtüsünün farklı seviyelerinden yansıyan LiDAR ışık darbeleri: (1) bitki örtüsünün üstünden geri dönen, (2) ara yüzeyden geri dönen ve (3) yer yüzeyinden geri dönen	23
Şekil 5. PMF algoritmasının lidR kütüphanesine uyarlanmış hâli (URL-1).....	36
Şekil 6. CSF algoritmasının şekilsel gösterimi (URL-2).....	37
Şekil 7. Filtreleme sonucu zemin nesnesine ait şematik gösterim (Guo vd., 2023).....	38
Şekil 8. Eğim tabanlı filtreleme algoritmasının şematik gösterimi (Guo vd., 2023).....	39
Şekil 9. Temel morfolojik işlemlerin gösterimi: (a) açma, (b) kapatma (Guo vd., 2023).....	41
Şekil 10. Tekrarlayan en küçük kareler enterpolasyonuna dayalı filtreleme algoritmasının iş akışı (Gup vd., 2023)	44
Şekil 11. Aşamalı TIN yoğunlaştırma filtreleme yöntemi iş akışı (Chen vd., 2021).....	46
Şekil 12. Segmentasyona dayalı filtreleme yöntemlerinden elde edilen sonuçlar: (a) ham nokta bulutu, (b) filtrelenmiş nokta bulutu (Guo vd., 2023)	47
Şekil 13. Nokta tabanlı tam evrişimli sinir ağının mimarisi(Guo vd., 2023)	50
Şekil 14. İş akış diyagramı.....	81
Şekil 15. Çalışma alanının konumsal gösterimi.....	83
Şekil 16. Çalışma alanına ait Orman genel Müdürlüğü e-harita uygulaması	84
Şekil 17. Çalışma alanına ait Google Earth profil gösterimi	85
Şekil 18. Çalışma alanının eş yükselti eğrili çizimi.....	85
Şekil 19. Çalışma alanı arazi topoğrafik yapısı	86
Şekil 20. Çalışma alanına ait uçuş anında çekilmiş bir hava fotoğrafı	87
Şekil 21. DJI Matrice 350 RTK İHA modeli P1 sensörlü (sol), L1 sensörlü (sağ)	88
Şekil 22. Uçuş yapılan alanda elde edilen nokta sayısı (sol) ve bu alana dair sınır (sağ)	89
Şekil 23. Elde edilen sonuçların doğruluğunu tespit etmek için atılan noktalar.....	90

Şekil 24.	P1 uçuşu ile elde edilen karesel ortalama hata	91
Şekil 25.	L1 uçuşu ile elde edilen karesel ortalama hata	91
Şekil 26.	İki blok halinde ve farklı yüksekliklerden gerçekleştirilen uçuşlar.....	92
Şekil 27.	İki farklı yükseklikten elde edilen nokta yoğunlukları	93
Şekil 28.	Nokta bulutunun otomatik sınıflandırılması.....	94
Şekil 29.	Çalışma alanına ait Zemin (2-Ground) noktalarının kesit görünümü.....	95
Şekil 30.	Çalışma alanına ait Yüksek Bitki Örtüsü (5-High Vegetation) noktalarının kesit görünümü	95
Şekil 31.	Çalışma alanına ait Bina (6-Building) noktalarının kesit görünümü	96
Şekil 32.	Çalışma alanında bulunan Telesiyeje (14-Wire-Conductor) ait sınıflandırmanın kesitler yardımıyla yapılan iyileştirme öncesi (sol) ve sonrası (sağ)	97
Şekil 33.	Çalışma alanına ait zemin (2-Ground) noktalarının genel görünümü	98
Şekil 34.	Çalışma alanına ait yüksek bitki örtüsü (5-High Vegetation) noktalarının genel görünümü.....	98
Şekil 35.	Çalışma alanına ait bina (6-Building) noktalarının genel görünümü	99
Şekil 36.	Çalışma alanından alınan iki farklı kesit	99
Şekil 37.	TBC yazılımı ile yarı otomatik şekilde yapılan sınıflandırmaya ait kesitler.....	100
Şekil 38.	PMF algoritması ile elde edilen sınıflandırmaya ait kesitler.....	100
Şekil 39.	CSF algoritması ile elde edilen sınıflandırmaya ait kesitler.....	101
Şekil 40.	Çalışma alanının yeni sınırı ve iki sınıfa ait noktaların dağılımı.....	103
Şekil 41.	Meşçere boy modeli (URL-4)	103
Şekil 42.	Zemine ait noktaların (sol) ve zemine ait olmayan noktaların (sağ) görünümü.....	104
Şekil 43.	Zemine ait nokta bulutu kullanılarak elde edilen ağ (mesh) model.....	105
Şekil 44.	Zeminin ağ (mesh) modeli ile zemin üstü noktaların birlikte görünümü	105
Şekil 45.	C2M yöntemiyle elde edilen MBM.....	106
Şekil 46.	Çalışma alanına ait ağaç boylarının dağılımı.....	107
Şekil 47.	Nokta bulutu verisinden raster verinin farkı alınarak elde edilen normalizasyon (IDW) ve zemine ait noktaların yükseklik grafiği.....	108
Şekil 48.	Nokta bulutu verisinden raster verinin farkı alınarak elde edilen normalizasyon (TIN) ve zemine ait noktaların yükseklik grafiği.....	108
Şekil 49.	IDW enterpolasyon yöntemiyle elde edilen normalizasyon ve zemin noktalarının yüksekliğine ait grafik.....	109

Şekil 50.	TIN enterpolasyon yöntemiyle elde edilen normalizasyon ve zemin noktalarının yüksekliğine ait grafik.....	109
Şekil 51.	Çalışma alanına ait yükseklik normalizasyon öncesi (sol) ve sonrası (sağ) kesitler.....	110
Şekil 52.	IDW (sol) ve TIN (sağ) ile elde edilen SAM verileri.....	111
Şekil 53.	Çalışma alanına ait elde edilen SYM verisi.....	112
Şekil 54.	IDW (sol) ve TIN (sağ) ile elde edilen MBM'ler.....	112
Şekil 55.	İki farklı enterpolasyon yöntemi ile elde edilen MBM'ler arasındaki benzerlik ve farklar	113
Şekil 56.	KNNIDW (sol) ve TIN (sağ) algoritmaları ile elde edilen SAM verileri	114
Şekil 57.	p2r (sol) ve pit-free (sağ) algoritmaları ile elde edilen SYM verileri.....	114
Şekil 58.	lidR kütüphanesine ait algoritmalar kullanılarak elde edilen MBM	115
Şekil 59.	Yapay zekâ kullanılarak üretilen Meşçere Boy Modeli (MBM).....	116
Şekil 60.	BIRCH algoritmasıyla segmentasyon öncesi (sol) ve sonrası (sağ).....	118
Şekil 61.	DBSCAN algoritmasıyla segmentasyon öncesi (sol) ve sonrası (sağ).....	119
Şekil 62.	K-Means algoritmasıyla segmentasyon öncesi (sol) ve sonrası (sağ)	120
Şekil 63.	GaussMixture algoritmasıyla segmentasyon öncesi (sol) ve sonrası (sağ)	120
Şekil 64.	li2012 algoritmasına ait farklı parametre değerleri ile elde edilen sonuçlar.....	121
Şekil 65.	YMA ile elde edilen 18 adet ağaç tepe noktasının farklı açılardan gösterimi	122
Şekil 66.	Tepe noktaları tespit edilen ağaçların yatay ve düşey konum bilgileri	123
Şekil 67.	p2r yöntemiyle farklı çözünürlüğe sahip MBM verisi üzerinden ağaç tepe noktası tespiti	124
Şekil 68.	pitfree yöntemiyle farklı çözünürlüğe sahip MBM verisi üzerinden ağaç tepe noktası tespiti	125
Şekil 69.	Dalponte2016 algoritması ile 0.10 (sol), 0.50 (orta) ve 1.00 (sağ) metre çözünürlüklerle elde edilen segmentasyona ait yandan ve üstten görünüm.....	126
Şekil 70.	Silva2016 algoritması ile 0.10 (sol), 0.50 (orta) ve 1.00 (sağ) metre çözünürlüklerle elde edilen segmentasyona ait yandan ve üstten görünüm.....	127
Şekil 71.	Çalışma alanındaki referans verinin konumsal dağılımı ve araziden görünümü.....	129
Şekil 72.	Çalışma alanındaki ağaçlara ait konum ve yükseklik bilgisinin elde edilmesi.....	129

Şekil 73.	Gövde çapının çap ölçer aletiyle ölçülmesi	130
Şekil 74.	TruPulse cihazı ve ölçme yöntemleri (URL-6)	130
Şekil 75.	Çalışma alanına ait Silva2016 algoritması ile elde edilen segmentasyon sonucu.....	131
Şekil 76.	Silva2016 algoritması segmentasyonuna ait taç çizimleri.....	132
Şekil 77.	Segmentasyon iyileştirmesi öncesi (sol) ve sonrası (sağ) nokta bulutunun dağılımı.....	133
Şekil 78.	1 kapalı alana ait ladin ağaçlarının segmentasyon sonucu görünümü	134
Şekil 79.	1 kapalı alana ait kayın ağaçlarının segmentasyon sonucu görünümü	134
Şekil 80.	1 kapalı alana ait kuru ladin ağaçlarının segmentasyon sonucu görünümü.....	134
Şekil 81.	2 ve 3 kapalı alana ait ladin ağaçlarının segmentasyon sonucu görünümü.....	135
Şekil 82.	2 ve 3 kapalı alana ait kayın ağaçlarının segmentasyon sonucu görünümü.....	135
Şekil 83.	Konik, elipsoid ve silindirik modellerin gösterimi	140
Şekil 84.	Gevşek (1) kapalılık düzeyine sahip alandan alınan ladin ve kayın ağaç türlerine ait ağaç boyu ve gövde çapı bilgileri.....	141
Şekil 85.	Gövde çapı (DBH) bilgisinin tespitine yönelik görseller	141
Şekil 86.	Radyal yöntemle elde edilen meşçere parametreleri	142
Şekil 87.	Gevşek (1) kapalı alandaki ladin ağaç türüne ait meşçere bileşenleri (97 adet)	142
Şekil 88.	Ladin ağaç türüne ait yükseklik ve gövde çapı verilerinin kutu grafik gösterimi	143
Şekil 89.	Ladin ağaç türüne ait meşçere parametrelerinin korelasyon ilişkisi.....	143
Şekil 90.	Ladin ağaç boyu ve gövde çapı verilerine ait regresyon modelleri	144
Şekil 91.	Gevşek (1) kapalı alandaki kayın ağaç türüne ait meşçere parametreleri (76 adet).....	145
Şekil 92.	Kayın ağaç türüne ait yükseklik ve gövde çapı verilerinin kutu grafik gösterimi	145
Şekil 93.	Kayın ağaç türüne ait meşçere parametrelerinin korelasyon ilişkisi	146
Şekil 94.	Kayın ağaç boyu gövde çapı verilerine ait regresyon modelleri	147
Şekil 95.	Gevşek (1) kapalı alandaki kuru ladin ağaç türüne ait meşçere parametreleri (16 adet).....	148
Şekil 96.	Kuru ladin ağaç türüne ait yükseklik ve gövde çapı verilerinin kutu grafik gösterimi.....	148
Şekil 97.	Kuru ladin ağaç türüne ait meşçere parametrelerinin korelasyon ilişkisi	149

Şekil 98.	Kuru ladin ağaç boyu ve gövde çapı verilerine ait regresyon modelleri	150
Şekil 99.	Gevşek kapalı meşçere alanında etiketlenmiş ağaç türlerinin mekânsal dağılımı.....	152
Şekil 100.	Orta ve tam kapalı meşçere alanında etiketlenmiş ağaç türlerinin mekânsal dağılımı.....	152
Şekil 101.	PointNet algoritmasına ait model ile tahmin edilen ağaç türlerine ait örnekler.....	155
Şekil 102.	PointNet mimarisinde kullanılan etiketli ağaçların mekânsal dağılımı.....	155
Şekil 103.	PointNet++ algoritmasına ait model ile tahmin edilen ağaç türlerine ait örnekler.....	158
Şekil 104.	PointNet++ mimarisinde kullanılan etiketli ağaçların mekânsal dağılımı.....	158
Şekil 105.	DGCNN algoritmasına ait model ile tahmin edilen ağaç türlerine ait örnekler.....	161
Şekil 106.	DGCNN mimarisinde kullanılan etiketli ağaçların mekânsal dağılımı.....	161
Şekil 107.	Uçuş yüksekliği 150 m. (üst) ve 350 m. (alt) olan nokta bulutu verileri.....	163
Şekil 108.	P1 sensörü kullanılarak elde edilen nokta bulutu verisi	164
Şekil 109.	L1 ve P1 nokta bulutu verilerinin birleştirilmiş hali.....	164
Şekil 110.	Zemine ait olan ve olmayan noktaların tespitinde kullanılan yöntemlere ait sonuçlar; a) TBC-yarı otomatik, b) PMF, c) CSF	165
Şekil 111.	Nokta bulutu yöntemleriyle elde edilen MBM'ye ait bilgiler	166
Şekil 112.	Raster tabanlı MBM ve ağaç tepe noktaları	168
Şekil 113.	Kapalılık seviyeleri farklı alanlardaki ağaç tepe noktası tespiti ve tür dağılımı.....	171
Şekil 114.	Bireysel ağaç segmentasyonu zor örnekler.....	171
Şekil 115.	Taç sınırı tespiti için kullanılan yöntemlerin karşılaştırılması	172

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Nokta Veri Kaydı (Format 6)	24
Tablo 2. ASPRS standart LiDAR Nokta Sınıfları (Format 6-10)	25
Tablo 3. Bireysel ağaç segmentasyon yöntemleri hakkında yapılan çalışmalar	62
Tablo 4. İHA ve sensörlere ait özellikler (URL-1)	88
Tablo 5. Sınıflandırma işlemi sonrası elde edilen sınıflar ve nokta sayıları	97
Tablo 6. Zemin ve zemin dışı noktaların tespiti için kullanılan yöntem ve sonuçları	101
Tablo 7. Çalışma alanındaki referans veriye ait bilgiler	128
Tablo 8. Ağaç boyu tespitine yönelik pseudo kodu	135
Tablo 9. Ağaç gövde çapı tespiti için yazılan pseudo kodu	136
Tablo 10. Ağaç tepe çapı tespiti için yazılan pseudo kodu	136
Tablo 11. Ağaç tepe alanının tespitine ait pseudo kodu	137
Tablo 12. Ağaç gövde hacmine ait yazılan pseudo kodu	139
Tablo 13. Ağaç tepe hacmine ait yazılan pseudo kodu	139
Tablo 14. Regresyon modellerinin elde etmiş olduğu performans metrikleri	151
Tablo 15. PointNet mimarisine ait hiperparametreler	153
Tablo 16. Test ve doğrulama veri setlerine ait başarı metrikleri	153
Tablo 17. Test ve doğrulama veri setlerine ait karışıklık matrisi	154
Tablo 18. PointNet++ mimarisine ait hiperparametreler	156
Tablo 19. Test ve doğrulama veri setlerine ait başarı metrikleri	156
Tablo 20. Test ve doğrulama veri setlerine ait karışıklık matrisi	157
Tablo 21. DGCNN mimarisine ait hiperparametreler	159
Tablo 22. Test ve doğrulama veri setlerine ait başarı metrikleri	160
Tablo 23. Test ve doğrulama veri setlerine ait karışıklık matrisi	160
Tablo 24. Referans verisi ve nokta bulutu tabanlı yöntemlerle bulunan ağaç boylarının karşılaştırılması	167
Tablo 25. Referans verisi ve raster tabanlı yöntemlerle bulunan ağaç boylarının karşılaştırılması	168
Tablo 26. Nokta bulutu tabanlı algoritmalarla yapılan segmentasyon sonuçları	167
Tablo 27. Raster tabanlı algoritmalarla yapılan segmentasyon sonuçları	167

Tablo 28.	Gövde çapı tahmininde kullanılan modellerin sonuçları ve referans verinin karşılaştırılması	173
Tablo 29.	Nokta bulutu verisiyle elde edilen çap ve hacim değerlerinin referans verilerle karşılaştırılması	174
Tablo 30.	PointNet modeliyle eğitilen ağaç türlerine ait test verisinin karışıklık matrisi	175
Tablo 31.	PointNet mimarisine ait başarı metrikleri	176
Tablo 32.	PointNet++ mimarisine ait başarı metrikleri	176
Tablo 33.	DGCNN mimarisine ait başarı metrikleri	176



SEMBOLLER VE KISALTMALAR DİZİNİ

R^2	: Belirtme katsayısı (regresyon)
3B, 3D	: Üç Boyutlu (x, y, z)
AI	: Yapay Zekâ (Artificial Intelligence)
ALS	: Havadan Lazer Tarama (Airborne Laser Scanning)
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
ASCII	: Amerikan Bilgi Değişim Standart Kodu
ASPRS	: Amerikan Fotogrametri ve Uzaktan Algılama Derneği
AOL	: Hava-Oşinografik LiDAR
CSF	: Cloth Simulation Filtering
DBSCAN	: Density-Based Clustering Applications with Noise
DT	: Karar Ağaçları (Decision Tree)
ESA	: Avrupa Uzay Ajansı
GEDİ	: Küresel Ekosistem Dinamikleri Araştırması
GLAS	: Jeobilimsel Lazer Altimetre Sistemi
GNSS	: Küresel Konum Belirleme Sistemi
ICESat	: Buz, Bulut ve Kara Yükseklik Uydusu
IMU	: Ataletsel Ölçüm Birimi
INS	: Ataletsel Navigasyon Sistemi
İHA	: İnsansız Hava Aracı
MBM	: Meşçere Boy Modeli
LiDAR	: Işık Algılama ve Mesafe Ölçümü (Light Detection and Ranging)
NASA	: Ulusal Havacılık ve Uzay Dairesi
PMF	: Progressive Morphological Filtering
PPK	: Post Processing Kinematic
RF	: Rastgele Orman (Random Forest)
SAM	: Sayısal Arazi Modeli
SLAM	: Eşzamanlı Konumlandırma ve Haritalama
SVM	: Destek Vektör Makineleri (Support Vector Machines)
SYM	: Sayısal Yükseklik Modeli
TLS	: Karasal Lazer Tarama (Terrestrial Laser Scanning)

1. GENEL BİLGİLER

Ormanlar, karasal ekosistemlerin temel bileşenleri arasında yer almaktadır. Orman ekosistemleri, insan yaşamı ve ekonomik kalkınma açısından doğrudan fayda sağlayan odun ve yan ürünler gibi çeşitli maddi kaynaklar sunmaktadır. Ayrıca, biyosferin dengesinin korunmasına katkıda bulunarak ekolojik çevrenin iyileştirilmesine hizmet etmektedir. Yer yüzeyindeki gizli ve hissedilir ısı geçişlerini düzenleyerek su döngüsünü destekler ve hidrolojik süreçleri şekillendirmektedir (Lefsky vd., 2002; Bonan, 2008).

Orman ekosistemleri, atmosferdeki karbondioksit seviyelerini düşürerek küresel ısınmanın etkilerini azaltan en büyük karasal karbon emiciler arasında yer almaktadır. Su ve toprağın korunması, rüzgar ve erozyonun önlenmesi gibi ekolojik işlevlerde de kritik bir rol üstlenmektedir. Bu nedenle, ormanlara ilişkin verilerin doğru ve etkin bir şekilde toplanması ve ekosistemde meydana gelen değişimlerin zamanında izlenmesi, ormancılık çalışmalarının temel hedefleri arasında bulunmaktadır (Fang vd., 2001; Houghton, 2005; Pan vd., 2011).

Orman ekosistemleri, diğer ekosistem türleriyle karşılaştırıldığında hem yatay hem de dikey yönde yüksek düzeyde heterojenlik göstermektedir. Farklı orman yapıları, ekolojik işlevler bakımından çeşitlilik arz ederken; tür dağılımı, çevresel faktörler, orman büyümesi, gelişimi ve yenilenme süreçleri arasındaki ilişkilerin anlaşılması büyük önem taşımaktadır. Geleneksel olarak, orman yapısının incelenmesi genellikle deneyimli araştırmacılar tarafından meşçere düzeyinde yürütülmektedir. Ancak bu yöntem, oldukça zaman alıcı ve yoğun emek gerektiren bir süreçtir. Ayrıca, bu araştırmaların sonuçları çoğunlukla metin veya istatistiksel veriler şeklinde sunulması, orman ekosistemlerinde görülen mekânsal heterojenlik yeterince iyi yansıtılamamasına neden olmaktadır (Hurt vd., 2004; Medvigy vd., 2009; Shugart vd., 2010).

Uydu tabanlı uzaktan algılama teknolojilerindeki gelişmelerle birlikte, orman yapısının ve biyokütlesinin belirlenmesinde optik görüntüleme yöntemleri kullanılmaya başlanmıştır. Ancak optik uzaktan algılama yöntemleri, orman kanopisinin içine nüfuz etme konusunda yetersiz kaldığından, alt tabaka ve zemin katmanlarına ilişkin veriler yeterli düzeyde elde edilememektedir. Bu tür pasif uzaktan algılama tekniklerinin sınırlamalarını aşmak ve orman ekosistemlerini üç boyutlu (3B) ve gerçek zamanlı olarak izleyebilmek amacıyla, daha gelişmiş ve hassas teknolojilere duyulan ihtiyaç her geçen gün artmaktadır (Wessman vd., 1988; Defries vd., 2000; Lu, 2006; Li vd., 2012).

Geleneksel pasif uzaktan algılama yöntemlerinden farklı olarak, LiDAR teknolojisi, nesnelerin üç boyutlu konum bilgilerini doğrudan, hızlı ve yüksek doğrulukla elde edebilmektedir. LiDAR sistemleri, genellikle kızılötesi ve yakın kızılötesi dalga boylarında çalışan lazer darbeleri kullanmaktadır. Bu nedenle, doğal ışık koşullarından bağımsız olarak çalışabilmekte ve günün her saatinde, farklı hava koşullarında veri toplayabilmektedir. Orman ekosistemlerini anlamaya yönelik çalışmalarda iki temel yaklaşım öne çıkmaktadır: sabit nokta gözlemleri ve model simülasyonları (Guo vd., 2023). LiDAR teknolojisi, her iki yaklaşıma da katkı sağlayarak ormanların yapısal özellikleri ve kuruluşları hakkında bilgi edinilmesini önemli ölçüde kolaylaştırmaktadır.

Orman ekosistemlerinin incelenmesinde en yaygın kullanılan yöntemlerden biri saha araştırmalarıdır. Genellikle 1 hektarlık alanlar, saha çalışmaları için standart bir birim olarak kabul edilmektedir. Bu tür alanlarda gerçekleştirilen ölçümler yüksek düzeyde güvenilirlik sunmaktadır. Ancak, dağlık ve karmaşık arazi yapısına sahip bölgelerde iş yükünün artması nedeniyle, çoğunlukla tüm saha yerine yalnızca belirli noktalardan alınan örneklerle çalışılmaktadır. Bu durum, elde edilen verilerin genellenebilirliğini ve güvenilirliğini azaltabilmektedir. Daha büyük ölçekli incelemelerde, uydu tabanlı optik uzaktan algılama yöntemleri daha pratik çözüm sunmaktadır. Uydu görüntüleri, bölgesel ve küresel düzeyde orman ekosistemlerinin mekânsal çeşitliliğini tanımlamak amacıyla kullanılmaktadır. Ancak optik sensörlerin orman örtüsüne nüfuz edememesi, bu tür gözlemlerin doğruluğunu sınırlayabilmektedir. Özellikle yüksek kapalılığa sahip alanlarda, bu yöntemlerin hata payı artış göstermektedir (Fu, 2010; Xue vd., 2015).

Yukarıda belirtilen kısıtlamalar nedeniyle, saha ölçeğinde gerçekleştirilen ölçümler ile bölgesel ölçekli gözlemleri birleştiren yeni yöntemlere duyulan ihtiyaç artmaktadır. LiDAR teknolojisi, birkaç kilometrekareden onlarca kilometrekareye kadar veri toplayabilme kapasitesiyle bu ihtiyacı karşılayabilecek potansiyele sahiptir. Bölgesel düzeyde biyokütle tahmini yapılabilmesi için, öncelikle saha ölçeğinde elde edilen biyokütle verileri ile havadan LiDAR verilerinden türetilen ağaç boyu gibi yapısal özellikler arasındaki ilişkinin belirlenmesi gerekmektedir. Ardından, bu ilişki temel alınarak, havadan LiDAR verileri ve optik uzaktan algılama verileri birleştirilmekte ve daha geniş ölçekli biyokütle tahminleri gerçekleştirilebilmektedir. Bu yöntem, orman ekosistemlerinin hem küçük ölçekli hem de büyük ölçekli izlenmesinde etkili ve güçlü bir araç sunmaktadır (Lefsky vd., 2006; Boudreau vd., 2008; Li vd., 2015; Su vd., 2016).

Orman ekosistemleri, karmaşık yapıları ve iklim değişikliği ile küresel ısınmanın etkileri nedeniyle simülasyonlar yoluyla tahmin edilmesi güç sistemler arasında yer almaktadır. Bu tahminlerde üç temel belirsizlik kaynağı öne çıkmaktadır: model yapısı, girdi verileri ve model parametreleri. Geleneksel optik uzaktan algılama yöntemleri, yaprak alan indeksi gibi parametreleri sağlayarak simülasyon modellerine katkı sunabilmektedir. Ancak, orman örtüsünün alt katmanlarına nüfuz edememesi nedeniyle ağaç boyu gibi kritik yapısal bilgileri eksik bırakmaktadır. Bu durum, model simülasyonlarındaki belirsizliğin artmasına neden olmaktadır (Purves ve Pacala, 2008; Sitch vd., 2008).

Günümüzde birçok ekolojik model, çok yıllık iklim verilerini kullanarak ekosistemlerin zaman içindeki değişimini simüle etmektedir. Ancak, model tarafından kullanılan potansiyel bitki örtüsü dağılımı ile gerçek bitki örtüsü dağılımı arasında farklılık bulunması durumunda, simülasyon sonuçları hatalı olabilmektedir. Bu noktada, LiDAR teknolojisi, büyük ölçeklerde ağaç boyu ve biyokütle bilgisi sağlayarak söz konusu sorunun giderilmesine katkı sunmaktadır. Ayrıca, asimilasyon yöntemlerinin uygulanmasıyla model parametreleri optimize edilmekte ve simülasyonların doğruluğu artırılabilir. Böylece, LiDAR destekli modeller, orman ekosistemlerinin gelecekteki durumunu daha isabetli bir şekilde tahmin edebilmektedir (Yu vd., 2011; Castanho vd., 2013).

Orman ekosistemlerinin ayrıntılı bir biçimde anlaşılması ve etkin bir şekilde yönetilebilmesi amacıyla nokta bulutu verileri önemli bir potansiyel sunmaktadır. LiDAR teknolojisi ve gelişmiş nokta bulutu işleme yöntemlerinin kullanılmasıyla, orman alanlarının daha verimli bir şekilde izlenmesi, analiz edilmesi ve sürdürülebilir ormancılık uygulamalarının desteklenmesi mümkün hâle gelmektedir. Gelecekte, bu teknolojilerin daha da geliştirilmesiyle birlikte ekosistem dinamiklerinin daha hassas biçimde modellenmesi ve doğa koruma çalışmalarının daha etkin bir şekilde yürütülmesi sağlanabilecektir.

Özellikle hava LiDAR teknolojisi, ormanlık alanlardan yüksek hassasiyetli nokta bulutu verisi elde edilmesini mümkün kılarak, meşçere bileşenlerinin belirlenmesinden, ağaç türü sınıflandırmasına, karbon depolama analizlerinden yangın riski tahminlerine kadar geniş bir uygulama yelpazei sunmaktadır. Nokta bulutu verisi, milyonlarca 3B koordinattan oluşan, düzensiz ve çok katmanlı bir veri yapısına sahip olduğundan, bu verilerin analiz süreci dikkatli bir şekilde planlanmalıdır.

Nokta bulutlarının üretilmesinde, insansız hava araçlarına monte edilen L1 ve P1 sensörleri kullanılmaktadır. L1 sensörü, doğrudan üç boyutlu nokta verisi elde etmek amacıyla kullanılmakta; P1 sensörüyle çekilen hava fotoğrafları ise fotogrametrik

yöntemlerle işlenerek nokta bulutu oluşturulmaktadır. P1 sensörü aracılığıyla elde edilen hava fotoğrafları, görüntü eşleştirme teknikleri kullanılarak analiz edilmekte ve bu analizler sonucunda görüntülerdeki benzer bölgeler tespit edilerek konum, yön, ölçek ve diğer dönüşümler hesaplanmaktadır.

Nokta bulutu verilerinde yer alan geometrik özellikler, yüzeylerin ve nesnelerin şekil, yapı ve mekânsal düzenini anlamaya yönelik önemli ölçütler olarak öne çıkmaktadır. Bu özellikler; düzlemsellik, doğrusallık, dikeylik, pürüzlük ve küresellik gibi çeşitli parametreler aracılığıyla değerlendirilmektedir. İlgili geometrik parametreler, LiDAR ve fotogrametrik nokta bulutlarının analizinde kritik rol oynamaktadır. Yapay zeka ve makine öğrenimi tabanlı yöntemler ise bu özelliklerden faydalanarak segmentasyon, sınıflandırma, nesne tanıma ve üç boyutlu modelleme gibi çeşitli analizlerin gerçekleştirilmesini mümkün kılmaktadır (Atik vd., 2021).

Geometrik özelliklerden düzlemsellik, bir noktayı çevreleyen komşu noktaların düz bir yüzeye ne ölçüde uyum sağladığını ifade etmektedir. Doğrusallık, komşu noktaların bir doğru boyunca hizalanma derecesini ölçmektedir. Dikeylik ise bir noktanın ya da yüzeyin yerçekimi yönüne, yani Z eksenine göre yaptığı açığı tanımlamaktadır. Pürüzlük, bir yüzeyin ne kadar düzgün veya engebeli olduğunu belirleyen bir ölçüt olarak öne çıkmaktadır. Küresellik ise bir noktanın küresel bir yüzeyle ne ölçüde uyumlu olduğunu göstermektedir.

Nokta bulutu verisinde zemin ve zemin üstü (bina, ağaç, araç vb.) noktaları filtrelemek amacıyla yaygın olarak kullanılan iki yöntem bulunmaktadır: Progressive Morphological Filtering (PMF) ve Cloth Simulation Filtering (CSF). PMF yöntemi, matematiksel morfoloji işlemlerine dayanarak noktaların filtrelenmesini sağlamaktadır. CSF yöntemi ise fiziksel bir kumaş simülasyonu modeli aracılığıyla noktaları sınıflandırmaktadır.

Ticari yazılımlar tarafından gerçekleştirilen nokta bulutu sınıflandırma işlemlerinde kullanılan spesifik algoritmalar ve matematiksel modeller genellikle kamuya açık olarak paylaşılmamaktadır. Ancak bu yazılımlar, sınıflandırma işlemini yaygın olarak makine öğrenmesi tabanlı, kural tabanlı ve segmentasyon temelli teknikler aracılığıyla gerçekleştirmektedir. Makine öğrenmesi tabanlı yöntemler arasında Destek Vektör Makineleri (DVM), Karar Ağaçları (KA), Rastgele Ormanlar (RO) ve Derin Öğrenme (DÖ) gibi algoritmalar yer almaktadır. Kural tabanlı yöntemlerde ise yükseklik, yoğunluk ve eğim gibi fiziksel parametrelere dayalı olarak belirlenen eşik değerleri kullanılarak noktalar gruplandırılmaktadır. Segmentasyon teknikleri ise bölge büyütme ve kümeleme algoritmalarını kullanarak benzer özelliklere sahip noktaların bir araya getirilmesi yoluyla

sınıflandırma işlemini gerçekleştirmektedir. Bu yöntemler aracılığıyla ticari yazılımlar, nokta bulutu verilerini analiz ederek zemin, bina, bitki örtüsü gibi farklı kategorilere ayırabilmektedir.

Ormancılık literatüründe “kapalılık” terimi, genellikle “canopy cover” veya “crown closure” kavramlarıyla ifade edilmekte olup, orman zemininde ağaç tepelerinin dikey izdüşümünün kapladığı alanın oranını tanımlamaktadır. Bu oran %0 ile %100 arasında değişmekte ve orman yapısının önemli bir göstergesi olarak kabul edilmektedir. Kapalılık oranı; %0-10 aralığında boşluklu kapalı (B), %11-40 aralığında gevşek kapalı (1), %41-70 aralığında orta kapalı (2) ve %71-100 aralığında tam kapalı (3) şeklinde sınıflandırılmaktadır (OGM, 2017). Kapalılık, orman ekosisteminin ışık geçirgenliği, alt tabaka bitki örtüsünün gelişimi ve genel ekosistem dinamikleri üzerinde belirleyici rol oynamaktadır. Örneğin, yüksek kapalılık oranlarının, alt tabaka bitki örtüsünün gelişimini sınırlayarak biyolojik çeşitlilik üzerinde olumsuz etkiler yaratabileceği belirtilmektedir. Bu nedenle, ormanların işletilmesi ve korunmasında kapalılık oranının düzenli olarak izlenmesi ve gerekli durumlarda müdahale edilmesi, orman sağlığı ve sürdürülebilirliği açısından büyük önem arz etmektedir (Jennings vd., 1999).

Bu tez çalışmasında, hava LiDAR verileri kullanılarak meşcerelere ait temel yapısal parametrelerin (bileşenlerin) belirlenmesi ve ağaç türü tahmini gerçekleştirilmiştir. Çalışma kapsamında, ağaç boyu, gövde çapı, tepe çapı, tepe alanı, tepe hacmi gibi meşcere parametreleri elde edilmiştir. Ayrıca, farklı ağaç türlerinin sınıflandırılmasına yönelik olarak, iğne yapraklı türlerden ladin (*Picea orientalis*), geniş yapraklı türlerden kayın (*Fagus orientalis*) ve kurumuş ladin ağaçlarının tespitine ilişkin analizler gerçekleştirilmiştir.

Çalışmada yalnızca LiDAR nokta bulutu verisi kullanılmış olup, herhangi bir optik görüntüleme verisi veya spektral bant bilgisine dayalı analiz gerçekleştirilmemiştir. Dolayısıyla, ağaç türü tahmini süreci, yalnızca nokta bulutu verisinin içerdiği geometrik ve yapısal özniteliklere dayalı olarak yürütülmüştür. Çalışma alanı, üç farklı tepe kapalılığı sınıfını içermektedir. Bu heterojenlik, model çıktılarının çeşitli tepe kapalılığı düzeyleri açısından karşılaştırmalı olarak değerlendirilmesine imkân tanımıştır. Özellikle düşük tepe kapalılığına sahip bölgelerden elde edilen LiDAR verileri ile orta ve tam kapalılığa sahip bölgelerdeki meşcere parametre kestirimleri ve ağaç türü sınıflandırma doğrulukları arasında karşılaştırma yapılabilmektedir. Böylece, tepe kapalılığı seviyelerinin hem meşcere parametreleri hem de ağaç türü tahmin doğruluğu üzerindeki etkileri de kapsamlı bir şekilde analiz edilmiştir.

1.1. Problemin Tanımı

Orman ekosistemleri, tepelerden zemine kadar farklı katmanlardan oluşan, diri örtü ve ölü örtü gibi ekosistemin devamlılığı için kritik öneme sahip unsurları barındıran karmaşık sistemlerdir. Orman yapısının ayrıntılı biçimde anlaşılması ve doğru bir şekilde analiz edilmesi, etkin orman yönetimi, biyolojik çeşitliliğin korunması ve sürdürülebilir ormancılık uygulamalarının hayata geçirilmesi açısından büyük önem taşımaktadır. Geleneksel yöntemlerin zaman alıcı olması ve geniş alanlarda uygulanmasının zorluğu nedeniyle, gelişen teknolojiler sayesinde daha hızlı, hassas ve güvenilir bilgilere ulaşmak mümkün hâle gelmiştir.

Literatürde yapılan çalışmalarda, meşçere parametre kestirimi ve ağaç türü tahmini amacıyla LiDAR verisinin genellikle optik verilerle birlikte kullanıldığı görülmektedir. Özellikle uydu görüntüleri ve hava fotoğraflarından elde edilen spektral bilgiler, ağaç türlerinin ayırt edilmesinde kritik bir rol oynamaktadır. Farklı ağaç türleri, belirli dalga boylarında farklı yansıtma özelliklerine sahip olduğundan, optik veriler tür sınıflandırma süreçlerinde yüksek doğruluk sağlamaktadır. Ancak bu çalışmada, yalnızca LiDAR teknolojisiyle elde edilen nokta bulutu verisi kullanılarak ağaç tespiti ve tür tahmini gerçekleştirilmiştir. Spektral bilgiye dayanmadan yapılan bu tür tahminler, tamamen bireysel ağaçların yapısal ve geometrik özelliklerine dayalı bir analiz gerektirdiğinden, daha yüksek düzeyde zorluk içermektedir.

Ayrıca, çalışma alanında yer alan bazı bölgeler, özellikle yüksek kapalılık sınıfına (2 ve 3 sınıfları) sahip alanlar, nokta bulutu yoğunluğu açısından çeşitli kısıtlamalar içermektedir. Yoğun tepe örtüsü nedeniyle, LiDAR sinyallerinin orman zeminine ve ağaç gövdelerine ulaşması sınırlı olmakta; bu durum, gövde çapı gibi meşçere bileşenlerinin doğru ve güvenilir şekilde tespit edilmesini zorlaştırmaktadır.

1.2. Çalışmanın Amacı

Bu tez çalışması, hava LiDAR verilerinden elde edilen nokta bulutu kullanılarak meşçere parametrelerinin tahmin edilmesi ve farklı ağaç türlerinin ayırt edilmesi amaçlanmaktadır. Çalışma kapsamında, ağaç boyu, gövde çapı, tepe çapı, tepe hacmi gibi temel meşçere bileşenlerinin yüksek doğrulukla tahmin edilmesi hedeflenmiştir. Ayrıca, geniş yapraklı kayın (*Fagus orientalis*), iğne yapraklı ladin (*Picea orientalis*) ve kurumuş ladin ağaçlarının birbirinden ayırt edilmesi amaçlanmıştır. Bu işlemleri yaparken hem nokta

bulutu tabanlı hem de raster tabanlı veri türleri kullanılmış, farklı yöntemlerle elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir.

Meşçere parametre kestirimi amacıyla istatistiksel modelleme, regresyon analizleri ve makine öğrenimi tabanlı yöntemler değerlendirilmiştir. Ağaç türü tahmini sürecinde ise, nokta bulutu verisinden türetilen yapısal ve yoğunluk temelli özellikler kullanılarak çeşitli sınıflandırma algoritmaları uygulanmıştır. Ayrıca, farklı tepe kapallılığı sınıflarına ilişkin model doğruluklarının karşılaştırılmış ve bu doğrultuda yöntemin, karmaşık orman ekosistemlerinde sağladığı etkinlik analiz edilmiştir.

Ham nokta bulutu verisi kullanılarak gerçekleştirilen analizlerin doğruluk oranları, hata payları ve uygulanabilirlik düzeyi ele alınarak, bu yöntemin ormancılık çalışmalarındaki güvenilirliği ortaya konmuştur. Tercih edilen yöntem ve algoritmaların sınıflandırma ve tahmin başarısı test edilmiş; yalnızca LiDAR verisi kullanılarak gerçekleştirilen analizlerin sağladığı avantajlar ve karşılaşılan sınırlamalar belirlenmiştir. Elde edilen bulgular, gelecekte yürütülecek benzer çalışmalar için referans niteliği taşımaktadır. Bu araştırma, optik veri kullanılmaksızın yürütülen ağaç türü tahmini ile meşçere parametre kestirimi çalışmalarının etkinliğini değerlendirerek literatüre katkı sağlamayı amaçlamaktadır.

Bu araştırma, hava LiDAR verilerinin ormanların planlaması, yönetimi ve ekosistem izleme süreçlerinde nasıl daha etkin bir şekilde kullanılabileceğine yönelik bilimsel bir katkı sunmayı amaçlamaktadır. Elde edilen sonuçların, ormancılık planlaması, biyoçeşitliliğin korunması ve ekolojik analizler açısından önemli bir veri kaynağı oluşturması beklenmektedir.

1.3. Tezin Ana Hattı

Tezin ikinci bölümünde, “Temel Kavramlar” başlığı altında orman ekosistemi, LiDAR teknolojisi ve nokta bulutu verisinin temel özellikleri ele alınmaktadır. Ayrıca, nokta bulutu verisinin yapısı ile sınıflandırma ve segmentasyon işlemlerinde kullanılan algoritmalara ilişkin ayrıntılı açıklamalara yer verilmiş; bu çerçevede, literatürde konuya dair gerçekleştirilen çalışmalar incelenerek tez konusu ile doğrudan ilişkili bir literatür özeti sunulmuştur. Bu bölüm, araştırmanın teorik çerçevesini oluşturarak, tez kapsamında kullanılan yöntemlerin bilimsel dayanaklarını ortaya koymaktadır.

Üçüncü bölümde, uygulama alanına ilişkin bilgiler, kullanılan veri setleri ve tercih edilen yöntemler detaylı biçimde ele alınmaktadır. Çalışmada kullanılan verilerin temin süreci ile analiz aşamasında uygulanan metotlar açıklanmakta; meşçere parametre kestirimi ve ağaç türü tahmini konuları ise ayrı başlıklar altında incelenmektedir. Bu iki konu birbirinden bağımsız olarak değerlendirilmiş; her biri için uygulanan yaklaşımlar, veri işleme süreçleri ve kullanılan modelleme teknikleri ayrıntılı bir şekilde sunulmuştur. Ayrıca, farklı yöntemlerle elde edilen sonuçlar karşılaştırılarak, hangi tekniklerin daha etkili olduğu konusunda değerlendirmelerde bulunmaktadır.

Dördüncü bölümde, çalışma kapsamında elde edilen bulgular sunulmakta; uygulanan yöntemler aracılığıyla ulaşılan sonuçlar, literatürde yer alan diğer çalışmalarla karşılaştırılmaktadır. Elde edilen sonuçlar, doğruluk ve güvenilirlik açısından değerlendirilmiş; tercih edilen analiz tekniklerinin avantajları ve sınırlamaları ayrıntılı olarak ele alınmıştır.

Beşinci bölümde, ulaşılan sonuçlar doğruluk metrikleri ile birlikte sunulmakta ve analiz sonuçlarının güvenilirliğine ilişkin detaylı açıklamalara yer verilmektedir.

Altıncı bölümde, benzer konular üzerine araştırma yapacak akademisyenler ve uygulayıcılar için öneriler geliştirilmektedir. Çalışma sürecinde karşılaşılan zorluklar ile potansiyel iyileştirme alanları belirtilmiş; ayrıca, gelecekte yürütülecek araştırmalara katkı sağlayabilecek tavsiyeler paylaşılmaktadır.

Yedinci bölümde, tez yazım sürecinde yararlanılan kaynaklar kapsamlı bir şekilde sunulmakta; literatüre dayalı olarak yapılan tüm alıntılar ve referanslar eksiksiz biçimde listelenmektedir.

Sekizinci ve son bölüm olan ekler kısmında ise, uygulama aşamasında kullanılan kodlara yer verilmektedir. Bu bölüm, araştırmanın tekrarlanabilirliğini sağlamak ve uygulanan yöntemlerin ayrıntılarını paylaşmak amacıyla hazırlanmıştır.

1.4. Literatür Özeti

Lazer teknolojisi kullanılarak ağaç boyu değerlendirmesine yönelik ilk çalışmalar, Nelson ve diğerleri tarafından 1984 yılında gerçekleştirilmiştir (Nelson vd., 1984). Bu araştırmalarda, lazer darbelerinin orman kapalılığı içindeki nüfuz kapasitesi ve geri dönüş süreci ayrıntılı olarak incelenmiştir. Elde edilen bulgular, orman örtüsünün lazer sinyallerinin yansımalarını önemli ölçüde etkilediğini ortaya koymuştur. Lazer teknolojisi,

güçlü bir zemin yansıması bulunmayan tepe yansımaları ile zemin yansımalarının karşılaştırılmasında kullanılmıştır. Söz konusu yöntem, fotogrametri ile elde edilen yükseklik ölçümleriyle kıyaslandığında yaklaşık bir metrelik bir farkla, meşçere boyu değerlendirmelerinde kullanılabilecek düzeyde bir doğruluk sunduğunu göstermektedir.

Nelson ve çalışma arkadaşları tarafından 1988 yılında gerçekleştirilen ileri düzey araştırmalar, havadan lazer tarama (Airborne Laser System-ALS) teknolojisinin orman analizlerindeki potansiyelini ortaya koymaktadır (Nelson vd., 1988). Bu çalışmalarda, ALS tabanlı boy ölçümleri ve kapalılık yoğunluğu verileri kullanılarak, toplam dikili hacim ve biyokütle hesaplamalarının yapılabileceği gösterilmiştir. Böylece, lazer teknolojisinin yalnızca bireysel ağaç boylarının belirlenmesiyle sınırlı kalmadığı; aynı zamanda orman ekosistemlerinin genel yapısının değerlendirilmesine de olanak sağladığı anlaşılmaktadır. Bu gelişmeler, ormancılık çalışmalarında LiDAR teknolojisinin kullanımının yaygınlaşmasına zemin hazırlamış ve yüksek hassasiyetli veri toplama süreçlerinde önemli bir ilerleme sağlamasına katkıda bulunmuştur.

Biyokütle ve dikili odun hacminin, ağaç boyu ve göğüs yüzeyi ile güçlü bir korelasyona sahip olduğu uzun süredir bilinmektedir (Krigul, 1972; Lang vd., 2016). Bu nedenle, orman yapısının hassas bir şekilde belirlenebilmesi için boya dayalı ölçümlerin kullanımı yaygın bir yaklaşım hâline gelmiştir. Havadan lazer tarama verileri ile oluşturulan meşçere boyu modelleri, sahada elde edilen meşçere boyu ölçümleri ile yüksek düzeyde doğrusal korelasyon göstermektedir. Söz konusu modellerin temelini, ALS nokta bulutundan türetilen boy yüzdelik değerleri oluşturmaktadır (Naesset, 1997a; 1997b; Yu vd., 2006; Lang, 2010; Bottalico vd., 2017). Literatürde yapılan çalışmalar, ALS tabanlı boy tahminlerinin genellikle 1 ila 2 metre arasında değişen bir hassasiyet düzeyine sahip olduğunu ortaya koymuştur.

Hassas ormancılık, Choudhry ve O'Kelly (2018) tarafından ortaya atılan bir kavram olup, ormancılık endüstrisinin dönüşümünün yalnızca dijitalleşme ile sınırlı kalmadığını, aynı zamanda geleneksel orman yönetim sistemlerinde köklü değişiklikler gerektirdiğini ileri sürmektedir. Hassas ormancılık yaklaşımı, planlama aşamasından pazarlamaya kadar ormancılık faaliyetlerinin tüm bileşenlerinde karar alma süreçlerini desteklemek amacıyla, yapay zekâ tabanlı yöntemler ve yazılımlar aracılığıyla analiz edilebilen büyük verilerin toplanmasını içermektedir. Bu süreçte, çeşitli araçlar ve ileri teknolojiler kullanılarak orman ekosistemlerinden elde edilen veriler anlamlı hâle getirilmekte ve orman yöneticilerine daha bilinçli ve etkili kararlar alma olanağı sunulmaktadır.

Yapay zeka ve derin öğrenme algoritmaları, otomatik düzeltici eylemleri destekleme kapasiteleri sayesinde, ormancılık sektöründe veri analitiği için tahmin ve düzenleme modellerinin oluşturulmasında kritik bir rol oynamaktadır (Vrontis vd., 2021; Chaudhuri vd., 2021). Hassas ormancılık kapsamında kullanılan bu ileri teknolojiler, doğru veri ölçümü ve zamanında gerçekleştirilen envanterler çalışmaları ile daha verimli ve gerçekçi karar alma süreçlerine katkı sağlamaktadır (Hasan vd., 2019). Bu sistemlerden elde edilen büyük veri setleri; genetik haritalama, yapılan ekimlerin operasyonel kontrolü, planlama reçetelerinin oluşturulması, orman ekosistemlerinin hizmet analizleri, dijital envanter sistemleri (RADAR veya LiDAR), orman yangını tahmini ve risk yönetimi gibi birçok farklı alanda kullanılabilir. Ayrıca, orman bilgi sistemleri ve planlama araçlarına erişimde mobil cihazların kullanımı, karar alma süreçlerini desteklemekte ve iş verimliliğini artırmaktadır (Feng ve Audy, 2020).

Hassas ormancılık yaklaşımı, mevcut teknolojilerden ve yüksek doğruluklu ölçüm sistemlerinden faydalananak, büyük veri analizinin ormancılık yönetimi ve planlamasında nasıl etkin bir şekilde kullanılabileceğini ortaya koymaktadır. Bu büyük veri sistemleri, ormancılık politikalarının şekillendirilmesi, sürdürülebilir yönetim uygulamalarının desteklenmesi ve orman kaynaklarının çevresel, ekonomik ve sosyal açılardan korunup geliştirilmesi noktasında önemli bir potansiyele sahiptir (Hasan vd., 2019).

Ormanların sunduğu ekosistem hizmetlerinin sürdürülebilir biçimde korunması ve etkili orman yönetimiyle desteklenmesi, günümüzde hâlen önemli bir öncelik olarak kabul edilmektedir. Ancak bu hedefe ulaşabilmesi için, orman ekosistemlerinin işleyişi, dinamikleri ve yönetim süreçleri hakkında derinlemesine bilimsel bir anlayış gerekmektedir. Geçmişte bu tür analizler, genellikle saha çalışmalarıyla sınırlı kalmış; doğrudan arazi ölçümleriyle gerçekleştirildiği için zaman alıcı ve maliyetli olmuştur (Masek vd., 2015). Orman ekosistemlerinin sürekli olarak izlenmesi ve değerlendirilmesi, sürdürülebilir kaynak yönetimi açısından kritik bir rol oynamakta, özellikle orman yönetiminde doğru kararların alınmasına ve gerekli koruma çabalarının yönlendirilmesine katkı sağlayacak önemli veriler sunmaktadır (Wang vd., 2021).

Son yıllarda gelişen uzaktan algılama teknolojileri, ormanların yapısını, bileşimini, dinamiklerini, bozulmalarını ve üretkenlik seviyelerini izlemek amacıyla uygun maliyetli ve etkili alternatifler sunmaktadır (Masek vd., 2015; Almeida vd., 2019). Özellikle orman yönetimi ve ekosistem analizinde mekânsal ve zamansal olarak kapsamlı bilgilere ihtiyaç duyulduğunda, uzaktan algılama verileri geniş alanlarda sürekli gözlem yapma olanağı

sunarak, geleneksel yöntemlere kıyasla önemli avantajlar sağlamaktadır (Masek vd., 2015). Bu teknolojik gelişmeler, orman yönetiminde daha bilinçli ve sürdürülebilir kararların alınmasını mümkün kılmakta; doğal kaynakların korunması ve verimli şekilde kullanılması süreçlerine anlamlı katkılar sunmaktadır.

Varvia vd. (2018), hava LiDAR verilerini kullanarak, Gaussian Process Regression (GPR) yöntemi aracılığıyla tür bazlı meşçere parametreleri olan ağaç boyu, göğüs çapı, ağaç sayısı, göğüs yüzeyi ve hacmi tahmin etmiştir. Çalışma, GPR yönteminin k-en yakın komşu (KNN) yöntemine kıyasla ortalama %4.6 daha düşük hata oranı sağladığını ve belirsizlik tahminlerinde yüksek başarı gösterdiğini ortaya koymuştur.

Sasaki vd. (2012), hava LiDAR verileri ve yüksek çözünürlüklü görüntü verilerini entegre ederek, nesne tabanlı sınıflandırma yöntemiyle arazi örtüsü ve baskın ağaç türlerini sınıflandırmıştır. Elde edilen sonuçlar, LiDAR verilerinin sınıflandırma sürecine dâhil edilmesinin genel doğruluk oranını artırdığını ortaya koymaktadır.

Shi vd. (2018), bitki fonksiyonel özelliklerini (örneğin, yaprak su içeriği, klorofil miktarı) LiDAR ve hiperspektral verilerden elde ederek ağaç türü sınıflandırması gerçekleştirmiştir. Sonuçlar, söz konusu özelliklerin kullanımının sınıflandırma doğruluğunu önemli ölçüde artırdığını ortaya koymaktadır.

Zhong vd. (2022), Çin'in kuzeydoğusunda yer alan karışık iğne yapraklı ve geniş yapraklı ormanlarda, İHA tabanlı hiperspektral görüntüler ile LiDAR verilerinin birleşimini kullanarak ağaç türlerini tanımlamıştır. Sonuçlar, veri füzyonunun tek kaynaklı verilere kıyasla daha yüksek sınıflandırma doğruluğu sağladığını ortaya koymaktadır.

Mayra vd. (2021), hava LiDAR ve hiperspektral verileri kullanarak, 3B evrişimli sinir ağları (3D-CNN) ile ağaç türü sınıflandırması gerçekleştirmiştir. Elde edilen sonuçlar, 3D-CNN yönteminin diğer makine öğrenme sınıflayıcılarına kıyasla daha yüksek performans gösterdiğini ve bireysel ağaç seviyesinde yüksek sınıflandırma doğruluğu sağladığını ortaya koymaktadır.

Oshio vd. (2022), yüksek çözünürlüklü ve çoklu geri dönüşlü hava LiDAR verilerini kullanarak, bireysel ağaçların üç boyutlu yaprak alan yoğunluğu dağılımını tahmin etmiştir. Çalışmada, son ve ara lazer darbelerinin kullanımı, taç içi yaprak dağılımının daha doğru şekilde modellenmesini sağlamıştır.

Grondin vd. (2022), derin öğrenme modelleri kullanarak LiDAR verileri üzerinden ağaç tespiti ve çap tahmini gerçekleştirmiştir. Çalışmada, 43.000 sentetik ve 100 gerçek görüntüden oluşan veri setleri oluşturulmuştur. Uygulanan modeller, ağaç tespiti ve

segmentasyonu süreçlerinde yüksek doğruluk sağlamış; çap tahminlerinde ise santimetre düzeyinde hassasiyet elde edilmiştir.

Brieche vd. (2020), 3B Derin Sinir Ağı (DSA) PointNet++ modelini kullanarak, İHA tabanlı LiDAR verileri ve multispektral görüntüler aracılığıyla birden fazla ağaç türünün ve taçlı ayakta duran ölü ağaçların sınıflandırılmasını gerçekleştirmiştir. Çalışma, orman sağlığının izlenmesi ve yönetimi açısından önemli bir örnek teşkil etmektedir. Sonuçlar, ağaç türlerinin sınıflandırılması açısından oldukça umut verici bulunmuştur.

Quan vd. (2023), doğal ikincil ormanlarda UAV tabanlı LiDAR ve hiperspektral verilerin entegrasyonu kullanarak ağaç türlerinin sınıflandırılmasında yüksek doğruluk elde etmiştir. Çalışmada, bireysel ağaç seviyesinde sınıflandırma doğruluğunu artırmak amacıyla çok kaynaklı uzaktan algılama verilerinin kullanımının önemini vurgulamaktadır.

Gaydon ve Roche (2024), Avrupa'nın tek tür ormanlarını kapsayan büyük ölçekli, tür etiketli ve doğrulanmış bir nokta bulutu verisi sunan PureForest veri setini geliştirmiştir. Çalışma, makine öğrenmesi ve derin öğrenme tabanlı modellerin eğitimi için önemli bir açık kaynak altyapısı sağlamaktadır. Bu katkı, standardizasyonun sağlanması ve farklı modellerin karşılaştırmalarına imkân tanıyarak, algoritmaların genellenebilirliğini test etme açısından literatürde önemli bir boşluğu doldurmaktadır.

Michalowska vd. (2021), hava LiDAR verileri kullanılarak gerçekleştirilen ağaç türü sınıflandırma çalışmalarını inceleyen bir derleme çalışması gerçekleştirmiştir. Çalışma, LiDAR verilerinden türetilen özniteliklerin ve kullanılan sınıflandırma algoritmalarının etkinliğini değerlendirmektedir. Elde edilen sonuçlar, tam dalga formu verilerinden elde edilen özniteliklerin en yüksek doğruluğu sağladığını ve Rastgele Orman ile Destek Vektör Makineleri gibi algoritmaların en başarılı tür ayrımı sonuçlarını verdiğini ortaya koymaktadır.

Lin vd. (2024), 3B LiDAR nokta bulutu verilerinden doğrudan ağaç türü sınıflandırması yapılmasına olanak tanıyan, transformer tabanlı bir model olan PCTreeS'i tanıtmıştır. Geleneksel CNN veya PointNet tabanlı yapılardan farklı olarak, bu model uzun menzilli bağımlılıkları ve geometrik ilişkileri daha etkili öğrenebilmektedir. Literatürde ilk kez transformer mimarisinin ağaç türü sınıflandırmasında bu ölçekte başarıyla uygulanmış olması, çalışmayı dikkat çekici hâle getirmektedir.

Bu çalışmada, hava LiDAR verisinden elde edilen nokta bulutu kullanılarak meşçere parametrelerinin kestirimi ve ağaç türü tahmini gerçekleştirilmiştir. Yalnızca nokta bulutu verisine dayanılarak, ağaçlara ait spektral imzaların elde edilmesini gerektiren optik verilere

ihitiyaç duyulmaksızın tür ayrımı yapılabilmekmiştir. Bu yönüyle, literatürde yaygın olan optik veri tabanlı yaklaşımlardan ayrışmaktadır. Tür tahminine yönelik gerekli veri seti, tüm aşamalarıyla oluşturulmuş ve farklı yöntemlerle karşılaştırmalı olarak değeriendirilmiştir.


Meşçere parametre kestiriminde, aynı meşçere tipine sahip tepe kapalılığı 1 olan alandaki ağaç boyu-gövde çapı ilişkisi kullanılarak, tepe kapalılığı 2 ve 3 olan alanlardaki gövde çapları tahmin edilmiştir. Farklı kapalılık sınıflarına sahip alanlarda gerçekleştirilen meşçere parametre kestirimi ve ağaç türü tahmini sonucunda elde edilen yüksek doğruluk değeri, bu çalışmanın hem yöntemsel doğruluğunu hem de literatüre katkı sağlayan ayırt edici yönünü ortaya koymaktadır.



2. TEMEL KAVRAMLAR

2.1. LiDAR Teknolojisi ve Tarihi Gelişimi

LiDAR, “Işık Algılama ve Mesafe Ölçümü” anlamına gelmektedir. Bu teknoloji, lazer darbeleri göndererek hedef nesnelere olan mesafeyi ölçmekte ve geri dönen sinyalleri analiz ederek üç boyutlu (3B) yüzey bilgilerini elde etmektedir (Şekil 1). LiDAR sistemleri, genellikle kızılötesi veya yakın kızılötesi dalga boylarını kullanmakta olup, bu sayede hava koşullarından bağımsız olarak gece ve gündüz veri toplama kapasitesine sahip bulunmaktadır (Guo vd., 2023).



Şekil 1. LiDAR sisteminin çalışma prensibinin şematik gösterimi (Guo vd., 2023)

LiDAR teknolojisi ilk olarak 1968 yılında Syracuse Üniversitesi'nden Hickman ve Hogg tarafından geliştirilmiştir. Bu teknoloji başlangıçta, kıyıya yakın okyanus derinliklerinin ölçülmesi amacıyla kullanılmıştır. Geliştirilen sistem, lazer ışınlarının yayılma süresi ile hedeften geri dönüş süresini ölçerek su derinliğini belirlemekteydi (Hickman ve Hogg, 1969). 1970'li yılların sonlarında, Amerika Birleşik Devletleri Ulusal Havacılık ve Uzay Dairesi (NASA) tarafından geliştirilen Hava Oşinografik LiDAR (Airborne Oceanographic Lidar – AOL) sistemi, su altı haritalama çalışmalarında önemli bir ilerleme olarak kaydedilmiştir (Hoge vd., 1980).

1980'li yılların başlarında, LiDAR teknolojisinin potansiyeli fark edilmiş ve bu teknoloji topografik haritalama çalışmalarında kullanılmaya başlanmıştır (Arp vd., 1982; Krabill vd., 1984). Ancak, söz konusu dönemde LiDAR sistemlerinin lazer darbeleri yoğun bitki örtüsünden geçmekte yetersiz kalmıştır; bu nedenle orman alanlarındaki kullanımı sınırlı düzeyde kalmıştır. 1984 yılında, Nelson ve ekibi, LiDAR teknolojisinin bitki örtüsü yoğunluğu ile olan ilişkisini inceleyerek, bu yöntemin orman yapısının belirlenmesi ve ağaç yüksekliğinin tahmini amacıyla kullanılabileceğini ortaya koymuştur (Nelson vd., 1984). Bununla birlikte, erken dönem LiDAR sistemlerinin 8 metreden kısa boylu ağaçları algılayamaması, ormancılık uygulamaları açısından önemli bir sınırlılık oluşturmuştur (Nelson vd., 1984).

1980'li yılların sonlarına doğru, Küresel Navigasyon Uydu Sistemleri (Global Navigation Satellite System-GNSS) ve Ataletsel Navigasyon Sistemleri (Inertial Navigation System-INS) gibi yeni teknolojiler geliştirilmiştir. Bu sistemlerin entegrasyonu sayesinde, lazer tarayıcılarının konumu ve yönelimi gerçek zamanlı olarak belirlenebilir hâle gelmiştir. 1990 yılında, Almanya'daki Stuttgart Üniversitesi'nden Profesör Ackermann, LiDAR teknolojisini gerçek zamanlı konumlandırma sistemleriyle entegre eden ilk lazer tarama sistemini geliştirmiştir. Bu gelişmeyi takiben, 1993 yılında Almanya'da ilk ticari havadan LiDAR sistemi TopScan ALTM 1020 üretilmiş ve 1995 yılında havadan LiDAR sistemleri ticari olarak yaygınlaşmaya başlamıştır (Pang vd., 2005).

1990'lı yıllarda, uydu tabanlı LiDAR sistemlerinin geliştirilmesine yönelik çalışmalar hız kazanmıştır. 2003 yılında, NASA tarafından kutup bölgelerindeki buz yüzeyindeki değişimleri ölçmek amacıyla Yerbilimleri Lazer Altimetre Sistemi (Geoscience Lazer Altimetre Sistemi-GLAS) tasarlanmıştır. GLAS ve Buz, Bulut ve Kara Yükselti Uydusu (Ice, Cloud and land elevation Satllite-ICESat), 2003 yılında birlikte uzaya fırlatılmış ve yedi yıl boyunca veri toplamıştır. 2018 yılında başlatılan ICESat-2 ve Küresel Ekosistem

Dinamikleri Araştırması (Global Ecosystem Dynamics Investigation-GEDI) projeleri, orman ekosistemlerinin yapısal özelliklerini büyük ölçeklerde yüksek hassasiyetle analiz etme imkânı sunmuş; bu sayede ekologlar için önemli bilimsel fırsatlar yaratmıştır (Hand, 2014; White vd., 1996). Bu gelişmelere dair LiDAR teknolojisinin tarihsel gelişim sürecindeki önemli kilometre taşları gösterilmiştir (Şekil 2).



Şekil 2. LiDAR gelişiminin kısa bir geçmişi ve önemli kilometre taşları (Guo vd., 2023)

Havadan LiDAR teknolojisi, orman alanlarının haritalanması ve ekolojik analizlerde yaygın olarak kullanılmaktadır. Bu teknoloji, orman yapısı, ağaç yüksekliği, tepe hacmi, karbon depolama miktarı gibi pek çok kritik parametrenin belirlenmesine olanak sağlayan veri setleri sunmaktadır. Geleneksel yöntemlerle karşılaştırıldığında, daha hızlı ve yüksek doğrulukta veri üretme kapasitesine sahip olması sayesinde, orman yönetimi ve ekolojik araştırmalara önemli katkılar sağlamaktadır (Saatchi vd., 2011).

LiDAR sistemleri, teknolojik gelişmelerle birlikte yerden, havadan ve uzaydan veri toplayabilme kapasitesine ulaşmış ve büyük ölçekli orman analizlerinde vazgeçilmez bir araç hâline gelmiştir. Günümüzde, orman yapısının haritalanması, biyokütle tahmini ve karbon stok hesaplamaları gibi çalışmalarda en yaygın kullanılan teknolojilerden biri olarak öne çıkmaktadır (Lefsky vd., 1999; Lefsky, 2010).

LiDAR teknolojisinin gelişmesiyle birlikte, farklı kullanım senaryolarına yönelik çeşitli sistem türleri geliştirilmiştir. Mesafe ölçüm sistemine göre LiDAR sistemleri, darbe tabanlı (pulse-based) ve faz tabanlı (phase-based) olmak üzere iki ana kategoriye ayrılmaktadır. Darbe tabanlı LiDAR sistemleri, lazerin yaydığı ışık darbesinin hedefe çarpıp geri dönmesi arasındaki süreyi ölçerek mesafeyi hesaplamaktadır. Buna karşılık, faz tabanlı sistemler, modüle edilmiş bir lazer sinyali göndererek geri dönen sinyal ile faz farkını karşılaştırmak suretiyle mesafe ölçümü gerçekleştirmektedir. Faz tabanlı sistemler, daha yüksek hassasiyet sunmalarına rağmen düşük enerji kapasiteleri nedeniyle genellikle kısa menzilli uygulamalarda tercih edilmektedir (Guo vd., 2023).

LiDAR sistemleri, veri toplama ölçeğine bağlı olarak farklı platformlara monte edilebilmektedir. Karasal LiDAR (Terrain Laser System-TLS) sistemleri, sabit bir konumdan bireysel ağaçların veya küçük alanların ayrıntılı bir şekilde taranması amacıyla kullanılmaktadır. Mobil LiDAR sistemleri, taşıtlar, sırt çantaları ya da çeşitli mobil platformlar üzerine entegre edilerek daha geniş alanlarda hızlı ve esnek veri toplama imkânı sunmaktadır. Havadan LiDAR (Airbone Laser Scanning-ALS) sistemleri, uçaklar veya insansız hava araçları (İHA) aracılığıyla geniş ormanlık alanların yüksek çözünürlüklü olarak haritalanmasını mümkün kılmaktadır. Uydu tabanlı LiDAR sistemleri ise, küresel ölçekteki orman ekosistemlerinin analizine yönelik geniş kapsamlı veri sağlayarak uzaktan algılama çalışmalarına yeni perspektifler kazandırmaktadır (Guo vd., 2023).

Karasal LiDAR sistemleri (TLS), ormancılık araştırmalarında önemli bir yere sahip bulunmaktadır. Bu sistemler, yüksek hassasiyetli 3B nokta bulutu verisi sağlayarak, orman envanteri çalışmalarında ayrıntılı analizlerin gerçekleştirilmesine olanak tanımaktadır. Bireysel ağaçların yapısal özellikleri, gövde çapı, ağaç boyu ve dal gelişimi gibi parametrelerin belirlenmesinde etkin şekilde kullanılmaktadır. Ayrıca, tahribatsız bir ölçüm yöntemi olması, TLS sistemlerini orman ekolojisi ve sürdürülebilir orman yönetimi açısından değerli kılmaktadır. Günümüzde TLS sistemleri, GNSS, IMU ve Eşzamanlı Konumlandırma ve Haritalama (Simultaneous Localization and Mapping-SLAM) teknolojileri ile entegre edilerek daha hızlı ve otomatik veri toplama olanağı sunmaktadır. Bu teknolojik gelişmeler, karasal ve mobil LiDAR sistemlerinin ormancılık ve ekolojik araştırmalar açısından yaygın ve etkili biçimde kullanılmasına olanak sağlamaktadır.

Havadan LiDAR sistemleri, lazer tarayıcıların GNSS ve IMU sistemleriyle entegre edilmesi sayesinde geniş alanların yüksek doğrulukla taranmasına olanak sağlamaktadır. Bu sistemler; uçaklar, zeplinler, motorlu delta kanatlar ve insansız hava araçları (İHA) gibi

çeşitli platformlara monte edilebilmektedir. Bu sayede, geniş alanlar kısa sürede taranabilmekte ve orman yapısının ayrıntılı biçimde incelenmesi mümkün hâle gelmektedir. Teknolojik gelişmelerle birlikte, ticari lazer tarayıcılar daha küçük boyutlarda, hafif ve ekonomik çözümler sunacak şekilde geliştirilmektedir.

Karasal ve havadan LiDAR sistemleriyle karşılaştırıldığında, uzay tabanlı LiDAR sistemleri çok daha geniş alanları kapsayabilmekte ve küresel ölçekte veri toplayabilmektedir. Bu sistemler, lazer darbelerinin yansıma izlerini veya kesitlerini kullanarak, yüksek irtifadan geniş hatlar boyunca gözlem gerçekleştirebilmektedir. Uzay tabanlı LiDAR sistemleri; topografik haritalama, orman yoğunluğunun izlenmesi ve geniş ölçekli orman araştırmaları gibi birçok alanda önemli avantajlar sunmaktadır. Ancak, yüksek yörüngeli platformların kullanılması ve sınırlı lazer darbe yoğunluğu nedeniyle elde edilen veriler, mekânsal yoğunluk açısından sınırlı olmakta ve sürekli gözlem yetenekleri kısıtlı kalmaktadır. Günümüze kadar, uzay tabanlı LiDAR sistemleri Dünya gözlem hizmetleri kapsamında altı büyük projede kullanılmıştır (Saatchi vd., 2011).

Bu projeler arasında, 2003 yılında fırlatılan ICESat uydusu üzerindeki GLAS ve 2018 yılında fırlatılan ICESat-2 uydusunda yer alan Gelişmiş Topografik Lazer Altimetre Sistemi, kutup bölgelerindeki buz hacminin hesaplanmasında kullanılmakta ve aynı zamanda meşçere boyuna ilişkin doğrudan bilgi sunmaktadır. Bulut ve aerosol yapılarını analiz etmeye yönelik olarak geliştirilen Cloud-Aerosol LiDAR ve CloudSat sistemleri, atmosferik özelliklerin dikey profillerini yüksek doğrulukla belirlemek amacıyla kullanılmaktadır. Avrupa Uzay Ajansı (European Space Agency-ESA) tarafından 2018 yılında fırlatılan Aeolus uydusu ise, dünya genelindeki rüzgâr hareketlerini ölçen ilk Doppler LiDAR sistemine sahiptir. Bu gelişmeler, uzay tabanlı LiDAR ölçümlerinin performansının değerlendirilmesine olanak tanımakta; ekosistem araştırmaları ve çevresel analizler açısından önemli potansiyel sunmaktadır (Lefsky, 2010; Lefsky vd., 1999).

LiDAR sistemleri, farklı alanlardaki teknolojilerin entegrasyonu ile oluşturulmaktadır. Optoelektronik, makine mühendisliği, navigasyon ve bilgisayar bilimi gibi çeşitli disiplinlerden yararlanarak çalışmaktadır. Lazer darbeleri ile mesafe ölçümü gerçekleştiren bu sistemler, yansıyan sinyallerin analiz edilmesiyle ayrıntılı 3B haritalar oluşturabilmektedir. Bir LiDAR sisteminin işleyişi, elde edilen verilerin doğruluğu ve güvenilirliği açısından kritik öneme sahiptir. Tipik bir LiDAR sistemi; lazer tarayıcı, alıcı sensörler, konum belirleme bileşenleri (GNSS ve IMU) ve veri işleme yazılımlarından

oluşmaktadır. Bu bileşenlerin birlikte çalışması, sistemin yüksek doğrulukla ölçüm yapmasını ve nitelikli veriler üretmesini sağlamaktadır.

LiDAR teknolojisi, nesneler arasındaki mesafeyi lazer darbeleri kullanarak yüksek hassasiyetle ölçmektedir. Bu ölçüm, lazer ışınının bir yüzeye çarpıp geri dönmesi sırasında geçen sürenin hesaplanması yoluyla gerçekleştirilmektedir. Işık hızının sabit olduğu varsayıldığından, bu süre kullanılarak hedefe olan mesafe belirlenebilmektedir. Mesafe hesaplamak için kullanılan temel formül $R = (c \times t) / 2$ şeklindedir; burada R, lazer sensörü ile hedef arasındaki mesafeyi, c ışık hızını, t lazer darbesinin gidiş-dönüş süresini temsil etmektedir. LiDAR sistemleri, mesafe ölçümünde iki farklı yöntem kullanmaktadır: darbeli lazer mesafe ölçümleri ve faz lazer mesafe ölçümleri (Guo vd., 2023).

Darbeli lazer mesafe ölçüm sistemleri, lazer darbesinin yayılması ile yansıyan sinyalin alıcı tarafından toplanması arasındaki zaman farkını kaydederek mesafeyi belirlemektedir. Bu süreç, dört temel aşamadan oluşmaktadır. İlk aşamada, lazer emisyonu gerçekleşmekte; lazer kaynağından yayılan darbe, bir tarama prizması veya optik sistem aracılığıyla yönlendirilerek belirli bir alana dağıtılmaktadır. İkinci aşama olan lazer algılama sürecinde, hedef yüzeyden yansıyan lazer darbesi bir alıcı tarafından yakalanmakta ve bu sinyal, elektriksel ışınımına dönüştürülerek analiz edilmektedir. Üçüncü aşamada gecikme hesaplama işlemi gerçekleştirilmekte; bu adımda, ışınım dağılımı işlenerek lazerin hedeften dönüş süresi belirlenmektedir. Son aşamada ise zaman ayrıntıları devreye girmekte ve yüksek hassasiyetli zamanlama cihazları yardımıyla lazer darbesinin süresi, atom saatine referansla hesaplanmaktadır.

Faz lazer mesafe ölçüm yöntemi, lazer ışığını sürekli bir dalga halinde yayarak çalışmaktadır. Bu yöntemde, yayılan lazer ışınının fazı belirli bir biçimde modüle edilmekte ve geri dönen yansıyan ışın ile karşılaştırılarak faz farkı ölçülmektedir. Ölçülen bu faz farkı, hedef nesneye olan mesafenin yüksek hassasiyetle hesaplanmasında kullanılmaktadır.

Darbeli lazer mesafe ölçümü ile karşılaştırıldığında, faz lazer mesafe ölçüm yöntemi genellikle daha yüksek bir hassasiyet sunmakta ve milimetre düzeyinde doğruluk sağlamaktadır. Ancak, bu yöntemin en büyük dezavantajı algılama mesafesinin sınırlı olmasıdır. Lazerin yaydığı enerjinin düşük olması nedeniyle, faz tabanlı sistemler genellikle 100 metreyi aşmayan mesafelerde etkili olabilmektedir. Bu nedenle, faz lazer mesafe ölçüm sistemleri daha çok kısa menzilli ve yüksek hassasiyet gerektiren uygulamalarda tercih edilmektedir. Özellikle endüstriyel üretim süreçlerinde, hassas yüzey ölçümlerinde ve bina içi taramalarda yaygın olarak kullanılmaktadır (Guo vd., 2023).

LiDAR'ın mesafe belirleme doğruluğu, sistem performansını değerlendirmede önemli bir ölçüt olarak kabul edilmektedir. Bu doğruluk, temel olarak lazer darbesinin uzunluğu, yükselme süresi ve dalga boyu gibi fiziksel parametrelere bağlıdır. Genel olarak, LiDAR sistemlerinin mesafe ölçüm doğruluğu, sinyal-gürültü oranının (Signal to Noise Rate-SNR) karekökü ile ilişkili olmaktadır. SNR seviyesi arttıkça, sistemin ölçüm performansının da aynı oranda yükseldiği gözlemlenmektedir (Wehr ve Lohr, 1999).

SNR değerleri, birçok belirsizliği bünyesinde barındırmaktadır. Giriş enerjisi sinyali, gürültü bant genişliği ve amplifikatör kaynaklı gürültüler, SNR seviyesini doğrudan etkileyen başlıca faktörler arasında yer almaktadır. Alınan sinyal gücünün düşük olduğu durumlarda, termal gürültü baskın hale gelmekte; bu koşullarda diğer gürültü türlerinin etkisi görece azalmakta ve SNR seviyesi doğrudan alınan sinyal gücüne bağlı olarak değişiklik göstermektedir. Ayrıca, darbe genişliği, faz kayması bant genişliği ve yükselme süresi gibi parametrelerdeki değişiklikler, sinyal gücünde azalmaya neden olan önemli faktörler arasında yer almaktadır. Özellikle darbe süresinin kısalması, bant genişliğini artırmakta ve bu durum ölçüm doğruluğu üzerinde doğrudan etkili olabilmektedir (Wehr ve Lohr, 1999).

Tüm LiDAR sistemleri, kullanılan LiDAR denklemlerinin temel prensiplerine ve geri dönüş sinyallerinin kaydedilme yöntemine göre iki ana kategoriye ayrılmaktadır: ayrık geri dönüş (discrete return) sistemler ve tam dalga form (full waveform) sistemler. Ayrık geri dönüş sistemleri, lazer darbesinin hedefe çarpıp geri dönmesiyle oluşan sinyalleri belirli noktalarda örnekleyerek kaydetmektedir. Bu sistemlerde, geri dönüş sayısı ve sinyallerin kaydedilme biçimi, kullanılan lazer cihazının teknik özelliklerine ve hedef yüzeyin yapısına bağlı olarak farklılık göstermektedir.

LiDAR denklemleri, alınan lazer sinyalinin gücünün çeşitli parametrelere bağlı olduğunu ortaya koymaktadır. Alınan enerji; gönderilen lazer darbesinin gücü, hedef yüzeyin yansıtma katsayısı, nesne boyutu ve cihazın alıcı açıklığı ile doğru orantılıdır. Buna karşılık, sinyal gücü gönderim açısı, saçılma açısı ve menzilin artmasıyla birlikte azalma göstermektedir. Lazer darbesi bir yüzeye çarptığında, yüzeyin fiziksel ve yapısal özelliklerine bağlı olarak farklı sayıda geri dönüş sinyali oluşmaktadır. Örneğin, düz ve sert yüzeyler genellikle tek bir geri dönüş üretirken, ormanlık alanlar veya karmaşık yüzey yapıları üç ya da daha fazla geri dönüş sinyali oluşturabilmektedir.


Ayrık geri dönüş sistemlerinde, alınan sinyal belirli bir enerji eşiğini aştığında bir nokta olarak kabul edilmektedir. Bu yaklaşım, gereksiz verilerin kaydedilmesini engelleyerek veri depolama ve işleme süreçlerini daha verimli hâle getirmektedir. Ancak,

söz konusu sistem karmaşık yüzey yapılarına sahip bölgelerde küçük ayrıntıların gözden kaçmasına neden olabilmektedir. Özellikle yoğun bitki örtüsünün bulunduğu ormanlık alanlarda, alt tabakalara ulaşabilen lazer darbesi sayısı azalmakta ve bu durum bazı önemli detayların tespit edilmesini zorlaştırmaktadır. Bu nedenle, düzenli aralıklarla yürütülen uygulamalarda, tam dalga form sistemi daha fazla ayrıntı sunma kapasitesi nedeniyle tercih edilmektedir.

Tam dalga formlu sistemler, geri saçılan lazer sinyalinin tamamına ait dalga formunu kaydedebilme yeteneğine sahiptir. Bu özellik, hedef nesnelerin ayrıntılı 3B yapısal özelliklerinin elde edilmesine ve dalga profili analizleri yoluyla ek fiziksel bilgilerin çıkarılmasına olanak tanımaktadır (Zhugeng ve Huashun, 2011). Ancak, bu sistemlerin veri hacmi oldukça büyük olmakta ve uygulama süreçleri daha karmaşık ve zorlu hâle gelmektedir. Lazer noktasının boyutuna bağlı olarak, tam dalga formlu sistemler küçük ayak izli ve büyük ayak izli olmak üzere iki grupta sınıflandırılmaktadır.


Küçük ayak izli tam dalga formlu sistemler, yüksek nokta yoğunluğu ve hassasiyetleri ile öne çıkmakta olup, ayrıntılı bir nokta bulutu oluşturabilme kapasitesine sahiptir. Ancak, yüksek maliyetleri ve düşük darbe enerjileri nedeniyle lazer darbelerinin hedef içindeki nüfuz kabiliyeti sınırlı kalmaktadır. Bu nedenle, söz konusu sistemler daha çok küçük ölçekli ve yüksek detay gerektiren analizlerde tercih edilmektedir. Öte yandan, büyük ayak izli tam dalga formlu sistemler, daha geniş alanları kapsayabilen güçlü darbe enerjilerine sahip olup, bu avantajları sayesinde geniş ölçekli uygulamalarda kullanılmaktadır. Ancak, bu sistemler daha düşük mekânsal çözünürlüğe sahip veriler üretmekte ve nokta bazlı veriler yerine daha sürekli dalga formu verileri sağlamaktadır. Ayrık nokta bulutlarının elde edilmesi, LiDAR verilerinin işlenmesi ve paylaşımı açısından hâlen en yaygın kullanılan veri formatlarından biri olma özelliğini sürdürmektedir.

Lazer tarayıcı sistemleri, çeşitli platformlara entegre edilebilecek esneklikte tasarlanmaktadır. Bu sistemler; üçayaklı sabit düzeneklerden sırt çantası sistemlerine, kara taşıtlarına, insansız hava araçlarına (İHA), insanlı hava araçlarına ve hatta uydulara kadar farklı taşıyıcı yapılar üzerinde kullanılabilmektedir. Söz konusu çok yönlülük sayesinde, LiDAR uygulamaları arazi ölçeğinden küresel ölçekte veri elde etmeye kadar oldukça geniş bir kullanım alanı sunmaktadır (Şekil 3).



Şekil 3. Çeşitli platformlara monte edilmiş farklı LiDAR sensörleri (Guo vd., 2023)

LiDAR uzaktan algılama teknolojisi, ormancılık uygulamalarında hızlı, hassas ve verimli veri toplama olanakları sunmaktadır. Özellikle düzenli alanlarda gerçekleştirilen LiDAR taramaları sırasında, lazer darbeleri bitki örtüsünün farklı katmanlarından yansımalar oluşturmaktadır. Bu yansımalar; bitki örtüsünün en üst kısmı (ilk dönüş), ağaçların ara katmanları (ikinci ve sonraki dönüşler) ve zemin yüzeyi (son dönüş) gibi farklı seviyelerden meydana gelmektedir (Şekil 4). LiDAR sistemleriyle elde edilen ilk ve ikinci dönüş verileri, bireysel ağaçların yapısal özelliklerinin tahmin edilmesinde kullanılmaktadır. Bu veriler aracılığıyla, ağaçların tepe genişliği, gövde çapı, hacmi ve adedi gibi ormancılık açısından kritik öneme sahip parametreler yüksek doğrulukla belirlenebilmektedir (Reutebuch vd., 2003, Maltamo vd., 2004).



Şekil 4. Bitki örtüsünün farklı seviyelerinden yansıyan LiDAR ışık darbeleri: (1) bitki örtüsünün üstünden geri dönen, (2) ara yüzeyden geri dönen ve (3) yer yüzeyinden geri dönen (Reutebuch vd., 2003)

2.2. LiDAR Nokta Bulutu Verileri

LiDAR sistemi tarafından elde edilen ham veriler, genellikle 3B koordinat bilgileri (x, y, z) ile birlikte hedef nesnelerin geri yansıttığı yoğunluk (intensity) bilgilerini içeren büyük ölçekli bir nokta bulutu şeklinde yapılandırılmaktadır. Bu veriler, yaygın olarak Lazer Dosya Formatı (LASer File Format-LAS) veya Amerikan Standart Kodlama ve Bilgi Değişim Sistemi (American Standard Code for Information Interchange-ASCII) formatında düzenlenmektedir.

LAS dosya formatı, Amerikan Fotogrametri ve Uzaktan Algılama Derneği (ASPRS) tarafından Mayıs 2003'te yayımlanmış ve LiDAR verilerinin depolanması ile analiz edilmesi için standart bir yapı hâline gelmiştir. Format, zaman içerisinde gelişen donanım teknolojileri ve artan veri ihtiyaçlarına paralel olarak birçok kez güncellenmiş; en güncel sürüm LAS 1.4 olarak yayımlanmıştır.

Veri işleme yazılımlarının çeşitlenmesi ve LiDAR sistemlerindeki donanımsal gelişmelere bağlı olarak, Nokta Veri Kaydı Formatları (Point Data Record Formats) da güncellenmiştir. İlk sürüm olan Format 0, yalnızca temel 3B konum ve yoğunluk verilerini

içermekteyken, sonraki sürümler (Format 1–6), zaman bilgisi, renk (RGB), sınıflandırma, yüzey tipi, sensör yönelimi gibi ek parametreleri de içerecek şekilde genişletilmiştir (Tablo 1). Bu yapı, nokta bulutu kayıtlarının uygulama alanlarına göre özelleştirilmesine ve daha zengin veri içeriğiyle çalışılmasına olanak tanımaktadır.

Tablo 1. Nokta Veri Kaydı (Format 6)

Öge	Boyut	Öge	Boyut
X	4 bayt	Scanner channel	2 bit
Y	4 bayt	Scan direction flag	1 bit
Z	4 bayt	Edge of flight line	1 bit
Intensity	2 bayt	Classification	1 bayt
Return Number	4 bit	User data	1 bayt
Number of returns (given pulse)	4 bit	Scan angle	2 bayt
Classification flags	4 bit	Point source ID	2 bayt
GPS time	8 bayt		

X, Y, Z: Ölçekleme faktörü ve ofset dikkate alınarak hesaplanan gerçek koordinat değerleridir.

Intensity (Yoğunluk): Yankı yoğunluğu olup, algılanan bir nesnenin lazer darbesine verdiği yansıma özelliklerini ifade etmektedir.

Return Number (Dönüş Numarası): Her bir lazer darbesine karşılık gelen yankı dizisini belirtmektedir.

Number of Returns (Verilen Darbe): İlgili darbeden toplam kaç yankı alındığını göstermektedir.

Scan Direction Flag (Tarama Yönü Bayrağı): Lazer taramasının yönünü belirtmekte olup, ileri tarama için 1, geri tarama için 0 değeri kullanılmaktadır.

Edge of Flight Line (Uçuş Çizgisinin Kenarı): Yalnızca bir nokta, bir tarama çizgisinin son noktası olduğunda 1 değerini almaktadır.

Classification (Sınıflandırma): Her noktanın kategori niteliğini belirtmektedir. Sınıflandırılmamış noktalar için değer 0 olarak ayarlanmakta olup, ASPRS tarafından tanımlanan standart sınıflandırma kodlarını içermektedir.

Scan Angle Rank (Tarama Açısı Sıralaması): Sensörün eğim açısını, yuvarlanma, eğim ve sapma dahil olmak üzere kaydetmektedir.

User Data (Kullanıcı Verileri): Kullanıcı tarafından belirlenen isteğe bağlı verilere ayrılmış alandır.

Point Source ID (Nokta Kaynak Kimliği): Her bir noktanın hangi dosyadan geldiğini belirtmekte olup, 1–65.535 aralığında geçerli değerlere sahiptir.

Classification Flags (Sınıflandırma Bayrakları): Noktanın özel niteliklerini temsil eden bayrakları içermektedir.

Scanner Channel (Tarayıcı Kanalı): Çok kanallı sistemlerde her bir kanalın belirtildiği alandır.

GPS Time (GPS Zamanı): Atomik saatlerle senkronize çalışan yüksek hassasiyetli zaman bilgisini sunmaktadır.

Amerikan Fotogrametri ve Uzaktan Algılama Derneği (ASPRS), LiDAR verilerinin etkin ve tutarlı bir biçimde sınıflandırılabilmesi amacıyla bir nokta sınıflandırma sistemi geliştirmiştir. Bu sistem, LiDAR nokta bulutu verilerinin farklı yüzey tiplerini ve nesneleri ayırt edebilmesini sağlayarak, analiz sürecinin doğruluğunu artırmakta ve kullanım alanlarının çeşitliliğini genişletmektedir.

Nokta Veri Kayıt Formatı 6 ve sonraki sürümlerle birlikte, ASPRS tarafından tanımlanan standart LiDAR nokta sınıfları daha da genişletilmiş ve çeşitli arazi özellikleri ile yapısal unsurları temsil edebilecek şekilde güncellenmiştir. ASPRS tarafından tanımlanan bazı temel standart LiDAR nokta sınıfları Tablo 2’de sunulmuştur.

Tablo 2. ASPRS standart LiDAR Nokta Sınıfları (Format 6-10)

Kod	Anlam	Kod	Anlam
0	Varsayılan (Default)	11	Yol Yüzeyi (Road surface)
1	Sınıf (Class)	12	Ayrılmış Tanım
2	Zemin (Ground)	13	Güç Hattı (Power line)
3	Düşük Bitki Örtüsü (Low vegetation)	14	Güç Hattı (Power line)
4	Orta Bitki Örtüsü (Medium vegetation)	15	Direk (Pylon)
5	Yüksek Bitki Örtüsü (High vegetation)	16	Güç Hattı (Power line)
6	Bina (Building)	17	Köprü (Bridge)
7	Düşük Gürültü (Low noise)	18	Yüksek Gürültü (High noise)
8	Ayrılmış Tanım (Reserved definition)	19-63	Ayrılmış Tanım
9	Su (Water)	64-255	Kullanıcı Tanım
10	Demiryolu (Railway)		

LiDAR, 3B veri toplama kapasitesi sayesinde tarım, ormancılık ve şehircilik gibi birçok disiplinde yaygın olarak kullanılmaktadır. Bu teknolojinin veri özelliklerinin ayrıntılı biçimde anlaşılması, kullanıcıların LiDAR nokta bulutu verilerini daha etkin işlemesine ve analiz etmesine olanak sağlamaktadır.

Lazer tarayıcılar, yüksek bir örnekleme frekansına sahip olup kısa sürede binlerce veri noktası toplayabilmektedir. Geleneksel iki boyutlu uzaktan algılama yöntemlerinin aksine, LiDAR sistemleri coğrafi nesnelerin 3B koordinat bilgilerini doğrudan elde etmektedir. Ancak, nokta yoğunluğu genellikle sensörden uzaklaştıkça azalma göstermekte ve LiDAR verileri ayrık nokta kümeleri şeklinde dağılmaktadır. Bu sistemler yalnızca koordinat bilgisiyle sınırlı kalmamakta, aynı zamanda nesnelerden yansıyan lazer sinyallerinin yankı yoğunluğu bilgilerini de kaydetmektedir. Yoğunluk verileri, nokta bulutlarının filtrelenmesi ve sınıflandırılmasında kullanılmaktadır (Lu vd., 2014). Bununla birlikte, gerekli kalibrasyonun yapılmaması, yoğunluk bilgisinin yaygın olarak kullanılmamasına neden olmaktadır. Bu teknik sınırlamalar, özellikle veri işleme sürecinin sonraki aşamalarında çeşitli zorluklara yol açabilmektedir (Liang vd., 2005).

LiDAR'ın 3B yapı elde etme kapasitesi, yükseklik bilgilerini doğrudan ölçemeyen klasik uzaktan algılama yöntemlerini tamamlayıcı nitelik taşımaktadır. Ancak, LiDAR verilerinde hedef nesnelere ilişkin spektral veya dokusal bilgiler bulunmamaktadır. Bu eksiklik nedeniyle, birçok çalışmada LiDAR verileri optik uydu görüntüleri veya hiperspektral verilerle entegre biçimde kullanılmaktadır (Persson vd., 2004; Popescu ve Wynne, 2004).

Karasal LiDAR sistemleri (Terrain Laser Scanner-TLS), özellikle geniş alanlarda veri edinimi için çok açılı ve çok konumlu taramalara ihtiyaç duymaktadır. Günümüzde, çok istasyonlu TLS verilerinin kaydedilmesi, hâlâ farklı tarama noktalarındaki bağlama noktalarının manuel olarak belirlenmesini gerektirmektedir (Lefsky vd., 2002). Ancak, ormanlık alanlarda ağaç formlarının yüksek çeşitliliği nedeniyle bu bağlama noktalarının tespit edilmesi oldukça güç olmaktadır. Ayrıca, sınırlı görüş alanı ve menzil kısıtlamaları ile karmaşık arazi yapısı ve nesneler arası tıkanma etkileri, eksik nokta bulutu verilerinin oluşmasına neden olabilmektedir.

Ormanlık alan uygulamalarında, aşağıdan yukarıya doğru gerçekleştirilen TLS veya sırt çantalı LiDAR taramaları, ağaç gövdeleri ve alt tepe katmanları hakkında yüksek ayrıntılı bilgiler sunmaktadır. Ancak, bu sistemlerle üst tepe katmanlarına ilişkin verilerin elde edilmesi oldukça güç olmaktadır. Öte yandan, İHA veya hava araçlarına entegre edilen

ve yukarıdan aşağıya doğru tarama yapan lazer sistemleri, üst tepe yapısına ilişkin detayları başarılı bir şekilde yakalayabilmektedir. Bununla birlikte, yoğun ve sık örtülü alanlarda bu sistemler alt katman verilerini elde etmede yetersiz kalabilmektedir. Bu nedenle, farklı LiDAR platformlarının birbirini tamamlayacak şekilde entegre edilmesi, orman ekosisteminin bütüncül analizinin sağlanabilmesi açısından kritik öneme sahiptir.

2.3. Nokta Bulutu Sınıflandırması

Nokta bulutu verileri, genellikle zemin, ağaçlar ve binalar gibi belirgin geometrik özelliklere sahip çok sayıda nesne içermektedir. Bu kategoriler, kullanım amacına bağlı olarak farklılık gösterebilmekte; ancak nokta bulutu sınıflandırma yöntemleri çoğunlukla model uyumu, bölge büyütme, kümeleme, hiyerarşik strateji, makine öğrenimi ve derin öğrenme gibi benzer genel ilkelere dayanmaktadır (Guo vd., 2023).

2.3.1. Model Uyumuna Dayalı Nokta Bulutu Sınıflandırması

Birçok yapay nesne, belirli geometrik şekiller kullanılarak tanımlanabilmektedir. Örneğin, bir binanın cephesi düzlem olarak kabul edilirken, direkler ve ağaç gövdeleri silindirik yapılarla temsil edilebilmektedir. Bu tür geometrik şekiller, birkaç parametre aracılığıyla tasvir edilebilmektedir. Bu nedenle, model uydurmaya dayalı sınıflandırma yaklaşımları, parametre tabanlı sınıflandırma olarak da adlandırılmaktadır (Guo vd., 2023). Bu yaklaşım kapsamında en yaygın kullanılan yöntemlerden ikisi, Hough dönüşümü ve Random Sample Consensus (RANSAC) olarak öne çıkmaktadır.

Hough dönüşümü, görüntü analizi ve bilgisayarlı görme alanında en yaygın kullanılan özellik çıkarma yöntemlerinden biri olarak öne çıkmaktadır. Bu yöntem, iki boyutlu görüntülerden çizgi, daire ve elips gibi nesnelerin tespit edilmesi amacıyla yaygın biçimde uygulanmaktadır. Hough dönüşümü, basit geometrik nesneleri parametreler aracılığıyla tanımlayarak, hesaplama karmaşıklığını önemli ölçüde azaltmaktadır (Ballard, 1981; Hough, 1962).

Nokta bulutu verilerinden ağaçların çapını (diameter-d) belirlemek amacıyla iki boyutlu Hough dönüşümünü kullanılmaktadır. Bu yöntemde, öncelikle yerden 1,25-1,35 metre yükseklikteki noktalar seçilmekte ve bu noktalar, 1 cm ızgara boyutuna sahip raster görüntüye enterpole edilmektedir. Hough dönüşümü ile daire algılaması yapılırken, çap

bilgisinin önceden tanımlanması gerektiğinden, başlangıçta çap değeri 100 cm olarak ayarlanmakta ve 10 cm'lik aralıklarla azaltılmaktadır. Daire doğru şekilde algılandığında, belirlenen çap değeri optimum çap olarak kabul edilmektedir (Ballard, 1981; Hough, 1962).

RANSAC, gözlemlenen verilerden optimal parametre modelini tahmin etmek amacıyla kullanılan bir yöntem olarak tanımlanmaktadır (Fischler & Bolles, 1981). Yöntemin temel adımları şu şekilde sıralanmaktadır: Öncelikle, tüm veri kümesinden rastgele bir nokta alt kümesi örneklenmekte ve bu alt kümedeki noktalar başlangıç aday noktaları olarak belirlenmektedir. Bu aday noktalardan yola çıkılarak başlangıç parametre modeli oluşturulmaktadır. Daha sonra, diğer noktalar ile aday model arasındaki sapmalar hesaplanmaktadır. Eğer bir noktanın sapması belirli bir eşik değerin altında kalıyorsa, bu nokta da aday nokta olarak kabul edilmekte ve mevcut modele dâhil edilmektedir. Aday noktaların sayısı önceden tanımlanmış bir eşik değere ulaştığında, aday model makul olarak değerlendirilmekte ve tüm aday noktalar modele yeniden uydurulmak üzere kullanılmaktadır. Yeni oluşturulan model, orijinal modelden daha iyi performans gösteriyorsa, mevcut model bu yeni modelle değiştirilmektedir; aksi durumda, mevcut model korunmaktadır. Bu adımlar, yeterli sayıda aday nokta elde edilene ve aday modelin performansı kararlı bir duruma ulaşana kadar tekrarlanmaktadır.

Schnabel vd. (2007), RANSAC algoritmasını kullanarak nokta bulutlarından düzlem, küre, koni, silindir ve halka gibi geometrik yapılar çıkarmaktadır. Söz konusu çalışmada, başlangıç noktalarının sayısı, her noktanın normal vektörü ve her aday modelin uyumlu noktaları dikkate alınarak, iki parametrelili standart bir değerle azaltma işlemi gerçekleştirilmektedir. Bu parametrelerden biri, uyumlu noktalardan düzleme olan maksimum uzaklığı; diğeri ise nokta normal vektörleri ile düzlem normal vektörü arasındaki sapmayı temsil etmektedir.

2.3.2. Bölge Büyümesine Dayalı Nokta Bulutu Sınıflandırması

Algoritma, tohum noktasının (seed point) seçilmesi ve yüzeyin belirli ölçütlere göre büyütülmesi olmak üzere iki ana adımdan oluşmaktadır. Bu algoritma, noktaların bir düzleme oturtulması ve belirli bir aralıktaki her nokta ile komşu noktalar için hata değerlerinin (residuals) hesaplanması yoluyla tohum yüzeyini belirlemektedir. Hata kareleri toplamı, belirli bir eşik değerinin altında kaldığında, bu toplamın en düşük olduğu noktalar tohum yüzeyini oluşturmaktadır. Ancak bu yöntem, aykırı değerler (outliers) ve anormal

noktalar karşısında duyarlılık göstermektedir. Bu tür durumlarda, tohum yüzeyinin sağlam en küçük kareler (robust least squares) ya da Hough dönüşümüne dayalı düzlem uyumu ile belirlenmesi önerilmektedir. Yüzey büyütme işlemi ise genellikle aşağıdaki ölçütlere göre gerçekleştirilmektedir:

(1) Noktaların yakınlığı: Düzleme yalnızca yakın konumda bulunan noktalar eklenmektedir. 2,5 boyutlu verilerde bu yakınlık, bir aday noktanın mevcut düzlemdeki noktalara bir Delaunay üçgen ağı aracılığıyla bağlanıp bağlanamayacağının kontrolüyle değerlendirilmektedir.

(2) Yerel düzlem: Tohum yüzeyinde yer alan her nokta ve komşu noktaları için bir düzlem uydurulmakta; yalnızca bu düzleme olan dik uzaklığı önceden tanımlanmış bir eşik değeri d 'den küçük olan aday noktalar kabul edilmektedir.

(3) Normal vektör: Aday noktanın normal vektörleri ile en yakın komşu noktanın normal vektörü arasındaki açı, belirli bir eşik değerinden küçükse, söz konusu aday nokta geçerli düzleme dahil edilmektedir (Guo vd., 2023).

Pu ve Vosselman (2006), başlangıç nokta bulutu segmentasyonunu gerçekleştirmek amacıyla Vosselman vd. (2004) tarafından geliştirilen bölge büyütme algoritmasını benimsemiştir. Söz konusu çalışmada, segmentlerin boyut, konum, yönelim ve topolojik yapı gibi önemli özellikleri çıkarılmış; bu özellikler, duvarlar, pencereler ve kapılar gibi farklı bina bileşenlerini hassas şekilde elde etmek için kullanılmıştır.

Xu vd (2009), nokta bulutu verilerinden oluşturulan yansıma görüntüsünü kullanarak, tohum noktalarının elde edilmesi amacıyla grafik teorisine dayalı bir segmentasyon yaklaşımı önermiştir. Bu yöntemde, yansıma görüntüsü grafik teorisi esas alınarak segmente edilmiş; ardından, nokta bulutu verileri bölge büyütme işlemi hem de elde edilen tohum noktaları doğrultusunda segmentlere ayrılmıştır.

Geleneksel bölge büyütme algoritmalarının tek bir başlangıç noktasına dayalı olması, bu yöntemlerin büyük hacimli 3B nokta bulutu veri kümelerine uygulanmasında hesaplama maliyetini artırmakta ve işlemleri zaman alıcı hâle getirmektedir. Bu soruna çözüm olarak, Vo vd (2015), kaba ölçekten ince ölçeğe doğru ilerleyen bir segmentasyon süreci gerçekleştirmek amacıyla sekizli ağaç (octree) tabanlı bir bölge büyütme algoritması önermiştir.

Önerilen iş akışı şu şekilde tanımlanmaktadır: İlk olarak, nokta bulutu verilerini çevreleyen minimum küp tanımlanmakta ve bu küp, sekizli ağacın kök düğümü olarak atanmaktadır. Ardından, kök düğüm, belirli sonlandırma ölçütleri sağlanan kadar yinelemeli

biçimde sekiz alt düğüme ayrılmaktadır. Hata değerleri ve normal vektörler gibi temel özellikler her düğüm için hesaplanmakta, ardından bölge büyütme algoritması uygulanarak kaba segmentasyon gerçekleştirilmektedir. Son aşamada, sınırdaki yer alan düğümler kaba segmentasyon sonuçlarına göre belirlenmekte ve ince segmentasyon işlemi, bu sınır düğümlerinin çevresindeki tampon bölgelerde uygulanmaktadır.

Bölge büyümesine dayalı segmentasyon yöntemleri, basit yapıları ve düzgün bağlı bölgelerde yüksek etkinlik göstermeleri sayesinde öne çıkmaktadır. Ancak, bu yöntemlerin doğruluğu ve verimliliği büyük ölçüde başlangıç noktalarının veya bölgelerinin seçimlerine bağlı kalmaktadır. Buna karşın, söz konusu başlangıç noktalarının ya da bölgelerin seçiminde kullanılabilecek evrensel ve etkili yöntemler henüz geliştirilmemiştir (Teboul ve diğerleri, 2010).

2.3.3. Kümeleme Tabanlı Nokta Bulutu Sınıflandırması

Kümeleme, nesneleri belirli kurallara ve nesne özelliklerine göre otomatik olarak farklı gruplara ayıran gözetimsiz bir sınıflandırma yöntemi olarak tanımlanmaktadır. Kümeleme yöntemleri genel olarak iki ana kategoriye ayrılmaktadır: hiyerarşik kümeleme ve bölümlü kümeleme (Jain vd., 1999). Bu iki yöntem arasındaki temel fark; bölümlü kümeleme, birbirinden bağımsız kümeler üretirken, hiyerarşik kümeleme belirli kurallara dayalı olarak ağaç benzeri bir yapı içerisinde farklı düzeylerde kümeler oluşturmaktır.

Bölümlü kümeleme yöntemlerinde karşılaşılan en büyük zorluklardan biri, küme sayısının önceden belirlenmesidir. Günümüzde optimum küme sayısının tahmini için dirsek yöntemi (elbow method), ortalama silüet yöntemi (average silhouette method) ve boşluk istatistiği (gap statistic) gibi çeşitli teknikler kullanılmaktadır. Genellikle, bölümlü kümeleme, büyük ölçekli nokta bulutu veri kümeleri için daha uygun görülmektedir. Buna karşılık, hiyerarşik kümeleme, yüksek hesaplama maliyeti nedeniyle büyük veri kümeleri için uygun bir seçenek olarak değerlendirilmemektedir.

Klasik kümeleme yöntemleri arasında K-ortalama kümeleme (K-means clustering), yoğunluk tabanlı uzamsal kümeleme (DBSCAN) ve bulanık kümeleme (fuzzy clustering) yer almaktadır.

MacQueen (1967), N boyutlu verileri K kümeye ayırmak amacıyla K-ortalama kümeleme algoritmasını önermiştir. Bu yöntemde, kullanıcı tarafından önceden belirlenen K sayısı kadar nokta, başlangıç küme merkezleri olarak nokta bulutu verilerinden rastgele

seçilmektedir. Daha sonra, her nokta en yakın küme merkezine atanmaktadır ve her küme için yeni merkezler hesaplanmaktadır. Bu işlem, küme merkezleri sabitlenene kadar ya da merkezlerdeki değişim belirli bir eşik değerin altına düşüne kadar yinelemeli sürdürülmektedir.

Algoritmanın uygulanması görece kolay olmakla birlikte, zıt özellikler içeren veri kümelerinde dahi yüksek doğruluk ve verimlilik sağlayabilmektedir. Bununla birlikte, bazı sınırlamaları da bulunmaktadır. Öncelikle, küme sayısı K 'nin önceden belirlenmesi gerekmekte olup, uygun bir değer seçmek çoğu zaman ön bilgi olmadan güç olabilmektedir. Ayrıca, başlangıçta rastgele seçilen küme merkezleri, kümeleme sonucunu önemli ölçüde etkileyebilmektedir. Yineleme süreci ise, özellikle büyük boyutlu veri kümelerinde zaman alıcı olabilmektedir.

Aykırı değer içeren veri kümeleri için geliştirilen Yoğunluk Tabanlı Uzamsal Kümeleme (Density-Based Spatial Clustering of Application with Noise-DBSCAN), belirli kavramlara ve tanımlara dayalı olarak çalışan yoğunluk tabanlı kümeleme algoritması olarak tanımlanmaktadır (Ester vd., 1996). Bu algoritma, yüksek yoğunluklu bölgeleri kümeler olarak tanımlarken, düşük yoğunluklu ve kümelere ait olmayan noktaları aykırı değer olarak sınıflandırmaktadır.

(1) Bir noktanın Eps (Epsilon) komşuluğu, ilgili noktanın belirli bir Eps yarıçapı içerisinde yer alan tüm komşu noktaları kapsamaktadır.

(2) Çekirdek noktalar, Eps komşuluğu içerisinde belirli bir eşik değere eşit ya da bu değerden fazla sayıda nokta içeren noktalar olarak tanımlanmaktadır. Bu çekirdek noktalar, kümelerin merkezini oluşturmakta ve yeni noktaların kümeye dâhil edilmesini sağlamaktadır.

DBSCAN algoritmasının temel amacı, yoğunluk açısından birbirine bağlı noktaların oluşturduğu en büyük kümeleri belirlemektir. Bu doğrultuda, algoritma öncelikle veri kümesinden bir çekirdek nokta P seçmekte ve bu noktadan yoğunluk açısından erişilebilir tüm noktaları belirlemektedir. Bir noktanın çekirdek nokta olarak kabul edilmesi için, Eps yarıçapı içerisinde en az belirli sayıda komşu nokta (MinPts) içermesi gerekmektedir.

Daha sonra, P noktasının Eps komşuluğunda yer alan diğer çekirdek noktalar da incelenmekte, bu noktalardan yoğunluk açısından erişilebilir yeni noktalar tespit edilmekte ve kümeye dâhil edilmektedir. Bu işlem, kümeye yeni nokta eklenemeyene kadar yinelemeli olarak sürdürülmektedir.

Bu süreçte, çekirdek nokta olma koşulunu karşılamayan ancak bir çekirdek noktanın Eps komşuluğunda bulunan noktalar, sınır noktaları olarak tanımlanmaktadır. Tüm kümeler oluşturulduktan sonra, herhangi bir kümeye dâhil edilemeyen noktalar gürültü noktaları olarak sınıflandırılmaktadır. Gürültü noktaları; çekirdek ya da sınır noktası olmayan ve herhangi bir kümeyle ilişkilendirilemeyen veri noktalarıdır.

DBSCAN algoritması, kümelerin sayısını önceden belirleme gereksinimi duymamakta ve düzensiz şekillere sahip kümeleri başarılı bir şekilde tespit edebilmektedir. Ayrıca, gürültü noktalarını tanımlayarak, veri kümesindeki yer alan aykırı ve anormal değerlerin belirlenmesine olanak sağlamaktadır.

2.3.4. Hiyerarşik Nokta Bulutu Sınıflandırması

Hiyerarşik nokta bulutu sınıflandırması, genellikle farklı sınıfları tanımlamak amacıyla bir dizi uzman kuralına dayalı olarak gerçekleştirilen kural tabanlı bir sınıflandırma yöntemi olarak tanımlanmaktadır. Kentsel ekosistemlerde nokta bulutu verilerinin hiyerarşik sınıflandırmasına ilişkin bir örnek, Carlberg vd. (2009) tarafından sunulmuştur.

Hiyerarşik sınıflandırma süreci, öncelikle kolaylıkla tanımlanabilen nesnelerin belirlenmesiyle başlatılmaktadır. Örneğin, su yüzeyleri, yakın kızılötesi radyasyonu (1064 nm veya 1550 nm) güçlü bir şekilde emdiği için, nokta bulutlarında boşluklar veya seyrek noktalar şeklinde görünmektedir.

Sınıflandırmanın bir sonraki adımında, yer noktaları ile yer üstü noktaları birbirinden ayrılmakta ve bu işleme nokta bulutu filtrelemesi adı verilmektedir. Daha sonra, bitki örtüsü ve yapay nesneler; belirgin boyut ve şekil özelliklerine dayalı olarak önceden tanımlanmış kurallar aracılığıyla sınıflandırılmaktadır. Örneğin, direkler veya bina çatıları gibi yapay nesneler genellikle belirgin doğrusal veya düzlemsel özellikler sergilerken, bitki örtüsü daha dağınık bir nokta dağılımına sahip olmaktadır.

Kaba sınıflandırma tamamlandıktan sonra, bitki örtüsüne ait noktalar; yükseklik gibi yapısal özellikler kullanılarak çimen, çalı veya ağaç olarak daha ayrıntılı biçimde sınıflandırılmaktadır. Ancak, bu aşamada elde edilen sınıflandırmanın doğruluğu, büyük ölçüde önceki kaba segmentasyonun başarısına bağlı olmaktadır.

Zemin ve bitki örtüsü noktalarının tanımlanmasının ardından, veri kümesinde kalan noktaların büyük çoğunluğunu yapay nesnelere ait noktalar oluşturmaktadır. Bu noktalar genellikle kümelenmiş yapılar hâlinde bulunmakta olup, bu noktaların segmentasyonu, bağlı

bileşen etiketleme (connected component labeling) yöntemi kullanılarak hızlı ve etkili bir şekilde gerçekleştirilmektedir.

Etiketlenmemiş kümeler, segmentlerin boyut, şekli ve yükseklik dağılımı gibi özellikleri temel alınarak tanımlanmaktadır. Ayrıca, şekil tanıma kuralları da uygulanabilmekte; bu kurallar, bir kümenin doğrusallığı, düzlemselliği ve saçılma düzeyi gibi niteliklere dayandırılmaktadır (Carlberg vd., 2009).

2.3.5. Makine Öğrenmesine Dayalı Nokta Bulutu Sınıflandırması

Gözetimli makine öğrenme yöntemleri, etiketli eğitim verilerinden belirli bir özellik alanındaki farklı sınıfların ayırt edici niteliklerini öğrenmek amacıyla, nokta bulutu sınıflandırmasında yaygın olarak kullanılmaktadır (Guo vd., 2023). Bu yöntemlerde eğitilen sınıflandırıcı, daha sonra yeni bir veri kümesinde yer alan her nokta için ait olduğu sınıf etiketini tahmin etmek üzere kullanılabilir.

Bu bağlamda, Karar Ağacı (Decision Tree-DT), Destek Vektör Makinesi (Support Vector Machine-SVM) ve Rastgele Orman (Random Forest-RF) gibi üç temel gözetimli sınıflandırma yöntemi öne çıkmaktadır.

Karar ağacı (DT), ağaç yapısına sahip bir dizi basit karar kuralını öğrenerek hedef noktanın sınıf etiketini tahmin etmektedir. Bu yöntemde, veri kümesi her düğümde test edilen bir özniteliğe göre alt kümeler ayrılmaktadır.

Gini endeksi ya da entropi gibi istatistiksel ölçütler, özniteliklerin önem derecesini belirlemek ve farklı düzeylerde eşik değerleri tahmin etmek amacıyla kullanılmaktadır. Oluşturulan karar ağacının nihai yaprak düğümleri, farklı sınıfları temsil etmektedir.

Destek Vektör Makinesi (SVM), ikili sınıflandırma problemi için verileri mümkün olan en iyi şekilde ayıran bir hiper düzlemi bulmayı amaçlamaktadır. Bu yöntem, bire bir (one-vs-one) stratejisi kullanılarak çok sınıflı sınıflandırma görevlerine de kolaylıkla uyarlanabilmektedir.

Ancak, klasik SVM modelleri tahmin edilen sınıfa ilişkin olasılık değeri sağlamamaktadır. Bu eksiklik, Platt ölçeklemesi gibi yöntemlerle giderilmekte olup, böylece hem ikili hem de çok sınıflı görevlerde, verilen bir girdinin belirli bir sınıfa ait olma olasılığı tahmin edilebilmektedir (Swami & Jain, 2013; Wu vd., 2003).

Rastgele Orman (RF), tam büyütülmüş birçok Karar Ağacı (DT) içeren bir topluluk öğrenme (ensemble learning) yöntemi olarak tanımlanmaktadır (Breiman, 2001; Chehata

vd., 2009). Her bir karar ağacı, önyükleme (bootstrap) örnekleme kullanılarak oluşturulan eğitim verilerinin rastgele bir alt kümesi üzerinden inşa edilmektedir.

Karar ağacının her düğümünde gerçekleştirilen veri bölme işlemi, tüm öznitelik kümesi yerine özniteliklerin rastgele bir alt kümesine dayalı olarak yapılmaktadır. Bu yaklaşım, her bir ağacın farklı yapılar geliştirmesini sağlamakta ve genel sınıflandırma performansını arttırmaktadır.

2.3.6. Derin Öğrenme Tabanlı Nokta Bulutu Sınıflandırması

Derin Sinir Ağları (DSA), son yıllarda önemli bir gelişim göstermiş ve büyük veri kümelerinden mekânsal-zamansal özelliklerin çıkarılmasındaki üstün yetenekleri sayesinde, bilgisayarla görme ve uzaktan algılama alanlarındaki pek çok sınıflandırma görevinde yüksek performans sergileyen yöntemlerden biri hâline gelmiştir. DSA tabanlı modeller, sınıflandırma ve segmentasyon gibi çeşitli görevler kapsamında LiDAR verilerinin işlenmesinde etkin bir biçimde kullanılmaktadır. Özellikle, PointNet (Qi vd., 2017), PointCNN (Li vd., 2018) ve Alt Çok Katmanlı Seyrek Evrişimli Ağlar (Graham vd., 2018) gibi 3B derin öğrenme modelleri, nokta bulutu verilerinin seyrek ve düzensiz yapısından kaynaklanan işlem darboğazlarını aşarak, bu verilerden anlamlı özelliklerin çıkarılmasında umut verici uçtan uca çözümler sunmuştur.

PointNet, sırasız nokta bulutu verilerini doğrudan giriş olarak alan ve her bir nokta için sınıf etiketi tahmininde bulunan yenilikçi bir sinir ağı mimarisi olarak öne çıkmaktadır. Bu model, nokta bulutlarını önceden yapılandırmaya gerek duymadan doğrudan işleyebilme yeteneği ile dikkat çekmektedir. Öte yandan, PointCNN modeli, düzensiz yapıdaki nokta bulutlarını işleyebilmek amacıyla, geleneksel evrişimli sinir ağlarının mimarisini genişleterek, düzenli olmayan verilere uygulanabilir bir yapı hâline getirilmiştir. Yapılan karşılaştırmalı çalışmalar, PointCNN'nin, çeşitli zorluk düzeylerine sahip sınıflandırma görevlerinde mevcut yöntemlerle benzer ya da daha yüksek doğruluk sağladığını ortaya koymaktadır. Bu nedenlerle, 3B derin sinir ağı modelleri, LiDAR nokta bulutu verilerinin işlenmesi ve sınıflandırılmasında yaygın olarak uygulanmakta ve hâlen hızla geliştirilmeye devam etmektedir.

Yousefhussien vd. (2018), gözden geçirilmiş bir PointNet modeline dayanan tamamen evrişimli bir mimari önererek, spektral bilgilerle zenginleştirilmiş 3B nokta bulutlarının anlamsal olarak sınıflandırılmasını sağlamıştır. Önerilen model, farklı yoğunluklara sahip

nokta bulutlarından hem nokta düzeyinde hem de blok düzeyinde anlamlı özellikler öğrenebilmekte ve kentsel ortamlarda sınıflandırma doğruluğunu kayda değer şekilde artırmaktadır.

Benzer şekilde, Zhang vd. (2018), iki boyutlu (2B) görüntülerle üç boyutlu (3B) nokta bulutlarını birleştirerek, 3B kentsel sahnelerin sınıflandırılmasına yönelik geliştirilmiş bir DSA yaklaşımı sunmuştur. Bu yöntem aracılığıyla, binaların ince yapısal özellikleri etkin bir şekilde çıkarılabilmiş ve geliştirilen model, büyük ölçekli sahnelerde kullanılmak üzere uygun hâle getirilmiştir.

Zou vd. (2020), tekil ağaçlara ait 3B nokta bulutlarının, farklı açılardan elde edilen raster görüntülere yansıtılması yoluyla, ağaç türlerinin sınıflandırılmasını derin sinir ağları (DSA) kullanarak gerçekleştirmiştir. Ancak, bu tür görüntü yansıtma ya da veri dönüştürme yaklaşımları, orijinal nokta bulutu verilerinin içerdiği mekânsal bilgilerin bir kısmının kaybolmasına neden olabilmektedir.

Bu sorunu üstesinden gelmek amacıyla, Chen vd. (2021), türlere özgü yerel özellikleri etkili bir şekilde çıkarmak ve aynı zamanda küresel mekânsal özellikleri koruyabilmek için farklı örnekleme stratejileri kullanan yeni bir derin öğrenme çerçevesi önermiştir. Söz konusu çerçevede, nokta bulutu verileri doğrudan işlenerek, mekânsal ve öznitelik temelli özellikler yüksek boyutlu bir özellik uzayına eşlenmiş ve bu sayede ağaç türlerinin sınıflandırılması gerçekleştirilmiştir. Önerilen bu yaklaşım, veriyi başka bir formata dönüştürmeden çalışmakta ve mevcut üç boyutlu DSA modelleriyle karşılaştırıldığında, sınıflandırma doğruluğunu %2 ila %6 oranında artırabilmektedir.

Guo ve diğerleri (2019), 3B nokta bulutu sınıflandırmasına yönelik derin öğrenme tabanlı yöntemlerin kapsamlı bir incelemesini sunmuştur. Bunu takiben, Guo vd. (2020) ile Jin vd. (2020), ekolojik araştırmalarda derin öğrenme yaklaşımlarının uygulanmasına ilişkin karşılaşılan zorlukları ve beraberinde getirdiği potansiyel fırsatları ayrıntılı olarak tartışmıştır.


DSA'ların gelişimine paralel olarak, gelecekteki araştırmaların önemli bir yönünü, LiDAR verilerinin uydu radar verileri gibi diğer büyük ölçekli uzaktan algılama kaynaklarıyla entegre edilerek sınıflandırma doğruluğunu artırılması oluşturmaktadır. Bunun yanı sıra, derin öğrenme modellerinin neden tatmin edici sonuçlar verdiğini açıklamaya yönelik yaklaşımlar da önem kazanmaktadır. Bu bağlamda, açıklanabilir zekâ (Explainable Artificial Intelligence-XAI) yöntemlerinin geliştirilmesi, model şeffaflığı ve yorumlanabilirliğinin artırılması açısından kritik görülmektedir.

Ayrıca, uzun dönemli mekânsal bağlantılar tarafından yönlendirilen ekosistem dinamiklerinin daha iyi anlaşılabilmesi amacıyla, veri odaklı yöntemlerle fiziksel süreç modellerini bütünleştiren hibrit modelleme çerçevelerinin geliştirilmesi, gelecekteki çalışmalarda öne çıkan bir araştırma alanı olarak değerlendirilmektedir.

2.3.7. Zemin Sınıflandırması (PMF ve CSF Algoritmaları)


İlerlemeli Morfolojik Filtre (Progressive Morphological Filter -PMF) yöntemi, nokta bulutundaki noktaları yükseklik bilgisine (Z koordinatı) göre sıralayarak, matematiksel morfolojiye dayalı açma işlemleri aracılığıyla zemin sınıflandırmasını gerçekleştirmektedir (Zhang vd., 2003). Bu yöntemde, farklı ölçeklerde uygulanan açma işlemleri sayesinde yüksek nesneler (örneğin ağaçlar ve yapılar) veri kümesinden aşamalı olarak filtrelenmektedir. Açma işlemi, artan pencere boyutları kullanılarak yinelemeli biçimde uygulanmakta; böylece ilk olarak küçük nesneler, ardından daha büyük yapılar elimine edilmektedir. İşlemin sonunda, açma operasyonundan sonra kalan noktalar zemin sınıfı olarak tanımlanmakta, diğer noktalar ise zemine ait olmayan nesneler şeklinde işaretlenmektedir.

PMF algoritmasının uygulanması, Zhang vd. (2003) tarafından önerilen ve lidR paketinde açıklanan yöntemle dayanmaktadır. Ancak, uygulama sürecinde, bazı teknik uyarlamalar gerçekleştirilmiştir. Orijinal yöntem raster tabanlı olarak geliştirilmiş olmakla birlikte, lidR kütüphanesi nokta tabanlı bir yapı ile çalıştığından; algoritmanın doğrudan nokta bulutu verisi üzerinde uygulanabilmesi için nokta tabanlı morfolojik işlemler kullanılmıştır (URL-1). Söz konusu yöntemle ilişkin açıklamalar, ilgili şekil üzerinde görsel olarak sunulmuştur (Şekil 5).



Şekil 5. PMF algoritmasının lidR kütüphanesine uyarlanmış hâli (URL-1)

Kumaş Simülasyon Filtre (Cloth Simulation Filtering -CSF) yöntemi ise, zemin ile zemine ait olmayan nesnelerin ayrımını, kumaş simülasyonu prensibine dayalı olarak gerçekleştirmektedir (Karasaka, 2020). Bu yöntemde, nokta bulutunun ters çevrilmiş hâli üzerine sanal bir kumaş (mesh grid) yerleştirilmekte ve kumaş, yerçekimi ile esneklik prensiplerine göre şekil alarak ters yüzeyin üzerine oturmaktadır. Kumaşla temas eden noktalar zemin olarak, kumaşın üzerinde kalan noktalar ise ağaç, bina ve araç gibi zemine ait olmayan nesneler olarak sınıflandırılmaktadır (Şekil 6). CSF yöntemi, özellikle karmaşık yüzey topolojileri ve düzensiz arazi yapıları içeren ortamlarda etkili ve güvenilir sonuçlar verebilen bir zemin sınıflandırma tekniği olarak öne çıkmaktadır.



Şekil 6. CSF algoritmasının şekilsel gösterimi (URL-2)

2.4. LiDAR Veri Filtreleme ve Sayısal Yükseklik Modeli Oluşturma

Sayısal Yükseklik Modeli (SYM), arazi yüzeyini temsil eden üç boyutlu dijital bir kartografik veri kümesi olarak tanımlanmaktadır. Yüksekliğin ekosistem süreçleri üzerindeki etkisinin belirleyici olması, doğru ve güvenilir bir SYM elde edilmesini orman ekolojisi çalışmaları açısından vazgeçilmez bir unsur hâline getirmektedir. Lazer darbelerinin bitki örtüsüne nüfuz edebilmesi ve zemine ilişkin detaylı bilgi sağlayabilmesi, LiDAR teknolojisini, yüksek çözünürlüklü ve yüksek hassasiyetli SYM'lerin oluşturulmasında devrim niteliğinde bir araç konumuna getirmiştir. LiDAR tabanlı bir

SYM'nin oluşturulabilmesi için, öncelikle yer (zemin) noktalarının, zemine ait olmayan diğer noktalardan ayrıştırılması gerekmektedir. Bu işlem, LiDAR veri filtrelemesi olarak adlandırılmaktadır.

LiDAR sistemleri tarafından yayımlanan lazer darbeleri, doğal bitki örtüsü, yapay yapılar ve hareketli varlıklar da dâhil olmak üzere, hem zeminden hem de zemin üstü nesnelerden yansıtılmakta ve sistem tarafından algılanmaktadır. LiDAR verileri, filtreleme işlemi sonrasında, doğal yüzeyler (örneğin, çıplak toprak, kum ve kaya çıkıntıları) ile yapay yüzeyleri (örneğin, yollar) içerecek şekilde korunmakta ve bu veriler, SYM oluşturulmasında temel bileşenler olarak kullanılmaktadır (Şekil 7).




Şekil 7. Filtreleme sonucu zemin nesnesine ait şematik gösterim (Guo vd., 2023)

Filtreleme işlemi, LiDAR veri işleme iş akışının kritik aşamalarından biri olarak değerlendirilmektedir. Bu bağlamda, araştırmacılar son yirmi ila otuz yıllık süreçte, filtreleme algoritmalarının geliştirilmesine yönelik olarak çeşitli ilkelere dayanan yöntemler üzerinde çalışmalar yürütmüştür. Geliştirilen bu algoritmalar, genel olarak eğim tabanlı,

bölge tabanlı, yüzey tabanlı ve kümeleme tabanlı olmak üzere dört ana kategori altında sınıflandırılmaktadır (Sithole & Vosselman, 2004). Son yıllarda, LiDAR veri filtreleme alanında derin öğrenme tekniklerinin uygulanmaya başlanmasıyla birlikte, bu alanda yeni fırsatlar ve gelişim olanakları ortaya çıkmıştır.

2.4.1. Eğim Tabanlı Filtreleme Yöntemleri

Eğim tabanlı filtreleme algoritmaları, bitişik noktalar arasındaki büyük yükseklik farklarının, genellikle dik arazi koşullarından ziyade zemine ait olmayan nesnelerden kaynaklandığını varsaymaktadır. Bu yaklaşıma göre, iki nokta arasındaki yatay mesafe kısa ve yükseklik farkı belirli bir eşik değerin üzerindeyse, daha yüksek konumda yer alan noktanın zemin değil, bir nesneye ait olma olasılığı artmaktadır. Bu nedenle, yükseklik farkı ile nokta yakınlığı arasındaki ilişki, zemin ve zemin dışı nesnelerin ayrımında temel bir ölçüt olarak kullanılmaktadır (Şekil 8).



Şekil 8. Eğim tabanlı filtreleme algoritmasının şematik gösterimi (Guo vd., 2023)

Wang ve Tseng (2010a), eğime dayalı uyarlanabilir bir ikili filtreleme algoritması önermiştir. Söz konusu filtreleme yöntemi, birden fazla yönde çalışacak şekilde tasarlanmış olup, bu özelliği sayesinde dik eğimli alanlarda aşırı filtreleme riskini azaltabilmektedir.

Elde edilen sonuçlar, yöntemin önemli eğim değişiklikleri içeren bölgelerde topografik özellikleri koruyabildiğini ortaya koymaktadır.

Susaki (2012), çeşitli eğim parametrelerine dayalı olarak başlangıç bir SYM oluşturmuş ve yerel maksimum eğimi hesaplayarak, düzlem tahmini aracılığıyla başlangıç zemin noktalarını belirlemiştir. Daha sonra, eğim parametrelerinin güncellenmesi amacıyla yinelemeli bir süreç uygulanmış ve bu süreç sonunda optimum bir zemin noktası kümesi elde edilmiştir. Söz konusu yöntemin, çok sayıda sokak ve binanın bulunduğu kentsel alanlarda başarılı bir performans sergilediği ifade edilmektedir.


Genel olarak, eğim tabanlı filtreleme yöntemlerinin düz eğimli alanlar için uygun olduğu; ancak dik eğimli arazilerde, diğer yöntemlere kıyasla nispeten daha düşük doğruluk sağladığı belirtilmektedir.

Jingi vd. (2023), yoğun bitki örtüsüne sahip arazilerde havadan LiDAR verisinin filtrelenmesine yönelik eğim tabanlı bir yöntem önermiştir. Bu yöntemde, nokta bulutu verisi sanal bir ızgara yapısına bölünerek, her bir noktanın ait olduğu ızgara hücresi tanımlanmıştır. Ardından, her ızgara hücresindeki en düşük kot değerine sahip nokta belirlenmiş ve diğer noktaların bu referans nokta ile olan yükseklik farkları hesaplanmıştır. Her hücredeki tüm noktaların eğim değerleri tespit edilmiş ve bu değerlere dayanarak yerel eğim istatistikleri üzerinden uyarlanabilir bir eğim eşiği tanımlanmıştır.

Son aşamada, önceden belirlenmiş yükseklik farkı eşiği ile birlikte, k-ortalamlar kümeleme algoritması ve normal dağılım analizleri kullanılarak elde edilen uyarlanabilir eğim eşiği doğrultusunda zemin noktalarının filtrelenmesi gerçekleştirilmiştir. Önerilen yöntem, yoğun bitki örtüsü bulunan alanlarda daha hassas ve doğru zemin noktası tespiti sağlamayı hedeflemektedir.

2.4.2. Morfolojik Filtreleme Yöntemleri

Morfolojik filtreleme yöntemlerinin teorik temeli, topolojik yapı bilgilerini görüntülerden veya nokta bulutlarından çıkarmak amacıyla yapılandırma öğelerini kullanan matematiksel morfolojiye dayanmaktadır (Haralick & Shapiro, 1992). Matematiksel morfolojinin temelini oluşturan dört ana işlem; genişleme, aşınma, açma ve kapama olarak tanımlanmaktadır. Bu işlemler, nokta bulutu verilerinin filtrelenmesi, özellik çıkarımı ve gürültülerin giderilmesi gibi uygulamalarda yaygın biçimde kullanılmaktadır (Şekil 9).



Şekil 9. Temel morfolojik işlemlerin gösterimi: (a) açma, (b) kapatma (Guo vd., 2023)

Morfolojik filtreleme yöntemlerinin iş akışı, genellikle şu adımlardan oluşmaktadır: İlk olarak, ham LiDAR verileri raster formatına dönüştürülmekte ve her ızgara hücresinde yer alan en düşük yükseklik değerine sahip nokta çıkarılmaktadır. Tüm ızgara hücreleri, başlangıçta zemin hücresi olarak işaretlenmektedir. Rasterleştirme sürecinde oluşan boş hücrelerin doldurulması amacıyla, genellikle enterpolasyon yöntemleri uygulanmaktadır.

İkinci adımda, her zemin hücresinin eğimi, komşu zemin hücrelerine göre hesaplanmakta ve yükseklik farkı eşiği, bu eğime bağlı olarak tanımlanmaktadır. Üçüncü adımda, rasterleştirilmiş görüntü, belirli bir kayan pencere boyutuyla açma işlemine tabi tutulmaktadır. Açma işleminden önce ve sonra bir zemin hücresine ait yükseklik farkı, tanımlanan eşiği aşıyorsa, ilgili hücre zemin dışı hücre olarak yeniden etiketlenmekte; aksi takdirde, zemin hücresi olarak korunmaktadır.

Dördüncü adımda, ikinci ve üçüncü adımlar, önceden belirlenmiş maksimum pencere boyutuna ulaşıncaya kadar, artan pencere boyutlarıyla yinelemeli şekilde tekrarlanmaktadır. Son aşamada ise, aynı yatay konumda bulunan ham LiDAR verileri içerisinde, her zemin hücresi ile ilişkili noktalar seçilmekte ve bu noktalara ait yükseklik farkları hesaplanmaktadır. Hesaplanan farkların belirli bir eşik değerinin altında olması durumunda, ilgili noktalar zemin noktaları olarak sınıflandırılmaktadır.

Morfolojik filtreleme yöntemlerinde ilk adımı, nokta bulutunun belirli bir ızgara boyutuna sahip raster formata dönüştürülmesi oluşturmaktadır. Bu işlem sırasında, her bir hücreye ait yükseklik değeri, hücre içerisindeki en düşük nokta esas alınarak tanımlanmaktadır. Kilian vd. (1996), ardışık morfolojik filtreleme işlemlerinin uygulanabilmesi amacıyla, küçükten büyüğe doğru artan kayan pencere boyutları kullanmıştır. Her bir açma işlemi sonrasında hücrelerin ağırlıkları, pencere boyutuna göre belirlenmiş; nihai filtreleme sonuçları, son yineleme adımında elde edilen bu hücre ağırlıklarına dayalı olarak tayin edilmiştir.

Zhang vd. (2003) ise, her bir ızgara hücresindeki minimum yükseklik değerini esas alarak nokta bulutunu rasterleştirmiş ve bu raster veri üzerinde açma işlemini uygulamıştır. Açma işlemi öncesi ve sonrası elde edilen yükseklik farkı, önceden tanımlanan eşik değerin altında kaldığı durumlarda, ilgili hücre zemin hücresi olarak kabul edilmiştir. Devam eden aşamalarda, yükseklik farkına bağlı olarak kayan pencere boyutları kademeli olarak artırılmış ve açma işlemi tekrar edilerek nihai filtreleme sonuçlarına ulaşılmıştır.

Bu yöntemin temel varsayımı, arazi eğiminin belirli bir aralıkta sürekli değiştiğidir. Ancak bu varsayım özellikle karmaşık topoğrafik yapılara sahip alanlarda geçerliliğini yitirebilmekte ve dolayısıyla, söz konusu yöntemin kentsel alanlar gibi heterojen topoğrafik yapılar içeren bölgelerde istenen düzeyde performans sergileyemediği ifade edilmektedir.

Pingel vd. (2013), morfolojik filtreleme algoritmasını üç açıdan geliştirmişlerdir: (1) raster verilerdeki boşlukların yeniden örnekleme yöntemiyle doldurulması, (2) kayan pencere boyutunun artışında üstel yerine doğrusal bir yöntemin tercih edilmesi ve (3) eğim eşiğinin belirlenmesinde kullanılan süreçlerin sadeleştirilmesi.

Morfolojik filtreleme yöntemlerinin başlıca avantajı, uygulanabilirliğinin yüksek olmasıdır. Birden fazla açma işlemiyle artan pencere boyutlarının kullanılması, yalnızca tek bir açma işlemine kıyasla daha yüksek sınıflandırma doğruluğu sağlamaktadır. Bununla birlikte, yükseklik farkı eşiği ile pencerenin maksimum boyutunun manuel olarak tanımlanması gerekliliği, yöntemin geniş uygulama alanlarında kullanılmasını kısıtlayıcı bir unsur hâline getirmektedir.

Ayrıca, dik eğimli araziler ile zemin nesnelerinin bulunduğu bölgelerin ayrıştırılması da önemli bir zorluk olarak değerlendirilmektedir. Bu tür alanlarda, açma işlemi öncesi ve sonrası hesaplanan yükseklik farkları birbirine yakın olabilmekte, bu durum ise basit bir eşik değeriyle gerçekleştirilen filtrelemenin doğruluğunu olumsuz etkileyebilmektedir.

Buna ek olarak, nokta bulutunun rasterleştirilmesi süreci de çeşitli hatalara neden olabilmektedir. Daha büyük bir ızgara boyutunun tercih edilmesi, bazı zemin noktalarının yanlışlıkla zemin dışı olarak sınıflandırılmasına yol açarken; daha küçük bir ızgara boyutunun kullanılması, bazı zemin dışı noktaların filtreleme sürecinde kaçmasına neden olabilmektedir.

Zhenyang vd. (2019), karmaşık parametre ayarları ve düşük doğrulukla elde edilen sonuçlar gibi morfolojik filtreleme yöntemlerine özgü sorunları çözebilmek amacıyla otomatik bir filtreleme yöntemi önermiştir. Söz konusu çalışmada, ardışık morfolojik üst şapka (top-hat) işlemleri uygulanarak, optimum filtreleme pencere boyutu otomatik olarak belirlenmiş ve eğim değişikliklerine duyarlı uyarlamalı eşik değerleri aracılığıyla filtreleme süreci gerçekleştirilmiştir.

2.4.3. Enterpolasyon Tabanlı Filtreleme Algoritmaları

Enterpolasyon tabanlı filtreleme algoritmalarının iş akışı, öncelikle bir arazi yüzeyinin oluşturulmasıyla başlamaktadır. Daha sonra, sınıflandırılmamış noktalar belirli kriterler doğrultusunda değerlendirilmekte ve bu noktalar, tanımlanan gereksinimleri karşılamaları hâlinde, doğru ve sürekli bir arazi yüzeyi elde edilene kadar yinelemeli olarak zemin noktası kümesine dâhil edilmektedir.

Kraus ve Pfeifer (1998) tarafından, doğrusal tahmine dayalı yinelemeli en küçük kareler enterpolasyonunu temel alan bir filtreleme algoritması önerilmiştir (Kraus ve Mikhail, 1972). Söz konusu algoritma, aşağıda sıralanan adımlardan oluşmaktadır:


(a) Tüm noktalar için başlangıçta eşit ağırlıklar atanarak en küçük kareler enterpolasyonu uygulanmakta ve bu işlem sonucunda eğrisel bir yüzey hesaplanmaktadır. Elde edilen bu yüzey, gerçek arazi yüzeyi ile yüzey örtüsü arasındaki geçici bir model olarak başlangıç arazi yüzeyi şeklinde kabul edilmektedir.

(b) Her bir noktanın ağırlığı, ilgili hata (residual) değeri esas alınarak güncellenmektedir. Bu aşamada, arazi noktalarının genellikle negatif hata değerleri gösterdiği, buna karşılık bitki örtüsüne ait noktaların ise hafif negatif ya da pozitif hatalarla karakterize olduğu varsayılmaktadır. Kaydırma parametresi (g) genellikle negatif bir değere sahip olup, bir noktanın ağırlığını belirleyici ölçüt olarak kullanılmaktadır. Bu değerden büyük pozitif kalıntılara sahip olan noktalara sıfır ağırlık ($w = 0$) atanmakta ve bu noktalar arazi yüzeyinden hariç tutulmaktadır.

(c) Ağırlıkların yeniden hesaplanmasının ardından, ağırlığı sıfır olan noktalar enterpolasyon sürecine dâhil edilmemekte, yalnızca geçerli ağırlıklara sahip noktalar, bir sonraki eğrisel yüzeyin hesaplanmasında kullanılmaktadır.

(d) Bu yinelemeli süreç, hesaplanan eğrisel yüzeyin gerçek arazi topografyasını yeterli düzeyde yansıttığı belirlenene kadar tekrarlanmaktadır.

Bu enterpolasyon tabanlı filtreleme algoritmasının iş akışı, Şekil 10'da şematik olarak görselleştirilmiştir.



Şekil 10. Tekrarlayan en küçük kareler enterpolasyonuna dayalı filtreleme algoritmasının iş akışı (Guo vd., 2023)

Lee ve Younan (2003) tarafından, geleneksel en küçük kareler yönteminin yerine normalleştirilmiş en küçük kareler yaklaşımı kullanılarak filtreleme işlemi gerçekleştirilmiştir. Chen vd. (2013) ise, filtreleme amacıyla çok çözünürlüklü hiyerarşik bir sınıflandırma algoritması geliştirmiştir. Geliştirilen bu yöntemde, örnekleme noktaları ile entpole edilen arazi yüzeyi arasındaki yükseklik farklarına dayanarak zemin ve zemin üstü noktaların sınıflandırılmasına olanak tanıyan üç seviyeli bir yapı oluşturulmuştur.

Her bir seviyede, daha fazla zemin noktası sınıflandırılmayana kadar, ince levha eğrileri (thin-plate splines) kullanılarak yinelemeli biçimde arazi yüzeyi oluşturulmuştur. Bu süreçte sınıflandırılan zemin noktaları, sonraki yinelemelerde arazi yüzeyinin güncellenmesinde temel referans verileri olarak kullanılmıştır. Hiyerarşik yapı, alt seviyelerden üst seviyelerine doğru bir ilerleme ile organize edilmiş; ikinci ve üçüncü

katmanlarda kullanılacak veri türleri, bir önceki katmanın sonuçlarına bağlı olarak belirlenmiştir.

Bu yöntemin uygulama süreci, önceden arazi yüzeyinin karmaşıklığına dair herhangi bir bilgi gerektirmemekte ve hem düz hem de eğimli arazilerde yüksek doğrulukla çalışabilmektedir.

Mongus ve Zalik (2012) tarafından, ince levha spline interpolasyonunun uygulanmasına yönelik olarak yinelemeli biçimde azalan boyutta kayan pencere kullanan bir yaklaşım geliştirilmiştir. Söz konusu yöntemde, binalar gibi zemin dışı nesnelerin oluşturduğu kesikli yükseklik değerlerinden kaynaklanan sorunların giderilmesi amacıyla silindirik şapka dönüşümü (cylindrical hat transform) uygulanmıştır.

Enterpolasyon sürecinde, ince levha eğrilerinin kontrol noktalarının düzenlenmesinde çok çözünürlüklü hiyerarşik bir yapıdan faydalanılmıştır. Her yinelemenin ardından, zemin dışı noktalar hata değerlerine göre filtrelenmiş ve bu noktaların yükseklikleri, ince levha enterpolasyonu ile elde edilen değerlerle güncellenmiştir. Bu işlem, arazi rasterının hedeflenen çözünürlüğe ulaşmasına kadar tekrarlanmıştır.

Önerilen bu yöntem, özellikle belirgin topografik değişimlerin gözlemlendiği bölgeler veya farklı boyut ve şekillerde nesnelerin bulunduğu çevresel koşullar altında, nokta bulutu filtrelemesinin zor olduğu durumlarda etkili sonuçlar sağlamaktadır.

2.4.4. Aşamalı Yoğunlaştırma Filtreleme Yöntemleri


Aşamalı yoğunlaştırma filtreleme yönteminin temel prensibi, önceden tanımlanmış bir strateji doğrultusunda başlangıç arazi yüzeyinin oluşturulması amacıyla ilk zemin noktalarının seçilmesi ve ardından, belirli kriterlere dayalı olarak bu zemin noktalarının yinelemeli biçimde artırılmasıdır.

Bu bağlamda Axelsson (2000) tarafından aşamalı üçgenleştirilmiş düzensiz ağ (TIN) yoğunlaştırma algoritmasını önerilmiştir. Söz konusu yöntemde, öncelikle çalışma alanı belirli ızgara hücrelerine ayrılmakta ve her bir hücredeki en düşük yükseklik değerine sahip nokta, başlangıç zemin noktası (Potential Ground Point- P_G) olarak seçilmektedir. Bu başlangıç noktaları kullanılarak oluşturulan TIN modeli, başlangıç arazi yüzeyi olarak kabul edilmektedir.

Sonraki adımda, henüz sınıflandırılmamış noktalar ($P_{\text{Etiketlenmemiş}}$), oluşturulan TIN modeline yansıtılmakta ve her bir nokta ayrı ayrı değerlendirilmeye tabi tutulmaktadır. Her

bir P_i noktası için, bu noktanın en yakın TIN yüzeyine olan dik mesafesi hesaplanmaktadır. Eğer bu mesafe, önceden tanımlanmış bir yükseklik eşiğini altında kalmakta ve aynı zamanda P_i noktasından TIN yüzeyine çizilen doğrunun oluşturduğu eğim açısı belirlenen eşik açıdan küçükse, ilgili nokta zemin noktası olarak sınıflandırılmaktadır.

Zemin olarak etiketlenen her yeni P_i noktası, TIN modelinin güncellenmesinde kullanılmakta ve model yeniden oluşturulmaktadır. Bu süreç, yeni zemin noktaları belirlemeye devam ettiği sürece yinelenmeli olarak sürdürülmekte; böylece, arazi yüzeyi giderek daha yüksek doğrulukla modellenmektedir (Şekil 11).



Şekil 11. Aşamalı TIN yoğunlaştırma filtreleme yöntemi iş akışı (Chen vd., 2021)


Klasik ilerlemeli TIN yoğunlaştırma yöntemi, özellikle dik eğimli arazilerde ve keskin morfolojik geçişlerin bulunduğu bölgelerde düşük doğrulukla sonuçlanmaktadır. Bu sınırlamaları aşmak amacıyla, Zhang ve Lin (2013), bölge büyütme algoritmasına dayalı olarak birden fazla başlangıç tohum noktası ekleyerek yöntemi geliştirmiştir. Söz konusu iyileştirme, başlangıçta daha güvenilir zemin noktalarının belirlenmesini sağlamış ve arazi yüzeyinin daha doğru şekilde modellenmesine olanak tanımıştır.

Benzer biçimde, Zhao vd. (2016), klasik ilerlemeli TIN yoğunlaştırma yöntemini morfolojik filtreleme yaklaşımıyla birleştirerek, özellikle ormanlık alanlara yönelik geliştirilmiş bir TIN yoğunlaştırma algoritması önermiştir. Bu bütünlük yaklaşım, arazi yüzeyinin karmaşık yapısını daha etkin bir biçimde temsil etmeyi hedeflemiş ve yoğun bitki

örtüsüyle karakterize edilen alanlarda zemin noktalarının daha yüksek doğrulukla ayrıştırılmasına imkân tanımıştır.

2.4.5. Segmentasyona Dayalı Filtreleme Yöntemleri

Segmentasyona dayalı filtreleme yöntemlerinde, ilk adım olarak nokta bulutu kümelenmekte ve giriş verilerinin (örneğin, ızgara, TIN veya nokta bulutu) ortak geometrik ve istatistiksel özelliklerine (örneğin, yükseklik farkı, eğim ve normal vektörler) göre yüzeyler oluşturulabilmesi amacıyla bölge büyütme yöntemi uygulanmaktadır. Sonraki aşamada, yükseklik farkı, pürüzsüzlük, yapısal ilişki, geometrik özellikler veya öznelilik bilgisine dayalı eşik değerleri kullanılarak bölgesel sınıflandırma gerçekleştirilmektedir. Bu süreç, tek bir noktaya değil, zemin nesnelerinin benzerlik özelliklerine dayalı olarak yürütülmektedir. Ardından, filtreleme sonuçları; kenar algılama, bölge büyütme, görüntü benzerliği veya süreksizlik temelli kümeleme gibi çeşitli görüntü segmentasyon teknikleri kullanılarak tanımlanmaktadır. Çatı yamalarının segmentasyon sonrasında nispeten düzenli bir yapıya sahip olduğu, bitki örtüsü yamalarının ise daha düzensiz bir dağılım sergilediği ve daha az sayıda nokta içerdiği; buna karşılık zemin yamalarının uzamsal olarak daha geniş bir yayılım gösterdiği gözlemlenmektedir (Şekil 12).



Şekil 12. Segmentasyona dayalı filtreleme yöntemlerinden elde edilen sonuçlar: ham nokta bulutu (sol), filtrelenmiş nokta bulutu (sağ) (Guo vd., 2023)

Bölge büyütme yönteminde, komşu aramasının türü giriş verilerinin yapısına bağlı olarak belirlenmektedir. Giriş verileri bir ızgara formatında ise, komşu hücrelerinin aranması en uygun yaklaşım olarak değerlendirilmektedir. Giriş verileri bir TIN yapısında ise,

komşuluk ilişkisi, TIN'deki üçgenler arasındaki ortak kenarlar üzerinden tanımlanmaktadır. Giriş verileri doğrudan nokta bulutu şeklindeyse, komşu arama işlemi belirli bir mekânsal mesafe içerisindeki noktaların belirlenmesi esasına dayanmaktadır.

Sithole (2005), nokta bulutu verilerini dikey segmentlere göre düzenlemiş ve segmentlerdeki noktaları farklı yönlerdeki yakınlıklarına göre düz çizgilere ayırarak, düz çizgiler arasındaki ortak noktalara dayalı olarak yamalar üretmiştir. Üretilen yamalar, daha sonra farklı tiplere sınıflandırılmıştır. Tovari ve Pfeifer (2005), normal vektörlere ve mekânsal benzerliklere dayalı bir bölge büyütme yöntemi önermiştir. Bu yöntemle elde edilen ana parametreler, normal vektörlerin benzerliği ile aday noktayla ayar düzlemi arasındaki mesafe olarak tanımlanmıştır. Wang ve Tseng (2010b) ise, sekizli bir ağaç yapısına dayalı bir böl ve birleştir segmentasyonu önermiştir. Söz konusu yöntemde, bir düzlem uydurma tekniğiyle optimum parametreler tahmin edilmiş ve nokta bulutu filtrelemesi için parçalı düzlemlerin coğrafi özellikleri (örneğin, düzlemlerin kesişimleri) çıkarılmıştır. Bu yaklaşımın, hem havadan hem de karadan LiDAR verilerinin filtrelenmesinde başarılı bir performans sergilediği belirtilmektedir.


Sanchez-Lopera ve Lerma (2014), kentsel alanlarda binaları, bitki örtüsünü, zemini ve diğer nesneleri ayırt edebilmek amacıyla bölge büyütme işlemine açısız bir sınıflandırma yöntemi entegre etmişlerdir. Önerilen yöntem, kasabalar ve şehirler gibi belirgin geometrik ve morfolojik özelliklere sahip nesnelerin yoğunlukta olduğu alanlar için uygun bulunmaktadır. Buna karşılık, ormanlık alanların karmaşık arazi yapısı, net ve tekdüze özellikler sunmaması nedeniyle, nokta bulutlarının kümelenmesi ve sınıflandırılması açısından önemli zorluklar oluşturmaktadır.

2.4.6. Derin Öğrenme Tabanlı Filtreleme Yöntemleri

Mevcut filtreleme yöntemlerinde ele alınması gereken ortak bir sorun, el yapımı kurallara veya istatistiksel olarak türetilen eşiklere olan bağımlılıktır. Bu durum nedeniyle, mevcut filtreleme yöntemlerinin karmaşık alanlarda yeterli sağlamlığı sağlayamayacağı belirtilmektedir. Son yıllarda, derin öğrenme tekniklerindeki gelişmeler, bu sorunun çözümü için önemli bir fırsat sunmaktadır. Yapılan öncü çalışmalar, LiDAR verilerinin filtrelenmesi için derin öğrenme yöntemlerinin uygulanabilirliğini ortaya koymuştur. Schmohl ve Sörgel (2019), havadan LiDAR verilerini filtrelemek amacıyla, seyrek alt çok katmanlı evrimsel ağlara sahip bir kodlayıcı-kod çözücü mimarisi önermiştir. Ancak, büyük ölçekli

vokselleştirilmiş temsillerin getirdiği zorluklar nedeniyle, bu yöntemin hâlen sınırlı çözünürlük ve örnekleme aralığı gibi sorunlarla karşı karşıya olduğu ifade edilmektedir. Yousefhussien vd. (2018), kentsel ve kırsal alanlarda anlamsal nokta segmentasyonu gerçekleştirmek amacıyla PointNet modelinden modifiye edilen çok ölçekli tam evrişimli bir sinir ağı kullanmışlardır. Bu segmentasyon çalışmasında dokuz sınıf tanımlanmış olup; elektrik hatları, düşük bitki örtüsü, geçirimsiz yüzeyler, arabalar, çitler, çatılar, cepheler, çalılar ve ağaçlar olarak belirlenmiştir. Normalleştirilmemiş noktaların sınıflandırılmasında umut verici sonuçlar elde edildiği ifade edilmektedir.

Genel olarak, LiDAR veri filtrelemesinde derin öğrenme teknolojilerinin uygulanmasının hâlen erken aşamada olduğu ve bu alandaki çalışmaların sınırlı sayıda olduğu vurgulanmaktadır. Ormanlık ortamlarda, havadan elde edilen LiDAR verilerinden yer noktalarının filtrelenmesi amacıyla geliştirilen yaklaşımlardan biri de, nokta tabanlı tam evrişimli sinir ağı (Point-based Fully Convolutional Neural Network-PFCN) kullanılarak gerçekleştirilen çalışmadır (Jin ve diğerleri, 2020). PFCN modeli, üç ana bileşenden oluşmaktadır: giriş katmanı, gizli katmanlar ve çıktı katmanları (Şekil 13). Giriş katman verileri, N nokta sayısı ve M her bir noktanın öznetelik sayısı olmak üzere $N \times M$ boyutunda bir matris şeklinde yapılandırılmaktadır.



Şekil 13. Nokta tabanlı tam evrişimli sinir ağının mimarisi (Guo vd., 2023)

Normalizasyondan sonra, normalleştirilmiş 3B veriler, bir mekânsal dönüştürücü ağ ve üç çok katmanlı tam evrişimli (MFC) katmandan oluşan gizli katmanlara aktarılmaktadır. Mekânsal dönüştürücü ağ, özellik çıkarma işleminden önce noktaları kanonik bir uzayda hizalayabilen, veriye bağlı bir ağ olarak tanımlanmaktadır. Her bir MFC katmanı, çok sayıda filtreden oluşmakta olup, her filtre, 1 boyutlu toplu normalizasyon ve aktivasyon işlemleriyle birlikte özellik boyutunda 1 boyutlu bir evrişim gerçekleştirmektedir. İlk MFC katmanı, nokta ve döşeme bazlı özellikleri çıkarmak amacıyla 64, 128, 128, 128, 512, 1024 ve 2048 boyutunda yedi katmandan oluşmaktadır. İkinci MFC katmanı, çıkarılan bu özellikleri nokta bulutu sınıflaması için kullanmakta; üçüncü MFC katmanı ise her bir noktanın zemin veya zemin üstü nokta olarak sınıflandırılma olasılığını temsil eden bir $N \times 2$ boyutunda çıktı matrisi üretmektedir. Elde edilen sonuçlar, önerilen PFCN yönteminin mevcut filtreleme

yöntemlerinin çoğuna kıyasla daha üstün performans sergilediğini ve farklı bitki örtüsü yoğunlukları ile topografik koşullar altında da yüksek düzeyde sağlamlık gösterdiğini ortaya koymaktadır.

2.4.7. Sayısal Yükseklik Modeli (SYM) Enterpolasyon Yöntemleri

Sayısal Yükseklik Modeli (SYM), düzenli bir ızgara yapısı veya Üçgenlenmiş Düzensiz Ağ (Triangulated Irregular Network-TIN) biçiminde ifade edilmektedir. Düzenli ızgaralar, yatay yönde eşit aralıklarla yerleştirilen hücrelerden oluşmakta ve her hücre, düz arazilere uygun şekilde yükseklik değerleri ile temsil edilmektedir. Buna karşılık, TIN yapıları, düzenli ızgaralara göre çok daha karmaşık bir yapıya sahip olup, yükseklik bilgileri büyük arazi dalgalanmalarının bulunduğu alanlar için daha uygun olan üçgen düğüm noktalarının öznitelik değerleri ile tanımlanmaktadır.

Zemin noktaları, eşit olmayan şekilde dağıtılmış ayırık 3B noktalar olduğundan, bu ayırık noktaların sürekli bir SYM katmanına dönüştürülebilmesi için bir mekânsal enterpolasyon prosedürüne ihtiyaç duyulmaktadır. Mekânsal enterpolasyon, bilinen değerlere sahip noktaları kullanarak, diğer bilinmeyen noktalar için değerlerin tahmin edilmesi süreci olarak tanımlanmaktadır (Chen & Chang, 2003). Yaygın olarak kullanılan enterpolasyon yöntemleri arasında Ters Mesafe Ağırlıklandırma (Inverse Distance Weighting-IDW), Doğal Komşu (Natural Neighbor-NN), Kriging ve Spline enterpolasyonu yer almaktadır.

- Ters Mesafe Ağırlıklandırma Enterpolasyonu

Bu yöntem, tahmin konumuna daha yakın olan noktaların tahmin üzerinde daha fazla etkiye sahip olduğu ilkesine dayanmaktadır. Enterpolasyon sürecinde, bilinen noktalara ağırlık ataması yapılırken, her bir bilinen noktanın ağırlığı, tahmin konumu (bilinmeyen nokta) ile bilinen nokta arasındaki mesafenin tersine bağlı olarak belirlenmektedir. Ağırlık hesaplaması, mesafenin gücü parametresi tarafından kontrol edilmektedir. Güç değeri bir (1) olduğunda, noktalar arasındaki değer değişim oranının sabit olduğu kabul edilmekte ve bu durum doğrusal enterpolasyon kategorisine girmektedir. Daha yüksek bir güç değeri seçildiğinde, en yakın noktalara daha büyük ağırlık atanmaktadır. Bu durum, daha fazla ayrıntı içeren ancak daha az pürüzsüz bir enterpolasyon yüzeyi oluşturmaktadır. Buna karşılık, daha küçük bir güç değeri, uzak noktalara daha fazla vurgu yapar ve daha pürüzsüz

ancak daha az ayrıntılı bir enterpolasyon yüzeyinin oluşmasına yol açmaktadır (Guo vd., 2010).

- Kriging Enterpolasyonu

Kriging, bölgesel değişim teorisine dayanan gelişmiş bir jeostatistiksel enterpolasyon yöntemi olarak tanımlanmaktadır. Bu yöntem, incelenen yüzey boyunca mekânsal varyasyonun istatistiksel olarak tutarlı bir yapıya sahip olduğunu varsaymaktadır (Guo vd., 2010). Kriging enterpolasyonunun temel ilkesi, bir özelliğin mekânsal dağılımının ne tamamen rastlantısal ne de tamamen deterministik olduğudur. Bunun yerine, bu dağılımın mekânsal otokorelasyon, sapmalar ve rastgele hataların ortak etkisiyle belirlendiği kabul edilmektedir.

Kriging, en iyi tarafsız doğrusal enterpolasyon yöntemi olarak kabul edilmektedir. Burada “en iyi” ifadesi, gerçek değer ile tahmin edilen değer arasındaki varyansın en küçük olmasını ifade etmektedir. “Tarafsız” ifadesi, tahmin hatasının beklenen değerinin sıfıra eşit olduğu anlamına gelmektedir. “Doğrusal” ifadesi ise, tahmin edilen değer, bilinen değerlerin ağırlıklı doğrusal kombinasyonu ile elde edildiğini ifade etmektedir. Mekânsal otokorelasyonun farklı açıklamalarına ve tahminin tarafsız olup olmamasına bağlı olarak, sıradan Kriging, blok Kriging, küresel Kriging ve eş-Kriging gibi çeşitli Kriging enterpolasyon yöntemleri geliştirilmiştir. Sıradan Kriging yöntemi, herhangi bir sapmanın bulunmadığını varsaymakta ve yalnızca mekânsal ilişkilere dayalı faktörleri dikkate almaktadır.

- Radyal Baz Fonksiyonu Enterpolasyonu

Radyal baz fonksiyonu (Radial Basis Function-RBF), temel fonksiyonların tek değişkenli matematiksel fonksiyonlardan oluştuğu bir dizi kesin enterpolasyon tekniği olarak tanımlanmaktadır. RBF'de kullanılan tek değişken, bilinen nokta ile tahmin edilecek nokta arasındaki mesafeyi ifade etmektedir. RBF yöntemleri arasında karmaşık logaritmik fonksiyon, karmaşık kuadratik fonksiyon, ters karmaşık kuadratik fonksiyon, doğal kübik spline fonksiyonu, ince levha spline fonksiyonu ve gerilim spline fonksiyonu yer almaktadır. Bu yöntem, özellikle büyük veri kümeleri ve düz arazi alanları için uygun bir enterpolasyon tekniği olarak değerlendirilmektedir (Guo vd., 2023).

2.5. Orman Yapısal Nitelik Çıkarımı

Ormanın yapısal nitelikleri, özellikle dikey yaprak profili, ağaç boyu ve tepe boyutu gibi üç boyutlu özellikler, orman biyokütlesinin tahmin edilmesi, orman amenajmanı ve işletmesi ile biyolojik çeşitliliğin araştırılması ve korunması süreçlerinde önemli bir rol oynamaktadır. Bu nedenle, orman yapısal niteliklerinin çıkarılması, orman süreçlerinin ve işlevlerinin nicelleştirilmesi için temel bir ön koşul olarak kabul edilmektedir. Orman yapılarını ölçmeye yönelik geleneksel yöntemlerin ise ağırlıklı olarak saha araştırmalarına ve iki boyutlu uzaktan algılama görüntülerine dayandığı, ancak bu yöntemlerin doğruluklarının sınırlı olduğu bilinmektedir. Aktif bir uzaktan algılama teknolojisi olan LiDAR, özellikle yüzeye yakın LiDAR platformlarının son yıllarda hızla gelişmesiyle birlikte, orman yapısal niteliklerinin ölçülmesinde önemli bir dönüşüm sağlamaktadır.

Ormanın mevcut durumunu ve dinamiklerini anlamada, orman düzeyindeki yapısal nitelikler belirleyici unsurlar arasında yer almaktadır. LiDAR teknolojisi, üç boyutlu orman bilgilerini doğru ve etkili biçimde ortaya koymak için güçlü bir araç olarak öne çıkmaktadır. Günümüzde, ağaç boyu, tepe örtüsünün çapı ve alanı ile gövde çapı gibi birçok yapısal özellik, orman düzeyindeki LiDAR verilerinden yüksek doğrulukla elde edilebilmektedir (Guo vd., 2023).

2.5.1. Meşçere Boyu ve Kapalılık Tespiti

Meşçere Boy Modeli (MBM), zemin ile tepe üst yüzeyi arasındaki mutlak yükseklik farkını temsil etmekte ve LiDAR verilerinden türetilen en yaygın raster ürünlerden biri olarak öne çıkmaktadır. MBM'nin türetilmesinde yaygın olarak kullanılan yöntemlerden biri, Sayısal Arazi Modeli (SAM) ve Sayısal Yüzey Modeli (SYM) arasındaki farkın alınmasıdır. SAM, zemin noktalarının Kriging algoritması (Guo vd., 2010; Jin, Su, Gao, Hu vd., 2018) gibi yöntemlerle enterpolasyonu yoluyla üretilmekte; SYM ise LiDAR verilerinin ilk dönüşlerinden veya tepe üst yüzey dönüşlerinden benzer prosedürler uygulanarak oluşturulmaktadır. Alternatif bir yaklaşımda ise, SYM doğrudan normalleştirilmiş LiDAR noktalarından da hesaplanabilmektedir. Arazinin etkisini ortadan kaldıran MBM, LiDAR verilerinden türetilen orman yapısal niteliklerinin (örneğin tepe yüksekliği ve örtüsü) farklı ormanlık alanlar arasında karşılaştırılabilir olmasına olanak sağlamaktadır.

MBM'ler, orman yapısal niteliklerinin çıkarılmasında yaygın olarak kullanılmakta olup (Hill vd., 2014; Khosravipour vd., 2015; Silva vd., 2019), "çukur" olarak adlandırılan

boş pikseller, bireysel ağaç tespiti ve tepe boyutu hesaplaması gibi sonraki analizleri olumsuz yönde etkileyebilmektedir (Khosravipour vd., 2014). Bu çukurlar, lazer ışınının ilk yankıyı üretmeden önce tepe içerisine derinlemesine nüfuz etmesi sonucunda oluşmakta ve hem veri kalitesi (örneğin nokta yoğunluğu) hem de son işlem adımları (örneğin şerit hizalama ve filtreleme) ile doğrudan ilişkilendirilmektedir (Khosravipour vd., 2014). MBM'deki çukurların varlığı, tepe yapısal niteliklerinin doğru şekilde çıkarılmasını engellemektedir. Bu nedenle, standart MBM'leri yumuşatarak çukursuz MBM'ler üretmeye yönelik çeşitli çalışmalar gerçekleştirilmiştir (Hosoi vd., 2012). Bu çalışmaların çoğunluğu, iki boyutlu çekirdek fonksiyonlarına dayalı ortalama, medyan ve Gauss filtrelerini içermektedir (Dralle ve Rudemo, 1996). Söz konusu filtreler, yalnızca çukurları gidermekle kalmamakta, aynı zamanda MBM'nin tüm piksel değerlerini de değiştirmektedir (Ben-Arie vd., 2009; Shamsoddini vd., 2013; Zhao vd., 2013).

Bu sınırlamaları aşmak amacıyla, 3B LiDAR noktalarından doğrudan çukursuz MBM'lerin üretilmesine yönelik algoritmalar geliştirilmiştir. Örneğin, MBM oluşturulurken tüm ilk dönüşler yerine yalnızca her pikseldeki en yüksek ilk dönüşün kullanılması önerilmektedir; çünkü bazı ilk dönüşlerin tepe içerisine düşerek yükseklik değerlerinde sapmalara neden olabileceği belirtilmektedir (Leckie vd., 2003; Popescu & Wynne, 2004). Ayrıca, tepe içindeki yükseklik varyasyonlarını en aza indirmek amacıyla daha büyük piksel boyutlarının tercih edilmesi gerektiği vurgulanmaktadır (Chen vd., 2006). Bu tür algoritmalar, MBM'deki çukurların büyük bir kısmını ortadan kaldırabilmekle birlikte, zemin yerine tepe içindeki yaprak ve dallardan kaynaklanan çukurları giderilmesinde yetersiz kalabilmektedir. Bu soruna çözüm olarak, Khosravipour vd. (2014), iki aşamalı bir geliştirilmiş çukursuz MBM üretim algoritması önermiştir. İlk aşamada, tüm ilk dönüşlerden standart bir MBM oluşturulmakta ve belirli yükseklik eşiklerinin üzerindeki dönüşlerden çeşitli MBM'ler türetilmektedir. İkinci aşamada ise, bu MBM'ler her piksel için maksimum yükseklik değeri kullanılarak birleştirilmektedir. Söz konusu yaklaşım, 2B filtreleme dayalı yöntemlerin aksine küçük ağaç tepelerinin korunmasını sağlamakta (Kaartinen vd., 2012; Solberg vd., 2006) ve Gauss filtreli MBM'lere kıyasla bireysel ağaç tespiti ile orman yapısal niteliklerinin çıkarımında üstün performans sergilemektedir.

Ormandaki boşluklar, doğal veya insan kaynaklı bozulmalar sonucunda oluşan açıklıklar olarak tanımlanmaktadır (Silva vd., 2019). Bu boşlukların büyüklüğü, dağılımı ve zaman içerisindeki değişimi, orman gençleştirilmesi, süksesyon ve olgunluk düzeyinin önemli göstergeleri arasında yer almaktadır (Asner vd., 2013; Vepakomma vd., 2008). Bu

bağlamda, kapalılıktaki boşlukların tespit edilmesi ve mekânsal özelliklerinin ölçülmesi, orman ekolojisi araştırmaları açısından büyük önem taşımaktadır (Dietze ve Clark, 2008; Dupuy ve Chazdon, 2008; Farrior vd., 2016).

LiDAR, orman kapalılığının yapısal dikey bileşenini yüksek doğrulukla temsil edebilmesi sayesinde, tepe boşluklarının tespitinde yaygın olarak kullanılan bir araç konumunda yer almaktadır (Heiskanen vd., 2015; Silva vd., 2019). Kapalılıktaki boşluklar, üç boyutlu nokta bulutlarının dikey profillerinin veya enterpolasyonla oluşturulan MBM'lerin analiz edilmesi yoluyla belirlenebilmektedir (Gaulton ve Malthus, 2010). Örneğin, Vepakomma vd. (2011), MBM üzerinden belirli yükseklik eşiklerinin altında kalan alanları belirleyerek kapalılığı haritalamış ve çok zamanlı LiDAR verileri kullanarak akarsu gibi sahte boşlukları ayırt etmiştir. Ayrıca, Vepakomma vd. (2008) ile Kellner ve Asner (2009), dikey kapalılık profilleri boyunca kapalılık sınıflandırmasını gerçekleştirmiştir. Bu yöntemler, boşlukların büyüklüğü ve mekânsal dağılımı üzerine yapılan analizleri mümkün hâle getirmekte (Koukoulas ve Blackburn, 2004) ve çok zamanlı LiDAR verileri sayesinde orman dinamiklerinin, iklim değişikliğinin ve insan faaliyetlerinin etkilerinin daha iyi anlaşılmasına olanak tanımaktadır (Vepakomma vd., 2008).

2.5.2. Meşçere Boy Profili

Orman kapalılığının dikey profili, topluluk ekolojisi açısından önemli bir yapısal özellik olarak değerlendirilmektedir. Bu profil, topluluğun fotosentetik kapasitesinin ve tür kompozisyonunun analizinde, ayrıca hayvan ve bitki habitatlarının kalite düzeyinin değerlendirilmesinde temel bir rol oynamaktadır. Geleneksel ekolojik çalışmalarda, meşçere boyu profilleri genellikle sahada elle çizilmekte, ancak bu yaklaşım hem zaman alıcı hem de öznel nitelikte olmakta ve ormanların üç boyutlu yapısal özelliklerini büyük ölçekte temsil etmede yetersiz kalmaktadır. Buna karşılık, LiDAR sistemleri tarafından elde edilen dalga formu ve nokta bulutu verileri, meşçere boyu profillerinin yüksek doğruluk ve verimlilikle doğrudan ölçülmesini mümkün kılmaktadır (Jaskierniak vd., 2011).

Harding vd. (2001) ile Lefsky vd. (1999; 2002), dalga formu verilerinden meşçere boy profillerinin mekânsal dağılımını elde etmek amacıyla SLICER (yankı kurtarma ile gölgelikleri tarayan LiDAR görüntüleyici) cihazını kullanarak öncü çalışmalar gerçekleştirmiştir. Lefsky vd. (2002), zemin dönüşlerini elimine ederek MacArthur ve Horn (1969) tarafından geliştirilen denkleme uygulamış ve LiDAR nokta bulutu verilerinden tepe

örtüsü oranı hesaplamıştır. Bu çalışma, tepe örtüsü verilerinin enine profiller şeklinde mekânsal dağılımının elde edilmesine imkân sağlamıştır. Asner vd. (2011), farklı coğrafi bölgelerdeki tropikal ormanlara ait meşçere profillerini hesaplamak amacıyla nokta bulutu verilerinden faydalanmıştır. Yapılan analizler sonucunda, Peru, Panama ve Madagaskar'daki ormanların dikey yapılarının, Hawaii'deki orman yapılarından anlamlı ölçüde farklılık gösterdiği belirlenmiştir. Ayrıca, tropikal ormanlarda üst tabakadan yaklaşık 7 metre aşağıda konumlanan bir alt tabakanın varlığı ortaya konulmuştur.

LiDAR verileri, yalnızca tüm ormanlık alanın genel yapısal özelliklerini belirlemekle kalmamakta, aynı zamanda farklı orman katmanlarının yapısal karakteristiklerini ayrı ayrı ölçmek amacıyla da kullanılabilir. Bu kapsamda, Ferraz vd. (2012), ortalama kaydırma algoritmasını kullanarak nokta bulutlarını tepe, çalılık ve zemin olmak üzere üç bileşene ayırmış ve her bir bitki katmanının yükseklik profillerini ayrı ayrı tahmin etmiştir. Benzer şekilde, Duncanson vd. (2014), nokta bulutlarının yükseklik frekans dağılımını kullanarak orman topluluklarını bir tepe katmanı ile bir alt tabaka katmanına ayırmıştır. Ardından, her katman içerisinde bireysel ağaçların belirlenebilmesi amacıyla su havzası algoritmasını uygulanmış ve her bir katman için ağaç sayısı, ağaç boyu ve tepe boyutlarını hesaplanmıştır. Bu yöntem, Amerika Birleşik Devletleri'nde Kaliforniya'daki Sierra Nevada Dağları ve Maryland eyaletindeki meşçerelerde test edilmiştir. Uygulama sonuçları, yöntemin tepe katmanında yer alan küçük ağaçların yaklaşık %21'inin başarıyla tespit edilebildiğini ortaya koymuştur.

2.5.3. Yoğunluk Profili

Yoğunluk, her bir lazer ışını için kaydedilen geri dönen enerji miktarını ifade etmekte olup, her bir nokta için toplanan bu değer esas olarak lazer darbesiyle taranan yüzeyin yansıtıcılığına bağlı olarak belirlenmektedir. Yoğunluk bilgisi; nesne algılama ve sınıflandırma doğruluğunun artırılması, bitki biyokimyasal özelliklerinin tahmin edilmesi (Zhu vd., 2015) ve siyah beyaz görüntülere benzer yoğunluk temelli görsellerin oluşturulması gibi çeşitli uygulamalarda kullanılabilir. Bununla birlikte, yoğunluk değerleri; tarama açısı, yüzey bileşimi, tarama mesafesi, yüzey pürüzlülüğü, çoklu yol etkisi ve nem içeriği gibi birçok dış faktörden etkilenebilmektedir. Bu nedenle, yoğunluk genellikle farklı coğrafi konumlardan ve farklı platformlardan toplanan veri kümeleri arasında doğrudan karşılaştırılamayan, göreceli bir ölçüt olarak değerlendirilmektedir.

Literatürde, yoğunluk değerlerinin kalibrasyonuna yönelik çeşitli çalışmalar gerçekleştirilmiştir (Zhu vd., 2015). Örneğin, Zhu vd. (2015), geniş yapraklı ağaçların yaprak su içeriğini tahmin etmek amacıyla, yoğunluk verilerini speküler yansıma etkisi ve tarama açısı gibi faktörlerden arındırarak kalibre edilmiş yoğunluk değerlerini kullanmış ve yaprak düzeyinde %74 doğruluk elde etmiştir.

Bir ormanlık alanın yoğunluk profili, tüm LiDAR noktalarının yoğunluk değerlerinin dikey dağılımını temsil etmekte olup, bu profil aracılığıyla ortalama yoğunluk, yoğunluk varyasyon katsayısı ve bağıl yoğunluk yüzdeleri gibi yapısal değişkenler çıkarılabilmektedir. Yoğunluk temelli değişkenlerin kullanımı, belirli orman yapısal parametrelerinin tahmin doğruluğunu artırmakta ve bazı işlevsel özelliklerin öngörülmesine katkı sağlamaktadır (Garcia vd., 2010). Ayrıca, yoğunluk verilerinin yapısal ölçümlerle birlikte kullanılması durumunda, bireysel ağaç segmentasyonu ve ağaç türü sınıflandırması gibi uygulamalarda daha yüksek başarı oranları elde edilebilmektedir (Budei ve St-Onge, 2018; Kim vd., 2011).

2.5.4. Regresyon Tabanlı Yapısal Nitelik Çıkarımı

Ormanlık alan düzeyindeki yapısal özellikler, ortalama ağaç boyu (Coops vd., 2007), ortalama çap (d) (Popescu vd., 2004) ve tepe yüksekliği (Andersen vd., 2005; Kramer vd., 2014) gibi parametreler aracılığıyla LiDAR verileri kullanılarak tahmin edilebilmektedir. Ancak bazı yapısal nitelikler, özellikle “d” gibi ölçütler, doğrudan havadan LiDAR verilerinden çıkarılamamaktadır. Bu sınırlamayı aşmak amacıyla, araziden elde edilen ölçümler ile LiDAR nokta bulutu yükseklik verileri arasında regresyon ilişkisi kurulmasına sıklıkla başvurulmaktadır. Bu yöntem, bilinmeyen alanlardaki orman yapısal niteliklerinin tahmin edilmesine olanak sunmaktadır.

Wing vd. (2012) tarafından yürütülen bir araştırmada, söz konusu yöntemin uygulanabilirliğini ortaya konulmuştur. Çalışmada, LiDAR yoğunluk verileri kullanılarak alt tabakadaki bitki örtüsünün (çalılar, ölü veya ölmekte olan ağaçlar ve küçük ağaçlar dâhil) hesaplanması amaçlanmıştır. İlk aşamada, belirlenen yoğunluk ve boy eşiklerine göre alt tabakada yer alan bitki örtüsü noktaları ayrıştırılmıştır. Ardından, bu katmandaki arazide ölçülmüş bitki örtüsü ile LiDAR yoğunluk profilleri arasında regresyon modelleri oluşturulmuştur.

Söz konusu çalışmada, beta regresyonu ve ağırlıklı doğrusal regresyon olmak üzere iki farklı regresyon algoritması, ABD’nin Kaliforniya eyaletinde bulunan Blacks Mountain

Deneysel Ormanı’nda test edilmiştir. Elde edilen bulgular, her iki regresyon yönteminin de alt tabakadaki bitki örtüsünü yüksek doğrulukla tahmin edebildiğini ortaya koymuştur. Regresyon analizleri sonucunda, tahmin edilen bitki örtüsü ile sahada ölçülen değerler arasındaki belirtme katsayısının (R^2), her iki yöntem için 0,7 ile 0,8 arasında değiştiği belirlenmiştir.

2.6. Bireysel Ağaç Segmentasyonu

Bireysel ağaç segmentasyonu, LiDAR nokta bulutlarından her bir ağacın mekânsal olarak ayrıştırılmasını sağlayan ve bireysel ağaç düzeyinde orman yapısal niteliklerinin çıkarılmasına temel teşkil eden bir adımdır. Son yıllarda, bu konu LiDAR tabanlı ormancılık araştırmalarında başlıca odak alanlarından biri hâline gelmiştir.

Segmentasyon yöntemleri, temel aldıkları veri türüne göre iki ana grupta sınıflandırılmaktadır: Meşçere Boy Modelleri’ne (MBM) dayalı yöntemler ve doğrudan üç boyutlu nokta bulutlarını kullanan yöntemler. Ayrıca, veri toplama platformuna bağlı olarak üç farklı yaklaşım tanımlanmaktadır: havadan LiDAR sistemlerine (örneğin, insansız hava araçları ve sabit kanatlı uçaklar), mobil LiDAR sistemlerine ve karasal LiDAR sistemlerine dayalı segmentasyon yöntemleri (Guo vd., 2023).

Her bir yaklaşım, farklı çözünürlüklerdeki veri karakteristikleri ve uygulama alanlarına bağlı olarak çeşitli avantajlar ve sınırlılıklar sunmaktadır. Bu çeşitlilik, bireysel ağaç düzeyindeki analizlerin doğruluğunu ve uygulanabilirliğini belirleyen önemli bir unsur olarak öne çıkmaktadır.

2.6.1. Meşçere Boy Modeli Tabanlı Bireysel Ağaç Segmentasyonu

Hava LiDAR verilerine dayalı bir Meşçere Boy Modeli (MBM) kullanılarak gerçekleştirilen bireysel ağaç segmentasyonu, en uzun kullanım geçmişine sahip yöntemlerden biri olarak öne çıkmaktadır. MBM’nin bir raster görüntü olması nedeniyle, bu yönteme dayalı bireysel ağaç segmentasyonu temel olarak gri tonlamalı görüntü işleme teknikleriyle ilişkilendirilmektedir. Farklı MBM tabanlı segmentasyon yaklaşımları, orman yapısının çözümlemesinde önemli rol üstlenmektedir.

Hyypä vd. (2001), iğne yapraklı ormanlar için bireysel ağaç segmentasyonu amacıyla bölge büyütme yöntemini kullanmıştır. Bu yöntemde, öncelikle MBM verileri düşük geçişli bir evrişim filtresiyle işlenmekte ve ardından yükseklik değerinin, bitişik 3×3 penceresindeki

sekiz komşu pikselin değerinden büyük olduğu bölgelerde en yüksek noktalar tespit edilmektedir. Son aşamada ise, tespit edilen en yüksek noktadan başlayarak bölge büyütme kuralı uygulanmaktadır. Söz konusu algoritmanın, nokta özelliklerine göre optimize edilmesi gereken dört parametresi bulunmaktadır.

Popescu vd. (2002), bölge büyütme yöntemini kullanarak ağaç sayısını ve boyunu tahmin etmiştir. Bu yöntemde, kare bir arama penceresi yerine, tepe örtüsünün gerçek şekline daha yakın olan dairesel bir arama penceresi kullanılmıştır. Yöntem, MBM görüntüsündeki her pikselin yükseklik değerini çıkarmakta ve zemin ölçümlerinden elde edilen ağaç boyu-tepe çapı ilişkisine dayanarak taç boyutunu tahmin etmektedir. Ardından, mevcut pikselin, merkez nokta kabul edilip taç boyutuna bağlı bir arama yarıçapı belirlenerek yerel en yüksek nokta olup olmadığı değerlendirilmektedir. Bu koşul sağlandığında bir ağacın algılandığı kabul edilmekte ve ilgili hücrenin yükseklik değeri ağaç boyu olarak kabul edilmektedir.

Koch vd. (2006), iğne yapraklı ve geniş yapraklı ormanların tepe segmentasyonunu, %62'lik genel doğruluk oranı ile gerçekleştirmiştir. Geliştirilen algoritma, öncelikle yerel bir yüksek nokta araması yapmakta, ardından segmentasyonun optimize edilmesi için HALCON yazılımını kullanmaktadır. Segmentasyon sonuçları, belirli bir dizi optimizasyon koşulu uygulanarak iyileştirilmiştir.

Chen vd. (2006), savan ormanlarında bireysel ağaçları tespit etmek amacıyla işaretleyici havza segmentasyon algoritmasını kullanarak %64'lük bir segmentasyon doğruluğu elde etmiştir. Geliştirilen algoritma, Koch vd. (2006) tarafından kullanılan yöntemle benzer şekilde, klasik bir grafik segmentasyon algoritmasına dayanmaktadır (Beucher, 1979). Meyer ve Beucher (1990), aşırı segmentasyon sorunlarının önüne geçebilmek için kullanıcı tanımlı işaretleyiciler ekleyerek söz konusu algoritmayı geliştirmiştir. Chen vd. (2006), en yüksek noktayı tespit etmek amacıyla Popescu vd. (2002) tarafından önerilen dairesel pencere yöntemini kullanmıştır. Ancak, Popescu vd. (2002) aksine, ağaç boyu ve tepe genişliği arasındaki ilişkiyi doğrudan MBM görüntülerinden ölçerek kurmuştur. Ayrıca, daha yüksek segmentasyon doğruluğu sağlamak amacıyla MBM görüntüleri üzerinden Gauss filtreleme ve mesafe dönüşümü işlemleri uygulanmıştır. Geliştirilen yöntemin, iğne yapraklı ormanların havadan LiDAR verilerinde yaygın olarak kullanılabildiği; ancak geniş yapraklı ormanlarda doğruluk açısından iyileştirmeye ihtiyaç duyduğu belirtilmiştir.

Diğer yaygın MBM tabanlı segmentasyon yöntemleri arasında morfoloji analizi, çoklu ölçekli segmentasyon, Gauss segmentasyonunun Laplasyeni ve MBM'nin minimum eğrilik hesaplaması yer almaktadır (Jing vd., 2012; Kaartinen vd., 2012). Daha fazla segmentasyon algoritması ve bunların karşılaştırmaları, Lu vd. (2014), Kaartinen vd. (2012) ve Yang vd. (2019) tarafından ayrıntılı bir şekilde ele alınmıştır. MBM yalnızca kapalılık yüzeyinin yüksekliğini yansıttığı için, MBM tabanlı bireysel ağaç segmentasyonu alt tabaka bitki örtüsünü tespit etmekte yetersiz kalabilmekte ve bu durum, ağaç sayısı ve boyu tahminlerinin doğruluğunu olumsuz yönde etkileyebilmektedir.

2.6.2. Hava LiDAR Verilerine Dayalı Nokta Bulutu Tabanlı Bireysel Ağaç Segmentasyonu

Bireysel nokta bulutu tabanlı ağaç segmentasyon algoritmaları, MBM tabanlı algoritmalarından daha doğrudan bir yaklaşım sunmakta ve bu sayede nokta bulutlarının MBM'lere enterpolasyonu sırasında oluşabilecek hatalardan kaçınılmasına olanak tanımaktadır. Ancak, nokta bulutu tabanlı segmentasyon algoritmalarının verimliliği, çok sayıda nokta nedeniyle oluşan hesaplama yükü sebebiyle MBM tabanlı algoritmalarla kıyasla daha düşük olabilmektedir. Morsdorf vd. (2004), iğne yapraklı ormanlarda bireysel ağaç segmentasyonu gerçekleştirmek amacıyla K-ortalama kümeleme yöntemini kullanmıştır. İlk aşamada, SYM'den yerel en yüksek noktayı tespit etmişler ve bu noktaları ağaçların en yüksek noktaları olarak kabul etmişlerdir. Daha sonra, her yerel en yüksek nokta, K-ortalama kümeleme için tohum noktası olarak atanmıştır.

Reitberger vd. (2009), bireysel ağaç segmentasyonu için nokta bulutlarından grafik tabanlı bir yaklaşım geliştirilerek, normalleştirilmiş kesim yöntemini önermişlerdir. Bu yöntemde, her bir nokta bir grafik oluşturacak şekilde birleştirilmekte, bağlantıların zayıf olduğu yerlerde kesimler yapılmakta ve böylece alt grafikler üretilmektedir. Bu işlem, grafikte zayıf bağlantı kalmayana kadar birkaç kez tekrarlanmaktadır. Reitberger vd. (2009), söz konusu algoritmayı Almanya'daki birkaç iğne yapraklı ve geniş yapraklı karışık ormanda test etmiş ve elde edilen sonuçları havza algoritması ile karşılaştırmışlardır. Karşılaştırmalar, normalleştirilmiş kesim yönteminin havza segmentasyon algoritmasına kıyasla daha yüksek doğruluk sağladığını ortaya koymuştur. Bununla birlikte, normalleştirilmiş kesim algoritmasının temel dezavantajı, yalnızca x, y ve z bilgileri kullanılsa dahi yüksek hesaplama maliyeti gerektirmesidir. Ayrıca, bağlantı ağırlığının Öklid mesafesine dayanarak hesaplanmasına rağmen segmentasyon sonuçlarında hatalar

oluşabilmektedir. Reitberger vd. (2009), bağlantı ağırlığını hesaplamak için nokta yoğunluğu gibi ek bilgiler kullanarak segmentasyon doğruluğunu artırmışlardır.

Günümüzde, grafik tabanlı teoriye dayalı nokta bulutu segmentasyonu çeşitli alanlarda yaygın olarak kullanılmaktadır (Strimbu ve Strimbu, 2015; Tao, Wu vd., 2015). Li vd. (2012), segmentasyonu desteklemek amacıyla bölge büyütme yöntemini bir eşik değeriyle birleştiren Nokta Bulutu Segmentasyonu (NBS) adını verdikleri bir yöntem önermişlerdir. Bu algoritma ile, iğne yapraklı ve geniş yapraklı karışık ormanlarda bireysel ağaç segmentasyonu gerçekleştirilebilmektedir. Yöntem, özellikle ağaç tepeleri arasındaki mesafeyi, yani bireysel ağaçlar arasındaki uzaklığı bir ayırma kriteri olarak kullanmaktadır. İlk adımda, algoritma nokta bulutundaki en yüksek noktayı belirlemekte; ardından bölge büyütme işlemi bireysel ağaçların segmentasyonu için uygulanmaktadır. Bu süreç, tüm ağaçlar başarıyla segmente edilene kadar tekrarlanmaktadır.

Nokta bulutu segmentasyonu (Point Cloud Segmentation-PCS) algoritmasına dayalı olarak, geniş yapraklı ormanlardaki bireysel ağaçları segmentlere ayırmak amacıyla aşağıdan yukarıya bir yöntem geliştirilmiştir (Lu vd., 2014). Bu yöntem PCS algoritmasına benzemekle birlikte, temel farkı, aşağıdan yukarıya yaklaşımın tohum noktalarını bulması ve ağaçları aşağıdan yukarıya doğru büyütme için ağaç gövdesi noktalarını kullanmasıdır. Algoritma, normalleştirilmiş yoğunluk bilgilerini kullanarak ağaç gövdelerini tanımlamaktadır. Genellikle ağaç gövdelerinin normalleştirilmiş yoğunluk değeri, dallar ve yapraklara ait değerlerden belirgin biçimde farklılık göstermektedir. Bu nedenle, önceden tanımlanmış bir eşik yoğunluk değeri kullanılarak gövde noktaları seçilmekte ve ardından gövde noktalarından başlayarak, bir mesafe eşiği temelinde uygulanan bölge büyütme yöntemi ile bireysel ağaçlar segmentlere ayrılmaktadır. Geliştirilen algoritma, ABD'nin Pensilvanya eyaletinden bulunan Shaver's Creek Havzası'ndaki geniş yapraklı bir yaprak dökken ormanda test edilmiş ve %84 oranında bireysel ağaç tespit oranı ile ağaçların %94'ünün doğru şekilde segmentlere ayrıldığı sonuçları elde edilmiştir.

2.6.3. Nokta Bulutu ve Meşçere Boy Modeli Tabanlı Bireysel Ağaç Segmentasyon Algoritmalarının Karşılaştırılması

Çeşitli koşullar için birçok bireysel ağaç segmentasyon yöntemi önerilmiş olup, bu yöntemler Meşçere Boy Modeli (MBM) tabanlı ve nokta bulutu tabanlı olmak üzere iki ana gruba ayrılmaktadır. Ancak, bu yöntemlerin doğruluklarının karşılaştırması güçlük arz etmektedir; zira LiDAR veri kümeleri farklı orman koşulları altında elde edilmekte ve

doğruluk değerlendirme yöntemleri genellikle farklılık göstermektedir (Tablo 3). Örneğin, Chen (2007), ağaç izolasyonunu değerlendirmek amacıyla elle belirlenmiş kıyaslama verilerini kullanarak mutlak doğruluk analizi gerçekleştirmiştir. Öte yandan, Li, Guo vd. (2012), segmentasyon doğruluğunu değerlendirmek için küresel navigasyon uydu sistemi (GNSS) ölçümlerinden ve F-puanı metodundan yararlanarak segmentlenen ağaçları referans ağaçlarla karşılaştırmışlardır (Sokolova vd., 2006).

Tablo 3. Bireysel ağaç segmentasyon yöntemleri hakkında yapılan çalışmalar

Algoritma	Referans	Bitki Örtüsü Yaprak Türü	Nokta Yoğunluğu (pts/m ²)	Doğruluk (%)	Değerlendirme Yöntemi
Region growing ^a	Hyypa vd. (2001)	İğne yapraklı	8-10	—	—
Pouring ^a	Koch vd. (2006)	İğne yapraklı, geniş yapraklı	5/10	62	MARA
Watershed ^a	Jing vd. (2012)	İğne yapraklı, geniş yapraklı	45	69	C, O
Marker- controlled watershed ^a	Chen vd. (2006)	İğne yapraklı	9.5	64	AATI
Local maxima ^a	Smits vd. (2012)	İğne yapraklı, geniş yapraklı	9	87.50	D
Pit-free canopy height model (PFCHM) ^a	Khosravipour vd. (2014)	İğne yapraklı, geniş yapraklı	160	74	AI
Normalized cut ^b	Reitberger vd. (2009)	İğne yapraklı, geniş yapraklı	25/10	66	—
Point cloud segmentation ^b	Li, Guo vd. (2012)	İğne yapraklı	6	90	F-score
Bottom-up region growing ^b	Lu vd. (2014)	Geniş yaprak	10.28	84	F-score
Region growing ^b	Hamraz vd. (2017)	Geniş yaprak	25/1.5	—	—
Layer stacking ^b	Ayrey vd. (2017)	İğne yapraklı, geniş yapraklı	21/6/5	72	D, C, O
Iterative watershed ^b	Duncanson vd. (2014)	Geniş yapraklı	18	70	—

Tablo 3'ün devamı

Watershed + K-means ^b	Tochon vd. (2015)	İğne yapraklı, geniş yapraklı	—	69.86	D, US, M, OS
Hierarchical approach ^b	Paris vd. (2016)	İğne yapraklı (çok katmanlı)	50/8	92-97	D, C, O

—: Bilgi mevcut değil,

a: MBM tabanlı bir segmentasyon yöntemine atıfta bulunur;

b: Nokta bulutu tabanlı bir segmentasyon yöntemine atıfta bulunur;

AATI: Segment tacı ve referans taç poligonlarının kaplama alanlarının karşılaştırılması;

AI: Doğruluk endeksi = $((N-O+C)/N) \times 100$ (Pouliot vd., 2005);

C: komisyon; D: tespit; M: eksik;

MARA: manüelden otomatik tanıma doğruluğu (Leckie vd., 2003);

N: ağaç sayısı; O: ihmal; OA: aşırı doğruluk; OS: aşırı segmentasyon; US: yetersiz segmentasyon.

Farklı orman özelliklerinin segmentasyon doğruluğu üzerindeki etkisi literatürde nadiren incelenmiştir. Bununla birlikte, bazı çalışmalar, ağaç sayısı, bitki örtüsü türü ve tepe örtüsü gibi faktörlerin bireysel segmentasyon performansını etkilediğini ortaya koymuştur (Peuhkurinen vd., 2011). Bu bağlamda, farklı orman tiplerinde bitki örtüsü özelliklerinin çeşitli segmentasyon yöntemleri üzerindeki etkisinin analiz edilmesi gerekli görülmektedir (Forzieri vd., 2009). Bireysel algoritmaların karşılaştırıldığı çalışmalara ek olarak, farklı bitki örtüsü koşullarının; orman türü, yaprak alanı indeksi (YAI), tepe örtüsü (TÖ), ağaç sayısı (AS) ve ağaç boyunun değişim katsayısı (ABDK) farklı segmentasyon yöntemleri üzerindeki etkileri analiz edilmiştir. Yapılan deneyler sonucunda, segmentasyon yöntemlerini etkileyen başlıca orman özelliklerinin, iğne yapraklı, geniş yapraklı ve karışık ormanlarda sırasıyla YAI ve TÖ, YAI ve AS, ve ABDK olduğu belirlenmiştir. Çoğu bitki örtüsü özelliğinin (YAI, TÖ ve AS) segmentasyon doğruluğu ile negatif korelasyon gösterdiği; buna karşılık, ABDK'nin etkisinin orman türüne göre farklılık gösterdiği rapor edilmiştir (Yang vd., 2019).

2.6.4. Derin Öğrenme Kullanılarak Bireysel Ağaç Segmentasyonu

Derin öğrenme kullanılarak bireysel ağaç segmentasyonu, yapay zekânın popüleritesinin artması, hesaplama kaynaklarının gelişmesi ve büyük veri birikiminin

sağlanmasıyla ortaya çıkan yeni bir araştırma alanı hâline gelmiştir. Makine öğreniminin yeni bir dalı olan derin öğrenme, yüksek boyutlu ve büyük veri kümelerinden karmaşık yapısal bilgileri çıkarma kapasitesine sahiptir (Guo vd., 2020; LeCun vd., 2015) ve nesne sınıflandırması (Guan vd., 2015), nesne tespiti (Jin, Su, Gao, Wu vd., 2018) ve segmentasyon (Jin vd., 2019) gibi uygulama alanlarında dikkate değer sonuçlar elde edilmiştir.

Derin öğrenme kullanılarak gerçekleştirilen bireysel ağaç segmentasyonunun temelinde, üç boyutlu hedef tespiti yer almaktadır. Günümüzde, üç boyutlu algılamayı gerçekleştirmek için iki ana yaklaşım bulunmaktadır: Bunlardan ilki, çoklu görünüm görüntü tabanlı derin öğrenme yöntemlerini kullanarak nesneleri iki boyutlu uzayda algılamak; diğeri ise, nokta tabanlı derin öğrenme yöntemleriyle nesneleri doğrudan üç boyutlu uzayda algılamaktır.

Bireysel ağaç segmentasyonu için görüntü tabanlı derin öğrenme yöntemi, dolaylı ancak etkili bir yaklaşım sunmaktadır. Örneğin, Jin, Su, Gao, Wu vd. (2018), üç boyutlu noktalardan türetilen sıkıştırılmış iki boyutlu görüntülerdeki nesneleri algılamak amacıyla iki boyutlu Faster R-CNN (Bölge Tabanlı Evrişimli Sinir Ağları) yöntemini kullanan bir dolaylı yöntem önermiştir. Bu yöntem, iki boyutlu görüntülerde algılanan nesnelerin üç boyutlu noktalara eşlenmesini sağlamak ve bu eşleşen noktalar, Tao, Guo vd. (2015) tarafından önerilen bölge büyütme yöntemi için tohum noktaları olarak kullanılmaktadır. Söz konusu yaklaşım, üç boyutlu CNN'lerin yüksek hesaplama ve depolama maliyetlerinden kaçınmak amacıyla iki boyutlu CNN yönteminden yararlanmaktadır. Ayrıca, bölge büyütme yöntemi sayesinde bireysel bitkilerin geometrik ilişkileri korunabilmektedir. Bu dolaylı yöntem, farklı ağaç yoğunluklarına sahip üç test sahasında 0,9'un üzerinde r, p ve F-puanı değerlerine ulaşarak umut verici sonuçlar elde etmiştir. İlgili algoritma, Wang vd. (2019) ile Windrim ve Bryson (2020) tarafından da karasal ve havadan LiDAR verilerinden bireysel ağaçların ve gövdelerin segmentasyonu amacıyla uygulanmış ve bireysel ağaç/gövde segmentasyon doğruluğunun %90'ın üzerinde olabileceği gösterilmiştir.

Görüntü tabanlı yöntemlerle karşılaştırıldığında, nokta tabanlı yöntemler daha doğrudan olmakla birlikte hesaplama açısından daha yoğun kaynak gerektirmektedir. Doğrudan nokta bulutu tabanlı yöntemler, nokta bulutlarının mekânsal yapısını tam olarak dikkate almamakta ve kolayca yakınsamamaktadır (Qi ve diğerleri, 2016, 2017). Bu nedenle, bazı çalışmalar, noktalar arasındaki yapısal ilişkiyi geliştirmek ve hesaplama maliyetini azaltmak için noktaları voksellere, sekizli ağaçlara ve grafik yapılarına dönüştürmüştür. Örneğin, Wang (2020) karasal LiDAR noktalarından bir süper nokta grafiği oluşturmuş ve

bu grafiğin grafik tabanlı derin öğrenme yöntemleri kullanılarak örnek/bireysel segmentasyon için teorik olarak analiz edilebileceğini ortaya koymuştur (Landrieu ve Simonovsky, 2017). Ancak, bireysel ağaç segmentasyonu için geliştirilen mevcut nokta tabanlı derin öğrenme yöntemlerinin hâlen sınırlı sayıda olduğu ve başlıca zorluklar arasında ağaç taçlarının üst üste binmesi, ormanların karmaşık dikey katman yapısı ve büyük ölçekli orman sahnelerindeki hesaplama maliyetleri bulunduğu ifade edilmektedir.

2.7. Ağaç Türü Sınıflandırması

Ağaç türü kompozisyonu ve dağılımı, hassas ormancılık uygulamaları, biyolojik çeşitlilik değerlendirmeleri, izleme çalışmaları ve yaban hayatı habitat haritalamaları açısından büyük öneme sahiptir. Ayrıca, ağaç türleri, ağaç büyüme modelleri, verim tahmin modelleri ve allometrik denklemler için temel girdilerini oluşturmaktadır. Ormandaki ağaç türlerinin doğru ve etkili bir şekilde tanımlanması, orman yöneticileri ve araştırmacılar için kritik bir gereklilik olarak değerlendirilmektedir.

Geleneksel olarak, ağaç türü kompozisyonu, oldukça zaman alıcı, yoğun emek ve sınırlı alanları kapsayan orman envanter çalışmaları aracılığıyla elde edilmektedir. Farklı ağaç türlerinin çeşitli spektral yansıma özelliklerine sahip olması nedeniyle, birçok çalışma, farklı ölçeklerde ağaç türü sınıflandırması gerçekleştirmek amacıyla optik uzaktan algılama verilerini kullanmayı hedeflemiştir. Ancak, farklı türlerin benzer yansıma özelliklerini paylaşabilmesi ve aynı türlerin dar spektral bantlara sahip uzaktan algılama görüntülerinde çeşitli arka plan etkileri nedeniyle farklı yansıma özellikleri gösterebilmesi, çok bantlı uydu görüntülerinden doğru tür sınıflandırmasını hâlen önemli bir zorluk haline getirmektedir. LiDAR teknolojisi ise, ormanlardan üç boyutlu bilgi toplayarak ağaç türlerini sınıflandırmak için yeni bir bakış açısı sunmaktadır (Guo vd., 2023).

2.7.1. Bireysel Ağaç Düzeyinde Ağaç Türü Sınıflandırması

Hem ALS hem de TLS, bireysel ağaç düzeyinde ağaç türlerini tanımlayabilmektedir. Yapılan çalışmalar, özellikle hiperspektral görüntüler ile birleştirilen nokta bulutu verilerinden segmentlenen bireysel ağaçların yapısal bilgilerini kullanarak ağaç türü tanımlamasına yönelik sınıflandırma modelleri geliştirmiştir. Taç ve dal yapısal özellikleri, LiDAR verilerini kullanarak ağaç türlerini belirlemek için başlıca kullanılan unsurlar arasında yer almaktadır. Othmani vd. (2013), rastgele orman algoritmasını kullanarak 75

ağaç örneği arasından beş ağaç türünü (gürgen, meşe, ladin, kayın ve çam) kabuk yüzeyinin üç boyutlu geometrik dokusu temelinde tanımlamıştır. Lin ve Herold (2016), ağaç yapısal özelliklerine (ağaç boyu, çap, tepe yüksekliği, dal açısı ve taç uzunluğu) dayanarak 40 ağaçtan dört türü sınıflandırmak için destek vektör makineleri algoritmasını kullanmıştır. Akerblom vd. (2017), nicel yapı modellerinden türetilen geometrik ve topolojik özellikler aracılığıyla ağaç türü tanımlamasına yönelik bir çerçeve önermiştir. Bu yöntemi kullanarak, nicel yapı modelinden türetilen 15 özellik ile 1200'den fazla ağacın yer aldığı beş meşçere sınıflandırması gerçekleştirmiştir. Terryn vd. (2020) de benzer şekilde, nicel yapı modellerinden elde edilen 15 özellik yardımıyla beş türü %77,5 ile %93 doğruluk aralığında sınıflandırmıştır. Ancak, bu çalışmaların çoğunda sınıflandırılabilen ağaç türü sayısı beş veya daha az türle sınırlı kalmıştır. LiDAR verilerine dayalı bireysel ağaç türü sınıflandırması hâlen zorlu bir problem olarak devam etmektedir. LiDAR verilerinin optik uzaktan algılama verileriyle birleştirilmesi, sınıflandırma doğruluğunu önemli ölçüde artırabilmektedir. Örneğin, Xu vd. (2020), insansız hava sistemlerinden elde edilen multispektral görüntülerden üretilen dijital hava fotoğrametrisi nokta bulutlarını kullanarak subtropikal doğal ormanların spektral, dokusal ve yapısal metrikleri çıkarmış ve sekiz ağaç türünü başarılı bir şekilde sınıflandırmıştır. Benzer şekilde, Zhao vd. (2020), Kuzeydoğu Çin'deki doğal karışık ormanlarda, destek vektör makineleri ve spektral açı eşleyici sınıflandırıcılar kullanarak havadan LiDAR verileri ile ve hiperspektral verileri birleştirmiş ve altı ağaç türünü %90'ın üzerinde sınıflandırma doğruluğu ile tespit etmiştir. Ancak, önceki çalışmaların çoğunun yalnızca sınırlı sayıda bireysel ağaç segmentasyonu üzerinde geçerli olduğu ve segmentasyon doğruluğunun sınıflandırma başarısını doğrudan etkilediği vurgulanmaktadır. Günümüzde, veri setlerinin genişlemesiyle birlikte, birçok araştırmacı önceden etiketlenmiş ağaç türü fotoğrafları ve bireysel ağaç nokta bulutu veritabanlarını kullanarak derin öğrenme yöntemlerini benimsemekte ve bireysel ağaç türü doğruluğunu artırma potansiyelini araştırmaktadır.

2.7.2. Topluluk Düzeyinde Ağaç Türü Sınıflandırması

Topluluk düzeyindeki ağaç türü sınıflandırması, aynı zamanda bitki örtüsü türü sınıflandırması olarak da adlandırılmaktadır. Bitki örtüsü türü bilgisi, orman yönetimi ve biyolojik çeşitliliğin korunması açısından temel bir veri kaynağıdır. LiDAR verilerinin sağladığı üç boyutlu yapısal bilgi, optik uzaktan algılama görüntülerinden elde edilen

spektral bilgilerle birleştirildiğinde, bitki örtüsü türlerinin sınıflandırılması amacıyla yaygın olarak kullanılmaktadır. Su, Guo, Fry vd. (2016), Bayes ve k-ortalama kümeleme algoritmalarına dayalı gözetimsiz bir sınıflandırma yöntemi geliştirmiştir. Elde edilen sonuçlar, LiDAR verileri ile hava fotoğraflarının entegrasyonundan elde edilen sınıflandırma sonuçlarının daha yüksek doğruluğa sahip olduğunu ve geleneksel yöntemlere kıyasla daha çeşitli bitki örtüsü türleri tespit edilebildiğini göstermiştir. Ayrıca, yapılan çalışmalar, LiDAR verileri tarafından sağlanan yapısal bilgilerin bitki örtüsü türü sınıflandırmasının performansını önemli ölçüde artırdığını ortaya koymuştur. Voss ve Sugumaran (2008), dört yaprak dökken tür ile üç yaprak dökmeyen türü sınıflandırmak amacıyla LiDAR verilerini Uygulamalar için Hava Görüntüleme Spektrometresi (Airborne Imaging Spectrometer for Applications-AISA) hiperspektral verileriyle birleştirmiştir. LiDAR verilerinin katkısıyla, hiperspektral verilerdeki gölgeleme etkisinin başarıyla düzeltildiği belirtilmiştir. Ayrıca, LiDAR ve AISA verilerinin birleştirilmesiyle türler, uzun ve kısa ağaçlar şeklinde doğru biçimde ayırt edilerek sınıflandırma doğruluğu artırılmıştır. Sugumaran ve Voss (2007) ise, optik görüntülerin segmentasyonuna yükseklik bilgisi entegre ederek nesne odaklı analiz ve regresyon yöntemlerini uygulamış ve sınıflandırma doğruluğunu yaklaşık %12 ile %24 arasında artırmayı başarmıştır.

2.8. Bireysel Ağaç Segmentasyon Algoritmaları

Bireysel ağaçların tespiti ve taçlarının belirlenmesi genellikle iki aşamada gerçekleştirilmektedir. İlk aşamada, ağaçların konumları ve yükseklikleri tahmin edilmekte olup, bu adım diğer ağaç özelliklerini modellemek için temel oluşturmakta ve çoğunlukla yeterli kabul edilmektedir. Ancak, ikinci aşama olan taç belirleme işlemi, taç genişliği ve şekli gibi ek bilgilerin çıkarılmasına imkân tanımakta ve daha ayrıntılı analizlere olanak sağlamaktadır (Persson vd., 2002). Bireysel ağaç tespiti çalışmalarının büyük bir bölümü, uzaktan algılama ve görüntü işleme tekniklerine dayanmaktadır. Bu yöntemler, genellikle ağaç tepelerini belirlemek amacıyla yerel yükseklik maksimumlarını tespit edilmesine odaklanmaktadır. Algoritmalar arasındaki temel farklar ise, farklı kapalılık koşullarında doğru sayıda yerel maksimum tespit edebilmek için uygulanan yumuşatma tekniklerinden kaynaklanmaktadır. Ağaç tespiti sürecinde, Meşçere Boy Modeli (MBM) üzerinde gerçekleştirilen yumuşatma işlemleri kritik bir rol oynamakta ve elde edilen sonuçları doğrudan etkileyebilmektedir.

Yerel maksimumları belirlemek amacıyla kullanılan pencere boyutu, ağaçların tespit edilme hassasiyetini doğrudan etkilemektedir (Popescu vd., 2003). Pencere boyutu ve yumuşatma derecesi, önceki arazi ölçümlerine, MBM yükseklik değerlerine veya tahmini meşcere yoğunluğu gibi ek bilgilere dayanarak ayarlanabilmektedir. Ağaç taçlarının sınırlarını belirlemek için en yaygın kullanılan yöntemlerden biri, havza (watershed) algoritmasıdır. Bu yöntem, belirlenen yerel maksimumları referans olarak taç sınırlarını belirlemekte ve böylece her ağaca ait taç alanının oluşturulmasını sağlamaktadır. Bunun yanı sıra, bölge büyütme teknikleri de taç belirleme sürecinde sıkça tercih edilen yaklaşımlar arasında yer almaktadır. Alternatif olarak, şablon eşleştirme (Holmgren ve Wallerman, 2006) veya nokta bulutu verilerinin kümelenmesi (Morsdorf vd., 2004) gibi teknikler de kullanılabilir. Kullanılan yöntemler, verinin türüne ve çözünürlüğüne bağlı olarak değişmekte olup, en uygun yöntem çalışma alanının özelliklerine ve veri yapısına göre seçilmektedir.

2.8.1. Dalponte2016 Algoritması

Ağaç ayrıntılarının belirlenmesi amacıyla kullanılan bir tohum ve bölge büyütme araştırması olan bu algoritma, Meşcere Boy Modeli (MBM) üzerinde çalışmaktadır. Algoritma, ilk olarak yerel maksimum noktalarını tespit etmekte ve bu noktalar ağaç yapraklarının başlangıç bölgeleri olarak işaretlenmektedir. Daha sonra, bu bölgelerin genişletilmesi için çevredeki dört yönlü piksellerin yükseklik farklılıkları hesaplanmaktadır. Kullanıcı, genişleme işlemi için iki temel parametre belirlemektedir: biri, yerel maksimumların sayısına bağlı olarak kaydedilen bir yüzde değeri, diğeri ise kabul edilebilir en büyük sapma farkıdır. Bir pikselin mevcut bölgeye eklenebilmesi için, bu iki parametrenin her birinin belirlenen eşik değerlerin altında olması gerekmektedir. Bu işlem, tüm noktalar değerlendirilene kadar yinelemeli olarak sürdürülmekte ve böylece her ağacın taç alanı belirlenmektedir (Dalponte ve Coomes, 2016).

Dalponte2016 algoritması, R programlama dilinde yer alan lidR kütüphanesinde aşağıdaki biçimde kullanılmaktadır:

```
dalponte2016(chm, treetops, th_tree=2, th_seed=0,45, th_cr=0,55, max_cr=10, ID="treeID")
```

chm: Meşçere Boy Modeli'ne ait raster veriyi ifade etmektedir. Bu veri *rasterize_canopy* fonksiyonu ile hesaplanabilmekte veya harici bir dosyadan okunabilmektedir.

treetops: Tespit edilen ağaç tepe noktalarını içeren vektör veri kümesidir. Bu veriler, *locate_trees* fonksiyonu ile üretilebilmekte ya da harici bir dosyadan alınabilmektedir.

th_tree: Ağaç boyu için kullanılan eşik değeri belirtmektedir. Varsayılan değer 2'dir. Ağaç tespiti sırasında yalnızca 2 metreden daha yüksek boy değerleri dikkate alınmaktadır.

th_seed: Bir pikselin, yüksekliği ağaç boyunun bu eşik değerle çarpımından büyükse mevcut bölgeye eklenmesini sağlayan parametredir. Değer aralığı 0 ile 1 arasında olup, varsayılan değeri 0,45'tir.

th_cr: Bir pikselin, mevcut bölgenin ortalama boyunun bu eşik değerle çarpımından büyük olması durumunda bölgeye eklenmesini sağlayan parametredir. Değer aralığı 0 ile 1 arasında olup, varsayılan değeri 0,55'tir.

max_cr: Algılanan ağacın tepe çapı için maksimum değer sınırını (piksel cinsinden) tanımlamaktadır. Varsayılan değeri 10'dur.

ID: Segmentasyon sonucunda her bir ağaca atanan kimlik numarasını ifade etmektedir.

2.8.2. Silva2016 Algoritması

Algoritma, kümeleme ve nokta filtreleme tekniklerini entegre ederek, karmaşık orman yapılarını MBM üzerinde verimli bir şekilde segmentlere ayırmayı amaçlamaktadır. Söz konusu algoritma, tohum noktalarına ve Voronoi diyagramlarına dayalı bir yaklaşım benimsemektedir. İlk aşamada, her bir tohum noktasından başlanarak, ağaç tepesinin başlangıç alanını sınırlamak amacıyla değişken yarıçaplı bir tampon alan oluşturulmaktadır. Taç alanı sınırlandırıldıktan sonra, veriler Voronoi diyagramları kullanılarak bölünmekte ve her ağacın etki alanını temsil eden çokgenler oluşturulmaktadır. Böylece, her ağaç tepesi ayrı ayrı izole edilmektedir. Sonraki aşamada, her bir çokgen içerisinde, yüksekliği ilgili ağacın maksimum yüksekliğinin belirli bir yüzdesinden daha az olan noktalar düşük yükseklik gürültüsünü ortadan kaldırmak amacıyla elenmektedir. Son olarak, ağaç tepeleri, oluşturulan ve filtrelenen çokgenlere göre her ağaca ait pikseller tanımlanarak ve gruplandırılarak sınırlandırılmaktadır (Silva vd., 2016).

Silva2016 algoritmasının R programlama dilindeki lidR kütüphanesi kullanılarak uygulanışı ve ilgili parametre açıklamaları şu şekilde ifade edilmektedir:

silva2016(chm, treetops, max_cr_factor=0.6, exclusion=0.3, ID="treeID")

chm: Meşçere Boy Modeli'ne ait raster veriyi temsil etmektedir. Bu veri, *rasterize_canopy* fonksiyonu ile hesaplanabilmekte veya harici bir dosyadan okunarak elde edilebilmektedir.

treetops: Tespit edilen ağaç tepelerine ait vektör veriyi ifade etmektedir. Bu veriler *locate_trees* fonksiyonu ile oluşturulabileceği gibi harici bir dosyadan da yüklenebilmektedir

max_cr_factor: Ağacın tepe çapını tatmin etmek amacıyla, ağaç boyunun belirli bir oranını kullanmaktadır. Varsayılan değer 0.6'dır, bu da ağaç yüksekliğinin %60'ının maksimum tepe çapı olarak kabul edildiği anlamına gelmektedir.

exclusion: Her ağaç için, ağaç boyu ile çarpılan eşik değerden daha düşük yükseklik değerine sahip piksellerin elenmesini sağlamaktadır. Bu parametre 0 ile 1 arasında bir değere sahip olmalıdır.

ID: Segmentasyon işlemi sonucunda her ağaca atanan benzersiz numarayı temsil etmektedir.

2.8.3. Watershed Algoritması

Watershed algoritması, bir manzara boyunca su akışını simüle etmektedir. Her bir MBM bölgesinin en düşük noktasına su havzası (watershed) kavramı uygulanmakta ve bu bölgeler su altında bırakılmaktadır. Farklı watershed'ların birleşmesi sonucunda, segmentasyon sırasında doğal bariyerler oluşmaktadır. Bu algoritmanın uygulanması sırasında, aşağıdaki parametrelerin tanımlanması gerekmektedir: maksimum ve minimum ağaç boyu, piksel cinsinden tampon boyutu ve tepe yükseklik eşiği. Tampon boyutu, bellek taşmalarını önlemek amacıyla blok boyutunu kontrol eden bir eşik işlevi görmektedir. Bu parametre değerinin, maksimum tepe alanından büyük olması gerekmektedir (Chen vd., 2006).

Watershed algoritmasının R programlama dilindeki *lidR* kütüphanesi kullanılarak uygulanmasına ilişkin kullanım şekli ve açıklamaları şu şekilde ifade edilmektedir:

watershed(chm, th_tree=2, tol=1, ext=1)

chm: Meşçere Boy Modeli'ne ait raster veriyi temsil etmektedir. Bu veri *rasterize_canopy* fonksiyonu kullanılarak üretilebilmekte veya harici bir dosyadan okunabilmektedir.

th_tree: Ağaç boyu için kullanılan eşik değeri ifade etmektedir. Varsayılan değer 2 olup, ağaç tespiti sırasında yalnızca 2 metrenin üzerindeki boy değerleri dikkate alınmaktadır.

tol: Bir bölgeyi genişletme eşiğini belirleyen bir parametre olarak kullanılmaktadır. Bir çukurun veya zirvenin, bölge olarak kabul edilmesi için gerekli olan minimum yükseklik farkını tanımlamaktadır.

ext: Yerel minimum veya maksimum noktalarının sayısını belirleyen bir parametredir. Segmentasyon işleminin kaç çukur veya tepe üzerinden başlatılacağını kontrol etmektedir.

2.8.4. Li2012 Algoritması

Li (2012), yerel maksimumlardan başlayarak ağaç taçlarını, yükseklik ve yakınlık kriterlerine dayalı yinelemeli bir bölge büyütme yaklaşımını ile ayırmıştır. Bu yaklaşım, doğrudan normalleştirilmiş 3B nokta bulutları üzerinde çalışmakta ve ağaçlar arasında her zaman boşlukların bulunduğunu varsaymaktadır. İşlem sırasında, ağaçların tepe noktalarından aşağıya doğru ilerlenmekte; sınıflandırılmamış noktalar ile önceden belirlenmiş bir ağaca ait olan en yakın nokta arasındaki yatay mesafe, belirli bir eşik değeri ile karşılaştırılmaktadır. Eşik değerinin dışında kalan noktalar ilgili ağaçtan çıkarılmaktadır (Li vd., 2012).

Li2012 algoritmasına ait R programlama dilindeki lidR paketinde kullanım ve açıklamalar şu şekilde belirtilmektedir:

li2012(dt=1,5, dt=2, R=2, Zu=15, hmin=2, speed_up=10)

dt1: Ağaç olarak belirlenecek noktalar arasındaki Öklid uzunluk eşiğini ifade etmektedir. Varsayılan değer 1,5 olarak seçilmiştir.

dt2: Ağaç olarak belirlenmeyen noktalar için belirlenen Öklid uzunluk eşiğini ifade etmektedir. Varsayılan değer 2 olarak tanımlanmıştır.

R: Yerel maksimumlar belirlendikten sonra kullanılan arama yarıçapıdır. Varsayılan olarak 2 değeri kullanılmaktadır.

Zu: Bir noktanın yüksekliği bu eşik değerden büyükse dt2, küçükse dt1 kullanılmaktadır. Varsayılan değer 15 olarak belirlenmiştir.

hmin: Bir ağacın kabul edilen minimum yükseklik değeridir. Varsayılan değer 2 olarak seçilmiştir.

speed_up: Bir tacın maksimum yarıçapını belirlemektedir. Varsayılan olarak 10 değeri kullanılmaktadır.

2.8.5. DBSCAN Algoritması

Gürültülü uygulamalarda kullanılan yoğunluk tabanlı mekânsal kümelenme algoritması olan DBSCAN (Density-Based Spatial Clustering of Applications with Noise), veri noktalarının yoğunluk bölgelerine dayanarak kümelenmesi ilkesine dayanmaktadır. Bu yöntemde, belirli bir yakınlık mesafesi içerisinde yeterli sayıda nokta bulunduran bölgeler küme olarak tanımlanmaktadır. Algoritmanın temel kavramları şu şekilde açıklanmaktadır:

ϵ (epsilon): Bir noktanın komşuluğunu tanımlayan yarıçapı ifade etmektedir. Bir noktanın belirlenen ϵ mesafesi içinde diğer noktalarla olan yoğunluk ilişkisi bu kavram üzerinden değerlendirilmektedir.

Minimum Nokta (MinPts): Bir noktanın “çekirdek nokta” olarak kabul edilebilmesi için, ϵ mesafesi içerisindeki minimum nokta sayısını ifade etmektedir.

Çekirdek Nokta (Core Point): Komşuluk çevresinde en az MinPts sayıda nokta bulunan nokta olarak tanımlanmaktadır.

Sınır Noktası (Border Point): Komşuluk çevresindeki nokta sayısı MinPts değerini karşılamasa da, bir çekirdek noktaya komşu olan noktaları ifade etmektedir.

Gürültü (Noise) Noktası: Ne çekirdek ne de sınır noktası sınıfına giren ve kümelere dâhil edilemeyen izole noktalar olarak tanımlanmaktadır.

Her bir nokta için ϵ yarıçapındaki komşu noktalar belirlenmektedir. Bir noktanın ϵ yarıçapı içerisinde MinPts veya daha fazla sayıda komşu bulunuyorsa, söz konusu nokta çekirdek nokta olarak işaretlenmektedir. Bir çekirdek noktanın etrafındaki tüm komşu noktalar kümeye dâhil edilmekte; bu komşu noktaların da çekirdek niteliği taşıması durumunda, ilgili noktaların komşulukları genişletilerek kümeye yeni noktalar eklenmektedir. Hiçbir kümeye dâhil edilemeyen noktalar ise gürültü noktaları olarak tanımlanmaktadır.

Algoritmanın avantajları arasında, küme sayısının önceden belirlenmesine gerek duyulmaması yer almaktadır. Ayrıca, farklı şekillerde ve yoğunluklarda kümeleri tanımlamada başarılı sonuçlar vermekte ve gürültü tespitinde etkili bir performans sergilemektedir. Dezavantaj olarak ise, uygun ϵ ve MinPts değerlerinin belirlenmesinin, özellikle veri setinin yoğunluğu değişkenlik gösterdiğinde, zorlayıcı olabileceği ifade

edilmektedir. Bunun yanı sıra, algoritmanın yüksek boyutlu verilerde etkinliğinin azalabildiği de bilinmektedir.

2.8.6. K-Means Algoritması

K-Means algoritması, veri setini önceden belirlenen K sayıda kümeye ayırmayı amaçlamaktadır. Temel hedef, her küme içerisindeki noktalar arasındaki karesel ortalama hatayı minimize etmektir. Algoritmaya ilişkin temel kavramlar şu şekilde tanımlanmaktadır:

K: Oluşturulacak küme sayısını, yani küme merkezlerinin sayısını ifade etmektedir.

Küme Merkezi (Centroid): Her kümenin ortalama konumunu temsil etmektedir. K-Means algoritması, her yineleme sonunda her küme için yeni bir küme merkezi hesaplamaktadır.

Atama Adımı: Her veri noktasının, genellikle Öklid mesafe ölçütüne göre en yakın küme merkezine atanması işlemidir.

Güncelleme Adımı: Her kümenin yeni merkezinin, kendisine atanan noktaların ortalamasına göre güncellenmesidir.

Algoritma, rastgele seçilen K adet merkez ile başlatılmaktadır. Her veri noktası, en yakın merkez noktasına atanmaktadır. Atanan noktalar kullanılarak yeni merkezler ortalamaları alınarak güncellenmektedir. Atama ve güncelleme adımları, merkez noktaları sabitlenene kadar veya belirli bir hata toleransına ulaşılan kadar tekrarlanmaktadır.

K-Means algoritmasının avantajları arasında, kavramsal olarak basit olması ve hızlı bir şekilde uygulanabilmesi yer almaktadır. Ayrıca, büyük veri setlerinde verimli bir şekilde çalışabilmektedir. Dezavantajları ise; küme sayısının önceden belirlenmesi gerekliliği, başlangıç merkezlerine duyarlılık nedeniyle yerel minimumlara takılma riski ve küme yapılarının genellikle küresel veya benzer dağılım varsayılmasını gerektirdiği için karmaşık kümelerde performansın düşebilmesi olarak belirtilmektedir.

2.8.7. Gaussian Mixture Models (GMM) Algoritması

GMM algoritması, verinin farklı Gauss dağılımlarının bir karışımından (mixture) kaynaklandığını varsaymaktadır. Her dağılım, bir kümenin temsilcisi olarak değerlendirilmektedir. Bu yaklaşım sayesinde, her veri noktasının birden fazla kümeye ait olma olasılığı hesaplanabilmektedir. Algoritmaya ilişkin temel kavramlar şu şekilde özetlenmektedir:

Normal (Gaussian) Dağılım: Her bir küme, ortalama (mean) ve kovaryans (covariance) matrisine sahip bir normal dağılım olarak tanımlanmaktadır.

Ağırlıklar (Mixing Coefficients): Her bir Gauss dağılımının veri setine katkısını belirleyen katsayılarıdır ve bu katsayılar, toplamı 1 olacak şekilde normalize edilmektedir.

Expectation-Maximization (EM) algoritması: GMM parametrelerini (ortalama, kovaryans, karışım katsayıları) iteratif olarak optimize eden bir algoritmadır.

Expectation (E) adımı: Her bir veri noktasının, her bir bileşene ait olma olasılığı hesaplanmaktadır.

Maximization (M) adımı: Elde edilen olasılık değerlerine göre model parametreleri güncellenmektedir.

Parametreler (kümelerin sayısı, her bir kümenin ortalaması, kovaryansı ve ağırlıkları) rastgele ya da belirli yöntemler kullanılarak seçilmektedir. Her bir veri noktasının, her bir Gauss bileşenine ait olma olasılığı (sorumluluk) hesaplanmakta; bu sorumluluk değerlerine göre her bileşenin parametreleri (ortalama, kovaryans, ağırlık) yeniden güncellenmektedir. E ve M adımları, log-olabilirlik değerinin sabitlenmesine kadar veya belirli bir iterasyon sayısına ulaşılan dek yinelemeli olarak sürdürülmektedir.

GMM algoritmasının avantajları arasında, yumuşak atama yapabilme yeteneği sayesinde her bir noktanın küme üyeliğinin olasılıksal olarak ifade edilebilmesi yer almaktadır. Ayrıca, kümelerin eliptik yapılarını modelleyebilmesi sayesinde K-Means algoritmasına göre daha esnek bir yapı sunmaktadır. Dezavantajları ise; parametrelerin başlatılmasının ve uygun model seçiminin zorluk içermesi, hesaplama maliyetinin K-Means algoritmasına kıyasla daha yüksek olması ve büyük veri setlerinde daha yavaş çalışabilmesidir.

2.9. Derin Öğrenme

Sinir ağları ve derin öğrenme, bilgisayarla görme alanında büyük bir devrim yaratmıştır. Özellikle nesne sınıflandırma ve algılama görevlerinde bu teknikler önemli başarılar elde etmiştir. 2012 yılında düzenlenen ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesi (ImageNet Large Scale Visual Recognition Challenge-ILSVRC) kapsamında, AlexNet adlı sinir ağı, önceki yöntemlere kıyasla çarpıcı bir başarı sergileyerek bilgisayarla görme alanında yeni bir dönemin başlamasına öncülük etmiştir (Krizhevsky vd., 2012). Bu gelişme, görüntü sınıflandırma, anlamsal segmentasyon, nesne algılama, izleme ve video

işleme gibi birçok farklı bilgisayarla görme görevine odaklanan çeşitli evrişimli sinir ağı (Convolutional Neural Network-CNN) modellerinin geliştirilmesini teşvik etmiştir. Günümüzde bu ağlar, otomatik sürüş sistemlerinden tıbbi görüntü analizine kadar birçok alanda kullanılmakta ve bilgisayarla görme teknolojisinin temel taşlarından biri hâline gelmiştir.

Nokta bulutu işleme, otonom sürüş, robotik görüş sistemleri ve bilgisayarla görme gibi alanlardaki artan araştırmalarla birlikte hızla gelişen bir teknoloji hâline gelmiştir. 2017 yılına kadar bu amaçla geliştirilen yöntemlerin büyük çoğunluğu, el yapımı özelliklere dayalı geleneksel algoritmalarından oluşmaktadır. Bu yöntemler, ağırlıklı olarak noktaların yerel 3B geometrik özelliklerini analiz ederek çalışmaktadır. Ancak, nokta bulutlarının düzensiz bir veri yapısına sahip olması nedeniyle, 2B görüntü verilerinde oldukça başarılı olan evrişimli sinir ağı (CNN) modellerinin doğrudan 3B nokta bulutlarına uygulanması kolay bir süreç olmamıştır.

Bu zorluğun üstesinden gelmek amacıyla yürütülen bazı araştırmalar, nokta bulutlarının düzenli yapılara dönüştürülmesini önermiştir. Bu kapsamda, nokta bulutları voksel ızgaralarına (3B piksellere) bölünmüş veya farklı açılardan alınan çoklu görüntülere yansıtılmıştır. Böylece, CNN ve derin öğrenme modellerinin bu yapılandırılmış veriler üzerinde uygulanması mümkün hâle getirilmiştir. Ancak, bu yöntemlerin bazı önemli sınırlamaları bulunmaktadır. Voksel ızgaralarının genellikle seyrek yapıda olması nedeniyle önemli verilerin kaybolabildiği ve bu dönüşüm süreçlerinin büyük hesaplama gücü gerektirdiği bilinmektedir. Ayrıca, örnekleme sırasında yaşanan bilgi kayıpları nedeniyle, bu yaklaşımlar doğrudan nokta bulutları üzerinde çalışan yöntemler kadar verimli olamamıştır.

2017 yılında, PointNet (Qi vd., 2017) adlı derin öğrenme modeli, nokta bulutlarını herhangi bir ön işleme veya dönüşüm gerektirmeden doğrudan işleyebilen ilk ağ olarak geliştirilmiştir. Bu yöntem, nokta kümelerini doğrudan analiz ederek 3B veri işleme alanında önemli bir yenilik ortaya koymuştur. Ancak, PointNet'in bazı sınırlamaları bulunmuştur. Bu eksiklikleri gidermek amacıyla kısa sürede PointNet++ (Qi vd., 2017) modeli önerilmiştir. Bu gelişmeler, 3B nokta bulutu işleme alanında yeni bir dönemin başlangıcını temsil etmiştir.

PointNet ve PointNet++, nesne sınıflandırma, anlamsal segmentasyon ve nesne algılama gibi birçok görev için daha derin ve güçlü ağların temelini atmıştır. Günümüzde, derin öğrenme tabanlı birçok gelişmiş nokta bulutu işleme yöntemi geliştirilmeye devam etmektedir. Bu modeller, büyük ölçekli nokta bulutu verileriyle ilgili çeşitli problemleri

çözmeye odaklanmakta ve nokta bulutu tabanlı derin öğrenme yaklaşımlarının daha verimli ve ölçeklenebilir hâle gelmesine katkı sağlamaktadır.

2.9.1. PointNet

PointNet, 2017 yılında Qi ve ekibi tarafından geliştirilmiş ve 3B nokta bulutlarını doğrudan işleyebilen ilk derin öğrenme modeli olmuştur. Geleneksel yöntemlerde, nokta bulutları 2B görüntülere veya 3B voksel yapıları dönüştürülerek işlenmekteydi. Ancak bu dönüşümler, bilgi kaybına yol açmakta ve hesaplama sürecini uzatmaktadır. PointNet ise, bu sorunu ortadan kaldırarak nokta bulutlarını doğrudan analiz edebilen bir model sunmuştur.

Bu model, her bir noktayı ayrı ayrı işleyerek özelliklerini öğrenmekte ve ardından tüm noktaları birleştirerek nesne veya sahne hakkında genel bir temsil oluşturmaktadır. Ön işleme veya dönüşüm gerektirmediği için daha hızlı ve verimli çalışmakta; ayrıca, dönüşümlere karşı dayanıklı olması sayesinde farklı açılardan gelen verileri etkili bir şekilde işleyebilmektedir. PointNet, nesne sınıflandırma, nokta bazlı etiketleme, 3B segmentasyon ve kayıt işlemleri gibi çeşitli görevlerde kullanılabilir.

Model, komşu noktalar arasındaki ilişkileri yeterince iyi anlayamadığı için bazı karmaşık 3B şekilleri algılamakta zorlanabilmektedir. Özellikle büyük ölçekli ve yoğun nokta bulutu verileriyle çalışıldığında modelin performansında düşüş gözlemlenebilmektedir. Bu nedenle, araştırmacılar, bu eksiklikleri gidermek amacıyla PointNet++ adlı gelişmiş bir versiyonu geliştirmiştir. PointNet++, nokta bulutlarını hiyerarşik seviyelere bölerek daha ayrıntılı ve doğru özellikler çıkarılmasına olanak sağlamaktadır.

Günümüzde, otonom sürüş, robotik, şehir modelleme, tıbbi görüntüleme ve artırılmış gerçeklik gibi birçok alanda nokta bulutu işleme amacıyla PointNet ve türevleri yaygın olarak kullanılmaktadır. Daha gelişmiş modeller olan PointNet++, DGCNN ve Point Transformer gibi yöntemler, nokta bulutları üzerinde daha başarılı sonuçlar elde etmektedir. Ancak PointNet, hâlâ 3B yapay zekâ uygulamalarında temel bir model olarak kabul edilmekte ve birçok araştırmacı için başlangıç noktası işlevi görmektedir.

PointNet'in başarısı, çeşitli deneysel çalışmalarla ortaya konulmuştur. Nesne sınıflandırma görevlerinde, model ModelNet40 veri kümesi üzerinde %89,2 genel doğruluk elde etmiştir (Wu vd., 2015). Bu sonuç, daha önce geliştirilen tüm voksel tabanlı yöntemlerden daha yüksek bir doğruluk oranı sunmuştur. Parça segmentasyonu görevinde

ise, model ShapeNet veri kümesi üzerinde ortalama %83,7 Kesişim-Üzeri-Birleşim (IoU) skoru ile başarılı bir performans sergilemiştir (Yi vd., 2016).

Ayrıca, S3DIS veri kümesi kullanılarak gerçekleştirilen anlamsal segmentasyon testlerinde, PointNet %47,71 ortalama IoU ve %78,62 genel doğruluk elde etmiştir (Armeni vd., 2016). Yapılan analizler, modelin daha az sayıda noktayı kullanarak şekilleri özetlemeyi öğrendiğini ortaya koymuştur. Bunun yanı sıra, PointNet'in giriş verisindeki küçük bozulmalara, aykırı değerlere ve eksik noktalara karşı dayanıklı bir yapı sergilediği belirlenmiştir. Bu özellikleri sayesinde, model gerçek dünyadaki düzensiz nokta bulutu verilerini işleme konusunda güçlü bir yaklaşım sunmaktadır.

2.9.2. PointNet++

PointNet++, PointNet modelinin eksikliklerini gidermek amacıyla geliştirilmiş bir derin öğrenme modelidir. PointNet, nokta bulutlarını doğrudan işleyerek önemli bir yenilik sunmuş olsa da, yerel komşuluk ilişkilerini yeterince iyi modelleyememesi nedeniyle bazı sınırlamalara sahip olmuştur. PointNet++, bu sorunu çözmek için nokta bulutlarını hiyerarşik seviyelere ayırarak işlemektedir. Bu yöntem, geleneksel CNN'lerin 2B görüntülerde uyguladığı çok ölçekli özellik çıkarma sürecine benzer şekilde, 3B nokta bulutlarında farklı seviyelerde özellik öğrenilmesini mümkün hale getirmektedir.

Bu model, öncelikle nokta bulutlarını küçük gruplara ayırmakta ve her grup için yerel özellikler çıkarmaktadır. Ardından, çıkarılan yerel özellikler daha büyük ölçekli özelliklerle birleştirilerek küresel bir temsil oluşturulmaktadır. Böylece, hem küçük detaylar hem de geniş kapsamlı nesne bilgileri model tarafından öğrenilebilmektedir. Bu yapı, özellikle yoğun nokta bulutlarında ve büyük ölçekli sahnelerde daha hassas segmentasyon ve sınıflandırma yapılmasını sağlamaktadır.

PointNet++'ın bir diğer önemli avantajı, daha karmaşık ve detaylı yüzeylerin daha iyi işlenmesine olanak sağlamasıdır. Özellikle nesne sınırlarının daha hassas bir şekilde ayrılabilmesini ve eğimli yüzeylerin daha doğru şekilde temsil edilebilmesini mümkün kılmaktadır. Ayrıca, giriş verisindeki gürültüye ve eksik noktalara karşı dayanıklılığı artırılarak, gerçek dünya verileriyle daha yüksek performans sergilemesi sağlanmıştır. Bu nedenle, otonom sürüş, robotik, artırılmış gerçeklik ve şehir modelleme gibi birçok uygulama alanında yaygın olarak kullanılmaktadır. PointNet++ ile birlikte, derin öğrenme tabanlı nokta bulutu işleme modelleri daha güçlü ve ölçeklenebilir bir yapıya kavuşmuştur.

PointNet++, PointNet'e kıyasla daha yüksek bir performans sergilemektedir. ModelNet40 veri kümesi üzerinde gerçekleştirilen testlerde, nesne sınıflandırma görevinde %90,7 doğruluk oranına ulaşılmıştır. Nokta normal bilgilerinin, nokta koordinatlarıyla birleştirilmesi durumunda ise doğruluk oranı %91,9'a kadar yükselmektedir. Bu sonuçlar, PointNet++ modelinin daha ayrıntılı ve doğru özellikler öğrenme kapasitesine sahip olduğunu ortaya koymaktadır (Liu vd., 2021).

Ayrıca, modelin Öklid dışı metrik uzayda (yani düzensiz ve karmaşık yüzeylerde) nokta bulutu sınıflandırmasını etkili bir şekilde gerçekleştirebildiği deneysel olarak kanıtlanmıştır. Bunun yanı sıra, farklı nokta yoğunluklarına sahip veri kümelerinde de başarılı sonuçlar elde edilmiştir. Özellikle, bazı bölgelerde yoğun, bazı bölgelerde ise seyrek dağılan nokta bulutlarıyla çalışırken modelin kararlılığını koruyabildiği gösterilmiştir. Bu özellikler sayesinde, PointNet++ büyük ölçekli sahnelerde ve karmaşık nesne şekillerinde daha hassas sonuçlar üretebilen güçlü bir model olarak öne çıkmaktadır (Liu vd., 2021).

2.9.3. Dinamik Grafik Evrişimsel Sinir Ağı

DGESA (Dinamik Grafik Evrişimsel Sinir Ağı), nokta bulutu verilerini işlemek amacıyla geliştirilmiş yenilikçi derin öğrenme modellerinden biridir. PointNet ve PointNet++ gibi önceki yöntemler, nokta bulutlarını doğrudan analiz etme yeteneğine sahip olmakla birlikte, noktalar arasındaki yerel ilişkileri tam anlamıyla yakalayamamıştır. DGESA, bu eksikliği gidermek amacıyla, nokta bulutlarını bir grafik yapısı olarak ele almakta ve noktalar arasındaki bağlantıları dinamik olarak oluşturup güncelleyebilen bir model olarak tasarlanmaktadır.

DGESA'nın en önemli özelliği, EdgeConv adı verilen özel bir evrişim işlemi kullanmasıdır. Bu işlem, her noktanın en yakın komşularıyla arasındaki ilişkileri analiz ederek, daha güçlü yerel ve küresel özelliklerin öğrenilmesini sağlamaktadır. Standart CNN'lerde olduğu gibi sabit bir komşuluk yapısı yerine, DGESA her adımda noktalar arasındaki bağlantıları güncelleyerek değişen veri yapısına dinamik bir şekilde uyum sağlamaktadır. Bu sayede, nesnelerin şekil değişimlerine, ölçek farklılıklarına ve farklı yoğunlukta örneklenmiş nokta bulutlarına karşı daha dayanıklı hâle gelmektedir.


DGESA, nesne sınıflandırma, semantik segmentasyon ve nokta bulutu tabanlı diğer yapay zekâ görevlerinde yüksek başarı sergilemektedir. Özellikle karmaşık 3B nesnelerin analizi, şehir modelleme, robotik ve tıbbi görüntüleme gibi alanlarda sıkça kullanılmaktadır.

Noktalar arasındaki dinamik ilişkilerin modellenenebilmesi, bu modeli daha esnek ve güçlü bir hâle getirerek PointNet ve PointNet++ gibi önceki yöntemlere göre önemli avantajlar sunmaktadır (Liu vd., 2021).

DGESA, nokta bulutu sınıflandırma görevlerinde oldukça başarılı sonuçlar elde etmektedir. ModelNet40 veri kümesi üzerinde yapılan testlerde, %93,5 doğruluk oranına ulaşarak yüksek bir performans sergilemiştir. Ayrıca, parça segmentasyonu görevinde kullanılan ShapeNet veri kümesinde ortalama Kesişim-Üzeri-Birleşim (IoU) skoru %85,2 olarak ölçülmüştür. S3DIS veri kümesi ile yapılan anlamsal segmentasyon testlerinde ise %84,1 genel doğruluk oranı elde edilmiştir. Bu sonuçlar, DGESA'nın nokta bulutları üzerinde detaylı analiz gerçekleştirebildiğini ve farklı 3B görme görevlerinde güçlü bir model olduğunu ortaya koymaktadır (Liu vd., 2021).

3. YAPILAN ÇALIŞMALAR

Hazırlanan doktora tezi kapsamında geliştirilen iş akışı, fotogrametrik (P1) ve LiDAR (L1) verilerinin birleştirilmesiyle elde edilen nokta bulutu verisinin, PPK yöntemiyle dengelenmesinden başlayarak sınıflandırılması, kesitlerle iyileştirilmesi ve ardından Meşçere Boy Modeli'nin (MBM) üretilmesi süreçlerini kapsamaktadır. Elde edilen KYM üzerinden bireysel ağaç segmentasyonu gerçekleştirilmekte ve bu segmentasyon hem nokta bulutu hem de raster tabanlı yöntemlerle iyileştirilmektedir. Son aşamada ise, segmentasyona dayalı olarak meşçere parametre kestirimi (örneğin, ağaç boyu, gövde çapı, hacim) ve ağaç türü tahmini yapılmaktadır. Bu süreçte, regresyon modelleri ve derin öğrenme algoritmaları (PointNet, PointNet++, DGCNN) kullanılmaktadır. İş akışı, orman yapısının detaylı analizine olanak tanıyan entegre bir uzaktan algılama ve yapay zekâ yaklaşımını ortaya koymaktadır (Şekil 14).




Şekil 14. İş akış diyagramı

3.1. Çalışma Alanı ve Kullanılan Veri

3.1.1. Çalışma Alanı

Artvin ili Merkez ilçesi Kafkasör mevkiinde yer alan Atabarı Kayak Merkezi'nin pist alanı içerisinde bulunan ormanlık alan, çalışma alanı olarak belirlenmiştir. Alanın seçiminde, hem ibreli hem de geniş yapraklı ağaç türlerinin bir arada bulunması ile tepe kapallılığı açısından gevşek kapalı (1), orta kapalı (2), tam kapalı (3) alanların yan yana yer alması etkili olmuştur (Şekil 15). Bu özelliklerin bir arada bulunması, elde edilecek sonuçların farklı tepe kapallılığı ve tür çeşitliliği koşullarında değerlendirilmesine olanak sağlayacağından, çalışmanın kapsam ve zenginliği açısından önemli görülmüştür. Çalışma alanı yaklaşık olarak 186.579,44 m² (18,66 ha) büyüklüğündedir.



LKnd1: Ladin-Kayın orta ağaçlık çağı gevşek kapalı (İbrelî-Yapraklı)

LKnd2: Ladin-Kayın orta ağaçlık çağı orta kapalı (İbrelî-Yapraklı)

KnLcd3: Kayın-Ladin ince-orta ağaçlık çağı tam kapalı (Yapraklı-İbrelî)


KnKsab3: Kayın-Kestane sınırlık-direklik çağı tam kapalı (Yapraklı-Yapraklı)

LGbc3: Ladin-Gökmar ince ağaçlık çağı tam kapalı (İbrelî-İbrelî)

Şekil 15. Çalışma alanına ait harita


Çalışma alanının belirlenmesinde bir diğer önemli etken, ormanlık alanın karışık meşçere yapısına sahip olmasıdır. Bu özellik, yapılacak çalışmanın sonuçlarının hem ibrelili hem de geniş yapraklı ağaç türleri üzerinde test edilen yöntem ve metotların uygunluğunu değerlendirmek açısından önemli bir faktör olarak değerlendirilmiştir.

Çalışma alanı, Artvin Orman Bölge Müdürlüğü, Artvin Orman İşletme Müdürlüğü ve Artvin Orman İşletme Şefliği sorumluluğunda bulunan, 1/25.000 ölçekli Artvin F47-c1 paftasında yer alan 100 ve 102 numaralı bölmeler içerisinde konumlanmaktadır. Bu alan içerisinde, LKnd1-2, LKnd2-2, KnLcd3, KnKsab3, LGbc3 meşçere tipleri bulunmaktadır (Şekil 16).




Şekil 16. Çalışma alanına ait Orman Genel Müdürlüğü e-harita uygulaması

Nokta bulutu verileri ile gerçekleştirilen işlemlerde, arazinin eğimi önemli bir etken olarak değerlendirilmektedir. Bu kapsamda, çalışma alanını gösteren Google Earth görüntüsü üzerinden profil çizimi yapılmıştır (Şekil 17).




Şekil 17. Çalışma alanına ait Google Earth profil gösterimi

Çalışma alanına ait en düşük kot seviyesi, deniz seviyesine göre 1785 m, en yüksek kot seviyesi ise 1975 m olarak belirlenmiştir. Bu iki kot değeri ile aralarındaki yatay mesafe dikkate alındığında, çalışma alanının genel eğiminin %35 olduğu tespit edilmiştir (Şekil 18). Ayrıca, aynı alan içerisinde eğim değerinin bazı bölgelerde %40'a kadar ulaştığı da gözlemlenmiştir.



Şekil 18. Çalışma alanının eş yükselti eğrili çizimi

Arazinin topografik yapısı, çalışma alanına ait en düşük kot değeri referans alınarak oluşturulan yüzey üzerinden gösterilmiştir (Şekil 19).



Şekil 19. Çalışma alanı arazi topografik yapısı

Uçuşun gerçekleştirileceği tarihin iklimsel koşullar açısından doğru bir şekilde belirlenmesi büyük önem taşımaktadır. Literatürdeki benzer çalışmalarda, uçuşların genellikle iki ayrı dönemde gerçekleştirildiği görülmektedir: Geniş yapraklı ağaçların yapraklarını döktüğü dönem (yapraksız dönem) ve yapraklarının bulunduğu dönem (yapraklı dönem). Bu yaklaşım, geniş yapraklı türler ile ibreli türlerin birbirinden daha kolay ayırt edilebilmesini sağlamaktadır. Ayrıca, düşük vejetasyon örtüsünün (çalı, ot, yosun) etkisinin azaldığı bu dönemlerde, zemine ait LiDAR noktalarının daha net bir şekilde tespit edilebilmesi mümkün olmaktadır.

İki farklı periyottan elde edilen veriler sayesinde, tür ayrımı ve meşçere yapısının analizinde benzerlikler ve farklılıklar daha kolay ortaya konulabilmektedir. Ancak bu çalışmada, uçuş yalnızca tek bir periyotta, Nisan ayının sonlarında gerçekleştirilmiştir. Bu dönemde, geniş yapraklı türler yapraklanmaya başlamış; ancak düşük vejetasyon örtüsü henüz tam olarak gelişmemiştir. Dolayısıyla, uçuşun gerçekleştirildiği zaman dilimi, kıştan bahara geçiş sürecine denk gelmekte olup, çalışma bu koşullar altında ve tek periyot verisi ile yürütülmüştür (Şekil 20).



Şekil 20. Çalışma alanına ait uçuş anında çekilmiş bir hava fotoğrafı

3.1.2. Veri Seti

Hava LiDAR verisinin elde edilmesinde DJI marka Matrice 350 RTK model insansız hava aracı (İHA) kullanılmıştır (Şekil 21). DJI Matrice 350 RTK ile gerçekleştirilen ilk uçuşta, Zenmuse P1 sensörü kullanılarak fotogrametrik veri toplanmış ve bu uçuşun sonucunda 3.940.272 adet noktadan oluşan bir fotogrametrik nokta bulutu üretilmiştir. Daha sonra, Zenmuse L1 sensörü ile gerçekleştirilen LiDAR uçuşu sonucunda 41.921.116 adet nokta elde edilmiştir. Kullanılan İHA ile P1 ve L1 sensörlerine ait teknik özellikler Tablo 4'te sunulmaktadır.




Şekil 21. DJI Matrice 350 RTK İHA modeli P1 sensörlü (sol), L1 sensörlü (sağ)

Tablo 4. İHA ve sensörlere ait özellikler (URL-3)

Özellik	Matrice 350 RTK	Zenmuse L1	Zenmuse P1
Maksimum Uçuş Süresi	55 dakika	-	-
Koruma Derecesi	IP55	IP44	-
Çalışma Sıcaklığı Aralığı	-20°C ila 50°C	-20°C ila 50°C	0°C ila 40°C
RTK Desteği	Evet	Evet	Evet
Sensör Tipi	-	Livox Lidar Modülü ve RGB Kamera, 20 MP	Full-frame CMOS, 45 MP
Veri Toplama Hızı	-	240.000 nokta/saniye	3 fps (Tam çözünürlükte)
Hassasiyet	-	Dikey: 5 cm, Yatay: 10 cm	Dikey: 3 cm, Yatay: 1 cm
Kapsama Alanı	-	2 km ² (%10 bindirme ile 100 m irtifada)	3 km ² (%80 boyuna, %60 enine bindirme ile 200 m irtifada)
Uygulama Alanları	Endüstriyel Denetimler, Haritalama, Arama-Kurtarma	3D Modelleme, Arazi Haritalama	Yüksek Çözünürlüklü Fotogrametri, Haritalama

Bireysel ağaçları daha iyi temsil edebilmek amacıyla, her iki sensörden elde edilen nokta bulutları birleştirilmiş ve böylece nokta yoğunluğunda artış sağlanmıştır. Uçuşun gerçekleştirildiği alan yaklaşık 186.579,44 m² (18,66 ha) büyüklüğünde olup, toplamda 45.861.388 adet nokta elde edilmiştir (Şekil 22). Bu işlem sonucunda, nokta bulutu yoğunluğu metrekare başına 245,8 nokta olarak belirlenmiştir. Nokta bulutuna ait ortalama nokta aralığı (point spacing) ise 0,063 m olarak hesaplanmıştır.



Şekil 22. Uçuş yapılan alanda elde edilen nokta sayısı (sol) ve bu alana dair sınır (sağ)

P1 ve L1 sensörleri ile gerçekleştirilen uçuşlarda kullanılan İHA RTK özellikli olmasına rağmen, ölçüm anında bu özellik aktif olarak kullanılmamıştır. Bunun yerine, ölçüm sonrası değerlendirme yöntemi olan PPK (Post-Processed Kinematics) yöntemi uygulanmış ve nokta bulutu verilerine GNSS düzeltmeleri ölçüm sonrasında entegre edilmiştir. Düzeltme verisi, uçuş alanına yaklaşık 5-6 km mesafede bulunan ve TUSAGA-AKTİF sistemine bağlı ARTV istasyonundan temin edilmiştir. Uçuşun gerçekleştirildiği gün ve saat aralığına ait 1 saniyelik RINEX verileri kullanılarak düzeltme işlemi gerçekleştirilmiştir. Bu işlem için, P1 sensöründen elde edilen veriler REDtoolbox yazılımı, L1 sensöründen elde edilen veriler ise DJI Terra yazılımı kullanılarak işlenmiştir.


DJI Terra ve REDtoolbox yazılımlarının kullanabilmesi için en önemli sistem gereksinimlerinden biri, NVIDIA grafik kartına ve en az 4 GB VRAM kapasitesine sahip olunmasıdır. Ayrıca, kullanılan bilgisayara ait işletim sistemi, işlemci ve bellek (RAM) özellikleri de işlem sürecini (process) doğrudan etkilemektedir.

L1 sensörü kullanılarak toplanan nokta bulutu verisi için PPK işlemi, DJI Terra yazılımı kullanılarak gerçekleştirilmiştir. Uçuş sonrasında oluşan LiDAR uçuş klasörü içerisinde yer alan RINEX verilerinin bulunduğu RTB uzantılı dosya ile sabit olarak

kullanılan TUSAGA istasyonuna ait gözlem dosyasının konumu değiştirilmiştir. Gözlem dosyasına ait koordinatlar, hassas bir şekilde elde edilen kartezyen koordinatlar kullanılarak sisteme girilmiştir. LiDAR uçuş klasörüne yönelik bu değişikliklerin ardından, DJI Terra yazılımı üzerinden ilgili işlem gerçekleştirilmiştir.


P1 sensörü kullanılarak elde edilen hava fotoğrafları için PPK işlemi, REDToolbox isimli harici bir yazılım kullanılarak gerçekleştirilmiştir. Bu işleme başlamadan önce, çekilen hava fotoğrafları ile birlikte uçuş klasöründe yer alan MRK uzantılı dosya ve obs uzantılı dosyaların yazılıma yüklenmesi gerekmektedir. Daha sonra, sabit olarak kullanılan istasyona ait gözlem ve navigasyon dosyaları yazılıma eklenmiştir. Yüklenen gözlem dosyası üzerinden istasyona ait koordinatlar coğrafi koordinat formatında sistemde görüntülenmiştir. Anten bilgileri kontrol edildikten sonra işlem süreci başlatılmıştır. İşlem tamamlandıktan sonra, düzeltilmiş fotoğraf koordinatları DJI Terra yazılımına yüklenerek işlenmiştir.

Düzeltilme işlemi sonrasında elde edilen sonuçların doğruluğunu kıyaslamak amacıyla, çalışma alanı içerisinde rastgele seçilen 16 adet nokta, CORS-TR sistemi ile uyumlu bir GNSS alıcısı kullanılarak belirlenmiştir. Bu noktalar, sisteme kontrol noktası (check-point) olarak kaydedilmiştir (Şekil 23).



Şekil 23. Elde edilen sonuçların doğruluğunu tespit etmek için atılan noktalar

Kontrol noktaları kullanılarak yapılan değerlendirme sonucunda, P1 sensörü için elde edilen karesel ortalama hata değeri 0,086 m olarak bulunmuştur (Şekil 24). L1 sensörü için hesaplanan karesel ortalama hata değeri ise 0,053 m'dir (Şekil 25).



Şekil 24. P1 uçuşu ile elde edilen karesel ortalama hata

Point Cloud Check Point Error										
Parameters	No. of Check Points	Average Altitude	Average Altitude Difference	Max Altitude Difference	Max Altitude Difference	Average Absolute Value of Altitude Difference	Root Mean Square	Standard Deviation		
Value	16	1833.38825 m	0.04092 m	-0.058026 m	0.081125 m	0.040385 m	0.053307 m	0.055056 m		

Point Cloud Check Point List

ID	Check Point Latitude(V-N)	Check Point Longitude (X-E)	Check Point Altitude (Z-U)	Reconstruction Altitude	Altitude Difference	Max Altitude Difference	Average Altitude Difference	Reconstruction Altitude Standard Deviation	Altitude Difference RMS E	Reflectivity
1	480620.531 m	4556140.944 m	1802.63 m	1802.68615 m	0.052115 m	0.071017 m	0.052115 m	0.000618 m	0.05279 m	63.82
2	480578.009 m	4556126.502 m	1804.08 m	1804.124912 m	0.040912 m	0.069514 m	0.040912 m	0.012974 m	0.048609 m	59.07
3	480523.407 m	4556124.169 m	1808.24 m	1808.3198 m	0.0808 m	0.122277 m	0.0808 m	0.026509 m	0.083275 m	52.76
4	480472.565 m	4556122.774 m	1814.76 m	1814.836125 m	0.081125 m	0.136798 m	0.081125 m	0.033511 m	0.08756 m	43.73
5	480416.062 m	4556118.806 m	1827.93 m	1827.979407 m	0.044407 m	0.139146 m	0.044407 m	0.052633 m	0.067696 m	51.11
6	480356.639 m	4556135.5 m	1845.08 m	1845.08231 m	-0.00149 m	0.08223 m	-0.00149 m	0.048707 m	0.048991 m	42.71
7	480292.699 m	4556150.864 m	1861.21 m	1861.149974 m	-0.058026 m	0.087355 m	-0.058026 m	0.042318 m	0.071409 m	32.37
10	480175.736 m	4556105.35 m	1928.91 m	1928.942437 m	0.034437 m	0.121972 m	0.034437 m	0.049506 m	0.059415 m	47.91
21	480246.986 m	4556140.869 m	1871.49 m	1871.529939 m	0.042939 m	0.134272 m	0.042939 m	0.047919 m	0.063936 m	43.25
22	480289.127 m	4556119.398 m	1859.83 m	1859.829858 m	0.000858 m	0.041027 m	0.000858 m	0.02149 m	0.02123 m	33.9
24	480334.625 m	4556119.204 m	1849.13 m	1849.17345 m	0.04145 m	0.111298 m	0.04145 m	0.040937 m	0.057806 m	45.56
25	480409.63 m	4556104.134 m	1829.86 m	1829.929136 m	0.065136 m	0.161521 m	0.065136 m	0.046356 m	0.079447 m	47.74
26	480404.756 m	4556109.823 m	1817.52 m	1817.58308 m	0.06488 m	0.123506 m	0.06488 m	0.034463 m	0.073325 m	49.14
27	480492.358 m	4556117.219 m	1812.02 m	1812.086256 m	0.066256 m	0.123837 m	0.066256 m	0.031736 m	0.07319 m	45.56
28	480555.948 m	4556110.717 m	1805.75 m	1805.801827 m	0.055827 m	0.08618 m	0.055827 m	0.017707 m	0.058469 m	56.07
29	480596.308 m	4556125.757 m	1803.65 m	1803.6833 m	0.0373 m	0.066427 m	0.0373 m	0.014215 m	0.039833 m	55.87


Şekil 25. L1 uçuşu ile elde edilen karesel ortalama hata

Yer Kontrol Noktaları (YKN) kullanılmadan gerçekleştirilen bu işlemlerde, hem P1 hem de L1 sensörleri için elde edilen karesel ortalama hata değerlerinin tarım, ormancılık gibi çalışmalar için yeterli doğruluk seviyesine (≤ 10 cm) ulaştığı görülmüştür (Türk ve Öcalan, 2020).

Çalışma alanının topoğrafik olarak oldukça eğimli bir yapıya sahip olması nedeniyle, ilk uçuş, kalkış noktasına göre yaklaşık 350 metre daha yüksek bir irtifada gerçekleştirilmiştir. P1 sensörü ile yapılan ilk uçuş, genel olarak çalışma alanını kapsayacak şekilde planlanmış ve %80 boyuna bindirme ile %60 enine bindirme oranlarına sahip dört uçuş hattı (kolon) kullanılarak gerçekleştirilmiştir.

Ardından, aynı uçuş yüksekliğinde, L1 sensörü kullanılarak %70 boyuna ve %50 enine bindirme (L1 sensörü aynı zamanda fotoğraf da çektiği için oranlar bu şekildedir) oranlarına sahip üç kolon kullanılarak ikinci bir uçuş yapılmıştır. Ancak, istenilen nokta yoğunluğu elde edilemediği için çalışma alanı, iki blok halinde farklı yüksekliklerden gerçekleştirilen uçuşlarla tamamlanmıştır.


Nokta bulutu yoğunluğunu arttırmak amacıyla, bu kez yalnızca DJI Zenmuse L1 LİDAR sensörü kullanılarak çalışma alanı iki ayrı blok ve her blokta iki uçuş hattı (kolon) olacak şekilde planlanmış ve ilave uçuşlar gerçekleştirilmiştir. Bu uçuşlar, aynı bindirme oranları korunarak (%70 boyuna, %50 enine) ancak farklı yüksekliklerden yapılmıştır. Birinci blok 50 metre, ikinci blok ise 150 metre uçuş yüksekliğinde planlanmıştır (Şekil 26).



Şekil 26. İki blok halinde ve farklı yüksekliklerden gerçekleştirilen uçuşlar

Uçuş yüksekliği 50 metre olan birinci blok uçuşu ile 150 metre olan ikinci blok uçuşu arasındaki nokta yoğunlukları karşılaştırılmıştır (Şekil 27). Bu yaklaşım ile hem düşük hem

de orta irtifa verileri kullanılarak alanın daha yoğun ve detaylı bir şekilde modellenmesi amaçlanmıştır.




Şekil 27. İki farklı yükseklikten elde edilen nokta yoğunlukları

3.2. Sınıflandırma (Classification)

Nokta bulutunun doğru bir şekilde sınıflandırılması, bireysel ağaç segmentasyonu işleminin başarısını doğrudan etkilediğinden, sınıflandırma aşaması bu çalışmanın en kritik adımlarından biri olarak değerlendirilmiştir. Uçuşlar sonrasında elde edilen ham nokta bulutu, öncelikle dengeleme işlemleriyle koordinatlı hale getirilmiş akabinde sınıflandırma aşamasına geçilmiştir.


Sınıflandırma işlemi, Trimble Business Center (TBC) yazılımı kullanılarak otomatik olarak gerçekleştirilmiş ve American Society for Photogrammetry and Remote Sensing (ASPRS) standartlarına göre belirlenen üç ana sınıf (2-Ground, 5-High Vegetation, 6-Building) üzerinde yoğunlaşmıştır (Şekil 28).




Şekil 28. Nokta bulutunun otomatik sınıflandırılması

TBC yazılımı, zemin noktalarını ayırt etmek amacıyla TIN tabanlı modelleme ve eğim analizine dayalı bir yaklaşım benimsemiş, yoğunluk ve kümeleme analizlerini kullanarak nesneleri geometrik yapılarına göre sınıflandırmıştır. Ayrıca, yazılım güncel sürümlerinde makine öğrenmesi temelli sınıflandırma algoritmaları da kullanılmaktadır.


Çalışma alanının yüksek eğim değerine sahip olması nedeniyle sınıflandırma hata payını azaltmak amacıyla, TBC yazılımı içerisinde yer alan kesit (section) analizleri kullanılarak iyileştirme çalışmaları yapılmıştır. Çalışma alanı boyunca 5 metre aralıklarla alınan kesitler üzerinde elle (manuel) düzeltmeler gerçekleştirilmiş ve böylece zemin (2-ground), yüksek bitki örtüsü (5-high vegetation) ve bina (6-building) sınıflarına ait noktaların daha doğru sınıflandırılması sağlanmıştır (Şekil 29-30-31).



Şekil 29. Çalışma alanına ait zemin (2-ground) noktalarının kesit görünümü



Şekil 30. Çalışma alanına ait yüksek bitki örtüsü (5-high vegetation) noktalarının kesit görünümü



Şekil 31. Çalışma alanına ait bina (6-building) noktalarının kesit görünümü


Özellikle zemin (2-Ground) ile düşük (3-Low Vegetation) ve orta (4-Medium Vegetation) yükseklikteki bitki örtüsü sınıfları arasında yükseklik tabanlı ayırım yapılması sürecinde önemli zorluklar yaşanmıştır. Sınıf geçiş hassasiyetinin artırılabilmesi amacıyla, çalışma alanı boyunca alınan 5 metre genişliğinde kesitler üzerinde gerçekleştirilen manuel kontroller ile sınıflandırma doğruluğu önemli ölçüde iyileştirilmiştir.

Her bir kesitte, otomatik sınıflandırma sırasında yanlış etiketlenen aykırı (outlier) noktalar görsel olarak incelenmiş ve doğru sınıflarına manuel olarak yeniden atanmıştır. Bu manuel müdahale süreci, sınıflandırma sonrasında otomatik sınıflandırmada kullanılan algoritmaların ayırt edemediği hataların düzeltilmesi amacıyla uygulanmıştır. Özellikle LiDAR ışınının diri örtü altına yeterli düzeyde nüfuz edememesi nedeniyle, düşük bitki örtüsüne ait noktaların zemin (ground) sınıfı olarak yanlış etiketlenmesi sonucu ortaya çıkan sınıflandırma hatalarının giderilmesine yönelik iyileştirmeler gerçekleştirilmiştir.

3B nokta bulutu üzerinde gerçekleştirilen interaktif düzeltmeler sonucunda, kural tabanlı otomatik filtreleme ile doğru şekilde sınıflandırılmayan noktalar, kesitler üzerinden yapılan manuel müdahalelerle düzeltilmiş ve böylece sınıflandırma doğruluğu önemli ölçüde artırılmıştır.

Bu iyileştirme sürecine örnek olarak, çalışma alanı içerisinde yer alan teleseyej yapısına ait noktalar gösterilebilir. Telesiyej tellerine karşılık gelen noktalar (14-Wire/Conductor), kesit analizleri yardımıyla daha doğru şekilde ayrılmış ve bu iyileştirme,

sınıflandırma öncesi ve sonrası elde edilen görsellerde açık bir şekilde gözlemlenmiştir (Şekil 32).




Şekil 32. Çalışma alanında bulunan Telesiyeje (14-Wire-Conductor) ait sınıflandırmanın kesitler yardımıyla yapılan iyileştirme öncesi (sol) ve sonrası (sağ)


Bu işlemler sonucunda elde edilen sınıflara ait sayısal bilgiler Tablo 5’te sunulmuştur. Ayrıca, iyileştirme sonrasında oluşan Zemin (2-Ground), Yüksek Bitki Örtüsü (5-High Vegetation) ve Bina (6-Building) sınıflarına ait görsel örnekler de ilgili şekillerde verilmiştir (Şekil 33-34-35).

Tablo 5. Sınıflandırma işlemi sonrası elde edilen sınıflar ve nokta sayıları


ASPRS Kodu	Sınıf	Nokta Sayısı
2	Zemin (Ground)	22.638.550
5	Yüksek Bitki Örtüsü (High Vegetation)	20.223.774
6	Bina (Building)	7.783
7	Gürültü veya Geçersiz Noktalar (Noise)	1.694
3-4	Düşük ve Orta Yükseklikteki Bitki Örtüsü (Low and Medium Vegetation)	2.977.695
0	Sınıflandırılmamış (Unclassified)	6.063
14	Tel-İletken Tel(Wire-Conductor)	5.829
Toplam:		45.861.388



Şekil 33. Çalışma alanına ait zemin (2-Ground) noktalarının genel görünümü




Şekil 34. Çalışma alanına ait yüksek bitki örtüsü (5-High Vegetation) noktalarının genel görünümü




Şekil 35. Çalışma alanına ait bina (6-Building) noktalarının genel görünümü

Zemin ve yüksek bitki örtüsü sınıfına ait noktaların yarı otomatik bir yöntemle sınıflandırıldığı bu aşama, diğer sınıflandırma yöntemleriyle karşılaştırılmak üzere çalışma alanından alınan iki farklı kesit üzerinde gösterilmiştir. Söz konusu kesitler, arazinin topografik yapısı ile noktalara ait yükseklik dağılımları gösterilmiştir (Şekil 36).



Şekil 36. Çalışma alanından alınan iki farklı kesit

R programlama dili kullanılarak, daha önce sınıflandırılmış olan bu veri seti, ASPRS tarafından belirlenen sınıf kodlarına göre yeniden düzenlenmiş ve aynı kesitler üzerinde görsel olarak sunulmuştur (Şekil 37).




Şekil 37. TBC yazılımı ile yarı otomatik şekilde yapılan sınıflandırmaya ait kesitler

R programlama dili kullanılarak, lidR kütüphanesi aracılığıyla zemin sınıflandırma işlemi için iki farklı algoritmanın karşılaştırması gerçekleştirilmiştir. İlk yöntem olan İlerlemeli Morfolojik Filtre (Progressive Morphological Filter - PMF) algoritması için, parametre değerlerinden biri olan hareketli pencere boyutu ($ws=c(3, 6, 12, 18)$) ve bir diğeri olan yükseklik eşiği ($th=c(0,4, 0,5, 0,6, 0,6)$) olarak seçilmiştir. Bu parametre seçimleri ile aynı nokta bulutu dört farklı konfigürasyon altında analiz edilmiş ve işlem süresi yaklaşık otuz (30) saat sürmüştür.

PMF algoritmasında, belirlenen pencere boyutu içerisindeki noktalar arasında ölçülen yükseklik farkı belirlenen eşik değerinin altında ise bu noktalar zemin; eşik değerinin üstünde ise zemin dışı nokta olarak sınıflandırılmaktadır. Parametreler belirlenirken, çalışma alanının yüksek eğimli ve ormanlık arazi yapısına sahip olması dikkate alınmıştır. Sınıflandırma işlemi sonucunda, zemine ait nokta sayısı 17.407.715, zemin üstü nesnelere ait nokta sayısı ise 28.453.673 olarak belirlenmiştir.


Çalışmada kullanılan veri, daha önce sınıflandırılmamış bir veri olduğundan, sınıflandırma işleminde lejant üzerinde algoritma tarafından otomatik olarak atanan değerler (1 ve 2) kullanılmıştır. Bu değerlerden 1, bitki örtüsünü; 2 ise zemini temsil etmektedir. Sınıflandırma sonuçları, çalışma alanından alınan aynı kesitler üzerinden görsel olarak sunulmuştur (Şekil 38).



Şekil 38. PMF algoritması ile elde edilen sınıflandırmaya ait kesitler

Zemin sınıflandırması için kullanılan ikinci algoritma, Kumaş Simülasyon Filtre (Cloth Simulation Filter - CSF) algoritması olmuştur. Bu algoritmanın uygulanmasında seçilen parametreler, çalışma alanının yüksek eğimli ve ormanlık arazi yapısı dikkate alınarak belirlenmiştir. (sloop_smoth=true, class_threshold=1, cloth_resolution=0.75, rigidness=2, time_step=0.65). CSF algoritmasının uygulanması, PMF algoritmasına kıyasla çok daha kısa süre içinde tamamlanmıştır. Sınıflandırma sonucunda, zemine ait nokta sayısı 14.323.021, zemine ait olmayan nokta sayısı ise 31.538.367 olarak belirlenmiştir.

Çalışma alanından alınan aynı kesitler, CSF algoritması için de uygulanmış ve elde edilen sonuçlar kesitler üzerinden görselleştirilmiştir (Şekil 39). Kullanılan veri daha önce sınıflandırılmamış olduğundan, lejant kısmındaki sınıf değerleri R programı tarafından otomatik olarak atanmıştır.



Şekil 39. CSF algoritması ile elde edilen sınıflandırmaya ait kesitler

Zemin ve bitki örtüsü ayrımını doğru bir şekilde gerçekleştirmek, sınıflandırma işleminin en zorlu aşamalarından birini oluşturmaktadır. Bu kapsamda, TBC yazılımı kullanılarak yarı otomatik yöntemle elde edilen sınıflandırma sonuçları ile R programlama dili aracılığıyla elde edilen sonuçlar karşılaştırılmıştır. Karşılaştırmanın sağlıklı şekilde yapılabilmesi amacıyla, her üç yöntem için de aynı kesitler kullanılmıştır. Kullanılan yöntemlerle elde edilen sonuçlar incelendiğinde, zemin sınıflandırmasında belirgin farklılıkları ortaya çıktığı görülmektedir. Zemine ait ve zemin dışı noktaların tespiti için uygulanan farklı yöntemlerden elde edilen sayısal sonuçlar ise Tablo 6'da sunulmuştur.

Tablo 6. Zemin ve zemin dışı noktaların tespiti için kullanılan yöntem ve sonuçları

Yöntem	Zemine ait nokta sayısı	Zemin dışı nokta sayısı
TBC – yarı otomatik	22.638.550 - (%49)	23.222.838 – (%51)
PMF	17.407.715 – (%38)	28.453.673 – (%62)
CSF	14.323.021 – (%31)	31.538.367 – (%69)

Kesit analizlerinden elde edilen bulgulara göre, TBC yazılımı kullanılarak gerçekleştirilen yarı otomatik sınıflandırmanın, zemin ve zemin üstü noktaları daha homojen bir dağılımla ayırt edebildiği belirlenmiştir. Öte yandan, PMF ve CSF algoritmaları kullanılarak elde edilen sınıflara ait kesitler incelendiğinde, zemin ve zemin üstü noktalar arasında belirgin bir karışıklık olduğu gözlemlenmiştir. Bu durum, uygulanan filtreleme algoritmalarına ait parametre seçimlerinin ve kullanılan teknik yaklaşımların sınıflandırma sonuçları üzerinde doğrudan etkili olduğunu ortaya koymaktadır. Bu nedenle, zemin sınıfına ait noktaların daha güvenilir şekilde belirlenmesi amacıyla ek düzeltme ve iyileştirme çalışmaları yapılmıştır.

Yapılan değerlendirmeler sonucunda, zemin ayırımında daha başarılı sonuçlar üreten TBC yazılımı ile elde edilen yarı otomatik sınıflandırma yöntemi tercih edilmiştir. Bu sınıflandırmaya dayanarak, Sayısal Arazi Modeli (SAM) ve Sayısal Yüzey Modeli (SYM) üretilcek; bu iki model arasındaki fark alınarak Meşçere Boy Modeli (MBM) oluşturulacaktır. MBM'nin doğruluk düzeyi, bireysel ağaç segmentasyonu ve meşçere bileşenlerinin kestirimi gibi ileri analizlerin doğruluk düzeyini doğrudan etkileyecektir. Bu nedenle, sınıflandırma aşamasında sağlanan yüksek doğruluk, analiz sürecinin tüm aşamalarında güvenilir sonuçlar elde edilmesi açısından kritik öneme sahiptir.

3.3. Meşçere Boy Modeli (Canopy Height Model)

Meşçere Boy Modeli (MBM) oluşturmadan önce, sınıflandırılmış nokta bulutunun incelenmesi sonucunda, ağaçları temsil eden noktaların yoğunluğu ve temsil gücünün uçuşlar arasında tutarsız gösterdiği tespit edilmiştir. Bu durumun temel nedeni, çalışma alanının eğimli topografik yapısı nedeniyle üç farklı yükseklikten uçuş yapılmak zorunda kalınmasıdır.

Yapılan ilk uçuşta elde edilen nokta bulutu, ağaçların taç yapısını daha iyi temsil edecek yoğunlukta veriler sunarken, diğer uçuşlarda bu kalite düzeyine ulaşamamıştır. Bu nedenle, ağaç morfolojisinin daha doğru ve ayrıntılı şekilde analiz edilebilmesi amacıyla, çalışma alanı daraltılmış ve daha yüksek nokta yoğunluğuna sahip bir bölge seçilerek analizler bu alan üzerinde yoğunlaştırılmıştır.


Sadece iki sınıfa ait noktaların olduğu bu veri setinde, zemin (ground) sınıfına ait nokta sayısı 20.952.536, yüksek bitki örtüsü (high vegetation) sınıfına ait nokta sayısı ise 18.817.306 olarak belirlenmiştir. Toplamda 39.769.842 adet noktanın, 149.622,20 m² (14,96

ha) alanı kapladığı, bu durumda metrekare başına yaklaşık 265,8 nokta düştüğü ve noktalar arasındaki ortalama boşluğun 0,063 m olduğu hesaplanmıştır (Şekil 40).



Şekil 40. Çalışma alanının yeni sınırı ve iki sınıfa ait noktaların dağılımı

Kapalılık, ağaçların taç yapraklarının oluşturduğu zemini örtme derecesini ifade etmektedir. Meşçere Boy Modeli (MBM) ise ağaç boyunun hesaplanması, bireysel ağaç tespiti ve biyokütle tahmini gibi birçok uygulamada kullanılan önemli bir modeldir. MBM, Sayısal Arazi Modeli (Digital Terrain Model) ile Sayısal Yüzel Modeli (Digital Surface Model) arasındaki farkın alınması yoluyla elde edilmektedir (Şekil 41).




Şekil 41. Meşçere boy modeli (URL-4)

Meşçere bileşenlerinden biri olan ağaç boyu, Meşçere Boy Modeli'nin (MBM) doğruluğu ve hassasiyeti ile doğrudan ilişkilidir (Hao vd., 2022). Ağaç boyunun belirlenebilmesi için kullanılan MBM, hem nokta (vektör) tabanlı hem de raster tabanlı olarak üretilmiş ve elde edilen sonuçlar, yersel ölçümlerle elde edilen referans veriler ile karşılaştırılmıştır.


3.3.1. Nokta Bulutu Tabanlı Meşçere Boy Modeli

Meşçere Boy Modeli'nin (MBM) oluşturulması için Sayısal Arazi Modeli (SAM) ve Sayısal Yüzey Modeli (SYM) nokta verileri kullanılmıştır. Bu süreçte, sınıflandırma işlemi sonucunda elde edilen zemine ait (ground) ve zemine ait olmayan, yüksek bitki örtüsüne karşılık gelen (high vegetation) noktalar kullanılarak analiz gerçekleştirilmiştir (Şekil 42).




Şekil 42. Zemin noktalarının (sol) ve zemine ait olmayan noktaların (sağ) görünümü

Meşçere Boy Modeli'ni nokta tabanlı olarak hesaplayabilmek amacıyla, zemine ait noktalar kullanılarak bir ağ (mesh) model oluşturulmuştur (Şekil 43). Bu işlem, açık kaynak kodlu bir yazılım olan Cloud Compare kullanılarak gerçekleştirilmiştir. Yüzeye ait modelin daha düzgün ve doğru bir şekilde oluşturulabilmesi için, noktalar ait normal (düzleme dik olan vektör) değerleri hesaplanmıştır. Zemine ait noktalar arasındaki ortalama boşluk 0,05 m olmasına rağmen, ağaçların yoğun olduğu bölgelerde LiDAR sinyalinin zemine kadar penetre edemediği alanlar bulunmuştur. Bu nedenle, oluşturulan mesh modelde boşlukların oluşmaması ve gereksiz üçgenlerin üretilmemesi amacıyla, maksimum üçgen kenarı uzunluğu 15 m olarak belirlenmiştir.




Şekil 43. Zeminine ait nokta bulutu kullanılarak elde edilen ağ (mesh) model

Cloud Compare yazılımı kullanılarak, Cloud to Mesh (C2M) işlemi ile Sayısal Yüzey Modeli'ni (SYM) temsil eden zemin üstü noktaların, Sayısal Arazi Modeli'ni (SAM) temsil eden zemine ait noktalardan oluşturulan ağ (mesh) modele olan uzaklıkları hesaplanmıştır (Şekil 44).



Şekil 44. Zeminin ağ (mesh) modeli ile zemin üstü noktaların beraber görünümü


Bu hesaplama, her noktanın en yakın üçgen yüzey modeline olan Öklid uzaklığına dayanarak gerçekleştirilmiştir. Bu yöntemle, nokta tabanlı Meşçere Boy Modeli (MBM) elde edilmiştir (Şekil 45). C2M yöntemiyle elde edilen sonuç incelendiğinde, çalışma alanında ölçülen en yüksek ağacın boyunun 37,705 m olduğu belirlenmiştir.



Şekil 45. C2M yöntemiyle elde edilen MBM

Meşçere Boy Modeli'nin (MBM) doğruluğu, doğrudan zemin noktalarının sınıflandırılmasındaki başarıyla ilişkilidir. Özellikle, düşük bitki örtüsü sınıfına ait noktalar ile zemin sınıfına ait noktaların doğru bir şekilde ayrılması büyük önem taşımaktadır. Aksi takdirde, Sayısal Arazi Modeli'ni (SAM) temsil eden mesh modelin doğruluğu bozulacak ve buna bağlı olarak hesaplanan Meşçere Boy Modeli'nde hatalar meydana gelecektir.

Ağaç boylarının doğruluğunu doğrudan etkileyen bu süreç, sınıflandırma işleminin önemini bir kez daha ortaya koymuştur. Meşçere Boy Modeli (MBM) ve mesh modelin, çalışma alanına ait cepheden görünümü üzerinden ağaç boylarının dağılımı görsel olarak sunulmuştur (Şekil 46).




Şekil 46. Çalışma alanına ait ağaç boylarının dağılımı

Nokta bulutu tabanlı Meşçere Boy Modeli (MBM) üretimi, R programlama dili ve lidR kütüphanesi kullanılarak da gerçekleştirilebilmektedir. Bu süreçte, yükseklik normalizasyonu (height normalization) olarak bilinen bu işlem uygulanmaktadır. Yükseklik normalizasyonu için iki farklı yöntem tercih edilmektedir. İlk yöntemde, nokta bulutu verisinden zemine ait raster veri çıkarılarak yükseklik normalizasyonu sağlanmaktadır. İkinci yöntemde ise, *normalize_height* fonksiyonu kullanılarak nokta bulutu içerisindeki zemin noktaları baz alınmakta ve yükseklik normalizasyonu doğrudan nokta düzeyinde gerçekleştirilmektedir.


Zemine ait olmayan noktaların, zemine ait raster veriden çıkarması sürecinde, piksellerin konumları ile zemin noktalarının konumları tam olarak örtüşmemektedir. Aynı piksele denk gelen birden fazla zemin noktasının bulunması nedeniyle, zemin yükseklikleri arasında farklılıklar oluşabilmektedir. Normalizasyon işleminde kullanılan raster veri, her hücreye ait farklı yükseklik değerleri nedeniyle kesintili bir yüzey oluşturmaktadır. Raster verinin bu kesintili yapısı, çıkarma işlemi sırasında hata oluşma riskini artırmaktadır.

Buna karşılık, *normalize_height* fonksiyonunda raster verinin kesintili yapısı kullanılmamakta; doğrudan noktalar arasında mekânsal enterpolasyon işlemi gerçekleştirilerek normalizasyon sağlanmaktadır. Enterpolasyon işlemi için iki farklı yöntem uygulanmıştır: Ters Mesafa Ağırlıklı (Inverse Distance Weighting-IDW) ve Düzensiz Üçgen Ağ (Triangulated Irregular Network-TIN) yöntemi.

Nokta bulutu verisinden elde edilen zemine ait noktaların, IDW enterpolasyonu ile oluşturulan raster veriden çıkarılması sonucunda elde edilen yükseklik normalizasyonunda, en yüksek nokta 38,312 m olarak belirlenmiştir. Diğer enterpolasyon yöntemi olan TIN kullanılarak yapılan normalizasyon sonucunda ise en yüksek nokta 37,674 m olarak bulunmuştur. Elde edilen normalizasyon sonuçlarına göre, noktalara ait yükseklik dağılımı ve zemine ait noktaların yükseklik değerlerini gösteren grafikler Şekil 47 ve Şekil 48’de verilmiştir.




Şekil 47. Nokta bulutu verisinden raster verinin farkı alınarak elde edilen normalizasyon (IDW) ve zemine ait noktaların yükseklik grafiği




Şekil 48. Nokta bulutu verisinden raster verinin farkı alınarak elde edilen normalizasyon (TIN) ve zemine ait noktaların yükseklik grafiği

R programlama dilinde bulunan lidR kütüphanesindeki *normalize_height* fonksiyonu kullanılarak gerçekleştirilen IDW enterpolasyonu ile elde edilen en yüksek boy değeri 38,337 m, TIN enterpolasyonu ile elde edilen en yüksek boy değeri ise 37,705 m olarak belirlenmiştir.

Normalizasyon işleminden sonra, nokta bulutuna ait boy dağılımı ve zemin noktalarının yükseklik değerlerini gösteren grafikler Şekil 49 ve Şekil 50’de verilmiştir.




Şekil 49. IDW enterpolasyon yöntemiyle elde edilen normalizasyon ve zemin noktalarının yüksekliğine ait grafik



Şekil 50. TIN enterpolasyon yöntemiyle elde edilen normalizasyon ve zemin noktalarının yüksekliğine ait grafik

Yükseklik normalizasyonu işlemi öncesi ve sonrasında, çalışma alanına ait bir kesit üzerinden noktalara ait yükseklik değerleri ile sınıflandırma sonucu elde edilen noktalar görsel olarak sunulmuştur (Şekil 51).



Şekil 51. Çalışma alanına ait yükseklik normalizasyon öncesi (sol) ve sonrası (sağ) kesitler

3.3.2. Raster Tabanlı Meşçere Boy Modeli

Meşçere Boy Modeli'ni (MBM) elde etmenin bir diğer yöntemi, raster verilerle çalışmaktır. Bu yöntemde, Sayısal Yüzey Modeli'ni (SYM) ve Sayısal Arazi Modeli'ni (SAM) temsil eden noktalar, düzenli bir grid yapısına sahip olan raster veri formatına dönüştürülmekte ve bu iki raster veri arasındaki fark alınarak MBM üretilmektedir.

Meşçere Boy Modeli'ni raster veri yapısında elde edebilmek için, SYM ve SAM verilerinin aynı grid yapısında, yani aynı çözünürlükte olması gerekmektedir. Bu doğrultuda, SYM ve SAM verilerini oluşturan noktaların arasındaki boşluk dikkate alınarak her iki veri seti için 0,3 m grid aralığı (çözünürlük) kullanılmıştır. SYM verisi oluşturulurken ilk dönen (first return) noktalar, SAM verisi oluşturulurken ise zemin (ground) noktalar kullanılmıştır.


SYM verisi raster veri yapısında elde edilirken, belirlenen grid aralığında kalan noktalar arasında yükseklik değeri en fazla olan nokta ilgili hücreyi (pikseli) temsil etmektedir. SAM verisi oluşturulurken ise, zemine ait noktalar arasında yükseklik değeri en düşük olan değer ilgili hücreye atanmıştır. Grid yapısında boş kalan hücrelerin doldurulması amacıyla iki farklı enterpolasyon yöntemi kullanılmıştır: Düzensiz Üçgen Ağ (TIN) ve Ters Mesafe Ağırlıklandırma (IDW). SYM verisinden her iki yöntemle elde edilen SAM verileri çıkarılarak raster tabanlı MBM üretilmiştir. İki yöntem kullanılarak oluşturulan MBM sonuçları arasındaki benzerlikler ve farklılıklar da tespit edilmiştir.

Jupyter Notebook ortamında, Python programlama dili ve WhiteboxTools kütüphanesi kullanılarak LiDAR verilerinden Sayısal Arazi Modeli (SAM), Sayısal Yüzey Modeli (SYM) ve Meşçere Boy Modeli (MBM) raster formatında üretilmiştir.

IDW enterpolasyon yönteminde, bilinmeyen noktaların değeri, çevresindeki sabit sayıda bilinen nokta kullanılarak veya belirli bir arama yarıçapı içerisindeki noktalar dikkate


alınarak tahmin edilmektedir. IDW yöntemi, bilinmeyen bir noktadaki değeri tahmin ederken, çevresindeki bilinen noktalara uzaklıklarının ters orantılı bir fonksiyonu üzerinden ağırlık atayan bir matematiksel modele dayanmaktadır (Lu vd., 2008). Yakın noktalar daha yüksek ağırlık alırken, uzak noktaların etkisi azalmaktadır. IDW fonksiyonunda kullanılan ağırlık (weight) parametresi, aynı zamanda güç (power, p) parametresi olarak da adlandırılmakta olup, uzaklığın etkisinin ne ölçüde azaltılacağını belirlemektedir. Bu çalışmada, IDW fonksiyonu için arama yarıçapı (r) 2,5 piksel ve güç parametresi (p) 1,0 olarak belirlenmiştir.

TIN enterpolasyon yöntemi, bir ızgaralama yöntemidir. Izgaralama, her piksel konumuna bir değer atama süreci olup, bu değerler tüm noktaların minimum, maksimum, ortalama ya da belirli bir matematiksel fonksiyonuna göre belirlenebilmektedir. TIN modelleri, türetilen noktaların (köşeleri) bir kenar ağı ile birleştirmesi yoluyla oluşturulan düzensiz üçgen ağlardan meydana gelmektedir. Bu çalışmada, oluşturulan üçgenlerin boyutunu kontrol etmek ve gereksiz üçgenlerin oluşumunu önlemek amacıyla, kullanılan en uzun üçgen kenarı uzunluğu 5 m olarak sınıflandırılmıştır. SAM verileri, her iki enterpolasyon yöntemi (IDW ve TIN) kullanılarak 0,3 m çözünürlükte üretilmiş ve sonuçlar Şekil 57’de sunulmuştur (Şekil 52).




Şekil 52. IDW (sol) ve TIN (sağ) ile elde edilen SAM verileri

SYM verisinin üretiminde kullanılan WhiteboxTools kütüphanesi, doğrudan bir enterpolasyon yöntemi tanımlamamakta; bunun yerine TIN tabanlı üçgenleme yaklaşımını kullanarak veri üretimi gerçekleştirmektedir (Şekil 53).




Şekil 53. Çalışma alanına ait elde edilen SYM verisi

MBM'nin klasik tanımına dayanılarak, elde edilen SYM verisinden SAM verileri çıkartılmış ve bu yöntemle çalışma alanına ait MBM'ler üretilmiştir (Şekil 54).



Şekil 54. IDW (sol) ve TIN (sağ) ile elde edilen MBM'ler

IDW ve TIN enterpolasyon yöntemleri kullanılarak elde edilen MBM verilerinin farkı alınarak, bu iki yöntem arasındaki benzerliklerin ve farklılıkların görsel olarak değerlendirilmesi sağlanmıştır (Şekil 55).




Şekil 55. İki farklı enterpolasyon yöntemi ile elde edilen MBM’ler arasındaki benzerlik ve farklar

Enterpolasyon yöntemleri arasındaki farklar incelendiğinde, boy değerinin sürekliliğini kaybettiği bölgelerde bu farkların daha belirgin hale geldiği görülmektedir. Özellikle yol kenarı gibi boy değerlerinin aniden değiştiği alanlarda, elde edilen verilerdeki renk farklılıkları dikkat çekmektedir. Bu farklılıklar, kullanılan yöntemlere ait matematiksel yaklaşımların doğal bir sonucu olarak değerlendirilmektedir. Çalışma alanının geneline bakıldığında ise, fark skalasında en düşük farkı temsil eden renk tonlarının daha yoğun olduğu gözlemlenmektedir. Bu benzerlik ve farklılıkların bireysel ağaç segmentasyonu üzerindeki etkileri, ilerleyen bölümlerde ayrıntılı olarak ele alınacaktır.


Raster veri tabanlı Meşçere Boy Modeli (MBM) üretmek için kullanılan bir diğer yöntem ise, R programlama dilinde yer alan *lidR* kütüphanesindeki *rasterize* fonksiyonuna ait algoritmaların uygulanmasıdır. Sayısal Arazi Modeli (SAM) üretiminde *knnidw* ve TIN algoritmaları, Sayısal Yüzey Modeli (SYM) üretiminde ise *p2r* ve *pitfree* algoritmaları kullanılmaktadır. Bu algoritmalarla üretilen SYM ve SAM verileri arasındaki fark alınarak, raster tabanlı MBM elde edilmektedir.

SAM üretiminde kullanılan *knnidw* algoritması, enterpolasyon sürecinde Ters Mesafe Ağırlıklandırması (IDW) ve k-En Yakın Komşu (KNN) yöntemlerini birlikte kullanmaktadır. Diğer bir algoritma olan TIN ise, yüzey oluşturma işlemini Delaunay üçgenlemesine dayalı olarak gerçekleştirmektedir. Bu algoritmalar için tanımlanan başlangıç parametreleri kullanılarak SAM verileri üretilmiş ve sonuçlar Şekil 56’da sunulmuştur.



Şekil 56. KNNIDW (sol) ve TIN (sağ) algoritmaları ile elde edilen SAM verileri


SYM üretiminde kullanılan *p2r* (*point-to-raster*) algoritması, belirlenen çözünürlüğe göre oluşturulan grid hücrelerine düşen noktalar arasından en yüksek yükseklik değerini seçerek veri üretmektedir. *Pit-free* algoritması ise, Delaunay üçgenlemesi yöntemiyle yüzey oluşturmakta ve bu yüzeyde ilk dönüş yaptığı noktaları dikkate alarak boşluk bırakmadan veri üretimini gerçekleştirmektedir. Bu algoritmalara ait başlangıç parametreleri kullanılarak SYM verileri üretilmiş ve sonuçlar Şekil 57’de sunulmuştur.



Şekil 57. *p2r* (sol) ve *pit-free* (sağ) algoritmaları ile elde edilen SYM verileri

SYM verisi üretilirken, *p2r* algoritması kullanıldığında çözünürlüğe bağlı olarak oluşan boşluklar, IDW enterpolasyon yöntemi ile doldurulmuştur. Benzer şekilde, *pit-free* algoritması kullanılarak üretilen veride oluşan boşluklar ise TIN enterpolasyon yöntemi ile tamamlanmıştır. Bu yaklaşımdan dolayı, MBM üretim sürecinde aynı enterpolasyon yöntemleri kullanılarak oluşturulan veriler birbirinden çıkarılarak MBM elde edilmiştir.

IDW yöntemi ortak olan, *p2r* algoritmasıyla üretilen SYM verisinden SAM verisi çıkarılarak bir MBM oluşturulmuştur. TIN yöntemi ortak olan, *pit-free* algoritmasıyla üretilen edilen SYM verisinden SAM verisi çıkarılarak ikinci bir MBM üretilmiştir (Şekil 58). Bireysel ağaç segmentasyonu işleminde kullanılacak olan bu MBM’lerin sonuçlar üzerindeki etkileri ilerleyen bölümlerde değerlendirilecektir.



Şekil 58. lidR kütüphanesine ait algoritmalar kullanılarak elde edilen MBM


Meşçere Boy Modeli (MBM) üretiminde kullanılan Sayısal Arazi Modeli (SAM) ve Sayısal Yüzey Modeli (SYM) verilerinin elde ediliş yöntemleri, doğrudan ağaç boyunun doğruluğunu etkilemektedir. Bu nedenle, SAM üretiminde farklı enterpolasyon yöntemleri olan IDW ve TIN teknikleri uygulanmıştır. Benzer şekilde, SYM üretimi için de farklı algoritmalar olan *p2r* ve *pit-free* yöntemleri kullanılarak veri oluşturulmuştur.

Farklı yöntemlerle elde edilen modeller, karşılaştırmalı analizlerin gerçekleştirilmesi ve doğruluk değerlendirmelerinin yapılabilmesi açısından önemli bir temel oluşturmuştur. Ayrıca, çalışma alanının yüksek eğimli topografik yapısı nedeniyle, gerçekleştirilen analizler aracılığıyla hangi yöntemlerin eğimli arazilerde daha başarılı sonuçlar verdiği de gözlemlenmiş ve değerlendirilmiştir.

3.3.3. Çalışma Alanına Ait Meşçere Boy Haritasının Yapay Zekâ ile Üretilmesi

Meta ve Dünya Kaynakları Enstitüsü (Meta and World Resources Institute) tarafından açık kaynak olarak sağlanan 1 m çözünürlüklü taç yükseklik verileri kullanılarak, çalışma

alanına ait bir Meşçere Boy Haritası, Python programlama ortamında oluşturulmuştur (Şekil 59).



Şekil 59. Yapay zekâ kullanılarak üretilen Meşçere Boy Modeli (MBM)

Bu veri seti, Meta ve Dünya Kaynakları Enstitüsü tarafından geliştirilmiş olup, yapay zekânın herkesin erişimine açık olmasının iklim değişikliğiyle mücadelede finansman sağlanması ve şeffaflığın artırılması açısından önemli bir araç olduğu düşünülmektedir. İlk kez, bu tür yüksek çözünürlüklü haritaların küresel ölçekte işlenebilmesi için gerekli yapay zekâ modelleri ve hesaplama gücü tüm kullanıcıların erişimine sunulmuştur.

Veri seti, 2009 ile 2020 yılları arasında elde edilen en iyi uydu görüntülerinin analiz edilmesiyle oluşturulmuştur. Görüntü seçiminde bulut örtüsü, mevsimsellik ve görüntü kalitesi gibi faktörler belirli kısıtlamalar getirmiş olsa da, verilerin yaklaşık %80'i 2018-2020 yılları arasına ait uydu görüntülerinden elde edilmiştir. Bu veri seti, meşçere boylarını belirlemek için kullanılmakta olup, çalışma alanının detaylı bir haritasını sunmaktadır (URL-5).

Bu işlem sonucunda, çalışma alanındaki MBM'nin hangi boy aralıklarında dağıldığı belirlenmiştir. Her ne kadar kullanılan veri seti en güncel uydu görüntülerini içermese de, çalışma alanında son yıllarda önemli bir değişiklik yaşanmamış olması nedeniyle bu veri seti geçerliliğini korumaktadır. Ayrıca, farklı yöntemlerle elde edilen MBM sonuçlarıyla karşılaştırma yapılabilmesi ve karşılaştırmalı analizlerde referans sağlanabilmesi açısından değerli bir kaynak oluşturmıştır.

3.4. Bireysel Ağaç Segmentasyonu (Individual Tree Segmentation)

Bireysel ağaç segmentasyonu, ormanlık alanlarda meşçere parametrelerinin doğru biçimde tahmin edilebilmesi açısından kritik bir süreçtir. Ormanlarda ağaç tepelerinin yeryüzünü örtme derecesi (kapalılık durumu) arttıkça, bireysel ağaçlar arasındaki mesafe azalmakta ve ağaçların birbirinden ayırt edilmesi zorlaşmaktadır. Kapalılık oranının yüksek olduğu alanlarda, LiDAR sinyalinin ağaç tepelerini geçerek zemine ulaşması da güçleşmektedir. Bu durum, hem zemin noktalarının doğru bir şekilde belirlenmesini hem de ağaçlara ait nokta yoğunluğunu olumsuz etkileyerek segmentasyon işleminin başarısını düşürmektedir.

LiDAR nokta bulutundan segmente edilen her bir ağaca ait noktalar büyük öneme sahiptir, çünkü bu noktalar üzerinden ağaç boyu, tepe çapı, hacim ve ağaç türü gibi temel parametreler doğru bir şekilde hesaplanabilmektedir. Bu nedenle, bireysel ağaç segmentasyonunun doğruluğu, elde edilen meşçere parametrelerinin güvenilirliği üzerinde doğrudan etkili olmaktadır.

Çalışma kapsamında, gevşek kapalı (LKnd1) olarak sınıflandırılan bir orman alanında referans verisi oluşturmak amacıyla, yersel ölçüm yöntemleri kullanılarak veri toplanmıştır. Bu ölçümler, ağaç türlerini, sayısını, gövde çapını (1,30 m yükseklikten ölçülerek), konumlarını ve boylarını kapsayan detaylı meşçere parametrelerini içermektedir. Aynı alan üzerinde, havadan elde edilen LiDAR verisinden oluşturulan nokta bulutu kullanılarak bireysel ağaç segmentasyonu gerçekleştirilmiş ve elde edilen sonuçlar yersel referans verileri ile karşılaştırılmıştır.

Bireysel ağaç segmentasyonu, hem nokta bulutu tabanlı hem de raster tabanlı yöntemler kullanılarak gerçekleştirilmiş ve elde edilen sonuçlar, referans veriye yakınlık açısından değerlendirilmiştir. Bu yaklaşım ile bireysel ağaç segmentasyonunun başarısının artırılması ve meşçere parametrelerinin daha doğru bir şekilde tahmin edilmesi hedeflenmiştir.

3.4.1. Nokta Bulutu Tabanlı Segmentasyon (Kümeleme)


Üç boyutlu nokta bulutu verisinden bireysel ağaçları tespit edilmesi amacıyla, birbirinden farklı nokta bulutu tabanlı segmentasyon yöntemleri uygulanmıştır. Noktaların konumsal özellikleri dikkate alınarak gerçekleştirilen bu segmentasyon süreci, denetimsiz makine öğrenimi algoritmalarına dayalı kümeleme işlemlerine dayanmaktadır. Çalışmada,

scikit-learn kütüphanesindeki çeşitli algoritmalar kullanılarak kümeleme işlemleri gerçekleştirilmiştir.

Denetimsiz makine öğrenimi algoritmaları kullanılarak gerçekleştirilen segmentasyon sürecinde, noktalar arasındaki mesafe en önemli kriterlerden biri olmuştur. Bir diğer önemli konu ise, algoritmalar uygulanırken ağaçların boylarına ilişkin herhangi bir ön bilgi kullanılmadığından, gövde çapı çok küçük olan ağaçların da segmente edilmesidir. Bu sebeplerden ötürü, elde edilen sonuçlara incelendiğinde, referans verisindeki ağaç sayısına yakın bir sonuca ulaşabilen bir algoritmanın bulunmadığı görülmüştür.

Seçilen algoritmaya ait parametre değerleri, elde edilen sınıf sayısını doğrudan etkilediğinden, optimum parametrelerin belirlenmesi büyük önem taşımaktadır. Nokta bulutu tabanlı segmentasyon işlemleri, Google Colab platformunda, kullanılan algoritmanın öğrenme süresine göre farklı GPU ve TPU donanımları kullanılarak gerçekleştirilmiştir.


BIRCH (Balanced Iterative Reducing and Clustering using Hierarchies) algoritması, veri yoğunluğunu dikkate alarak hiyerarşik bir segmentasyon işlemi gerçekleştirmektedir. Algoritmanın parametrelerinden biri olan eşik (threshold) değeri değiştikçe, elde edilen küme sayısında farklılıklar oluşmaktadır. Kullanılan veriye göre eşik değeri 2, 5, 10 ve 20 olarak belirlendiğinde, sırasıyla 276, 24, 8 ve 1 küme elde edilmiştir. Çalışma alanına ait kullanılan veri seti ve BIRCH algoritmasıyla (threshold=5) elde edilen segmentasyon sonuçları birlikte gösterilmiştir (Şekil 60).



Şekil 60. BIRCH algoritmasıyla segmentasyon öncesi (sol) ve sonrası (sağ)

DBSCAN (Density-Based Spatial Clustering of Applications with Noise) algoritması, komşuluk yarıçapı (eps) ve en az nokta sayısı (minpts) gibi parametrelere bağlı olarak


kümeleme işlemini gerçekleştirmektedir. Algoritmaya ait parametrelerden komşuluk yarıçap değeri 0,5, 1 ve 2 olarak belirlendiğinde, sırasıyla 70, 10 ve 6 küme elde edilmiştir. Çalışma alanına ait kullanılan veri seti ve DBSCAN algoritmasıyla ($\text{eps}=1$) elde edilen segmentasyon sonuçları birlikte gösterilmiştir (Şekil 61).



Şekil 61. DBSCAN algoritmasıyla segmentasyon öncesi (sol) ve sonrası (sağ)


K-Means algoritması, noktaların birbirine olan yakınlığına ve kullanıcı tarafından belirlenen k sayıda küme merkezine göre kümeleme işlemi gerçekleştirmektedir. Bu algorithmada küme sayısının önceden belirlenmesi, yöntemin temel dezavantajlarından biri olarak kabul edilmektedir.

Segmentasyon işleminde kaç adet ağaç bulunduğu önceden bilinmediğinden, K_means algoritması bireysel ağaç segmentasyonu için sınırlı bir kullanım sağlamaktadır. Çalışma alanına ait kullanılan veri ve K-Means algoritmasıyla ($n_clusters=20$) elde edilen segmentasyon sonuçları birlikte gösterilmiştir (Şekil 62).



Şekil 62. K-Means algoritmasıyla segmentasyon öncesi (sol) ve sonrası (sağ)

Gaussian Mixture Models (GMM) algoritması, K-Means algoritması gibi küme sayısının önceden belirlendiği bir yöntemdir. K-Means algoritmasına kıyasla daha iyi sonuçlar üretse de, bireysel ağaç segmentasyonu için yeterli doğruluk düzeyine ulaşamamaktadır. Çalışma alanına ait kullanılan veri seti ve GMM algoritmasıyla (n_clusters=20) elde edilen segmentasyon sonuçlar birlikte gösterilmiştir (Şekil 63).




Şekil 63. GaussMixture algoritmasıyla segmentasyon öncesi (sol) ve sonrası (sağ)

Yukarıda sunulan örnek uygulamalarda da görüldüğü üzere, nokta bulutu tabanlı segmentasyon işlemleri bireysel ağaç segmentasyon için yeterli düzeyde başarılı sonuçlar üretememiştir. Referans verisinde bulunan ağaç sayısına hiçbir algoritmanın yaklaşmadığı

gibi, ağaçları temsil eden noktaları şekilsel bütünlük içerisinde doğru şekilde gruplandıramadığı da gözlemlenmiştir.

R programlama ortamında, lidR kütüphanesine ait li2012 algoritması, raster veriye ihtiyaç duymadan doğrudan nokta bulutu üzerinde çalışmakta ve yükseklik farkı eşikleri (dt1, dt2) ile arama yarıçapı (R) parametrelerinin optimize edilmesi yoluyla istenilen segmentasyon sonuçlarına ulaşılabilmektedir (Liv d., 2012). Ayrıca, hmin parametresi ile düşük yükseklikteki nesnelerin aşırı segmentasyonunun önüne geçilmektedir. Algoritmaya ait parametre değerleri değiştirilerek, aynı veri seti üzerinde elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur (Şekil 64).



Şekil 64. li2012 algoritmasına ait farklı parametre değerleri ile elde edilen sonuçlar

Kullanılan algoritmalarda kümeleme işlemleri, genellikle noktaların yoğunluğuna ve aralarındaki mesafeye dayalı olarak gerçekleştirilmektedir. Bu nedenle, bireysel ağaç segmentasyonu sürecinde başlangıç noktasının gerçekten bir ağaç tepe noktası olup olmadığı

dikkate alınmamaktadır. Ayrıca, segmentasyonda kullanılan algoritmaların parametreleri arasında ağaçların boy bilgisine yer verilmemesi, bireysel ağaçların doğru şekilde ayrılmasını sağlamada ek bir zorluk oluşturmaktadır.


Parametre değerleri değiştirilerek algoritmaların optimize edilmeye çalışılmasına rağmen, bireysel ağaç segmentasyonunda istenilen doğruluk düzeyinde ayırım işleminin gerçekleştirilemediği gözlemlenmiştir. Bu durum, özellikle yoğun ve karışık yapıya sahip ormanlık alanlarda, ağaçlar arasındaki mesafenin azalmasıyla daha belirgin hale gelmektedir.

3.4.2. Raster Tabanlı Segmentasyon

Açık kaynak kodlu bir yazılım olan Cloud Compare kullanılarak üretilen nokta tabanlı Meşçere Boy Modeli (MBM), R programlama ortamında lidR kütüphanesindeki ttops fonksiyonunun Yerel Maksimum Algoritması (YMA) kullanılarak işlenmiş ve bireysel ağaç tepe noktaları (tree tops) tespit edilmiştir.


Bireysel ağaçların doğru şekilde segmente edilebilmesi için, ağaçlara ait tepe noktalarının hassas bir şekilde tespit edilmesi gerekmektedir. Bu amaçla, kullanılan fonksiyonun parametrelerinden pencere boyutu (ws) ve minimum ağaç yüksekliği (hmin), çalışma alanındaki nokta bulutu özelliklerine göre optimize edilmiştir. Tepe noktalarının, segmentasyon işleminin başlangıç noktası olması nedeniyle, doğru ve hassas bir şekilde belirlenmesi segmentasyon başarısı açısından kritik öneme sahiptir.

R programlama ortamında lidR kütüphanesi kullanılarak, nokta bulutu tabanlı Yerel Maksimum Algoritması (YMA) ile tespit edilen 18 adet ağaç tepe noktasına ait görseller, farklı açılardan gösterilmiştir (Şekil 65).



Şekil 65. YMA ile elde edilen 18 adet ağaç tepe noktasının farklı açılardan gösterimi

Tepe noktaları tespit edilen ağaçlara ait konumsal dağılımın iki boyutlu gösterimi ile ağaçların boy değerleri sunulmuştur (Şekil 66).



Şekil 66. Tepe noktaları tespit edilen ağaçlara ait yatay ve düşey konum bilgileri

Meşçere Boy Modeli (MBM) verisi, nokta bulutu formatında analiz edilerek bireysel ağaçların tepe noktaları tespit edilmiştir. Bu işlemin ardından, aynı MBM verisi raster formata dönüştürülmüş ve bireysel ağaç segmentasyonu gerçekleştirilmiştir.

Segmentasyon işlemi sırasında, önceden tespit edilen ağaç tepe noktaları (ttops) başlangıç noktaları olarak kullanılmıştır. Segmentasyon işlemi, R programlama ortamında yer alan lidR kütüphanesinin sunduğu iki farklı algoritma kullanılarak gerçekleştirilmiştir.

Dalponte2016 Algoritması: Bu algoritma, tepe noktalarını başlangıç kabul ederek, ağaç taçlarını havza (watershed) tabanlı bir yaklaşımla segmentlemektedir. Ağaç taçlarının sınırlarını, MBM üzerinde en düşük yükseklik değişimlerini temel alarak belirlemektedir (Dalponte vd., 2016).

Silva2016 Algoritması: Bu algoritma ise, ağaçların tepe noktalarına bağlı olarak bireysel ağaç segmentasyonu gerçekleştirmekte ve tepe çapı ile yükseklik gibi fiziksel özelliklere dayanarak ağaçları ayırt etmektedir (Silva vd., 2016).


Bu iki algoritmanın kullanılması, bireysel ağaç segmentasyonunda farklı yaklaşımlar sunarak, sonuçların karşılaştırılması ve doğruluklarının değerlendirilmesine imkân tanımıştır.

Referans verisine en yakın bireysel ağaç tepe noktası sayısının elde edebilmesi amacıyla, her iki algoritma için de gerekli parametreler optimize edilmiştir. Optimizasyon sürecinin ardından, Dalponte2016 ve Silva2016 algoritmaları için aynı parametre değerleri

kullanılmıştır. Segmentasyon işlemi öncesinde, MBM raster formata dönüştürülürken kullanılan p2r (point-to-raster) ve pit-free yöntemlerinin yanı sıra, raster çözünürlüğü ve seçilen segmentasyon algoritmalarının bireysel ağaç segmentasyonu üzerindeki etkileri de incelenmiştir.

Bu kapsamda, raster üretim yöntemlerindeki ve segmentasyon algoritmalarındaki farklılıkların, bireysel ağaçların doğru şekilde ayrılması ve tepe noktalarının belirlenmesindeki etkileri karşılaştırılmalı olarak değerlendirilmiştir.


R programlama ortamında, lidR kütüphanesi kullanılarak, p2r yöntemiyle 0,10 m, 0,50 m ve 1,00 m çözünürlüğe sahip MBM raster verileri üretilmiştir. YMA için optimize edilmiş parametreler kullanılarak gerçekleştirilen analiz sonucunda, söz konusu çözünürlüklerde sırasıyla 18, 18 ve 20 adet ağaç tepe noktası tespit edilmiştir (Şekil 67).



Şekil 67. p2r yöntemiyle farklı çözünürlüğe sahip MBM verisi üzerinden ağaç tepe noktası tespiti

Yapılan analizler, tepe noktalarının hem sayısal hem de konumsal olarak en doğru şekilde tespit edildiği en uygun çözünürlüğün 0,50 m olduğunu göstermiştir. 0,10 m çözünürlüğünde verinin aşırı ayrıntılı olması, bazı ağaçların tespit edilememesine neden olurken; 1,00 m çözünürlüğünde ise düşük detay seviyesi nedeniyle tepe noktalarının yanlış konumlandırıldığı veya gereksiz fazlalıkların olduğu gözlemlenmiştir. Elde edilen bu sonuçlar, bireysel ağaç segmentasyonunda doğru çözünürlük seçiminin kritik öneme sahip olduğunu açıkça ortaya koymaktadır.

Meşçere Boy Modeli (MBM) raster verisi, pitfree yöntemi kullanılarak 0,01 m, 0,50 m ve 1,00 m çözünürlüklerde üretilmiş ve Yerel Maksimum Algoritması (YMA) parametreleri optimize edilerek ağaç tepe noktaları tespit edilmiştir. Elde edilen sonuçlar, çözünürlük değişimine bağlı olarak hatalı tepe noktalarının olabileceğini göstermiştir (Şekil 68).




Şekil 68. pitfree yöntemiyle farklı çözünürlüğe sahip MBM verisi üzerinden ağaç tepe noktası tespiti

Çalışma alanındaki ağaç sayısını ve tepe noktalarını tespit etmek amacıyla üretilen MBM raster verisinin çözünürlüğü ile kullanılan algoritmaların optimize edilmiş parametre değerlerinin önemi, farklı örneklerle gösterilmiştir. Çözünürlük, yalnızca tepe noktalarının doğru şekilde tespit edilmesi açısından değil, aynı zamanda bireysel ağaç segmentasyonunda noktaların doğru ağaçlara atanabilmesi açısından da kritik bir rol oynamaktadır. Farklı çözünürlüklerle elde edilen sonuçlar, segmente edilen ağaçlara ait noktaların mekânsal dağılımını ve temsil doğruluğunu doğrudan etkilemektedir.

Segmentasyon sonuçları incelendiğinde, 0,10 m çözünürlüğün ağaçları temsil eden tüm noktaları seçmede yetersiz kaldığı gözlemlenmiştir. Özellikle yoğun ormanlık alanlarda, düşük çözünürlük nedeniyle ağaçların taç yapılarının tam olarak ayrıştırılamadığı ve bunun segmentasyon doğruluğunu olumsuz yönde etkilediği tespit edilmiştir. Bu bulgu, çözünürlük seçimindeki hassasiyetin, hem bireysel ağaç segmentasyonu hem de tepe noktası tespiti üzerindeki kritik etkisini açıkça ortaya koymaktadır.

Dalponte2016 algoritması kullanılarak, farklı çözünürlüklerde p2r yöntemi ile üretilen MBM raster verileri ve Yerel Maksimum Algoritması (YMA) ile tespit edilen ağaç tepe noktaları temel alınarak bireysel ağaç segmentasyonu gerçekleştirilmiştir. Aynı veri seti için farklı çözünürlüklerde (0,10 m, 0,50 m ve 1,00 m) oluşturulan raster veriler kullanılarak yapılan segmentasyon sonuçları karşılaştırmalı olarak değerlendirilmiştir (Şekil 69).



Şekil 69. Dalponte2016 algoritması ile 0,10 (sol), 0,50 (orta) ve 1,00 (sağ) metre çözünürlüklerle elde edilen segmentasyona ait yandan ve üstten görünüm

Silva2016 algoritması, bireysel ağaç segmentasyonunda, ağaçların tepe çaplarını, boylarını ve nokta yoğunluğunu dikkate alarak noktaları gruplamakta ve her bir ağacı ayrı bir segment olarak ayırmaktadır. Bu algoritmaya ait parametreler, segmentasyon sürecinde ağaçların fiziksel özelliklerini doğru şekilde modellemek açısından kritik öneme sahiptir.

Silva2016 algoritması, MBM raster verisi ile çalışabilmesine rağmen, doğrudan nokta bulutu tabanlı bir yöntem olarak tasarlandığı için daha doğru sonuçlar üretebilmektedir. Nokta bulutu üzerinde çalışması sayesinde, ağaçların bireysel özelliklerini detaylı bir şekilde analiz edebilmekte ve enterpolasyon kaynaklı veri kayıplarını en aza indirmektedir. Bu özellik, özellikle yoğun ve karmaşık ormanlık alanlarda algoritmanın segmentasyon doğruluğunu artırmaktadır.

Algoritma, optimize edilmiş parametreler kullanılarak, ağaçların tepe çapı ve boy sınırlarını dikkate alarak her bir tepe noktasından segmentasyon işlemini başlatmaktadır. Bu süreç, nokta tabanlı analiz yeteneği sayesinde hem küçük boyutlu ağaçların hem de geniş taç yapısına sahip ağaçların doğru şekilde ayrılmasını sağlamaktadır. Ayrıca, maksimum taç yarıçapı (max_cr) ve yükseklik dışlama eşiği (exclusion) gibi parametreler, segmentasyonun hassasiyetini artırmak amacıyla optimize edilebilmektedir.

Silva2016 algoritması, nokta yoğunluğu yüksek LiDAR verisi kullanılarak gerçekleştirilen bireysel ağaç segmentasyonunda, daha doğru ve detaylı sonuçlar elde etmek için ideal bir yöntemdir. Algoritmanın nokta tabanlı yaklaşımı, MBM raster verisi üzerinde yapılan segmentasyona kıyasla enterpolasyon etkilerini azaltmakta ve ağaç özelliklerinin daha doğru bir şekilde temsil edilmesine olanak sağlamaktadır.

Dalponte2016 algoritması ile yapılan segmentasyon işleminde kullanılan tüm parametre değerleri, Silva2016 algoritması için de aynı şekilde uygulanmıştır. Elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur (Şekil 70).



Şekil 70. Silva2016 algoritması ile 0,10 (sol), 0,50 (orta) ve 1,00 (sağ) metre çözünürlüklerle elde edilen segmentasyona ait yandan ve üstten görünüm

Silva2016 algoritması, bireysel ağaç segmentasyonu işlemini gerçekleştirirken, tepe çapı ve ağaç boyu gibi fiziksel özelliklere dayalı bir ayırma süreci uygulanmaktadır. MBM raster verisinin çözünürlüğü değişse dahi segmentasyon sonuçlarının aynı kalması, algoritmanın doğrudan nokta bulutundaki verilere dayanarak çalıştığını açıkça ortaya koymaktadır.

Bu algoritma için en kritik aşamanın, Yerel Maksimum Algoritması (YMA) parametrelerinin optimize edilmesi olduğu anlaşılmıştır. Tepe noktalarının doğru şekilde

belirlenmesi, segmentasyon işleminin doğruluğunu doğrudan etkilemekte ve Silva2016 algoritmasının genel başarısını önemli ölçüde artırmaktadır.

Farklı örneklerle yapılan analizler, bireysel ağaç segmentasyonu açısından Silva2016 algoritmasının diğer yöntemlere kıyasla üstün performans gösterdiğini ve doğru parametre optimizasyonu ile daha güvenilir sonuçlar ürettiğini ortaya koymuştur. Bu nedenle, segmentasyon işlemlerinde Silva2016 algoritmasının tercih edilmesi gerektiği açık bir şekilde pekiştirilmiştir.

3.4.3. Referans Verisinin Üretilmesi


Çalışma alanındaki seyrek ağaçların bulunduğu (1 kapalı) bölgede, referans veri oluşturmak amacıyla ağaçların konumları, gövde çapları, boyları ve türlerine ilişkin veriler toplanmıştır. Ağaç tepe noktalarının tespitinde kullanılan parametreler, referans verisindeki ağaç sayısına en yakın sonuçları elde edebilmek amacıyla optimize edilmiştir.

Her ne kadar referans verilerinin seyrek ağaçların bulunduğu bir alandan seçildiği belirtilmiş olsa da, bölgede birbirine yakın konumlanan ağaçların fazlalığı dikkat çekmektedir. Bu nedenle, karışık kapalılığa sahip bu bölgeden elde edilen parametre değerleri, çalışma alanının tamamına uygulanmıştır.

Referans veri olarak kullanılmak üzere, yaklaşık 1200 m² büyüklüğündeki bir alandan, gövde çapları 21-56 cm arasında değişen toplamda 16 adet ağaca (9 Kayın, 7 Ladin) ait veriler toplanmıştır. Ağaçlara ait veriler tablo halinde sunulmuş, konumsal dağılımları ise iki boyutlu olarak görselleştirilmiştir (Tablo 7, Şekil 71).

Tablo 7. Çalışma alanındaki referans veriye ait bilgiler

Ağaç No	Ağaç Türü	Ağaç Boyu (m)	Gövde Çapı (cm)	Ağaç No	Ağaç Türü	Ağaç Boyu (m)	Gövde Çapı (cm)
1	Kayın	15,50	36	9	Kayın	23,00	38
2	Kayın	23,00	31	10	Ladin	22,50	28
3	Kayın	18,00	44	11	Ladin	27,00	49
4	Kayın	23,00	50	12	Ladin	22,00	21
5	Kayın	20,50	45	13	Ladin	21,50	34
6	Kayın	21,50	34	14	Ladin	22,00	35
7	Kayın	17,50	38	15	Ladin	26,00	56
8	Kayın	18,50	25	16	Ladin	27,50	49



Şekil 71. Çalışma alanındaki referans verinin konumsal dağılımı ve araziden görünümü

Yersel ölçümler için elektronik ölçme cihazı (total station) kullanılarak, çalışma alanındaki ağaçların konum ve boy bilgileri elde edilmiştir. Konum ölçmeleri için, CORS uyumlu GNSS alıcısı ile belirlenen sabit noktalardan geriden kestirme yöntemi uygulanmış ve total station cihazı koordinatlı hale getirilmiştir. Daha sonra, cihazla yapılan ölçümlerle her ağacın konumu belirlenmiştir. Ağaç boyları ise, ağaç tepelerine ve reflektörlere yapılan düşey açı ölçümleri kullanılarak, trigonometrik yükseklik taşıma yöntemiyle hesaplanmıştır. Ancak, yoğun diri örtü nedeniyle reflektörle ölçüm yapılamayan bazı ağaçların konum bilgileri, doğrudan CORS uyumlu DGPS cihazı ile belirlenmiştir. Her iki yöntem sonucunda da santimetre düzeyinde konumsal hassasiyet elde edilmiştir (Şekil 72).



Şekil 72. Çalışma alanındaki ağaçların konum ve yükseklik bilgisinin elde edilmesi

Meşçere parametrelerinden biri olan gövde çapı, ağaç gövdesinin yerden 1,30 m yüksekliğinde (göğüs yüksekliği) ölçülerek belirlenmiştir. Ölçüm sırasında, ağaç gövdesine


çap ölçer yerleştirilmiş ve çap değeri iki farklı yönden alınmıştır. Alınan iki ölçümün ortalaması hesaplanarak ağacın kesin gövde çapı elde edilmiştir (Şekil 73).



Şekil 73. Ağaç gövde çapının çap ölçer aletiyle ölçülmesi

İki farklı yönden çap ölçümü yapılması, ağaç gövdesindeki asimetrik şekil ya da düzensizliklerden kaynaklanabilecek olası sapmaları azaltmayı amaçlamaktadır.

Elektronik ölçüm cihazı ile ağaç boyunun trigonometrik yöntemle hesaplanamadığı durumlarda ise, ağaçların yükseklik bilgileri TruPulse lazer mesafe ölçer kullanılarak belirlenmiştir. Bu cihaz, ağaç tepe noktası ve tabanına olan eğim açılarını ölçerek, lazerle mesafeyi tespit eder ve trigonometrik hesaplama yaparak ağaç boyunu otomatik olarak hesaplamaktadır (Şekil 74).




Şekil 74. TruPulse cihazı ve ölçme yöntemleri (URL-6)

TruPulse cihazı, taşınabilir yapısı ve hassas ölçüm yeteneği sayesinde, yoğun bitki örtüsü gibi zorlu koşullarda dahi güvenilir sonuçlar sunmaktadır. Cihaza ait ölçüm hassasiyeti $\pm 0,3-1$ metre aralığındadır. Yoğun bitki örtüsü nedeniyle elektronik ölçüm cihazlarının kullanılamadığı durumlarda, TruPulse cihazı alternatif bir çözüm olarak tercih edilmiştir.


3.4.4. Segmentasyon İyileştirilmesi

Bireysel ağaç segmentasyonu için, referans veri olarak kullanılan alandan elde edilen bilgiler doğrultusunda Silva2016 algoritmasının parametreleri optimize edilmiştir. Referans alandan alınan veriler, segmentasyonun doğruluğunu artırmak amacıyla temel alınmış ve algoritmanın parametreleri, çalışma alanının genel yapısına uyum sağlayacak şekilde ayarlanmıştır.

Optimizasyon sürecinin ardından, Silva2016 algoritması tüm çalışma alanına uygulanmış ve belirlenen parametre değerlerine göre toplamda 1325 adet tepe noktası tespit edilerek segmente edilmiştir. Segmentasyonu yapılan ağaçların tepe noktalarının konumsal dağılımı ve genel görünümleri görselleştirilmiştir (Şekil 75). Ayrıca, ağaçların taç şekilleri segmentasyon sınırları da elde edilmiştir (Şekil 76).



Şekil 75. Çalışma alanına ait Silva2016 algoritması ile elde edilen segmentasyon sonucu




Şekil 76. Silva2016 algoritması segmentasyonuna ait tepe çizimleri

Nokta bulutu verisinin düzensiz ve karmaşık yapısı, bireysel ağaç segmentasyonunun tamamen doğru şekilde gerçekleştirilmesini zorlaştırmaktadır. Bu nedenle, segmentasyon işleminden elde edilen sonuçlar dikkatlice incelenmiş ve özellikle birbirine çok yakın ağaçlara ait noktalarda oluşabilecek karışıklıkları gidermek amacıyla manuel düzeltmeler yapılmıştır. Bu müdahaleler, kullanılan algoritmanın ladin türü ağaçları başarıyla tespit etmesine karşın, kayın ağaçlarında aynı başarıyı gösterememesi nedeniyle gerekli olmuştur. Özellikle, tek bir kayın ağacının birden fazla ağaç olarak segmente edildiği durumlarda, ilgili segmentler birleştirilmiştir. Bu süreç, segmentasyon doğruluğunu artırmak ve hatalı ayrımları düzeltmek amacıyla uygulanmıştır.

Segmentasyon işleminin iyileştirilmesi, meşçere bileşenlerinin (örneğin ağaç sayısı, gövde çapı, ağaç boyu ve tepe çapı gibi) doğru bir şekilde hesaplanabilmesi için kritik bir adımdır. Manuel kontrol ve düzenleme, otomatik algoritmaların karışık orman yapılarında ortaya çıkarabileceği olası hataları telafi ederek, daha güvenilir ve doğru sonuçların elde edilmesine katkı sağlamaktadır.

Cloud Compare adlı açık kaynak yazılımı kullanılarak, nokta bulutu verisinin yatay ve düşey yöndeki dağılımları incelenmiş ve segmentasyon işleminin doğruluğu kontrol edilmiştir. Bu süreçte, yanlış ayrımların olup olmadığı dikkatlice analiz edilmiş; hatalı ayrımların tespit edildiği bölgelerde gerekli düzeltmeler yapılmış ve segmentasyon sonuçları manuel müdahalelerle iyileştirilmiştir.

Cloud Compare yazılımının sunduğu görselleştirme ve analiz araçları, nokta bulutunun detaylı bir şekilde incelenmesine olanak tanımış ve bu sayede daha doğru ve güvenilir segmentasyon sonuçları elde edilmiştir (Şekil 77).




Şekil 77. Segmentasyon iyileştirmesi öncesi (sol) ve sonrası (sağ) nokta bulutunun dağılımı

3.5. Meşçere Parametre (Bileşenlerinin) Kestirimi


Meşçere bileşenleri, ormanların ekolojik, ekonomik ve sosyal işlevlerini anlamak ve yönetmek için önemli bir bilgi kaynağıdır. Bu bileşenler, sürdürülebilir orman yönetimi,

karbon stoku izleme, ekosistem sađlıđının korunması ve orman kaynaklarının ekonomik deđerinin artırılması gibi birçok alanda kritik rol oynamaktadır.


Segmentasyon iyileřtirmesinin ardından, alıřma alanındaki ađalar ladin, kayın ve kuru ladin olmak zere  farklı kategoriye ayrılmıřtır. Gevřek kapalı (LKnd1) meřereden elde edilen bu  kategoriye ait bireysel ađalar grsel olarak sunulmuřtur (řekil 78, 79, 80).



řekil 78. 1 kapalı alana ait ladin ađalarının segmentasyon sonucu grnm




řekil 79. 1 kapalı alana ait kayın ađalarının segmentasyon sonucu grnm




řekil 80. 1 kapalı alana ait kuru ladin ađalarının segmentasyon sonucu grnm

Bireysel ađa segmentasyon iřleminin ardından 1-kapalı (LKnd1) alıřma alanındaki ađaların gvdelerine ait noktalara ulařmak mmkn olurken, 2 ve 3-kapalı (LKnd2-KnLcd3) alanlardaki ađalardan bu verileri elde etmek zor hale gelmiřtir. Bu alanlardan elde edilen bireysel ađa segmentasyon rnekleri ařađıda sunulmuřtur (řekil 81 ve 82).



Şekil 81. 2 ve 3 kapalı alana ait ladin ağaçlarının segmentasyon sonucu görünümü



Şekil 82. 2 ve 3 kapalı alana ait kayın ağaçlarının segmentasyon sonucu görünümü

Nokta bulutu verisinden ağaç boyu, gövde çapı, tepe çapı, tepe alanı ve tepe hacmi gibi meşçere bileşenlerinin doğru bir şekilde elde edilebilmesi, segmentasyon sonucunda noktaların ağaçları ne ölçüde doğru temsil ettiğine bağlıdır.

Çalışma alanındaki 1-kapalı meşçerenin bileşenleri, Python programlama dili kullanılarak Google Colab ortamında hesaplanmıştır. Segmentasyon işlemi sonucunda, aynı kimlik numarasına (treeID) atanan noktalar bir araya getirilmiş ve her bir kümeye karşılık gelen ağaçlar analiz edilmiştir. Bu analizde, her bir ağacın boyu, ilgili küme içindeki noktaların en yüksek Z (yükseklik) değeri kullanılarak hesaplanmıştır. Ağaç boyunun hesaplanmasına yönelik yazılan pseudo kodu Tablo 8’de verilmiştir.

Tablo 8. Ağaç boyu tespitine yönelik pseudo kodu

Girdi:

- points → Her biri (x, y, z) koordinatından oluşan 3B nokta bulutu dizisi

Adımlar:

1. Nokta bulutundaki tüm noktaların Z (yükseklik) değerlerini al
2. Bu Z değerleri arasından en yüksek olanını bul
3. Bu değer, ağacın en yüksek noktasıdır → tree_height olarak kaydet

Çıktı:

- tree_height → Ağaç boyu (en büyük Z değeri)

Gövde çapı (Diameter at Breast Height - DBH), ağacın yerden 1,30 metre yüksekliğindeki gövdesine ait noktalar kullanılarak hesaplanmıştır. Bu yükseklikte, nokta bulutu verisinde yer alan noktaların yatay (2D) izdüşümünün en uzun çap değeri belirlenmiştir. Gövde çapının hesaplanmasına yönelik yazılan pseudo kodu Tablo 9'da verilmiştir.

Tablo 9. Ağaç gövde çapı tespiti için yazılan pseudo kodu

Girdi: - points $\rightarrow$ (x, y, z) koordinatlarından oluşan 3B nokta bulutu (ağaca ait) Tanımlar: - dbh_height $\rightarrow$ Göğüs yüksekliği (standart: 1.3 metre) - dbh_tolerans $\rightarrow$ Bu yükseklik etrafında ± 0.1 m tolerans aralığı Adımlar: 1. Göğüs yüksekliğine yakın olan noktaları filtrele: - Z (yükseklik) değeri 1.2 m ile 1.4 m arasında olan noktalar seçilir - Bu noktalar $\rightarrow$ dbh_points 2. Bu noktalardan sadece yatay düzlemdeki (X, Y) koordinatlar alınır: - dbh_2d $\rightarrow$ sadece (x, y) bilgileri 3. dbh_2d noktalarından dış sınır (convex hull) oluşturulur: - hull $\rightarrow$ dbh_2d nokta kümesinin dış sınırını tanımlar 4. Bu sınır üzerindeki en uzak iki nokta arası mesafe hesaplanır: - Bu mesafe, ağacın çapı olarak kabul edilir - dbh_diameter = göğüs yüksekliği seviyesindeki maksimum yatay mesafe Çıktı: - dbh_diameter $\rightarrow$ Ağaç gövdesinin tahmini çapı (DBH)
--

Tepe çapı (canopy diameter), nokta kümesinin iki boyutlu yatay izdüşümü üzerinden hesaplanmıştır. Tepe çapı, yatay izdüşümde birbirine en uzak iki nokta arasındaki mesafe olarak tanımlanmıştır. Bu işleme ait pseudo kodu Tablo 10'da verilmiştir.

Tablo 10. Ağaç tepe çapı tespiti için yazılan pseudo kodu

Girdi: - points $\rightarrow$ (x, y, z) koordinatlarından oluşan 3B ağaç nokta bulutu Adımlar: 1. X eksen (doğu-batı yönü) boyunca minimum ve maksimum koordinatları belirle: - x_min = noktaların X koordinatları arasındaki en küçük değer - x_max = noktaların X koordinatları arasındaki en büyük değer
--

Tablo 10'un devamı

2. Y eksenini (kuzey-güney yönü) boyunca minimum ve maksimum koordinatları belirle:

- y_{min} = noktaların Y koordinatları arasındaki en küçük değer
- y_{max} = noktaların Y koordinatları arasındaki en büyük değer

3. X yönündeki tepe genişliğini hesapla:

- $dx = x_{max} - x_{min}$

4. Y yönündeki tepe genişliğini hesapla:

- $dy = y_{max} - y_{min}$

5. Tepe çapı olarak, bu iki genişlikten büyük olanını seç:

- $canopy_diameter = \max(dx, dy)$

Çıktı:

- $canopy_diameter \rightarrow$ Ağaç tepesinin taban düzlemindeki en geniş çapı (metrik çap)

Tepe alanı (canopy area) ve tepe hacmi (canopy volume) daha doğru hesaplanabilmesi için sınırlar hassas bir şekilde belirlenmiştir. Bu amaçla, radyal yöntem kullanılmıştır. Bu yöntem, bir merkez noktadan belirli yönlerde (radyal çizgiler boyunca) ilerleyerek en uzak noktaları tespit etmekte ve böylece dış sınırı oluşturmaktadır. Tepe alanlarının hesaplanmasına yönelik yazılan pseudo kodu Tablo 11'de verilmiştir.

Tablo 11. Ağaç tepe alanının tespitine ait pseudo kodu

Girdi:

- $points \rightarrow (x, y, z)$ koordinatlarından oluşan bir ağaç nokta bulutu

Adımlar:

1. Nokta bulutunun merkezini (ağırlık merkezi) hesapla:

- $center$ = tüm noktaların ortalama (x, y, z) koordinatı

2. Her nokta için merkezle yaptığı açığı (radyan cinsinden) hesapla:

- $angle = \arctan2(y - center_y, x - center_x)$
- Bu açılar, merkeze göre hangi yönde olduklarını belirler

3. Noktaları bu açılara göre küçükten büyüğe sırala:

- $sorted_indices$ = açılara göre sıralı indeks listesi
- $sorted_points$ = açılara göre sıralanmış noktalar
- $sorted_angles$ = sıralanmış açılar

4. Başlat:

- $boundary_points$ = boş liste (tepe sınır noktaları burada tutulacak)
- $current_angle$ = başlangıçta boş (her yeni açı için güncellenir)
- $max_distance$ = -sonsuz (merkezden en uzak nokta takibi için)

5. Her açı ve karşılık gelen nokta için döngü başlat:

- a. Şu anki açı, $current_angle$ 'dan belirgin şekilde farklıysa (tolerans: 0.01):

Tablo 11'in devamı

i. Eğer <code>current_angle</code> tanımlıysa: → bir önceki <code>farthest_point</code>'i <code>boundary_points</code> listesine ekle ii. <code>current_angle</code> = bu açı iii. <code>max_distance</code> = merkez ile bu nokta arasındaki mesafe iv. <code>farthest_point</code> = bu nokta (şimdilik en uzak nokta olarak seçilir) b. Açı aynıysa ve bu nokta, merkezden daha uzaktaysa: → <code>farthest_point</code> güncellenir 6. Döngüden çıktıktan sonra: → son kalan <code>farthest_point</code> de <code>boundary_points</code> listesine eklenir 7. <code>boundary_points</code> = açısal olarak seçilmiş sınır noktaları → bu noktalar, taç alanının dış sınırını temsil eder Çıktı: - <code>boundary_points</code> → tepe sınırını tanımlayan (x, y, z) noktalar listesi
--

Ladin ve kayın ağaç türlerinin taç hacimlerinin daha doğru hesaplanabilmesi için her türde farklı geometrik modeller kullanılmıştır. Ladin ağaçlarının konik formu andıran taç yapısı nedeniyle konik model, kayın ağaçlarının daha yayvan ve elipsoidal taç yapısı nedeniyle ise elipsoid model uygulanmıştır. Her iki türde de gövde hacmi hesaplamasında, gövdelerin genel olarak silindirik bir yapıya sahip olduğu varsayılmış ve bu nedenle silindirik model tercih edilmiştir.

Gövde hacmi hesabında, ağaç gövdeleri genellikle silindirik bir yapı olarak kabul edilmekle birlikte, gerçekte gövdeler tam anlamıyla düzgün bir silindir formuna sahip değildir. Ağaç gövdeleri alt kısımlarda geniş, üst kısımlara doğru ise daralan bir morfoloji sergilemektedir. Bu nedenle, gövde hacmi hesaplamalarında, ağaç boyunun yarısında tam gövde çapı, diğer yarısında ise çapın yarısı esas alınarak kaba bir hacim tahmini yapılabilmektedir. Ancak daha hassas sonuçlar elde edebilmek amacıyla, ağaç gövdelerinin morfolojik yapısına daha yakın modellemeler yapılmış, bu doğrultuda konik, paraboloid ve neiloid gibi çeşitli geometrik modeller geliştirilmiştir. Ayrıca, gözleme dayalı ampirik çalışmalarla oluşturulan allometrik denklemler aracılığıyla da gövde hacmi daha doğru biçimde tahmin edilebilmektedir.

Doğu ladini (*Picea orientalis*) için, çalışma alanına yakın bir bölgede yapılmış en güncel araştırmalardan biri olarak Kahrıman vd., (2023) tarafından geliştirilen çift girişli ağaç hacim denklemleri kullanılabilmektedir. Doğu kayını (*Fagus orientalis*) için ise, çalışma alanına yakın bölgelerde son yıllarda kapsamlı bir araştırma bulunmamakla birlikte,

Carus (1998) tarafından gerçekleştirilen doktora çalışmasında elde edilen çift girişli hacim denklemleri hâlen geçerliliğini korumakta ve kullanılabilir niteliktedir.

Nokta bulutu verisi kullanılarak gerçekleştirilen bireysel ağaç segmentasyonu işleminden sonra, segmentasyona ait ağaçlara ilişkin boy ve gövde çapı bilgileri kullanılarak gövde hacmi kaba bir şekilde hesaplanmıştır. Bu hesaplama ile ilgili pseudo kod Tablo 12’de verilmiştir.

Tablo 12. Ağaç gövde hacmine ait yazılan pseudo kodu

Girdi:
- DBH_cm → Ağaç göğüs yüksekliği çapı (cm cinsinden)
- Boy_m → Ağaç boyu (metre cinsinden)
Başlat:
- DBH_metre = DBH_cm / 100
- Yarım_Boy = Boy_m / 2
Adımlar:
1. Alt_Yarı_Alan = $\pi \times (DBH_metre / 2)^2$
2. Alt_Yarı_Hacim = Alt_Yarı_Alan $\times$ Yarım_Boy
3. Üst_Yarı_Çap = DBH_metre / 2
4. Üst_Yarı_Alan = $\pi \times (Üst_Yarı_Çap / 2)^2$
5. Üst_Yarı_Hacim = Üst_Yarı_Alan $\times$ Yarım_Boy
6. Toplam_Hacim = Alt_Yarı_Hacim + Üst_Yarı_Hacim
Çıktı:
- Gövde hacmi → Toplam_Hacim (m ³ cinsinden)

Konik modelde, tepe çapı kullanılarak yarıçap değeri çapın yarısı olarak tanımlanmış ve tepe hacmi, klasik koni hacim formülü ile hesaplanmıştır. Elipsoid modelde ise, taç yapısının üç boyutlu yayılımını daha gerçekçi temsil edebilmek amacıyla x, y ve z eksenlerindeki yarıçaplar ayrı ayrı belirlenmiş ve bu değerler elipsoid hacim formülünde kullanılmıştır. Her iki modele ilişkin tepe hacmi hesaplamalarına ait pseudo kod, Tablo 13’de verilmiştir.

Tablo 13. Ağaç tepe hacmine ait yazılan pseudo kodu

Girdi:
- tree_type → Ağaç türü ('Ladin' veya 'Kayın')
- canopy_radius → Taç çapının yarısı (m)
- canopy_height → Taç yüksekliği (m)
- a, b, c → Elipsoid model için X, Y, Z yönlerindeki yarıçaplar (m) [sadece Kayın için]

Tablo 13'ün devamı

Başlat:

- cone_volume = 0

- ellipsoid_volume = 0

- trunk_volume = 0

Eğer tree_type == 'Ladin' ise:

Tepe hacmi konik model ile hesaplanır

cone_volume = (1/3) * π * (canopy_radius)^2 * canopy_height

Eğer tree_type == 'Kayın' ise:


Tepe hacmi elipsoid model ile hesaplanır

ellipsoid_volume = (4/3) * π * a * b * c

Çıktı:

- Tepe hacmi → (Ladin için cone_volume, Kayın için ellipsoid_volume)


Hacim hesaplamalarında tercih edilen geometrik modellerin görselleştirilmesi, Google Colab ortamında Python programlama dili kullanılarak gerçekleştirilmiştir (Şekil 83).




Şekil 83. Konik, elipsoid ve silindirik modellerin gösterimi

Nokta bulutu verisinden ağaç boyu, gövde çapı, tepe çapı, tepe alanı ve tepe hacmi gibi meşçere bileşenlerinin doğru bir şekilde elde edilebilmesi, segmentasyonla belirlenen noktaların ağaçları ne ölçüde temsil edebildiğine bağlıdır. Ağaç yoğunluğuna göre değişkenlik gösteren bu temsil yeteneği, LiDAR sinyalinin ağaçlara nüfuz etme kapasitesini ve ağaçlara ait konumsal verilerin toplanma başarısını doğrudan etkilemektedir. Çalışma alanında düşük (1), orta (2) ve tam (3) kapalılık düzeyine sahip bölgeler bulunması, bu etkilerin ve farkların kolaylıkla gözlemlenebilmesine imkân sağlamıştır.

Çalışma alanındaki düşük (1) kapalılık düzeyine sahip alanda bulunan ladin ve kayın ağaç türlerine ait ağaç boyu ve gövde çapı bilgileri gösterilmiştir (Şekil 84 ve 85).




Şekil 84. Düşük (1) kapalılık sınıfına sahip alandan alınan ladin ve kayın ağaç türlerine ait ağaç boyu ve gövde çapı bilgileri



Şekil 85. Gövde çapının (DBH) tespitine yönelik görseller

Radyal yöntem kullanılarak elde edilen taç sınırına ait nokta dağılımı, taç alanı ve tepe taban çapı bilgileri gösterilmiştir (Şekil 86).



Şekil 86. Radyal yöntemle elde edilen meşçere bileşenleri

Orta ve tam kapalılığa sahip alanlarda, ağaç gövdelerine ait nokta verilerinin elde edilmesi önemli ölçüde güçleşmektedir. Bu nedenle, düşük kapalılık sınıfındaki alanlardan elde edilen ağaç boyu ile gövde çapı arasındaki ilişkiden yararlanılarak, diğer alanlardaki ağaçların gövde çapları ve ilgili meşçere bileşenlerinin tahmin edilmesi amaçlanmıştır.


Çalışma sınırları içerisinde yer alan kalan gevşek (1) kapalılık düzeyine sahip alandaki 97 adet Ladin ağaç türüne ait elde edilen meşçere bileşenleri gösterilmiştir (Şekil 87).

treeID	Ağaç No	Boy (m)	Gövde Çapı (cm)	Tepe Çapı (m)	Tepe Alanı (m ²)	Gövde Hacmi (m ³)	Tepe Hacmi (m ³)
0	828	L.23	20.356	56	7.947	33.537	3.133563
1	1164	L.24	21.332	49	7.592	32.850	2.514164
2	1252	L.14	12.115	36	6.616	17.264	0.770723
3	280	L.15	16.388	45	7.621	22.621	1.628999
4	597	L.129	19.427	42	6.407	18.271	1.682187
...	...	...	...	...	...	...	...
92	941	L.397	20.481	58	7.020	20.659	3.382027
93	740	L.395	19.546	56	6.945	22.786	3.008873
94	60	L.396	21.240	50	8.190	27.357	2.606540
95	400	L.309	24.696	63	10.032	47.046	4.811468
96	837	L.310	21.041	45	10.672	46.448	2.091517

97 rows × 8 columns


Şekil 87. Gevşek (1) kapalı alandaki ladin ağaç türüne ait meşçere bileşenleri (97 adet)

Ladin ağaç türüne ait meşçere bileşenlerinden ağaç boyu ve gövde çapına ait verilerinin dağılımını göstermek amacıyla kutu grafiği oluşturulmuştur (Şekil 88).




Şekil 88. Ladin ağaç türüne ait boy ve gövde çapı verilerinin kutu grafik gösterimi

Ladin ağaç türüne ait meşçere bileşenleri arasındaki ilişkilerin belirlenmesi amacıyla, korelasyon katsayılarını içeren ve renk skalasına dayalı olarak görselleştirilen bir korelasyon matrisi oluşturulmuştur. Şekil 89’da sunulan bu matriste, parametreler arasındaki ilişki düzeyleri renk yoğunlukları aracılığıyla temsil edilmiştir.



Şekil 89. Ladin ağaç türüne ait meşçere parametrelerinin korelasyon ilişkisi

Ağaç boyu ile gövde çapı arasındaki korelasyon oldukça yüksek olduğu ($r = 0,90$) tespit edilmiştir. Ladin ağaçlarında, boyu bilinen bireylerin gövde çapının tahmin edilebilmesi amacıyla çeşitli regresyon modelleri geliştirilmiştir. Söz konusu modellere ait performans metrikleri, tahmin denklemleri ve örnek bir boy değerine karşılık gelen tahmini gövde çapı sonuçları ayrıntılı olarak sunulmuştur (Şekil 90).



Şekil 90. Ladin ağaç boyu ve gövde çapı verilerine ait regresyon modelleri

Regresyon modellerinin karşılaştırılması sonucunda, R^2 (açıklama oranı) ve MAE (ortalama mutlak hata) performans metrikleri dikkate alındığında, Rastgele Orman Regresyon Modeli diğer modellere kıyasla daha başarılı sonuçlar vermiştir ($R^2:0,95$ – MAE: 2,19 cm).


Çalışma sınırları içinde yer alan gevşek (1) kapalılıktaki alanda bulunan 76 adet kayın ağaç türüne ait elde edilen meşçere bileşenleri sunulmuştur (Şekil 91).

	treeID	Ağaç No	Boy (m)	Gövde Çapı (cm)	Tepe Çapı (m)	Tepe Alanı (m2)	Gövde Hacmi (m3)	Tepe Hacmi (m3)
0	824	K.5	15.915	45	9.419	41.989	1.581982	536.546
1	386	K.4	17.328	50	11.068	58.070	2.126466	699.226
2	979	K.6	16.608	34	6.173	13.156	0.942421	240.220
3	893	K.7	12.912	38	8.816	48.059	0.915231	433.054
4	575	K.8	13.062	30	8.858	45.730	0.577061	437.508
...	...	...	...	...	...	...	...	...
71	996	K.215	22.464	48	6.542	17.198	2.540619	378.915
72	379	K.273	22.211	62	14.968	54.748	4.191036	1259.793
73	704	K272	20.057	54	11.513	27.919	2.870935	933.152
74	763	K.266	18.931	36	7.134	17.841	1.204338	215.155
75	971	K.304	18.165	49	12.940	69.019	2.140905	953.827

76 rows x 8 columns


Şekil 91. Gevşek (1) kapalı alandaki kayın ağaç türüne ait meşçere bileşenleri (76 adet)

Kayın ağaç türüne ait meşçere bileşenlerinden boy ve gövde çapına ait verilerin dağılımını gösteren bir kutu grafik oluşturulmuştur (Şekil 92).



Şekil 92. Kayın ağaç türüne ait boy ve gövde çapı verilerinin kutu grafik gösterimi


Kayın ağaç türüne ait meşçere bileşenleri arasındaki ilişkilerin analiz edilebilmesi amacıyla, korelasyon katsayılarını içeren ve renk skalasına dayalı olarak görselleştiren bir korelasyon matrisi oluşturulmuştur. Şekil 93'te sunulan matriste, bileşenler arasındaki ilişki düzeyleri renk yoğunlukları aracılığıyla temsil edilmiştir.



Şekil 93. Kayın ağaç türüne ait meşçere bileşenlerinin korelasyon ilişkisi

Ağaç boyu ve gövde çapı arasındaki korelasyonun yüksek düzeyde olduğu ($r = 0,87$) belirlenmiştir. Kayın ağaçlarında, boyu bilinen bireylerin gövde çapını tahmin edebilmek amacıyla çeşitli regresyon modelleri geliştirilmiştir.

Bu modellere ait performans metrikleri, tahmin denklemleri ve örnek bir boy değeri tahmini gövde çapı sonuçları ayrıntılı olarak sunulmuştur (Şekil 94).



Şekil 94. Kayın ağaç boyu ve gövde çapı verilerine ait regresyon modelleri


Regresyon modellerinin değerlendirilmesi sonucunda, R^2 (açıklama oranı) ve MAE (ortalama mutlak hata) değerleri dikkate alındığında Rastgele Orman regresyon modelinin diğer modellere kıyasla daha üstün performans gösterdiği belirlenmiştir ($R^2: 0.94$ – $MAE: 2.22$ cm).

Çalışma sınırları içinde kalan gevşek (1) kapalı alandaki 16 adet kuru ladin ağaç türüne ait elde edilen meşçere parametreleri sunulmuştur (Şekil 95). Ancak, kuru ladin bireylerinin düzensiz formu nedeniyle hacimle ilgili parametreler hesaplanmamıştır.

treeID	Ağaç No	Boy (m)	Gövde Çapı (cm)	Tepe Çapı (m)	Tepe Alanı (m ²)
0	10	L.6	22.971	49	4.015
1	582	L.8	16.932	34	2.527
2	431	L.9	17.620	35	2.248
3	385	L.5	16.308	28	3.447
4	7	L.12	16.985	45	3.684
5	335	L.22	14.368	31	2.549
6	1041	L.21	16.280	29	3.200
7	1316	L.19	13.808	34	3.204
8	1093	L.13	17.521	35	4.323
9	14	L.32	12.446	24	0.204
10	13	L.102	22.890	60	4.426
11	36	L.304	23.766	61	2.237
12	186	L.186	19.127	49	5.620
13	861	L.861	22.482	55	3.103
14	5	L.385	26.347	58	4.118
15	512	L.512	22.366	55	3.295


Şekil 95. Gevşek (1) kapalı alandaki kuru ladin ağaç türüne ait meşçere bileşenleri (16 adet)

Kuru Ladin ağaç türüne ait meşçere bileşenlerinden boy ve gövde çapına ait verilerin dağılımını gösteren kutu grafik çizilmiştir (Şekil 96).



Şekil 96. Kuru ladin ağaç türüne ait boy ve gövde çapı verilerinin kutu grafik gösterimi


Kuru ladin ağaç türüne ait meşçere bileşenleri arasındaki ilişkilerin analiz edilebilmesi amacıyla, korelasyon katsayılarını içeren ve renk skalasına dayalı olarak görselleştirilen bir korelasyon matrisi oluşturulmuştur. Şekil 97’de sunulan bu matraste, bileşenler arasındaki ilişki düzeyleri renk yoğunlukları aracılığıyla ifade edilmiştir.



Şekil 97. Kuru Ladin ağaç türüne ait meşçere bileşenlerinin korelasyon ilişkisi

Yükseklik ile gövde çapı arasındaki korelasyonun oldukça yüksek düzeyde olduğu ($r = 0,92$) belirlenmiştir. Kuru ladin ağaçlarında, boyu bilinen bireylerin gövde çapını tahmin edebilmek amacıyla çeşitli regresyon modelleri geliştirilmiştir.

Bu modellere ait performans metrikleri, tahmin denklemleri ve örnek bir boy değerine karşılık gelen tahmini gövde çapı sonuçları ayrıntılı olarak sunulmuştur (Şekil 98).



Şekil 98. Kuru ladin ağaç boyu ve gövde çapı verilerine ait regresyon modelleri

Regresyon modellerinin değerlendirilmesi sonucunda, R^2 (açıklama oranı) ve MAE (ortalama mutlak hata) değerleri dikkate alındığında Aşırı Gradyan Artırma (XGBoost) regresyon modelinin diğer modellere kıyasla en yüksek performansı gösterdiği belirlenmiştir ($R^2: 1,00$ – MAE: 0,25 cm).

Ladin, kayın ve kuru ladin gibi ağaç türlerinden elde edilen meşçere bileşenleri kullanılarak oluşturulan regresyon modelleri arasında, ağaç tabanlı makine öğrenme algoritmaları olan Rastgele Orman ve Aşırı Gradyan Artırma modellerinin en başarılı sonuçları verdiği belirlenmiştir (Tablo 14).

Tablo 14. Regresyon modellerinin elde etmiş olduğu performans metrikleri

Regresyon Modelleri	Ladin		Kayın		Kuru Ladin	
	R ²	MAE	R ²	MAE	R ²	MAE
Doğrusal	0,81	4,63	0,76	4,54	0,84	4,46
Polinomsal	0,81	4,58	0,76	4,46	0,84	4,47
Logaritmik	0,78	5,04	0,71	4,79	0,83	4,68
Destek Vektör	0,80	4,31	0,77	4,19	0,89	2,43
Rastgele Orman	0,95	2,19	0,94	2,22	0,96	1,88
XGBoost	0,93	2,63	0,92	2,57	1,00	0,25

3.6. Ağaç Türü Tahmini

Segmentasyon iyileştirme işlemi sonrasında, 115 ladin, 91 kayın ve 27 kuru ladin bireyine ait nokta bulutu verisi elde edilmiştir. Bu veriler, derin öğrenme algoritmalarından PointNet, PointNet++ ve DGCNN mimarileri kullanılarak eğitilmiş ve ağaç türü tahmini gerçekleştirebilen modeller oluşturulmuştur. Modeller, her bir ağaç türüne ait nokta bulutu verilerini analiz ederek tür sınıflandırması yapabilecek şekilde tasarlanmıştır. Böylece, ağaç türlerinin doğru ve hızlı bir şekilde tespit edilmesi hedeflenmiştir.

Model eğitime geçilmeden önce, veri hazırlık aşamasında nokta bulutu verileri standart bir formata düzenlenmiştir. Segmentasyon işlemi sonrasında elde edilen her nokta bulutunun nokta sayısı, 2048 olacak şekilde sabitlenmiştir. Bu süreçte:


- Nokta sayısı yetersiz olan nokta bulutları, enterpolasyon yöntemi kullanılarak çoğaltılmıştır.
- Nokta sayısı fazla olan nokta bulutları, FPS (Farthest Point Sampling) algoritması kullanılarak azaltılmıştır.
- Nokta sayıları sabitlenen her nokta bulutu verisine, ait olduğu ağaç türüne göre etiketler atanmıştır; Ladin=0, Kayın=1, Kuru Ladin=2 olacak şekildedir.
- Düzenlenmiş nokta bulutları ve ilgili etiketleri, HDF5 formatında (.h5) saklanmıştır.

Her ağaç türü için ayrı ayrı oluşturulan HDF5 dosyaları, tüm ağaç türlerini içerecek şekilde tek bir birleşik HDF5 veri kümesi hâline getirilmiştir. Hazırlanan bu veri kümesi, model eğitiminde kullanılmak üzere düzenlenmiştir.


Ladin, kayın ve kuru ladin ağaç türlerinden oluşan veri kümesi, eğitim (%70), test (%15) ve doğrulama (%15) olmak üzere üç gruba ayrılmıştır. Bu ayırım, veri kümesinin farklı aşamalarda etkili bir şekilde kullanılmasını sağlamıştır. Ayrılan veri grupları kullanılarak, PointNet, PointNet++ ve DGCNN mimarileri üzerinden modeller eğitilmiştir. Üç farklı derin

öğrenme mimarisinden elde edilen sonuçlara ilişkin başarı metrikleri hesaplanarak değerlendirilmiştir.

Model eğitiminde kullanılan veri setlerindeki etiketli bireylerin mekânsal dağılımı, gevşek kapalı meşçere alanı için Şekil 99'da, orta ve tam kapalı meşçere alanı için ise Şekil 100'de görselleştirilmiştir.



Şekil 99. Gevşek kapalı meşçere alanında etiketlenmiş ağaç türlerinin mekânsal dağılımı



Şekil 100. Orta ve tam kapalı meşçere alanında etiketlenmiş ağaç türlerinin mekânsal dağılımı

3.6.1. PointNet Mimarisi

Doğrudan ham nokta bulutu verileri üzerinde çalışan bu mimari, konvolüsyon katmanları (Conv1D) aracılığıyla noktalardan öznitelikler çıkarmaktadır (Qi vd., 2017). Ardından, maksimum havuzlama (GlobalMaxPooling1D) işlemi kullanılarak global

öznitelikler yakalanmakta ve tam bağlı (Dense) katmanlar aracılığıyla sınıflandırma işlemi gerçekleştirilmektedir (Qi vd., 2017).

PointNet sınıfı, Conv1D katmanları ve AdaptiveMaxPool1d katmanı içermektedir. Model, giriş olarak 2048 adet 3B noktayı almakta ve bu noktaları 256 boyutlu özellik vektörüne dönüştürmektedir. Eğitim sürecinde Adam optimizasyonu ve Çapraz Entropi Kayıp Fonksiyonu (CrossEntropyLoss) kullanılmıştır. PointNet mimarisinde kullanılan hiperparametreler Tablo 15’te sunulmuştur.

Tablo 15. PointNet mimarisine ait hiperparametreler

Hiperparametre	Değer	Açıklama
num_classes=3	Modelin çıkış sınıfı sayısı (Ladin, Kayın, Kuru Ladin)	Modelin kaç farklı sınıfa ayıracağını belirler
Kernel_size=1	Konvolüsyon katmanındaki çekirdek boyutu	Nokta bazlı öğrenme için kullanılır
dropout=0.3	%30 oranında rastgele nöronları devre dışı bırakır	Aşırı öğrenmeyi (overfitting) önler, modelin genelleştirme yeteneğini artırır
Öğrenme Oranı (learning_rate)	0.001	Modelin ağırlıklarını ne kadar hızla güncelleyeceğini belirler
Epoch Sayısı	50	Modelin eğitim süresi, veri setine bağlıdır
Batch Size	32	Kaç örneğin aynı anda işleneceğini belirler
Aktivasyon Fonksiyonu	ReLU	Lineer olmayan dönüşüm için kullanılır
Optimizasyon Algoritması	Adam	Verimli ve stabil öğrenme için kullanılır
Kayıp Fonksiyon	CrossEntropyLoss	Çok sınıflı sınıflandırma için uygundur

Modele ilişkin test ve doğrulama veri setlerine ait başarı metrikleri Tablo 16’da verilmiştir.

Tablo 16. Test ve doğrulama veri setlerine ait başarı metrikleri

	Test Veri Seti				Doğrulama Veri Seti			
	precision	recall	F1-score	support	precision	recall	F1-score	support
Ladin	0,8824	0,8333	0,8571	18	0,8571	0,8571	0,8571	14
Kayın	0,8462	0,8462	0,8462	13	0,8462	0,8462	0,8462	13
Kuru Ladin	0,8000	1,0000	0,8889	4	1,0000	1,0000	1,0000	8
accuracy			0,8571	35			0,8857	35
macro avg	0,8428	0,8932	0,8641	35	0,9011	0,9011	0,9011	35
weighted avg	0,8595	0,8571	0,8567	35	0,8857	0,8857	0,8857	35

Modelden elde edilen test ve doğrulama sonuçlarına ait karışıklık (confusion) matrisi Tablo 17’de verilmiştir.


Tablo 17. Test ve doğrulama veri setlerine ait karışıklık matrisi

	Test Veri Seti			Doğrulama Veri Seti		
	Ladin	Kayın	Kuru Ladin	Ladin	Kayın	Kuru Ladin
Ladin	15	2	1	12	2	0
Kayın	2	11	0	2	11	0
Kuru Ladin	0	0	4	0	0	8


Ağaç türü tahmini amacıyla eğitilen modele herhangi bir nokta bulutu verisi dâhil edilerek, bu verinin üç ağaç türünden hangisine ait olduğu tespit edilmeye çalışılmıştır. Model performansına ilişkin metrikler incelendiğinde, eğitim doğruluğu %95,09, test doğruluğu %85,71 ve doğrulama doğruluğu %88,57 olarak belirlenmiştir.

Modelin ladin, kayın ve kuru ladin ağaç türleri için gerçekleştirdiği tahmin sonuçları, elde edilen başarı oranlarını görsellerle desteklemektedir (Şekil 101). Söz konusu görseller, modelin ağaç türlerini doğru şekilde sınıflandırma performansını açık bir şekilde ortaya koymaktadır.

PointNet mimarisi ile gerçekleştirilen model eğitimi kapsamında kullanılan ağaç örneklerinin, üç farklı kapalılık sınıfına (gevşek, orta ve tam) göre mekânsal dağılımları da görselleştirilmiştir (Şekil 102).



Şekil 101. PointNet mimarisine ait model ile tahmin edilen ağaç türlerine ait örnekler



Şekil 102. PointNet mimarisinde kullanılan etiketli ağaçların mekânsal dağılımı

3.6.2. PointNet++ Mimarisi

PointNet modeli, PointNet mimarisinin geliştirilmiş bir versiyonudur. Nokta kümeleri (sub-sampling) kullanarak lokal özellikleri öğrenebilmekte ve ekstra bir konvolüsyon katmanı (Conv1D(512)) ekleyerek daha karmaşık desenleri yakalayabilmektedir. Daha derin bir ağ yapısına sahip olan bu model, güçlü temsil öğrenimini desteklemektedir. Ayrıca, hiyerarşik özellik öğrenimi (Hierarchical Feature Learning) mekanizması eklenerek daha yüksek doğruluk değerlerine ulaşması hedeflenmiştir (Qi vd., 2017). PointNet++ mimarisinde kullanılan hiperparametreler Tablo 18’de sunulmuştur.

Tablo 18. PointNet++ mimarisine ait hiperparametreler

Hiperparametre	Değer	Açıklama
Öğrenme Oranı (learning_rate)	0,0005	Daha derin bir ağ olduğu için daha düşük hızla öğrenmesi gerekir
Epoch Sayısı	100	Daha derin ağ yapısı olduğundan uzun sürede öğrenme sağlar
Batch Size	32	Daha fazla özellik çıkarımı yapıldığı için genellikle daha küçük tutulur
Aktivasyon Fonksiyonu	ReLU	Lineer olmayan dönüşüm için kullanılır
Optimizasyon Algoritması	Adam veya SGD	Adam genellikle kullanılsa da SGD ile momentum artırılabilir
Kayıp Fonksiyon	CrossEntropyLoss	Çok sınıflı sınıflandırma için uygundur

Modele ilişkin test test ve doğrulama veri setlerine ait başarı metrikleri Tablo 19’da verilmiştir.

Tablo 19. Test ve doğrulama veri setlerine ait başarı metrikleri

	Test Veri Seti				Doğrulama Veri Seti			
	precision	recall	F1-score	support	precision	recall	F1-score	support
Ladin	0,9444	0,9444	0,9444	18	0,8125	0,9286	0,8667	14
Kayın	0,9231	0,9231	0,9231	13	0,9167	0,8462	0,8800	13
Kuru Ladin	1,0000	1,0000	0,8889	4	1,0000	0,8750	0,9333	8
accuracy			0,9429	35			0,8857	35
macro avg	0,9558	0,9558	0,9558	35	0,9097	0,8832	0,8933	35
weighted avg	0,9429	0,9429	0,9429	35	0,8940	0,8857	0,8869	35

Modelden elde edilen test ve doğrulama sonuçlarına ait karışıklık (confusion) matrisi Tablo 20’de verilmiştir.


Tablo 20. Test ve doğrulama veri setlerine ait karışıklık matrisi

	Test Veri Seti			Doğrulama Veri Seti		
	Ladin	Kayın	Kuru Ladin	Ladin	Kayın	Kuru Ladin
Ladin	17	1	0	13	1	0
Kayın	1	12	0	2	11	0
Kuru Ladin	0	0	4	1	0	7


Verilere ait performans metrikleri incelendiğinde, eğitim doğruluğu %95,71, test doğruluğu %94,29 ve doğrulama doğruluğu %88,57 olarak belirlenmiştir.

Modelin ladin, kayın ve kuru ladin ağaç türleri için gerçekleştirdiği tahmin sonuçları, elde edilen başarı oranlarını görsellerle desteklemektedir (Şekil 103). Söz konusu görseller, modelin ağaç türlerini doğru şekilde sınıflandırma performansını açık bir şekilde ortaya koymaktadır.

PointNet++ mimarisi ile gerçekleştirilen model eğitimi kapsamında kullanılan ağaç örneklerinin, üç farklı kapalılık sınıfına (gevşek, orta ve tam) göre mekânsal dağılımları da görselleştirilmiştir (Şekil 104).



Şekil 103. PointNet++ mimarisine ait model ile tahmin edilen ağaç türlerine ait örnekler



Şekil 104. PointNet++ mimarisinde kullanılan etiketli ağaçların mekânsal dağılımı

3.6.3. DGCNN Mimarisi

Dinamik Grafik Konvolüsyonel Sinir Ağı (Dynamic Graph Convolutional Neural Network-DGCNN), nokta bulutu verisini grafik yapısında işleyerek noktalar arasındaki ilişkileri öğrenen bir derin öğrenme modelidir. Model, K-En Yakın Komşu (K-Nearest Neighbors) algoritması kullanarak noktalar arasındaki bağlantıları dinamik olarak belirlemekte ve bu bağlantılar üzerinden uzamsal ilişkileri öğrenmektedir (Wang vd., 2019).

DGCNN sınıfı, PointNet++ modeline benzer bir yapı kullanmakla birlikte, grafik tabanlı ilişkilendirme mekanizması aracılığıyla noktalar arasındaki bağları dinamik olarak hesaplamaktadır. Model, maksimum havuzlama (AdaptiveMaxPool1d) işlemi ile en belirgin öznitelikleri seçmektedir. DGCNN mimarisinde kullanılan hiper parametreler Tablo 21’de sunulmuştur.

Tablo 21. DGCNN mimarisine ait hiperparametreler

Hiperparametre	Değer	Açıklama
Öğrenme Oranı (learning_rate)	0,0005	Graf bazlı işlemler daha kompleks olduğu için düşük hızda öğrenme daha iyidir
Epoch Sayısı	200	Modelin dinamik grafik hesaplaması uzun sürdüğü için daha fazla epoch gereklidir
Batch Size	16	Büyük model olduğu için düşük batch size daha stabil çalışır
Aktivasyon Fonksiyonu	LeakyReLU	LeakyReLU, negatif değerler için daha stabil bir öğrenme sağlar
Optimizasyon Algoritması	AdamW veya SGD + Momentum	AdamW ağırlık çürümesiyle (weight decay) daha stabil sonuç verir
Kayıp Fonksiyon	CrossEntropyLoss	Çok sınıflı sınıflandırma için uygundur
KNN Komşuluk Sayısı (k)	20	Komşuluk ilişkileri için kullanılan nokta sayısı

DGCNN, klasik CNN’lerden farklı olarak noktalar arasındaki ilişkileri öğrenir. En yakın komşular hesaplandığı için ek hiperparametreler kullanılır. Daha düşük öğrenme oranı gereklidir, çünkü hesaplamalar daha karmaşıktır.

Modele ilişkin test test ve doğrulama veri setlerine ait başarı metrikleri Tablo 22’de verilmiştir.

Tablo 22. Test ve doğrulama veri setlerine ait başarı metrikleri

	Test Veri Seti				Doğrulama Veri Seti			
	precision	recall	F1-score	support	precision	recall	F1-score	support
Ladin	0,9375	0,8333	0,8824	18	0,8125	0,9286	0,8667	14
Kayın	0,8571	0,9231	0,8889	13	0,9091	0,7692	0,8333	13
Kuru Ladin	0,8000	1,0000	0,8889	4	1,0000	1,0000	1,0000	8
accuracy			0,8857	35			0,8857	35
macro avg	0,9558	0,9558	0,8867	35	0,9072	0,8993	0,9000	35
weighted avg	0,9429	0,9429	0,8855	35	0,8912	0,8857	0,8848	35

Modelden elde edilen test ve doğrulama sonuçlarına ait karışıklık (confusion) matrisi Tablo 23’de verilmiştir.


Tablo 23. Test ve doğrulama veri setlerine ait karışıklık matrisi

	Test Veri Seti			Doğrulama Veri Seti		
	Ladin	Kayın	Kuru Ladin	Ladin	Kayın	Kuru Ladin
Ladin	15	2	1	13	1	0
Kayın	1	12	0	3	10	0
Kuru Ladin	0	0	4	0	0	8


Verilere ait performans metriklerine bakıldığında eğitim doğruluğu %96,93, test doğruluğu %88,57 ve doğrulama doğruluğu %88,57 bulunmuştur.

Modelin ladin, kayın ve kuru ladin ağaç türleri için gerçekleştirdiği tahmin sonuçları, elde edilen başarı oranlarını görsellerle desteklemektedir (Şekil 105). Söz konusu görseller, modelin ağaç türlerini doğru şekilde sınıflandırma performansını açık bir şekilde ortaya koymaktadır.

DGCNN mimarisi ile gerçekleştirilen model eğitimi kapsamında kullanılan ağaç örneklerinin, üç farklı kapalılık sınıfına (gevşek, orta ve tam) göre mekânsal dağılımları da görselleştirilmiştir (Şekil 106).



Şekil 105. DGCNN mimarisine ait model ile tahmin edilen ağaç türlerine ait örnekler



Şekil 106. DGCNN mimarisinde kullanılan etiketli ağaçların mekânsal dağılımı

4. BULGULAR VE İRDELEME


İnsansız hava aracı (İHA) kullanılarak L1 ve P1 sensörleri ile elde edilen LiDAR nokta bulutu ve fotogrametrik nokta bulutunun üretimiyle başlayan süreç, meşçere bileşenlerinin kestirimi ve ağaç türü tahmini aşamalarına kadar ilerlemiştir. Bu süreçte, ham nokta bulutunun sınıflandırılması ve iyileştirilmesi, Meşçere Boy Modeli'nin (MBM) oluşturulması, bireysel ağaç segmentasyonu ile segmentasyon sonuçlarının iyileştirilmesi gibi temel işlem adımları gerçekleştirilmiştir. Ayrıca, her bir aşamda alternatif yöntemler değerlendirilmiş ve elde edilen sonuçlar ayrıntılı bir şekilde analiz edilmiştir.

Teknolojinin sürekli gelişimi ile birlikte, elde edilen verilerin doğruluğu artmakta ve kullanılan analiz yöntemleri giderek daha hassas hâle gelmektedir. Bu ilerleme, meşçere bileşenlerinin kestirimi ve ağaç türü tahmini süreçlerini daha güvenilir ve verimli bir hâle getirmiş; gelecekte ise daha yüksek doğrulukta tahminlerin yapılmasına olanak sağlayacaktır. Çalışmada gerçekleştirilen tüm analizler ve veri işleme adımları, Intel® Core™ i5-2400 CPU 3.10 GHz işlemcili ve 8 GB RAM'e sahip bir bilgisayar ortamında yürütülmüştür. Yazılım süreçlerinde Cloud Compare ve Global Mapper gibi yazılımların yanı sıra, Google Colab, R ve Jupyter Notebook gibi kodlama ortamları kullanılmıştır. Bu teknolojik altyapı, büyük veri kümeleri ile çalışma imkânı sunmuş ve farklı yöntemlerin karşılaştırmalı analizine olanak sağlayarak en uygun tekniklerin belirlenmesine katkı sağlamıştır.

4.1. Nokta Bulutu Verilerinin İrdelenmesi


İki farklı sensör (L1 ve P1) kullanılarak gerçekleştirilen ölçümlerde, arazinin yüksek eğimli yapısı dikkate alınarak farklı uçuş yükseklikleri tercih edilmiş ve veri toplama işlemi bu doğrultuda tamamlanmıştır. L1 sensörüyle gerçekleşen uçuşlar, üç farklı uçuş yüksekliği ve farklı rotalar olacak şekilde planlanmıştır. İlk uçuş, kalkış noktasının 50 metre üzerinde olacak şekilde gerçekleştirilmiş ve bu uçuş rotası boyunca LiDAR nokta bulutu verisi toplanmıştır. Takip eden etaplarda ise, zeminden sırasıyla 150 metre ve 350 metre yükseklikte yeni uçuş rotaları belirlenmiş ve bu yüksekliklerden de veri toplama işlemleri başarıyla gerçekleştirilmiştir.

Toplanan nokta bulutlarının analizleri sonucunda, 50 metre yükseklikte gerçekleştirilen uçuşlarda elde edilen nokta bulutu yoğunluğunun, 150 ve 350 metre yüksekliklerinden elde edilen nokta bulutlarına kıyasla daha yüksek olduğu gözlemlenmiştir. Daha düşük irtifadan gerçekleştirilen uçuşlar sayesinde, ağaçların yapısal özellikleri daha ayrıntılı biçimde temsil edilebilmiştir. Buna karşılık, 150 ve 350 metre yükseklikten elde edilen nokta bulutlarının ağaçları temsil etme kapasitesinin daha zayıf olduğu tespit edilmiştir. Bu durum, lazer darbelerinin hedef yüzeye ulaşmasındaki zayıflık ve detayları yeterince yakalayamaması ile ilişkilidir. Dolayısıyla, uçuş yüksekliği ile elde edilen veri ayrıntısı arasında doğrudan bir ilişki bulunduğu bir kez daha ortaya konmuştur (Şekil 107).




Şekil 107. Uçuş yüksekliği 150 m. (üst) ve 350 m. (alt) olan nokta bulutu verileri

P1 sensörü ile elde edilen hava fotoğraflarından üretilen nokta bulutu verisinin, L1 sensörü ile elde edilen nokta bulutuna kıyasla, ağaçları temsil eden nokta yoğunluğunun daha seyrek olduğu gözlemlenmiştir. Bu durum, P1 sensörünün veri toplama yönteminin ağaçların yapısal detaylarını daha düşük hassasiyetle yakalanmasından kaynaklanmaktadır. Özellikle yoğun bitki örtüsüne sahip alanlarda, P1 sensörü ile üretilen nokta bulutu verisinin, ağaçların tepe yapıları ve ince dallar gibi yapısal unsurlarını eksik veya daha düşük yoğunlukla temsil ettiği belirlenmiştir. Ayrıca, fotogrametrik yöntemle üretilen nokta bulutlarının ağaçlık alanlarda zemine ait noktaları yeterli düzeyde temsil edemediği de önemli bir eksiklik olarak tespit edilmiştir (Şekil 108).



Şekil 108. P1 sensörü kullanılarak elde edilen nokta bulutu verisi

İki farklı sensör kullanılarak gerçekleştirilen uçuşların ardından, elde edilen ham nokta bulutu verilerine PPK (Post-Processed Kinematic) yöntemi ile düzeltme uygulanmış; sonrasında her iki veri birleştirilerek daha yoğun bir birleşik nokta bulutu elde edilmiştir (Şekil 109). Nokta yoğunluğunun düşük olduğu alanlar, ağaçları temsil etme yeteneği zayıf olacağından veri setinden çıkartılmış ve çalışma alanı, daha yoğun nokta bulutuna sahip bölgelerle sınırlandırılmıştır. Hem LiDAR hem de fotogrametrik nokta bulutlarının, 10 cm'nin altında bir karesel ortalama hata ile dengeleyerek bütünleştirilmesi, çalışmanın önemli aşamalarından birini oluşturmaktadır.




Şekil 109. L1 ve P1 nokta bulutu verilerinin birleştirilmiş hali

4.2. Sınıflandırma Yöntemlerinin İrdelenmesi

Nokta bulutu verisi için gerçekleştirilen sınıflandırma işlemi, ilerleyen analiz süreçlerini doğrudan etkilediği için büyük dikkat gerektiren kritik bir aşamadır. Zemin ve zemin üstü noktaları birbirinden ayırt edebilmek amacıyla üç farklı yöntem uygulanmıştır. İlk olarak, TBC yazılımı kullanılarak otomatik sınıflandırma gerçekleştirilmiş; ardından kesitler yardımıyla sınıflandırma işlemi iyileştirilmiş ve yarı-otomatik bir süreçle tamamlanmıştır. Ayrıca, aynı nokta bulutuna PMF ve CSF algoritmaları uygulanarak da sınıflandırma yapılmıştır. Yüksek eğimli ve ormanlık alan özellikleri dikkate alınarak her

algoritma için uygun parametre seçimleri yapılmıştır. Üç farklı yöntemle ait sınıflandırma sonuçları incelendiğinde, zemine ait tespit edilen noktalarda belirgin farklılıkların bulunduğu gözlemlenmiştir (Şekil 110).



Şekil 110. Zemine ait olan ve olmayan noktaların tespitinde kullanılan yöntemlere ait sonuçlar; a) TBC-yarı otomatik, b) PMF, c) CSF


TBC yazılımı tarafından gerçekleştirilen otomatik sınıflandırmanın ardından, kesitler yardımıyla yapılan manuel düzeltmelerle süreç yarı otomatik bir hâl almıştır. PMF ve CSF algoritmalarında ise, sınıflandırma işleminin gerçekleştirilebilmesi için yalnızca çalışma alanına uygun parametre değerlerinin belirlenmesi yeterli olmuştur. Elde edilen sonuçlar değerlendirildiğinde, PMF algoritmasının TBC ile yarı otomatik yöntemle elde edilen sonuçlara oldukça yakın çıktılar ürettiği; buna karşın CSF algoritmasının aynı düzeyde başarılı olamadığı görülmüştür. TBC'nin ticari bir yazılım olması nedeniyle, benzer doğruluk düzeyine sahip sonuçlar sunabilen PMF algoritması alternatif olarak tercih edilebilir. Ancak, zemine ait olmayan noktaların kendi içinde sınıflandırılması aşamasında hâlâ kesitler yardımıyla yapılan yarı-otomatik yöntemlere ihtiyaç duyulmaktadır. Örneğin, telesiyaj yapısı gibi karmaşık nesneler farklı sınıflara atanmış olsa da, bu noktalar kesitler yardımıyla tespit edilerek doğru sınıflara yeniden dâhil edilmiştir. Ağaç boyu gibi meşçere bileşeninin doğruluğu, doğrudan zemin noktalarının doğruluğu ile ilişkilidir. Bu nedenle,

zemin noktası olarak kullanılacak verinin hassasiyeti, Meşçere Boy Modeli'nin doğru şekilde oluşturulmasını doğrudan etkileyecektir.

4.3. Meşçere Boy Modelinin İrdelenmesi

Meşçere Boy Modeli (MBM), yükseklik normalizasyonu olarak da bilinen ve sayısal yüzey modelinin sayısal arazi modelinden farkının alınması işlemidir. Bu işlemde, sınıflandırma başarısı kritik bir öneme sahiptir; zira yanlış sınıflandırılmış zemin noktaları, modelin doğruluğunu doğrudan etkilemektedir. Çalışma kapsamında, nokta bulutu tabanlı ve raster tabanlı olmak üzere iki farklı yöntemle Meşçere Boy Modeli (MBM) oluşturulmuştur.

Nokta bulutu tabanlı yöntemlerden ilki olarak, Cloud Compare yazılımında yer alan C2M (Clouth to Mesh Distance) fonksiyonu kullanılmıştır. Bu yöntemde, zemine ait nokta bulutuyla oluşturulan ağ (mesh) yapısı üzerinden, zemin üstü noktalara ait Öklid uzaklıkları hesaplanarak MBM elde edilmiştir. İkinci yöntem ise, R programla ortamında kullanılan *normalize_height* fonksiyonu aracılığıyla gerçekleştirilmiş; bu yöntemde, farklı enterpolasyon teknikleri olan (IDW ve TIN) kullanılarak MBM oluşturulmuştur (Şekil 111). Her iki yöntemle elde edilen sonuçlar, referans veride yer alan ağaç boyu yükseklik bilgileriyle karşılaştırılarak değerlendirilmiştir (Tablo 24).




Şekil 111. Nokta bulutu yöntemleriyle elde edilen MBM'ye ait bilgiler

Tablo 24. Referans verisi ve nokta bulutu tabanlı yöntemlerle bulunan ağaç boylarının karşılaştırılması

Ağaç Numarası	Ağaç Boyu (Referans) (m)	Cloud Compare (C2M) (m)	R – normalize_height (IDW) (m)	R – normalize_height (TIN) (m)
1	27,00	27,896	27,925	27,921
2	23,00	22,588	22,593	22,590
3	21,50	21,771	21,752	21,796
4	27,50	27,899	28,031	28,128
5	-	21,609	21,605	21,633
6	21,50	22,075	22,021	22,019
7	22,00	22,618	22,623	22,638
8	18,00	18,405	18,362	18,384
9	17,50	17,868	18,514	17,898
10	23,00	22,446	22,392	22,387
11	22,00	22,585	22,564	22,584
12	18,50	18,204	19,257	18,745
13	22,50	22,876	22,926	22,980
14	23,00	22,313	22,416	22,422
15	20,50	20,189	20,279	20,325
16	26,00	26,284	26,261	26,262
17	15,50	14,978	14,963	14,962

Çalışma alanı içerisinde belirlenmiş referans alan içinde, (a)-(c) *p2r* algoritması ile *idw* enterpolasyon yöntemiyle elde edilen raster MBM ve tespit edilen ağaç tepeleri, (b)-(d), *pitfree* algoritması ile *tin* enterpolasyon yöntemiyle elde edilen raster MBM ve tespit edilen ağaç tepeleri gösterilmiştir (Şekil 112).

Raster tabanlı yöntemlerle elde edilen sonuçlar referans verisiyle karşılaştırılmıştır (Tablo 25).



Şekil 112. Raster tabanlı MBM ve ağaç tepe noktaları

Tablo 25. Referans verisi ve raster tabanlı yöntemlerle bulunan ağaç boylarının karşılaştırılması

Ağaç Numarası	Ağaç Boyu (Referans) (m)	R (KYM-p2r) (m)	R (KYM-pitfree) (m)	Ağaç Boyu (Referans) (m)	Ağaç Numarası
1	17,50	18,885	17,965	17,50	1
2	20,50	20,371	20,156	20,50	2
3	18,50	19,384	18,646	18,50	3
4	23,00	22,714	22,366	23,00	4
5	22,00	22,839	22,750	22,00	5
6	21,50	22,226	22,116	21,50	6

Tablo 25'in devamı

7	21,50	22,056	21,790	21,50	7
8	23,00	22,624	22,389	23,00	8
9	-	22,014	21,730	-	9
10	27,50	28,170	28,048	27,50	10
11	22,00	22,756	27,964	27,00	11
12	27,00	28,240	22,702	22,00	12
13	18,00	18,501	18,418	18,00	13
14	23,00	22,848	22,639	23,00	14
15	26,00	26,305	26,228	26,00	15
16	22,50	23,216	22,849	22,50	16
17	15,50	-	14,930	15,50	17

Raster tabanlı MBM oluşturulmasında kullanılan *p2r* ve *pitfree* fonksiyonlarında, çözünürlük parametresi, tepe noktası arama pencere boyutları ve maksimum yükseklik gibi parametrelerde yapılan değişiklikler, elde edilen sonuçları doğrudan etkilemektedir. Yapılan karşılaştırmalar doğrultusunda, raster tabanlı yöntemler arasında *pitfree* fonksiyonunun, *p2r* fonksiyonuna kıyasla daha başarılı sonuçlar verdiği söylenebilir.

MBM oluşturulmasında kullanılan nokta bulutu tabanlı yöntemlerin, elde edilen sonuçların doğruluğu ve ağaç sayısını tespit etmekteki başarısı dikkat çekmektedir. Raster tabanlı yöntemler arasında ise, *pitfree* yöntemi, nokta bulutu tabanlı yöntemlerle elde edilen sonuçlara oldukça yakın bir performans sergilemiştir. Her iki yöntemin de, referans veriye kıyasla bir adet fazla ağaç tespit ettiği gözlemlenmiştir.

Meşçere bileşenlerinden ağaç boyunun en doğru şekilde tespit edebilmesi için, MBM yüksek hassasiyetle oluşturulması gerekmektedir. Bu nedenle, çalışmada her iki yöntem (nokta bulutu tabanlı ve raster tabanlı) kullanılarak hem yöntemler arası hem de referans verisi ile karşılaştırma yapılması mümkün kılınmıştır.

4.4. Segmentasyon Yöntemlerinin İrdelenmesi

Nokta bulutu ve raster tabanlı segmentasyon yöntemleri, birbirinden farklı algoritmalara dayalı olarak kümeleme ve ayırma işlemlerini gerçekleştirmektedir. Segmentasyon işlemlerinde başlangıç noktası seçimi kritik öneme sahiptir. Noktaların birbirinden ayrılabilmesi için uygun bir başlangıç noktası ve ayırma kriterlerinin belirlenmesi gerekmektedir. Nokta bulutu tabanlı algoritmalarda segmentasyon işlemi genellikle

kümeleme temelli bir yaklaşımı sergilemekte; bu kapsamda, nokta yoğunluğunun yüksek olduğu alandan bir başlangıç noktası seçilmekte ve ardından Öklid uzaklığına dayalı olarak nokta bulutu segmentlere ayrılmaktadır. Ancak bu yaklaşım, özellikle ormanlık alanlarda hava LiDAR verisinden bireysel ağaçları ayırt etmek için yeterince uygun değildir. Referans verilerin elde edildiği çalışma alanında uygulanan algoritmalar ve bu algoritmalarından elde edilen sonuçlar Tablo 26’da sunulmuştur.

Tablo 26. Nokta bulutu tabanlı algoritmalarla yapılan segmentasyon sonuçları

Algoritma ve Kullanılan Parametreler	Küme Sayısı	Referans (ağaç sayısı)
BIRCH (threshold=2, 5, 10, 20)	276, 24, 8, 1	17
DBSCAN (eps=0,5, 1, 2)	70, 10, 6	17
K-Means (n_clusters=20)	8	17
Gaussian Mixture (n_clusters=20)	9	17
li2012 (dt1=3, dt2=6, R=15) (dt1=2, dt2=5, R=10) (dt1=1, dt2=4, R=5) (dt1=0.5, dt2=6, R=2,5)	10, 11, 13, 24	17

Raster tabanlı segmentasyon algoritmalarının, nokta bulutu tabanlı algoritmalarla kıyasla daha başarılı sonuçlar verdiği gözlemlenmiştir. Bu durum, raster tabanlı algoritmaların çoğunun segmentasyon işlemine tepe noktası arayarak başlaması ve ardından belirli ayırt etme kriterlerine göre segmentasyon sürecini tamamlamasından kaynaklanmaktadır. Bu yaklaşım, bireysel ağaç segmentasyonu açısından daha uygun bir yöntem sunmaktadır. Bununla birlikte, kullanılan MBM çözünürlüğü ile tepe noktası arama algoritmalarına ait parametreler, segmentasyon başarısını doğrudan etkileyen önemli faktörlerdir. Uygulanan algoritmalar ve elde edilen segmentasyon sonuçları Tablo 27’de sunulmuştur.


Tablo 27. Raster tabanlı algoritmalarla yapılan segmentasyon sonuçları

Algoritma ve Kullanılan Parametreler	Küme Sayısı	Referans (ağaç sayısı)
dalponte2016 (0,1, 0,5, 1)	18, 18, 19	17
silva2016 (0,1, 0,5, 1)	18, 18, 18	17

Ağaçlara ait tepe noktalarının tespitinde tek bir pencere boyutunun kullanılması, ladin ve kayın ağaç türleri açısından farklı sonuçlar doğurmuştur. Ladin ağaçlarının tepe noktaları başarılı bir şekilde belirlenmişken, kayın ağaçlarının geniş ve yayvan tepe yapılarından dolayı aynı pencere boyutu ile yapılan tespitlerde benzer bir başarı elde

edilememiştir. Özellikle kapalılık sınıfı 1 olan alanda, tek bir kayın ağacının bulunduğu bölgelerde iki ya da üç adet tepe noktası tespit edildiği gözlemlenmiştir.

Kapalılık sınıfı 2 ve 3 olan alanlarda ise tür eşleşme oranlarının daha da düştüğü tespit edilmiştir. Bu durum karşısında, kayın ağaçlarına ait segmentasyon sonuçları iyileştirilerek çoklu tepe noktaları tek bir ağaç segmenti hâline getirilmiştir. Farklı kapalılık düzeylerine sahip alanlarda elde edilen tepe noktaları ile ağaç türlerinin dağılımları, grafik olarak gösterilmiştir (Şekil 113).



Şekil 113. Kapalılık seviyeleri farklı alanlardaki ağaç tepe noktası tespiti ve tür dağılımı

Kapalılık sınıfı 2 ve 3 olan alanlardaki tepe noktalarının belirlenmesinde karşılaşılan bir diğer sorun, gövde yüksekliği 1.30 m'nin altında çatallanan ağaçların ayı bireyler olarak tespit edilememesidir. Gövde çapı ölçümünde referans alınan 1,30 m yüksekliğinin üzerinde meydana gelen çatallanmalar, tek ağaç olarak kabul edilmekteyken; çatallanmanın bu yüksekliğin altında gerçekleştiği durumlarda, her bir gövde ayrı bir ağaç bireyi olarak değerlendirilmelidir. Bu durum, ladin ağaçlarına kıyasla kayın ağaçlarında daha sık gözlemlenmiştir. Çalışma alanından bu tür örnekler paylaşılmıştır (Şekil 114).




Şekil 114. Bireysel ağaç segmentasyonu için zor örnekler

4.5. Meşçere Bileşenlerinin İrdelenmesi

Çalışma alanındaki ağaç türleri ladin, kayın ve kuru ladin olarak segmente edilmiştir. Meşçere bileşenlerinden ağaç boyu ile gövde çapı arasındaki anlamlı korelasyondan yararlanılarak, boyu bilinen bu üç türe ait gövde çapı tahmini gerçekleştirilmiştir. Kapalılık sınıfı 1 olan alandan elde edilen gövde çapı verileri referans alınarak, diğer kapalılık sınıflarına sahip alanlarda yer alan bireylerin meşçere bileşenleri tahmin edilmiştir.

Ağaç boyu ve gövde çapı gibi temel meşçere bileşenlerinin tespitinden sonra, tepe çapı, tepe alanı ve tepe hacmi gibi diğer bileşenlerin doğru bir şekilde hesaplanabilmesi için tepe sınırının hassas biçimde belirlenmesi gerekmektedir. Bireysel ağaç segmentasyon işleminin ardından, ağacı temsil eden noktaların yatay düzlemdeki en dış noktaları birleştirilerek tepe alanı hesaplanmıştır. Bu hesaplamada, farklı yöntemler karşılaştırılmış ve radyal yöntemin, concavhull ve convexhull yöntemlerine kıyasla daha hassas sınır elde etmesi nedeniyle tercih edilmiştir (Şekil 115).



Şekil 115. Taç sınırı tespiti için kullanılan yöntemlerin karşılaştırılması

Belirlenen tepe sınırı içerisindeki en uzak iki nokta, tepe çapı olarak hesaplanmaktadır. Tepe hacminin hesaplanabilmesi için, tepe sınırına ait noktalardan en düşük yükseklik değeri alınarak bu değer ağaç boyundan çıkarılmasıyla tepe yüksekliği belirlenmiştir. Elde edilen bu yükseklik değeri, hacim formülünde kullanılarak tepe hacmi hesaplanmıştır.

Meşçere bileşenleri, allometrik ve dendrometrik formüllerde kullanılarak ormancılık ve ekoloji alanlarında gerçekleştirilen çalışmalara önemli katkılar sağlamaktadır. Bu çalışmada, doğrusal, polinomsal, logaritmik, destek vektör regresyonu, rastgele orman ve XGBoost olmak üzere çeşitli regresyon yöntemleri kullanılmıştır. Uygulanan modeller arasında en yüksek R^2 değerini veren Rastgele Orman ve XGBoost regresyon modelleri,

kapalılık sınıfı 2 ve 3 olan alanlardaki ağaçların gövde çaplarını tahmin etmek amacıyla tercih edilmiştir. Elde edilen tahmin sonuçları, referans verilerle karşılaştırılarak değerlendirilmiştir (Tablo 28).

Tablo 28. Gövde çapı tahmininde kullanılan modellerin sonuçları ve referans verinin karşılaştırılması

Model	2 – Kapalılık				3 – Kapalılık			
	Ağaç Boyu (m)	Ladin-Referans (cm)	Ağaç Boyu (m)	Kayın-Referans (cm)	Ağaç Boyu (m)	Ladin-Referans (cm)	Ağaç Boyu (m)	Kayın-Referans (cm)
Rastgele	28,68	66 – 62	22,42	49 – 49	21,04	48 - 45	18,16	45 – 49
Orman	29,99	74 – 75	14,47	36 – 36	24,70	62 - 63	31,16	75 – 79
Regresyon	27,30	60 – 58	17,17	41 – 42	21,24	50 - 50	22,42	50 - 49
Modeli	16,19	41 – 41	19,74	56 - 59	19,84	45 – 44	14,34	37 – 36
	21,77	54 – 51	27,39	70 – 73	16,00	41 - 43	16,20	41 - 43
Aşırı	28,68	65 – 62	22,42	50 – 49	21,04	46 – 45	18,16	44 - 49
Gradyan	29,99	73 – 75	14,47	35 – 36	24,70	63 – 63	31,16	78 - 79
Artırma	27,30	62 – 58	17,17	42 – 42	21,24	52 – 50	22,42	50 – 49
Regresyon	16,19	42 – 41	19,74	54 – 59	19,84	45 – 44	14,34	35 – 36
Modeli	21,77	53 – 51	27,39	71 - 73	16,00	42 - 43	16,20	42- 43

Gevşek kapalılık sınıfına ait alandan tespit edilen ağaç boyu ve gövde çapı verileri kullanılarak elde edilen korelasyon ilişkisi doğrultusunda, kapalılık sınıfı 2 ve 3 olan alanlardaki ladin ve kayın ağaç türlerinin gövde çapları tahmin edilmiştir. Tablo 28’de sunulan değerlere göre, yapılan tahminlerin 3 ila 5 cm aralığında bir hatayla elde edildiği gözlemlenmiştir.

Nokta bulutu verisinden ağaç boyu ve gövde çapı bilgileri tespit edilmiş; gövde çapı doğrudan elde edilemeyen bireyler için, ağaç boyu ile gövde çapı arasındaki yüksek korelasyondan yararlanılarak tahmin işlemi gerçekleştirilmiştir. Gövde hacminin hesaplanmasında, ağaç boyu ve gövde çapı birlikte kullanılmıştır. Ağaç gövdelerinin tam silindirik bir yapıya sahip olmaması nedeniyle, iki farklı gövde çapı ölçüsü dikkate alınarak yaklaşık bir gövde hacmi hesaplanmıştır. Elde edilen hacim sonuçları, Artvin Orman İşletme Şefliği’nden temin edilen dikili kabuklu gövde hacim ve artım tablosu ile karşılaştırılmıştır (Tablo 29).

Tablo 29. Nokta bulutu verisiyle elde edilen çap ve hacim değerlerinin referans verilerle karşılaştırılması

Ağaç Türü	Elde edilen (nokta bulutu)		Referans (Artvin O. İ. Ş.)	
	Çap (cm)	Hacim (m ³)	Çap (cm)	Hacim (m ³)
Ladin	38	1,061	38	1,007
	42	1,415	42	1,333
	46	1,778	46	1,720
	50	2,284	50	2,172
	54	2,847	54	2,695
	58	3,382	58	3,291
	62	4,054	62	3,967
	66	4,951	66	4,726
	70	5,633	70	5,573
	74	6,852	74	6,511
Kayın	38	1,121	38	1,117
	42	1,487	42	1,461
	46	1,757	46	1,853
	50	2,126	50	2,293
	54	2,871	54	2,781
	58	3,134	58	3,317
	62	4,191	62	3,901
	66	4,726	66	4,533
	70	5,164	70	5,213
	74	5,546	74	5,941

Referans hacim değerleri ile nokta bulutu verisi kullanılarak hesaplanan hacim değerleri arasındaki yakınlık, Tablo 29’da dikkat çekmektedir. Ancak hesaplamaların daha hassas ve güvenilir olabilmesi için, bölgesel amprik verilerden türetilmiş denklemlerin kullanılması gerekmektedir.

4.6. Ağaç Türü Tahmini İredelenmesi

Çalışma alanındaki üç farklı kapalılık sınıfından da elde edilen ladin, kayın ve kuru ladin türlerine ait hava LiDAR verileri, nokta bulutu tabanlı derin öğrenme mimarileri olan PointNet, PointNet++ ve DGCNN’e uygun şekilde hazırlanmıştır. Model eğitimi, Google Colab ortamında gerçekleştirilmiş olup, bu süreç sonunda test ve doğrulama veri setleri elde edilmiştir. Eğitilen modellerin performansını değerlendirmek amacıyla, test verisine ait

karışıklık (confusion) matrisindeki değerler kullanılarak doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru hesaplanmıştır (Tablo 30).

Tablo 30. PointNet modeliyle eğitilen ağaç türlerine ait test verisinin karışıklık matrisi

	Test Veri Seti		
	Ladin	Kayın	Kuru Ladin
Ladin	15	2	1
Kayın	2	11	0
Kuru Ladin	0	0	4

Doğruluk, modelin yaptığı tüm doğru tahminlerin toplamının, gerçekleştirilen tüm tahminlerin toplamına oranlanmasıyla elde edilmektedir.

$$\text{Doğruluk} = (15+11+4) / (15+11+4+2+2+1) = 0,86 = \%86$$

Kesinlik, bir sınıfa ait olarak tahmin edilen pozitif örneklerin, gerçekten o sınıfa ait olma oranını ifade etmektedir.

$$\text{Ladin için kesinlik} = 15 / (15+2+1) = 0,83$$

$$\text{Kayın için kesinlik} = 11 / (11+2+0) = 0,85$$

$$\text{Kuru Ladin için kesinlik} = 4 / (4+0+0) = 1,00$$

$$\text{Ortalama Kesinlik} = (0,83+0,85+1,00) / 3 = 0,89 = \%89$$

Duyarlılık, bir sınıfa ait gerçek pozitif örneklerin ne ölçüde doğru şekilde tespit edildiğini gösteren metriktir.

$$\text{Ladin için duyarlılık} = 15 / (15+2+0) = 0,88$$

$$\text{Kayın için duyarlılık} = 11 / (11+2+0) = 0,85$$

$$\text{Kuru Ladin için duyarlılık} = 4 / (4+0+1) = 0,80$$

$$\text{Ortalama Duyarlılık} = (0,88+0,85+0,80) / 3 = 0,84 = \%84$$

F1 skoru, kesinlik ve duyarlılığın harmonik ortalaması olarak tanımlanmaktadır.

$$\text{Ladin için F1 skoru} = 2 \times ((0,88 \times 0,83) / (0,88+0,83)) = 0,85$$

$$\text{Kayın için F1 kuru} = 2 \times ((0,85 \times 0,85) / (0,85+0,85)) = 0,85$$

$$\text{Kuru Ladin için F1 skoru} = 2 \times ((0,80 \times 1,00) / (0,80+1,00)) = 0,88$$

$$\text{Ortalama F1 Skoru} = (0,85+0,85+0,88) / 3 = 0,86 = \%86$$

PointNet mimarisiyle eğitilen modele ait performans metrikleri Tablo 31’de gösterilmiştir.

Tablo 31. PointNet mimarisine ait başarı metrikleri

Metrik	Ladin	Kayın	Kuru Ladin	Ortalama
Kesinlik	0,83	0,85	1,00	0,89
Duyarlılık	0,88	0,85	0,80	0,84
F1 Skoru	0,85	0,85	0,88	0,86

PointNet mimarisi için hesaplanan başarı metrikleri, aynı yöntemle PointNet++ ve DGCNN mimarileri için de hesaplanmış olup, ilgili sonuçlar sırasıyla Tablo 32 ve Tablo 33'te sunulmuştur.

Tablo 32. PointNet++ mimarisine ait başarı metrikleri

Metrik	Ladin	Kayın	Kuru Ladin	Ortalama
Kesinlik	0,94	0,92	1,00	0,95
Duyarlılık	0,94	0,92	1,00	0,95
F1 Skoru	0,94	0,92	1,00	0,95

Tablo 33. DGCNN mimarisine ait başarı metrikleri

Metrik	Ladin	Kayın	Kuru Ladin	Ortalama
Kesinlik	0,83	0,92	1,00	0,92
Duyarlılık	0,94	0,86	0,80	0,87
F1 Skoru	0,88	0,89	0,88	0,88

PointNet, PointNet++ ve DGCNN mimarilerine ait doğruluk değerleri sırasıyla, %86, %94 ve %89 olarak elde edilmiştir. Model eğitim sürecinde, farklı çalışmalara ait hazır veri setleri kullanılmak yerine, doğrudan çalışma alanından elde edilen nokta bulutu verileriyle oluşturulan özgün bir veri seti kullanılmıştır.

Çalışma alanına ait 115 adet ladin, 91 adet kayın ve 27 adet kuru ladin bireyi kullanılarak eğitilen modelin performansının artırılabilmesi için, özellikle kuru ladin türüne ait örnek sayısının artırılması kaçınılmaz bir gerekliliktir.

5. TARTIŞMA

Yang vd. (2021), kentsel ağaç metriklerinin çıkarımı amacıyla LiDAR ve fotogrametrik nokta bulutu verilerinin entegrasyonuna dayanan yenilikçi bir yaklaşım ortaya koymuştur. LiDAR verileri yüksek doğrulukta yükseklik bilgisi sağlarken; fotogrametrik veriler, renk ve dokusal bilgiler sunmaktadır. Bu veri füzyonu, kentsel ağaçların daha hassas ve ayrıntılı analizine imkân tanımaktadır. Bu tez çalışmasında ise, fotogrametrik nokta bulutu yalnızca nokta yoğunluğunu artırmak ve bireysel ağaç segmentasyonu sonrası meşçere bileşenlerinin tespitini iyileştirmek amacıyla kullanılmıştır. Ağaç türü tahmin sürecinde nokta bulutuna ait renk bilgileri değerlendirme dışında bırakılmış; tür ayrımı, yalnızca geometrik niteliklere dayalı morfolojik yapıların analiziyle gerçekleştirilmiştir.

Fareed vd. (2023), Kuzey Dakota'daki beş farklı tarım alanında İHA tabanlı LiDAR verilerini kullanarak zemin noktalarının sınıflandırılmasını incelemiştir. Çalışmada, geleneksel filtreleme algoritmaları (CSF, PMF, MCC) ile derin öğrenme temelli PointCNN modeli karşılaştırılmış; sınıflandırma doğruluğu, hata oranları ve Kappa katsayısı gibi nicel metriklerin yanı sıra kesit (cross-section) analizleriyle görsel değerlendirmelerde yapılmıştır. Bu tez çalışmasında ise, TBC yazılımı ile gerçekleştirilen otomatik sınıflandırma sonrasında, 5 m aralıklarla alınan kesitler aracılığıyla sınıflandırma sonuçları manuel olarak iyileştirilmiştir. Özellikle zemin ile düşük bitki örtüsü noktalarının ayırımında kesit analizleri belirgin katkı sağlamıştır. Ayrıca, CSF ve PMF algoritmaları optimize parametrelerle uygulanmış ve sonuçlar aynı kesitler üzerinden nitel olarak değerlendirilmiştir. Çalışma alanına ait doğruluk kontrol verileri olmadığından nicel bir değerlendirme yapılamamış; ancak üç farklı sınıflandırma yönteminin sonuçları aynı kesitler üzerinden karşılaştırılarak, zemin ve zemin üstü ayırımındaki başarı görsel olarak ortaya konmuştur. Eğimin yüksek ve diri örtünün yoğun olduğu alanlarda sınıflandırma doğruluğu, sonraki analiz adımları açısından kritik önem taşımaktadır.

Liu vd. (2020), Çin'in Henan Eyaleti'ndeki Jigongshan Ulusal Doğa Koruma Alanı'nda İHA tabanlı LiDAR ve fotogrametri verilerinden elde edilen Meşçere Boy Modellerini (MBM) karşılaştırılmıştır. Fotogrametrik MBM'lerin özellikle düşük meşçere boylarında LiDAR'a göre daha yüksek değerler ürettiği, ancak yüksek ağaçların temsilinde yetersiz kaldığı belirlenmiştir. Ayrıca nokta yoğunluğu, enterpolasyon yöntemi ve veri üretim protokolünün MBM kalitesi üzerinde belirleyici etkiye sahip olduğu ortaya

konmuştur. Bu tez çalışmasında ise, Sayısal Arazi Modeli (SAM) ve Sayısal Yüzey Modeli (SYM) üretiminde hem nokta bulutu tabanlı hem de raster tabanlı yöntemler kullanılmış, farklı enterpolasyon teknikleri uygulanarak sonuçlar karşılaştırılmıştır. Referans verilerle yapılan değerlendirmeler, nokta bulutu tabanlı normalizasyon işleminin en hassas sonuçları verdiğini; raster tabanlı yöntemlerden ise *pit-free* algoritmasının yakın doğrulukta sonuçlar sağladığını ortaya koymuştur. Ağaç boyunun belirlenmesinde temel rol oynayan bu modelleme sürecinde en doğru yöntemin seçimi, meşçere bileşenlerinin güvenilir biçimde elde edilmesi açısından kritik öneme sahiptir.

Yu vd. (2024), dört farklı orman tipinde (düz arazide iğne yapraklı orman, eğimli arazide iğne yapraklı orman, düze arazide karışık orman ve düz arazide geniş yapraklı orman) İHA tabanlı LiDAR verileri kullanarak bireysel ağaç segmentasyonu için yenilikçi bir yöntem önermiştir. Çalışmada, uyarlanabilir taç şekilli algoritma ile tohum noktası tespiti yapılmış ve bu noktalara dayalı olarak bölge büyütme yöntemiyle bireysel ağaç segmentasyonu gerçekleştirilmiştir. Elde edilen segmentasyon başarı oranları sırasıyla, düz arazide iğne yapraklı orman için %87,7, eğimli arazide iğne yapraklı orman için %80,6, düz arazide karışık orman için %73,2 ve düz arazide geniş yapraklı orman için %70,5 olarak belirlenmiştir. Bu tez çalışması eğimli arazide karışık meşçerede gerçekleştirilmiştir. Çalışmada, Silva vd. (2016) algoritması temel alınarak, yerel maksimum algoritması ile tespit edilen ağaç tepe noktalarına segmentasyon işlemi uygulanmıştır. Ladin ve kuru ladin türleri, dik yapıları nedeniyle yüksek doğrulukla tespit edilip başarıyla segmentlenmiştir. Ancak, yayvan taç yapısına sahip kayın ağaçlarında, yerel maksimum algoritmasının dinamik pencere boyutu kullanılmasına rağmen, tek bir ağacı birden fazla birey gibi algıladığı örneklere rastlanmıştır. Bu durum, segmentasyon sürecinde aşırı bölünmeye neden olmuş ve aynı ağaca ait taç yapısının birden fazla parçaya ayrılmasıyla sonuçlanmıştır. Segmentasyonun sonuçları üzerinde iyileştirme yapılarak işlem tamamlanmıştır.

Xu vd. (2024) tarafından yürütülen çalışmada, Çin'in Jilin Eyaleti'ndeki doğal iğne yapraklı ve geniş yapraklı karışık ormanlarında, ağaç boyu ile göğüs yüksekliğindeki çap arasındaki ilişki modellenmiştir. Bu kapsamda, geleneksel istatistiksel yöntem olan doğrusal olmayan karma model (NLME) ile makine öğrenme temelli rastgele orman algoritması karşılaştırılmıştır. Doğrulama veri seti üzerinde rastgele orman modelinin R^2 değeri 0.801, ortalama hata değeri ise 1.44 m olarak bulunmuş ve NLME modeline kıyasla daha yüksek doğruluk sağlamıştır. Söz konusu çalışmada, gövde çapını tahmin etmek amacıyla ağaç boyu bağımsız değişken olarak kullanılmıştır. Bu tez çalışmasında ise tersi bir yön izlenmiş; ağaç

boylarından gövde çapları tahmin edilmeye çalışılmıştır. Bu amaçla makine öğrenme algoritmalarından rastgele orman ve aşırı gradyan artırma modelleri uygulanmıştır. Elde edilen R^2 değerleri, rastgele orman için 0.95, aşırı gradyan artırma için ise 0.92 olarak belirlenmiştir. Tahmin edilen gövde çaplarının ortalama hata payı 3 ila 5 cm aralığında kalmış ve her iki model de yüksek doğrulukla çap tahminleri sunmuştur. Bu sonuçlar, makine öğrenme algoritmalarıyla çap tahminlerinin güvenilir bir şekilde yapılabileceğini göstermektedir.

Mäyrä vd. (2021) tarafından Finlandiya'nın güney boreal ormanlarında yürütülen çalışmada, hava LiDAR verileri ve spektral görüntüler kullanılarak bireysel ağaç türlerinin sınıflandırması amaçlanmıştır. Çalışmada, 3B konvolüsyonel sinir ağları (3D-CNN) modeli ile destek vektör makineleri (DVM), rastgele orman (RO), gradyan artırma (GA) ve yapay sinir ağı (YSA) gibi geleneksel makine öğrenme algoritmalarının sınıflandırma performansları karşılaştırılmıştır. En başarılı sonuçları veren 3D-CNN modeli, Avrupa huşu türü için F1 skoru 0,91, genel tür sınıflandırmasında ise F1 skoru 0,86 ve genel doğruluk %87 olarak raporlanmıştır. Geleneksel yöntemlerden DVM modeli F1 skoru 0.82 ve %82 doğruluk, YSA modeli ise yine F1 skoru 0.82 ve %82 doğruluk elde etmiştir. 3D-CNN modeli, özellikle iğne yapraklı türlerin birbirinden ayrılmasında ve ekolojik açıdan öneme sahip Avrupa huşu türünün doğru şekilde sınıflandırılmasında daha yüksek başarı sağlamıştır. Bu tez çalışmasında ise, ladin ve kayın türlerinin ayrımı yalnızca nokta bulutu verisine dayalı olarak gerçekleştirilmiştir. Bu amaçla, derin öğrenme tabanlı üç farklı mimari PointNet, PointNet++ ve DGCNN uygulanmıştır. Sırasıyla %86, %94 ve %89 doğruluk elde edilmiştir. Bu sonuçlar, özellikle PointNet++ modelinin ladin ve kayın türlerinin morfolojik yapılarındaki farklılıkları yüksek doğrulukla ayırt edebileceğini ortaya koymaktadır.

Literatürde ağaç türü tespitiyle ilgili yapılan çalışmaların önemli bir kısmında optik verilerin (örneğin spektral bantlar veya hiperspektral görüntüler) kullanıldığı ve bu sayede sınıflandırma başarılarının artırıldığı gözlemlenmektedir. Optik veriler, özellikle ağaç türleri arasında fotosentetik aktivite, pigment yoğunluğu ve yaprak dokusu gibi farkların ayrıştırılmasında önemli katkı sağlamaktadır.

Buna karşılık, bu tez çalışmasında gerçekleştirilen ağaç türü sınıflandırması yalnızca nokta bulutu verilerine dayanmakta olup herhangi bir optik veri katkısı bulunmamaktadır. Bu durum, sınıflandırma sürecinde yalnızca geometrik ve yapısal farklılıklara dayalı ayrımlar yapılmasını zorunlu kılmıştır. Elde edilen başarı metrikleri, bu

sınırlamaya rağmen, ladin ve kayın türleri arasında yüksek doğrulukla ayırım yapılabildiğini ortaya koymuştur.

Nokta bulutu tabanlı sınıflandırma yaklaşımına örnek olarak Hollaus vd. (2009) tarafından yürütülen bir başka çalışma verilebilir. Söz konusu araştırmada, tam dalga formu (full-waveform) hava lazer tarama (ALS) verileri kullanılarak karışık tür içeren orman alanlarında ağaç türlerinin sınıflandırılabilirliği değerlendirilmiştir. Bu çalışmada, yansıma genişliği (echo width), geri saçılım kesit alanı (backscatter cross-section) ve yansımaların dikey dağılımı gibi tam dalga formu verisinden türetilmiş metrikler kullanılarak sınıflandırma yapılmıştır. Elde edilen doğruluk oranı %83 olup, ladin, karaçam ve kayın türleri için sınıflandırma doğruluğu %75 olarak rapor edilmiştir. Çalışmada vurgulanan önemli bir bulgu, geometrik yapısal bilgiler ile geri saçılım özelliklerinin birleştirilmesinin, sınıflandırma performansını belirgin şekilde artırdığıdır.

Bu bağlamda, optik veri olmaksızın yalnızca LiDAR nokta bulutu kullanılarak gerçekleştirilen bu tez çalışması, benzer yapıda tür ayırımına odaklanan önceki araştırmalarla metodolojik açıdan benzerlik taşımakta, ancak tür ayırımında kullanılan derin öğrenme modelleri bakımından daha ileri bir yaklaşım sunmaktadır.

6. SONUÇLAR

Orman ekosistemleri, biyolojik çeşitliliğin korunması, karbon depolama kapasitesi ve su döngüsünün düzenlenmesi gibi kritik ekosistem hizmetleri sunmaktadır. Ancak iklim değişikliği, aşırı ağaç kesimi, orman yangınları ve kentleşme gibi tehditler, bu sistemlerin sürdürülebilir yönetimini her zamankinden daha önemli hâle getirmiştir. Gelişen teknolojiler, orman yönetimi ve planlama süreçlerinde daha hassas, verimli ve sürdürülebilir çözümler sunarak karar alma mekanizmalarını önemli ölçüde iyileştirmektedir. Uzaktan algılama ve uydu teknolojileri, LiDAR sistemleri, yapay zekâ ve büyük veri analitiği, nesnelerin interneti (IoT) sensörleri ve blockzincir (blockchain) teknolojisi gibi yenilikler sayesinde geleneksel ormancılık yaklaşımları daha etkin, sürdürülebilir ve şeffaf bir yapıya kavuşmaktadır.

Bu tez çalışmasında, hava LiDAR verileri kullanılarak meşçere bileşenlerinin kestirimi ve ağaç türü tahminine yönelik yöntemler ve bu yöntemlerin alternatifleri bütüncül bir şekilde değerlendirilmiştir. Literatürdeki benzer çalışmalardan farklı olarak, bu çalışmada yalnızca ham nokta bulutu verisi kullanılmış; herhangi bir optik görüntü verisine başvurulmadan süreç tamamlanmıştır. Çalışma alanı içerisinde farklı kapalılık sınıflarının yer alması, elde edilen sonuçların karşılaştırılmasına ve meşçere bileşenlerinin kestiriminde modelin başarısının test edilmesine olanak sağlamıştır. Bu yönüyle, halk arasında “gürge” olarak bilinen Doğu Kayını (*Fagus orientalis*) ve Doğu Ladini (*Picea orientalis*) türlerini kapsayan, bölgesel düzeyde gerçekleştirilen özgün bir çalışma ortaya konmuştur.

Bu çalışmada, nokta bulutu verisinin elde edilebilmesi amacıyla öncelikle saha çalışması gerçekleştirilmiştir. Ladin ve kayın türlerinin baskın olduğu, üç farklı kapalılık sınıfına sahip ve kayak pistleri arasında kalan bölgelerde havadan uçuşlar yapılmıştır. L1 sensörüyle üç farklı etapta, P1 sensörüyle ise tek etapta gerçekleştirilen uçuşların ardından elde edilen nokta bulutlarına PPK yöntemiyle düzeltme uygulanarak konumsal dengeleme sağlanmıştır. Fotogrametrik nokta bulutlarının nokta yoğunluğu nispeten düşük olmakla birlikte, hava LiDAR verileriyle birlikte yüksek konum doğruluğu ile entegre edilmesi, bu çalışmaya özgünlük kazandıran önemli bir unsurdur.

Nokta bulutu verisine yönelik sınıflandırma işlemlerinde uygulanan farklı yöntemler ve makine öğrenmesi algoritmalarıyla elde edilen sonuçların değerlendirilmesi, çıktıların güvenilirliğini önemli ölçüde artırmaktadır. Sınıflandırma aşaması, nokta bulutu işleme

sürecinin kritik bir bileşeni olup, bu aşamada sağlanan başarı diğer tüm analiz basamaklarının doğruluğunu doğrudan etkilemektedir. Bu nedenle, sınıflandırma işlemi titizlikle yürütülmesi gereken temel adımlardan biridir.

Sınıflandırma işleminin ardından, Meşçere Boy Modeli'nin oluşturulması için hem nokta bulutu tabanlı hem de raster tabanlı yöntemler uygulanmıştır. Bu yöntemsel çeşitlilik, elde edilen sonuçların karşılaştırılmasına ve yorumlanmasına olanak sağlamış; böylece analiz sürecinin daha güvenilir ve sağlam temellere dayalı olarak ilerlemesine katkı sunmuştur.

Bireysel ağaç segmentasyonu, bu tez çalışmasının temel hedeflerine ulaşabilmesi açısından kritik bir öneme sahiptir. Segmentasyon işlemi kapsamında hem nokta bulutu tabanlı hem de raster tabanlı yöntemler uygulanmış ve referans verisiyle en yüksek uyumu sağlayan algoritma kullanılarak segmentasyon gerçekleştirilmiştir. Ladin ve kayın türleri morfolojik açıdan belirgin farklılıklara sahip olduğundan, bu iki türün aynı anda yüksek doğrulukla tespit edilmesi sınırlı kalmıştır. Özellikle kapalılık sınıfı arttıkça segmentasyon başarısının daha da azaldığı gözlemlenmiştir. Çalışma alanında yer alan meşçere tipleri LKnd1-2, LKnd2-2, KnLcd3 olup, bu meşçerelerin gelişme çağı “d” (orta ağaçlık) olarak sınıflandırılmıştır. Bu nedenle, gövde çapı 36 cm'nin altında olan bireylerin segmentasyonla tespiti mümkün olmayacak şekilde, kullanılan algoritmanın parametreleri optimize edilmiştir. Ayrıca, bireysel ağaçları temsil eden noktalar segmentasyon iyileştirmesi uygulanarak daha hassas bir duruma getirilmiştir.

Meşçere bileşenlerinin kestirimi ve ağaç türü tahmini süreçlerinde, bireysel ağaç segmentasyondaki başarı kritik bir öneme sahiptir. Kapalılık sınıfının arttığı alanlarda, ağaç gövdelerine ait nokta sayısı yok denecek kadar az olduğundan doğrudan ölçümler yetersiz kalmaktadır. Bu durumda, daha düşük kapalılığa sahip alanlardan elde edilen meşçere bileşenleri ile bu bileşenler arasındaki korelasyonlardan yararlanarak regresyon analizleri uygulanmıştır. Özellikle, ağaç boyu ile gövde çapı arasındaki güçlü ilişki kullanılarak, kapalılığı yüksek alanlardaki ağaçların gövde çapı tahmin edilmiştir. Regresyon modelleri arasında, Rastgele Orman (Random Forest) ve Aşırı Gradyan Artırma (XGBoost) algoritmaları yüksek R^2 değerleri ile öne çıkmaktadır. Ağaç türü tahmininde ise, nokta bulutu tabanlı derin öğrenme mimarileri olan PointNet, PointNet++ ve DGCNN kullanılmış; sırasıyla %86, %94 ve %89 doğruluk oranlarına ulaşılmıştır. Bu mimarilerin performansının artırılabilmesi için model eğitiminde kullanılan veri sayısının artırılması büyük önem taşımaktadır.

Sonuç olarak, hava LiDAR verisi kullanılarak meşçere parametre kestirimi ve ağaç türü tahmini için gerekli temel adımlar atılmış ve bu sürecin her aşamasını geliştirmeye yönelik uygun altyapı oluşturulmuştur. Gelişen teknolojilerin sunduğu olanaklar, orman ekosistemlerinin daha hassas, verimli ve sürdürülebilir şekilde izlenmesine ve yönetilmesine katkı sağlamakta olup, bu doğrultudaki bilimsel çalışmaların kesintisiz olarak sürdürülmesi gerekliliği ortaya çıkmıştır.



7. ÖNERİLER

Doktora tezi kapsamında yürütülen bu çalışmada, hava LiDAR verileri kullanılarak meşçere bileşenlerinin kestirimi ve ağaç türü tahminine yönelik izlenebilecek yöntemler ve uygulanabilir yaklaşımlar ortaya konmuştur. Bu tez konusuyla benzer alanda çalışma yapmak isteyen araştırmacı ve uygulayıcılara yönelik öneriler aşağıda maddeler hâlinde sunulmuştur:

- Bu çalışmada DJI Zenmuse L1 sensörü kullanılmış olup, nokta bulutu yoğunluğunu artırmak amacıyla, imkânlar dahilinde DJI Zenmuse L2 sensörü önerilmektedir.
- Bu çalışma, tek periyot hâlinde Nisan ayında, yani ilkbaharın başlangıcında gerçekleştirilmiştir. İmkânlar dahilinde, benzer çalışmaların geniş yapraklı türlerin yapraksız ve yapraklı dönemlerini kapsayacak şekilde iki periyot hâlinde yürütülmesi önerilmektedir. Bu yaklaşım, dönemler arası farkların değerlendirilmesiyle bireysel ağaç segmentasyonu ve tür tespiti işlemlerinin daha yüksek doğrulukla gerçekleştirilmesine katkı sağlayacaktır.
- Uçuş gerçekleştirilecek alana ilişkin ön hazırlıkların yapılması önerilmektedir. Bu kapsamda, çalışma alanının ortalama arazi yüzeyine ait yükseklik bilgileri önceden belirlenmeli ve uçuş yüksekliği bu verilere göre optimize edilmelidir. Alternatif olarak, arazi yüzeyini takip eden uçuş modunun kullanılması da veri kalitesini artıracaktır. Özellikle çok yüksek irtifadan yapılan uçuşların, ağaçların yapısal detaylarını yakalayamama riskini artırabileceği göz önünde bulundurulmalıdır.
- Ham nokta bulutu verisine uygulanacak konum düzeltmeleri için birden fazla yöntem eş zamanlı olarak değerlendirilebilir. Eğer kullanılan cihaz RTK destekliyorsa, uçuş alanının RTK kapsama durumuna bağlı olarak bu bağlantıdan yararlanılabilir. Aynı zamanda PPK yöntemi için, uçuş sahasında koordinatları bilinen bir referans noktaya GNSS alıcısı kurulara, uçuş süresince uydu verisi toplanması önerilmektedir. Bu sayede, nokta bulutunun konumsal doğruluğu artırılabilir.
- Bireysel ağaç segmentasyonu sürecinde, ibreli ve geniş yapraklı türleri aynı anda ve daha hassas bir şekilde segmente edebilecek yöntemlerin geliştirilmesi gerekmektedir. Bu sayede, manuel müdahaleye ihtiyaç duyulmadan otomatik ve

türler arası morfolojik farklılıkları dikkate alan segmentasyon çözümleri elde edilebilir.

- Ağaç türü tespitinde yalnızca ibreli ve geniş yapraklı türler arasında genel bir ayrım yapılması yeterli değildir; aynı zamanda, her iki gruba ait bireysel türlerin de doğru şekilde ayırt edilebilmesi gerekmektedir. Bu doğrultuda, geniş yapraklı türler arasında kayın, meşe ve gürgen; ibreli türler arasında ise, ladin, göknar ve karaçam gibi türlerin kendi aralarında yüksek doğrulukla sınıflandırılabilmesi hedeflenmelidir.



8. KAYNAKLAR

- Akerblom, M., Raunonen, P., Makipaa, R., & Kaasalainen, M. (2017). Automatic tree species recognition with quantitative structure models. *Remote Sensing of Environment*, 191, 1-12.
- Almeida, D. R. A., Broadbent, E. N., Zambrano, A. M. A., Wilkinson, B. E., Ferreira, M. E., Chazdon, R., & Brancalion, P. H. S. (2019). Monitoring the structure of forest restoration plantations with a drone-lidar system. *International Journal of Applied Earth Observation and Geoinformation*, 79, 192–198.
- Andersen, H.-E., McGaughey, R.J., & Reutebuch, S.E. (2005). Estimating forest canopy fuel parameters using LIDAR data. *Remote Sensing of Environment*, 94(4), 441-449.
- Armeni, I., Sener, O., Zamir, A.R., Jiang, H., Brilakis, I., Fischer, M., & Savarese, S. (2016). 3d Semantic Parsing of Large-Scale Indoor Spaces. In 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27-30 June, Las Vegas (NV, USA), pp. 1534-1543.
- Arp, H., Griesbach, J., & Burns, J. (1982). Mapping in tropical forests: A new approach using the laser APR. *Photogrammetric Engineering and Remote Sensing*, 45, 785-792.
- Asner, G.P., Hughes, R.F., Mascaro, J., Uowolo, A.L., Knapp D.E., Jacobson, J., Kennedy Bowdoin, T., & Clark, J.K. (2011). High-resolution carbon mapping on the million hectare Island of Hawaii. *Frontiers in Ecology the Environment*, 9(8), 434-439.
- Asner, G.P., Kellner, J.R., Kennedy Bowdoin, T., Knapp, D.E., Anderson, C., & Martin, R.E. (2013). Forest canopy gap distributions in the southern Peruvian Amazon. *PloS One*, 8(4), e60875.
- Atik, M. E., Duran, Z., & Seker, D. Z. (2021). Machine learning-based supervised classification of point clouds using multiscale geometric features. *ISPRS International Journal of Geo-Information*, 10(3), Makale 187.
- Axelsson, P. (2000). DEM generation from laser scanner data using adaptive TIN models. *International Archives of Photogrammetry and Remote Sensing*, 33, 110-117.
- Ballard, D.H. (1981). Generalizing the Hough transform to detect arbitrary shapes. *Pattern Rocognition*, 132(2), 111-122.
- Ben-Arie, J.R., Hay, G.J., Powers, R.P., Castilla, G., & St-Onge, B. (2009). Development of a pit filling algorithm for LiDAR canopy height models. *Computers and Geosciences*, 35(9), 1940-1949.
- Beucher, S. (1979). Use of watersheds in contour detection. In: *Proceedings of the International Workshop on Image Processing*.

- Bonan, G.B. (2008). Forests and climate change: Forcings, feedbacks, and the climate benefits of forests. *Science*, 320(5882), 1444–1449.
- Bottalico, F., Chirici, G., Giannini, R., Mele, S., Mura, M., Puxeddu, M., McRoberts, R., Valbuena, R., & Travaglini, D. (2017). Modeling Mediterranean forest structure using airborne laser scanning data. *International Journal of Applied Earth Observations and Geoinformation*, 57: 145–153.
- Boudreau, J., Nelson, R.F., Margolis, H.A., Beaudoin, A., Guindon, L., & Kimes, D.S. (2008). Regional aboveground forest biomass using airborne and spaceborne LiDAR in Quebec. *Remote Sensing of Environment*, 112(10), 3876–3890.
- Breiman, L. (2001). Random Forests. *Machine Learning* 45, 5–32.
- Briechele, S., Krzystek, P., & Vosselman, G. (2020). Classification of tree species and standing dead trees by fusing UAV-based lidar data and multispectral imagery in the 3D deep neural network PointNet++. *ISPRS annals of the photogrammetry, remote sensing and spatial information sciences*, 2, 203–210.
- Budei, B.C., & St-Onge, B. (2018). Variability of multispectral lidar 3D and intensity features with individual tree height and its influence on needleleaf tree species identification. *Canadian Journal of Remote Sensing*, 44(4), 263–286.
- Carlberg, M., Gao, P., Chen, G., & Zakhor, A. (2009). Classifying urban landscape in aerial LiDAR using 3D shape analysis. In: *IEEE International Conference on Image Processing*, Cairo, Egypt, pp. 1701–1704.
- Carus, S. (1998). Aynı Yaşlı Doğu Kayını (*Fagus orientalis* Lipsky) Ormanlarında Artım ve Büyüme. İÜ Fen Bilimleri Enstitüsü (Doktora Tezi), İstanbul.
- Castanho, A.D.A., Coe, M.T., Costa, M.H., Malhi, Y., Galbraith, D., & Quesada, C.A. (2013). Improving simulated Amazon Forest biomass and productivity by including spatial variation in biophysical parameters. *Biogeosciences*, 10(4), 2255–2272.
- Chaudhuri, R., Chatterjee, S., Vrontis, D., & Thrassou, A. (2021). The influence of online customer reviews on customers' purchase intentions: A cross-cultural study from India and the UK. *International Journal of Organizational Analysis*.
- Chehata, N., Guo, L., & Mallet, C. (2009). Airborne lidar feature selection for urban classification using random forests.
- Chen, J., & Chang, K.t. (2003). *Introduction to geographic information systems*. China Science Publishing and Media Ltd.
- Chen, Q., Baldocchi, D., Gong, P., & Kelly, M. (2006). Isolating individual trees in a savanna woodland using small footprint lidar data. *Photogrammetric Engineering Remote Sensing*, 72(8), 923–932.
- Chen, Q. (2007). Airborne lidar data processing and information extraction. *Photogrammetric Engineering Remote Sensing*, 73(2), 109.

- Chen, C., Li, Y., Li, W., & Dai, H. (2013). A multiresolution hierarchical classification algorithm for filtering airborne LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 82, 1-9.
- Chen, C., Guo, J., Wu, H., Li, Y., & Shi, B. (2021). Performance Comparison of Filtering Algorithms for High-Density Airborne LiDAR Point Clouds over Complex LandScapes. *Remote Sensing*, 13(14), 2663.
- Chen, P., Liu, W., Dai, P., Liu, J., Ye, Q., Xu, M., Chen, Q., & Ji, R. (2021). Occlude them all: Occlusion-aware attention network for occluded person re-id. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 11833–11842.
- Choudhry, H., & O’Kelly, G. (2018). Precision forestry: a revolution in the woods. Advanced technologies could improve forest management significantly: what areas are most promising, and how can forestry companies start their digital transformation? (11 p.). Singapore: McKinsey & Company.
- Coops, N.C., Hilker, T., Wulder, M.A, St-Onge, B., Newnham, G., Siggins, A., & Trofymow, J.T. (2007). Estimating canopy structure of Douglas-fir forest stands from discrete-return LiDAR. *Trees*, 21(3), 295.
- Dalponte, M., & Coomes, D.A. (2016). Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data. *Methods Ecol. Evol.*, 7, 1236–1245.
- Defries, R.S., Hansen, M. C., Townshend, J.R., Janetos, A., & Loveland, T.R. (2000). A new global 1-km dataset of percentage tree cover derived from remote sensing. *Global Change Biology*, 6(2), 247-254.
- Dietze, M.C., & Clark, J.S. (2008). Changing the gap Dynamics paradigm: Vegetative regeneration control on forest response to disturbance. *Ecological Monographs*, 78(3), 331-347.
- Dralle, K., & Rudemo, M. (1996). Stem number estimation by kernel smoothing of aerial photos. *Camadian Journal of Forest Research*, 26(7), 1228-1236.
- Duncanson, L., Cook, B., Hurtt, G., & Dubayah, R. (2014). An efficient, multi-layered crown delineation algorithm for mapping individual tree structure across multiple ecosystems. *Remote Sensing of Environment*, 154, 378-386.
- Dupuy, J.M., & Chazdon, R.L. (2008). Interacting effects of canopy gap, understory vegetation and leaf litter an tree seedling recruitment and composition in tropical secondary forests. *Forest Ecology Management*, 255(11), 3716-3725.
- Ester M., Kriegel H.-P., Sander J., & Xu X. (1996). A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. *Proc. 2nd Int. Conf. on Knowledge Discovery and Data Mining*. Portland, OR, 226-231.
- Fang, J., Chen, A., Peng, C., Zhao, S., & Ci, L. (2001). Changes in forest biomass carbon storage in China between 1949 and 1998. *Science*, 292(5525), 2320-2322.

- Fareed, N., Flores, J. P., & Das, A. K. (2023). Analysis of UAS-LiDAR ground points classification in agricultural fields using traditional algorithms and PointCNN. *Remote Sensing*, 15(2), 483.
- Farrior, C., Bohlman, S., Hubbell, S., & Pacala, S.W. (2016). Dominance of the suppressed: Power-law size structure in tropical forests. *Science*, 351(6269), 155-157.
- Feng, Y., & Audy, J.F. (2020). Forestry 4.0: a framework for the forest supply chain toward Industry 4.0. *Gestão & Produção*, 27.
- Fischler, M.A., & Bolles, R.C. (1981) Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. *Communications of the ACM*, 24, 381-395.
- Forzieri, G., Guarnieri, L., Vivoni, E.R., Castelli, F., & Preti, F. (2009). Multiple attribute decision making for individual tree detection using high-resolution laser scanning. *Forest Ecology Management*, 258(11), 2501-2510.
- Fu, B. (2010). Trends and priority areas in ecosystem research of China. *Geogr Res*, 29(3), 383-396.
- Garcia, M., Riano, D., Chuvieco, E., & Danson, F.M. (2010). Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. *Remote Sensing of Environment*, 114(4), 816-830.
- Gaulton, R., & Malthus, T.J. (2010). LiDAR mapping of canopy gaps in continuous cover forests: A comparison of canopy height model and point cloud based techniques. *International Journal of Remote Sensing*, 31(5), 1193-1211.
- Gaydon, C., & Roche, F. (2025). Pureforest: A large-scale aerial lidar and aerial imagery dataset for tree species classification in monospecific forests. In 2025 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV) (pp. 5895-5904). IEEE.
- Graham, L., Aok, S., & Lu, S. (2018). Fruit Classification Based on Six Layer Convolutional Neural Network. 2018 IEEE 23rd International Conference on Digital Signal Processing (DSP), Shanghai, China, 2018, pp. 1-5.
- Grondin, V., Fortin, J. M., Pomerleau, F., & Giguère, P. (2023). Tree detection and diameter estimation based on deep learning. *Forestry*, 96(2), 264-276.
- Guan, H., Yu, Y., Ji, Z., Li, J., & Zhang, Q. (2015). Deep learning based tree classification using mobile LiDAR data. *Remote Sensing Letters*, 6(11), 864-873.
- Guo, Q., Li, W., Yu, H., & Alvarez, O. (2010). Effects of topographic variability and lidar sampling density on several DEM interpolation methods. *Photogrammetric Engineering and Remote Sensing*, 76(6), 701-712.
- Guo, X., Zhang, N., Guo, J., Zhang, H., Hao, Y., & Hang, J. (2019). Automated polyp segmentation for colonoscopy images: a method based on convolutional neural

- networks and ensemble learning. *Med. Phys.* 46(12), 5666–5676. doi:10.1002/mp.13865.
- Guo, Y., Bernal, J., & J Matuszewski, B. (2020). Polyp segmentation with fully convolutional deep neural networks-extended evaluation study. *Journal of Imaging* 6(7), 69.
- Guo, Q., Jin, S., Li, M., Yang, Q., Xu, K., Ju, Y., Zhang, J., Xuan, J., Liu, J., Su, Y., Xu, Q., & Liu, Y. (2020). Application of deep learning in ecological resource research: Theories, methods, and challenges. *Science China Earth Sciences*, 63(10), 1457-1474.
- Guo, Q., Su, Y., & Hu, T. (2023). *LiDAR principles, processing and applications in forest ecology*. Academic Press.
- Hand, E. (2014). Carbon-mapping satellite will monitor plants' faint glow. *Science*, 344, 1211-1212.
- Hao, J., Fang, Z., Wu, B., Liu, S., Ma, Y., & Pan, Y. (2022). Tree Canopy Height Estimation and Accuracy Analysis Based on Uav Remote Sensing Images. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 129-134.
- Haralick, R.M., & Shapiro, L.G. (1992). *Computer and robot vision*. 1. Reading: Addison-wesley.
- Harding, D., Lefsky, M., Parker, G., & Blair, J. (2001). Laser altimeter canopy height profiles: Methods and validation for closed-canopy, broadleaf forests. *Remote Sensing of Environment*, 76(3), 283-297.
- Hasan, S.S., Sarmin, N.S., & Miah, M.G. (2019). Assessment of scenario-based land use changes in the Chittagong Hill Tracts of Bangladesh. *Environ. Dev.* 34, 100463.
- Heiskanen, J., Korhonen, L., Hietanen, J., & Pellikka, P.K. (2015). Use of airborne lidar for estimating canopy gap fraction and leaf area index of tropical montane forests. *International Journal of Remote Sensing*, 36(10), 2569-2583.
- Hickman, G.D., & Hogg, J.E. (1969). Application of an airborne pulsed laser for near shore bathymetric measurements. *Remote Sensing of Environment*, 1(1), 47-58.
- Hill, A., Breschan, J., & Mandallaz, D. (2014). Accuracy assessment of timber volume map using forest inventory data and LiDAR canopy height models. *Forests*, 5(9), 2253-2275.
- Hoge, F. E., Swift, R. N., & Frederick, E. B. (1980). Water depth measurement using an airborne pulsed neon laser system. *Applied Optics*, 19(6), 871-883.
- Holmgren, J., & Wallerman, J. (2006). Estimation of tree size distribution by combining vertical and horizontal distribution of LIDAR measurements with extraction of individual trees. *University of Natural Resources and Applied Life Science, Vienna, Austria*, pp. 168-173.

- Hosoi, F., Matsugami, H., Watanuki, K., Shimizu, Y., & Omasa, K. (2012). Accurate detection of tree apexes in coniferous canopies from airborne scanning light detection and ranging images based on crown extraction filtering. *Journal of Applied Remote Sensing*, 6(1), 063502.
- Hough, P. V. C. (1962). Method and means for recognizing complex patterns. In U. S. Patent, 3069654.
- Houghton, R. (2005). Aboveground forest biomass and the global carbon balance. *Global Change Biology*, 11(6), 945-958.
- Hurt, G.C., Dubayah, R., Drake, J., Moorcroft, P.R., Pacala S.W., Blair J.B., & Fearon, M.G. (2004). Beyond potential vegetation: Combining lidar data a heightstructured model for carbon studies. *Ecological Applications*, 14(3), 873-883.
- Hyypä, J., Kelle, O., Lehtikainen, M., & Inkinen, M. (2001). A segmentation based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. *IEEE Transactions on Geoscience Remote Sensing*, 39(5), 969-975.
- Jain, A.K., Murty, M.N., & Flynn, P.J. (1999). Data Clustering: A Review. *ACM Computing Surveys*, 31, 264-323.
- Jaskierniak, D., Lane, P.N., Robinson, A., & Lucieer, A. (2011). Extracting LiDAR indices to characterise multilayered forest structure using mixture distribution functions. *Remote Sensing of Environment*, 115(2), 573-585.
- Jennings, S.B., Brown, N.D., & Sheil, D. (1999). Assessing forest canopies and understorey illumination: canopy closure, canopy cover and other measures, *Forestry: An International Journal of Forest Research*, Volume 72, Issue 1, 1999, Pages 59–74
- Jin, S., Su, Y., Gao, S., Wu, F., Hu, T., Liu, J., Li, W., Wang, D., Chen, S., Jiang, Y., Pang, S., & Guo, Q. (2018). Individual maize segmentation from terrestrial lidar data using faster R-CNN and regional growth algorithms. *Frontiers in Plant Science*, 9, 866-875.
- Jin, S., Su, Y., Gao, S., Wu, F., Ma, Q., Xu, K., Ma, Q., Hu, T., Liu, J., Pang, S., Guan, H., Zhang, J., & Guo, Q. (2019). Separating the structural components of maize for field phenotyping using terrestrial lidar data and deep convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 58(4), 2644-2658.
- Jin, D., Zhijing J., Joey, T. Z., Lisa O., & Peter, S. (2020). Hooks in the headline: Learning to generate headlines with controlled styles. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pages 5082–5093.
- Jin, S., Su, Y., Zhao, X., Hu, T., & Guo, Q. (2020). A point based fully convolutional neural network for airborne LiDAR ground point filtering in forested environments. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 3958-3974.

- Jing, L., Hu, B., Li, J., & Noland, T. (2012). Automated delineation of individual tree crowns from LiDAR data by multi-scale analysis and segmentation. *Photogrammetric Engineering Remote Sensing*, 78(12), 1275-1284.
- Jinqi, C., Chuanli K., Siyao Z., Yiling L., & Jiale Y. (2023). A slope filtering method for point cloud of dense vegetation terrain based on airborne LiDAR. *Proc. SPIE 12710, International Conference on Remote Sensing, Surveying, and Mapping (RSSM 2023)*, 127100D
- Kaartinen, H., Hyypä, J., Yu, X., Vastaranta, M., Hyypä, H., Kukko, A., Holopainen, M., Heipke, C., Hirschmugl, M., & Morsdorf, F. (2012). An international comparison of individual tree detection and extraction using airborne laser scanning. *Remote Sensing*, 4(4), 950-974.
- Kahriman, A., Çakır, C. Y., & Şahin, A. (2023). Artvin Ardanuç yöresi Doğu Karadeniz göknarı-Doğu ladini karışık meşcereleri için hacim denklemleri. *Turkish Journal of Forestry*, 24(1), 1-10.
- Karasaka, Lutfiye. (2020). CSF (Cloth Simulation Filtering) Algoritmasının Zemin Noktalarını Filtrelemedeki Performans Analizi. *Afyon Kocatepe University Journal of Sciences and Engineering, Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*.
- Kellner, J.R., & Asner, G.P. (2009). Convergent structural responses of tropical forests to diverse disturbance regimes. *Ecology Letters*, 12(9), 887-897.
- Khosravipour, A., Skidmore, A.K., Wang, T., Isenburg, M., & Khoshelham, K. (2015). Effect of slope on treetop detection using a LiDAR canopy height model. *ISPRS Journal of Photogrammetry Remote Sensing*, 104, 44-52.
- Khosravipour, A., Skidmore, A.K., Isenburg, M., Wang, T., & Hussin, Y.A. (2014). Generating pit-free canopy height models from airborne lidar. *Photogrammetric Engineering and Remote Sensing*, 80(9), 863-872.
- Kilian, J., Haala, N., & Englich, M. (1996). Capture and evaluation of airborne laser scanner data. *International Archives of Photogrammetry and Remote Sensing*, 31, 383-388.
- Kim, S., Hinckley, T., & Briggs, D. (2011). Classifying individual tree genera using stepwise cluster analysis based on height and intensity metrics derived from airborne laser scanner data. *Remote Sensing of Environment*, 115(12), 3329-3342.
- Koukoulas, S., & Blackburn, G.A. (2004). Quantifying the spatial properties of forest canopy gaps using LiDAR imagery and GIS. *International Journal of Remote Sensing*, 25(15), 3049-3072.
- Krabill, W., Colins, J., Link, L., Swift, R., & Butler, M. (1984). Airborne laser topographic mapping results. *Photogrammetric Engineering and Remote Sensing*, 50(6), 685-694.
- Kramer, H.A., Collins, B.M., Kelly, M., & Stephens, S.L. (2014). Quantifying ladder fuels: A new approach using LiDAR. *Forests*, 5(6), 1432-1453.

- Kraus, K., & Mikhail, E.M. (1972). Linear least-squares interpolation. *Photogrammetric Engineering and Remote Sensing*, 38, 016-1029.
- Kraus, K., & Pfeifer, N. (1998). Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 53(4), 193-203.
- Krigul, T. (1972). *Metsatakseerimine. (Forest mensuration)*. Valgus, Tallinn. 358 pp. (In Estonian).
- Krizhevsky, A., Sutskever, I., & Hinton, G.E. (2012). Imagenet classification with deep convolutional neural networks. In *NeurIPS*, volume 25.
- Koch, B., Heyder, U., & Weinacker, H. (2006). Detection of individual tree crowns in airborne lidar data. *Photogrammetric Engineering Remote Sensing*, 72(4), 357-363.
- Landrieu, L., & Simonovsky, M. (2017). Large-scale point cloud semantic segmentation with superpoint graphs. *arXiv preprint:1711.09869*.
- Lang, M. (2010). Estimation of crown and canopy cover from airborne lidar data. *Forestry Studies*, 52: 5–17.
- Lang, M., Lilleleht, A., Neumann, M., Bronisz, K., Rolim, S.G., Seedre, M., Uri, V., & Kiviste, A. (2016). Estimation of above-ground biomass in forest stands from regression on their basal area and height. *Forestry Studies*, 64: 70–92.
- Leckie, D., Gougeon, F., Hill, D., Quinn, R., Armstrong, L., & Shreenan, R. (2003). Combined high-density lidar and multispectral imagery for individual tree crown analysis. *Canadian Journal of Remote Sensing*, 29(5), 633-649.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Lee, H.S., & Younan, N.H. (2003). DTM extraction of LiDAR returns via adaptive processing. *IEEE Transactions on Geoscience and Remote Sensing*, 41(9), 2063-2069.
- Lefsky, M.A., Cohen, W., Acker, S., Parker, G.G., Spies, T., & Harding, D. (1999). Lidar remote sensing of the canopy structure and biophysical properties of Douglasfir western hemlock forests. *Remote Sensing of Environment*, 70(3), 339-361.
- Lefsky, M.A., Harding, D., Cohen, W., Parker, G., & Shugart, H. (1999). Surface lidar remote sensing of basal area and biomass in deciduous forests of eastern Maryland, USA. *Remote Sensing of Environment*, 67(1), 83-98.
- Lefsky, M.A., Cohen, W.B., Parker G.C., & Harding, D.J.J.B. (2002). Lidar remote sensing for ecosystem studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists. *BioScience*, 52(1), 19-30.

- Lefsky, M. A. (2010). A global forest canopy height map from the moderate resolution imaging spectroradiometer and the geoscience laser altimeter system. *Geophysical Research Letters*, 37(15).
- Li, D., Wang, C., Hu, Y., & Liu, S. (2012). General review on remote sensing-based biomass estimation. *Geomatics and Information Science of Wuhan University*, 37(6), 631-635 (in Chinese).
- Li, W., Guo, Q., Jakubowski, M.K., & Kelly, M. (2012). A new method for segmenting individual trees from the lidar point cloud. *Photogramm. Eng. Remote Sens.*, 78, 75–84.
- Li, L., Guo, Q., Tao, S., Kelly, M., & Xu, G. (2015). Lidar with multi-temporal MODIS provide a means to upscale predictions of forest biomass. *ISPRS Journal of Photogrammetry and Remote Sensing*, 102, 198-208.
- Li, Y., Bu, R., Sun, M., Wu, W., Di, X., & Chen, B. (2018). PointCNN: Convolution On χ -Transformed Points. *Advances in Neural Information Processing Systems*, 31.
- Liang, X., Zhang, J., Li, H., & Yan, P. (2005). Represent ations of LIDAR data in different applications. *Remote sensing Information*, 6, 60-64 (in Chinese).
- Lin, Y., & Herold, M. (2016). Tree species classification based on explicit tree structure feature parameters derived from static terrestrial laser scanning data. *Agricultural and Forest Meteorology*, 216, 105-114.
- Lin, H., Nazari, M., & Zheng, D. (2024). PCTreeS: 3D Point Cloud Tree Species Classification Using Airborne LiDAR Images. *arXiv preprint arXiv:2412.04714*.
- Liu, Q., Fu, L., Chen, Q., Wang, G., Luo, P., Sharma, R. P., ... & Duan, G. (2020). Analysis of the spatial differences in canopy height models from UAV LiDAR and photogrammetry. *Remote Sensing*, 12(18), 2884.
- Liu, S., Zhang, M., Kadam, P., Kuo, C. C. J., Liu, S., Zhang, M., & Kuo, C. C. J. (2021). Traditional Point Cloud Analysis. *3D Point Cloud Analysis: Traditional, Deep Learning, and Explainable Machine Learning Methods*, 15-52.
- Lu, D. (2006). The potential and challenge of remote sensing-based biomass estimation. *International Journal of Remote Sensing*, 27(7), 1297-1328.
- Lu, G. Y., & Wong, D. W. (2008). An adaptive inverse-distance weighting spatial interpolation technique. *Computers & geosciences*, 34(9), 1044-1055.
- Lu, X., Guo, Q., Li, W., & Flanagan, J. (2014). A bottom-up approach to segment individual deciduous trees using leaf-off lidar point cloud data. *Isprs Journal of Photogrammetry and Remote Sensing*, 94, 1-12.
- MacArthur, R.H., & Horn, H.S. (1969). Foliage profile by vertical measurements. *Ecology Letters*, 50(5), 802-804.

- MacQueen, J. (1967). Some Methods for Classification and Analysis of Multivariate Observations. *Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability*, 1, 281-297.
- Maltamo, M., Eerikainen, K., Pitkanen, J., Hyypä, J., & Vehmas, M. (2004). Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. *Remote Sensing of Environment*, 90, 319–330.
- Masek, J., Hayes, D., Turner, D., Hughes, M.J., & Healey, S. (2015). The role of remote sensing in process-scaling studies of managed forest ecosystems. *Forest Ecol. Manage.* 355, 109–123.
- Mäyrä, J., Keski-Saari, S., Kivinen, S., Tanhuanpää, T., Hurskainen, P., Kullberg, P., & Vihervaara, P. (2021). Tree species classification from airborne hyperspectral and LiDAR data using 3D convolutional neural networks. *Remote Sensing of Environment*, 256, 112322.
- Medvigy, D., Wofsy, S., Munger, J., Hollinger, D., & Moorcroft, P. (2009). Mechanistic scaling of ecosystem function and dynamics in space and time: Ecosystem demography model version 2. *Journal of Geophysical Research: Biogeosciences*, 114(G1).
- Meyer, F., & Beucher, S. (1990). Morphological segmentation. *Journal of Visual Communication Image Representation*, 1(1), 21-46.
- Mongus, D., & Zalik, B. (2012). Parameter-free ground filtering of LiDAR data for automatic DTM generation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 1-12.
- Morsdorf, F., Meier, E., Kötz, B., Itten, K.I., Dobbertin, M., & Allgöwer, B. (2004). LIDAR based geometric reconstruction of boreal type forest stands at single tree level for forest and wildland fire management. *Remote Sensing of Environment*, 92(3), 353-362.
- Naesset, E. (1997a.) Determination of mean tree height of forest stands using airborne laser scanner data. *ISPRS Journal of Photogrammetry & Remote Sensing*, 52: 49–56.
- Naesset, E. (1997b). Estimating timber volume of forest stands using airborne laser scanner data. *Remote Sensing of Environment*, 61: 246–253.
- Nelson, R., Krabill, W., & MacLean, G. (1984). Determining forest canopy characteristics using airborne laser data. *Remote Sensing of Environment*, 15(3), 201-212.
- Nelson, R., Krabill, W., & Tonelli, J. (1988). Estimating forest biomass and volume using airborne laser data. *Remote sensing of environment*, 24(2), 247-267.
- OGM, 2017. Ekosistem Tabanlı Fonksiyonel Orman Amenajman Planlarının Düzenlenmesine Ait Usul ve Esaslar. Tebliğ No.: 299, Orman Genel Müdürlüğü.

- Oshio, H., Asawa, T., Hoyano, A., & Miyasaka, S. (2011). Estimation of tree crown structure in urban areas using high resolution airborne LiDAR. In 2011 IEEE International Geoscience and Remote Sensing Symposium (pp. 2145-2148). IEEE.
- Othmani, A., Voon, L., Stolz, C., & Piboule, A. (2013). Single tree species classification from terrestrial laser scanning data for forest inventory. *Pattern Recognition Letters*, 34(16), 2144-2150.
- Pan, Y., Birdsey, R.A., Fang, J., Houghton, R., Kauppi, P.E., Kurz, W.A., Phillips, O.L., Shvidenko, A., Lewis, S.L., & Canadell, J.G. (2011). A large and persistent carbon sink in the world's forests. *Science*, 333(6045), 988-993.
- Pang, Y., Li, Z., Chen, E., & Sun, G. (2005). Lidar remote sensing technology and its application in forestry. *Scientia Silvae Sinicae*, 41(3), 129 (in Chinese).
- Persson, A., Holmgren, J., & Söderman, U. (2002). Detecting and measuring individual trees using an airborne laser scanner. *Photogrammetric Engineering & Remote Sensing*, 68(9), 925-932.
- Persson, A., Holmgren, J., Söderman, U., & Olsson, H. (2004). Tree species classification of individual trees in Sweden by combining high resolution laser data with high resolution near-infrared digital images. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36(8), 204-207.
- Peuhkurinen, J., Mehtatalo, L., & Maltamo, M. (2011). Comparing individual tree detection and the area-based statistical approach for the retrieval of forest stand characteristics using airborne laser scanning in Scots pine stands *Canadian Journal of Forest Research*, 41(3), 583-598.
- Pingel, T.J., Clarke, K.C., & 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.
- Popescu, S.C., Wynne, R.H., & Nelson, R.F. (2002). Estimating plot-level tree heights with lidar: Local filtering with a canopy-height based variable window size. *Computers Electronics in Agriculture*, 37(1-3), 71-95.
- Popescu, S.C., Wynne, R.H., & Nelson R.F. (2003). Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. *Can. J. Remote Sensing*, 29: 564-577.
- Popescu, S.C., & Wynne, R.H. (2004). Seeing the trees in the forest. *Photogrammetric Engineering & Remote Sensing*, 70(5), 589-604.
- Pu, S., & Vosselman, G. (2006). Automatic extraction of building features from terrestrial laser scanning, *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 36, part 5, Dresden, Germany, September 25-27.
- Purves, D., & Pacala, S. (2008). Predictive models of forest dynamics. *Science*, 320(5882), 1452-1453.

- Qi, C. R., Su, H., Mo, K., & Guibas, L. J. (2017). Pointnet: Deep learning on point sets for 3D classification and segmentation supplementary material. Qi, C.R., Yi, L., Su, H., Guibas, L.J. (2017). PointNet++: Deep hierarchical feature learning on point sets in a metric space. *Advances in Neural Information Processing Systems*, 30, 5105-5114.
- Qi, C. R., Yi, L., Su, H., & Guibas, L. J. (2017). Pointnet++: Deep hierarchical feature learning on point sets in a metric space. *Advances in neural information processing systems*, 30.
- Qi, Z., Li, Y., Zhao, B., Xu, C., Liu, Y., Li, H., Zhang, B., Wang, X., Yang, X., & Xie, W. (2017). BMP restricts stemness of intestinal Lgr5(+) stem cells by directly suppressing their signature genes. *Nat. Commun.* 8, 13824.
- Quan, Y., Li, M., Hao, Y., Liu, J., & Wang, B. (2023). Tree species classification in a typical natural secondary forest using UAV-borne LiDAR and hyperspectral data. *GIScience & Remote Sensing*, 60(1), 2171706.
- Reitberger, J., Schnörr, C., Krzystek, P., & Stilla, U. (2009). 3D segmentation of single trees exploiting full waveform LIDAR data. *ISPRS Journal of Photogrammetry Remote Sensing*, 64(6), 561-574.
- Reutebuch, S.E., McGauhey, R.J., Andersen, H.E., & Carson, W.W. (2003). Accuracy of high-resolution LIDAR terrain model under a conifer forest canopy. *Canadian J. of Remote Sensing*, 29, 527–535.
- Saatchi, S.S., Harris, N. L., Brown, S., Lefsky, M., Mitchard, E.T., Salas, W., Zutta, B.R., Buermann, W., Lewis, S.L., & Hagen, S. (2011). Benchmark map of forest carbon stocks in tropical regions across three continents. *Proceedings of the National Academy of Sciences*, 108(24), 9899-9904.
- Sanchez-Lopera, J., & Lerma, J.L. (2014). Classification of Lidar bare earth points, buildings, vegetation and small objects based on region growing and angular classifier. *International Journal of Remote Sensing*, 35(19), 6955-6972.
- Sasaki, T., Imanishi, J., Ioki, K., Morimoto, Y., & Kitada, K. (2012). Object-based classification of land cover and tree species by integrating airborne LiDAR and high spatial resolution imagery data. *Landscape and Ecological Engineering*, 8, 157-171.
- Schmol, S., & Sörgel, U. (2019). Submanifold sparse convolutional networks for semantic segmentation of large scale ALS point clouds. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4, 77-84.
- Schnabel, R., Wahl, R., & Klein, R. (2007, June). Efficient RANSAC for point- cloud shape detection. In *Computer graphics forum* (Vol. 26, No. 2, pp. 214-226). Oxford, UK: Blackwell Publishing Ltd.
- Shamsoddini, A., Turner, R., & Trinder, J. (2013). Improving lidar based forest structure mapping with crown level pit removal. *Journal of Spatial Science*, 58(1), 29-51.
- Shi, Y., Skidmore, A. K., Wang, T., Holzwarth, S., Heiden, U., Pinnel, N., & Heurich, M. (2018). Tree species classification using plant functional traits from LiDAR and

- hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 73, 207-219.
- Shugart, H., Saatchi, S., & Hall, F. (2010). *Journal of Geophysical Research: Biogeosciences*, 115(G2).
- Silva, C.A., Hudak, A.T., Vierling, L.A., Loudermilk, E.L., O'Brien, J.J., Jack, S.B., Gonzalez-Beneque, C., Hiers, J.K., Lee, H., & Falkowski, M.J. (2016). Imputation of Individual Loblolly Pine (*Pinus palustris* Mill.) Tree Attributes from Field and LiDAR Data. *Can. J. Remote Sens*, 42, 554–573.
- Silva, C.A., Valbuena R., Pinage, E.R., Moham, M., de Almeida, D.R., North Broadbent, E., Jaafar, W.S.W., de Almeida Papa, D., Cardil A., & Klauberg, C. (2019). ForestGapR: An R Package for forest gap analysis from canopy height models. *Methods in Ecology and Evolution*, 10(8), 1347-1356.
- Sitch, S., Smith, B., Prentice, I. C., Arneth, A., Bondeau, A., Cramer, W., Kaplan, J. O., Levis, S., Lucht, W., & Skykes, M. T. (2003). Evaluation of ecosystem dynamics, plant geography and terrestrial carbon cycling in the LPJ dynamic global vegetation model. *Global Change Biology*, 9(2), 161-185.
- Sithole, G., & Vosselman, G. (2004). Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59(1-2), 85-101.
- Sithole, G. (2005). Segmentation and classification of airborne laser scanner data. *Publications on Geodesy*, 59.
- Sokolova, M., Japkowicz, N., & Szpakowicz, S. (2006). Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation. In: *Australasian joint conference on artificial intelligence*. Springer.
- Solberg, S., Naesset, E., & Bollandsas, O.M. (2006). Single tree segmentation using airborne laser scanner data in a structurally heterogeneous spruce forest. *Photogrammetric Engineering Remote Sensing*, 72(12), 1369-1378.
- Strimbu, V.F., & Strimbu, B.M. (2015). A graph-based segmentation algorithm for tree crown extraction using airborne LiDAR data. *ISPRS Journal of Photogrammetry Remote Sensing*, 104, 30-43.
- Su, Y., Guo, Q., Fry, D.L., Collins, B.M., Kelly, M., Flanagan, J.P., & Battles, J.J. (2016). A vegetation mapping strategy for conifer forests by combining airborne LiDAR data and aerial imagery. *Canadian Journal of Remote Sensing*, 42(1), 1-15.
- Su, Y., Guo, Q., Xue, B., Hu, T., Alvarez, O., Tao, S., & Fang, J. (2016). Spatial distribution of forest aboveground biomass in China: Estimation through combination of spaceborne lidar, optical imagery, and forest inventory data. *Remote Sensing of Environment*, 173, 187-199.

- Sugumaran, R., & Voss, M. (2007). Object-oriented classification of LIDAR-fused hyperspectral imagery for tree species identification in an urban environment. Urban Remote Sensing Joint Event, 1-6.
- Susaki, J. (2012). Adaptive slope filtering of airborne LiDAR data in urban areas for digital terrain model (DTM) generation. Remote Sensing, 4(6), 1804-1819.
- Swami, A., & Jain, R. (2013). Scikit-learn: machine learning in python. Journal of Machine Learning Research, 12, 2825-2830.
- Tao, S., Wu, F., Guo, Q., Wang, Y., Li, W., Xue, B., Hu, X., Li, P., Tian, D., & Li, C. (2015). Segmenting tree crowns from terrestrial and mobile LiDAR data by exploring ecological theories. ISPRS Journal of Photogrammetry Remote Sensing, 110, 66-76.
- Teboul, O., Simon, L., Koutsourakis, P., & Paragiso, N. (2010). Segmentation of building facades using procedural shape priors. 010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Francisco, CA, USA, 2010, pp. 3105-3112.
- Terryn, L., Calders, K., Disney, M., Origo, N., Malhi, Y., Newnham, G., Raunonen, P., Akerblom, M., & Verbeeck, H. (2020). Tree species classification using structural features derived from terrestrial laser scanning. ISPRS Journal of Photogrammetry and Remote Sensing, 168, 170-181.
- Tovari, D., & Pfeifer, N. (2005). Segmentation based robust interpolation a new approach to laser data filtering. International Archives of Photogrammetry and Remote Sensing, 33, 935-942.
- Türk, T., & Öcalan, T. (2020). Examining the Accuracy of Photogrammetric Products Obtained by Unmanned Aerial Vehicles having PPK GNSS System with Different Approaches. Türkiye Fotogrametri Dergisi , vol.2, no.1, pp.22-28.
- URL-1. (2025, Ocak 15). PMF algoritması: www.r-lidar.github.io/lidRbook/gnd.html adresinden alındı.
- URL-2. (2025, Ocak 15). CSF algoritması: [www.cloudcompare.org/doc/wiki/index.php?title=CSF_\(plugin\)](http://www.cloudcompare.org/doc/wiki/index.php?title=CSF_(plugin)) adresinden alındı.
- URL-3. (2024, Aralık 11). İHA ürün bilgileri: www.dji.com/global adresinden alındı.
- URL-4. (2024, Ekim 21). Yapay zeka ile harita üretmek için: www.sustainability.fb.com/blog/2024/04/22/using-artificial-intelligence-to-map-the-earths-forests/ adresi kullanılmıştır.
- URL-5. (2024, Temmuz 29). Kanopi yükseklik modeli gösterimi: www.earthdatascience.org adresinden alındı.
- URL-6. (2024, Ağustos, 15). Lazer cihaza ait açıklayıcı bilgiler: www.arf.berkeley.edu/files/webfiles/all/arf/equipment/feld/LaserRangeFinder/lti_tru_pulse_360_user_manual.pdf; Laser Technology, Inc. (2007) adresinden alındı.

- Varvia, P., Lähivaara, T., Maltamo, M., Packalen, P., & Seppänen, A. (2018). Gaussian process regression for forest attribute estimation from airborne laser scanning data. *IEEE Transactions on Geoscience and Remote Sensing*, 57(6), 3361-3369.
- Vepakomma, U., St-Onge, B., & Kneeshaw, D. (2008). Spatially explicit characterization of boreal forest gap Dynamics using multi-temporal lidar data. *Remote Sensing of Environment*, 112(5), 2326-2340.
- Vepakomma, U., St-Onge, B., & Kneeshaw, D. (2011). Response of a boreal forest to canopy opening: Assessing vertical and lateral tree growth with multi-temporal lidar data. *Ecological Applications*, 21(1), 99-121.
- Vo, A., Linh, H., Debra, F., & Michela, B. (2015). Octree-based region growing for point cloud segmentation, *ISPRS Journal of Photogrammetry and Remote Sensing*, volume 104, 88-100.
- Voss, M., & Sugumaran, R. (2008). Seasonal effect on tree species classification in an urban environment using hyperspectral data, LiDAR, and an object-oriented approach. *Sensors*, 8(5), 3020-3036.
- Vosselman, G., Gorte, B.G.H., & Sithole, G. (2004a). Change detection for updating medium scale maps using laser altimetry. In: *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 34, Part B3, Istanbul, Turkey, 12-23July, pp. 207-212.
- Vrontis, D., Chatterjee, S., & Chaudhuri, R. (2021). Knowledge sharing in international markets for product and process innovation: Moderating role of firm's absorptive capacity. *International Marketing Review*.
- Wang, C.-K., & Tseng, Y.-H. (2010a). DEM generation from airborne LiDAR data by an adaptive dual-directional slope filter.
- Wang, M., & Tseng, Y.H. (2010b). Automatic segmentation of LiDAR data into coplanar point clusters using an octree based split and merge algorithm. *Photogrammetric Engineering and Remote Sensing*, 76(4), 407-420.
- Wang, Y., Sun, Y., Liu, Z., Sarma, S. E., Bronstein, M. M., & Solomon, J. M. (2019). Dynamic graph cnn for learning on point clouds. *ACM Transactions on Graphics (tog)*, 38(5), 1-12.
- Wang, J., Chen, X., Cao, L., An, F., Chen, B., Xue, L., & Yun, T. (2019). Individual rubber tree segmentation based on ground-based LiDAR data and faster R-CNN of deep learning. *Forests*, 10(9), 793-812.
- Wang, D. (2020). Unsupervised semantic and instance segmentation of forest point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 165, 86-97.
- Wang, W.-Z., Liu, L.-C., Liao, H., & Wei, Y.-M. (2021). Impacts of Urbanization on Carbon Emissions: An Empirical Analysis from OECD Countries. *Energy Policy* 151, 112171.

- Wehr, A., & Lohr, U. (1999). Airborne laser scanning—an introduction and overview. *ISPRS Journal of photogrammetry and remote sensing*, 54(2-3), 68-82.
- Wessman, C.A., Aber, J.D., Peterson, D. L., & Melillo, J.M. (1988). Remote sensing of canopy chemistry and nitrogen cycling in temperate forest ecosystems. *Nature*, 335(6186), 154-156.
- White, J.D., Ryan, K. C., Key C.C., & Running, S. W. (1996). Remote sensing of forest fire severity and vegetation recovery. *International Journal of Wildland Fire*, 6(3), 125-136.
- Windrim, L., & Bryson, M. (2020). Detection, segmentation, and model fitting of individual tree stems from airborne laser scanning of forests using deep learning. *Remote Sensing*, 12(9), 1469.
- Wing, B.M., Ritchie, M.W., Boston, K., Cohen, W.B., Gitelman, A., & Olsen, M.J. (2012). Prediction of understory vegetation cover with airborne lidar in an interior ponderosa pine forest. *Remote Sensing of Environment*, 124, 730-741.
- Wu, Z., Song, S., Aditya, K., Yu, F., Zhang, L., Tang, X., & Xiao, J. (2015). 3D ShapeNets: A deep representation for volumetric shapes, in: *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1912–1920.
- Wu, W., Black M.J., Gao Y., Serruya M., Shaikhouni A., Donoghue J., & Bienenstock E. (2003) Neural decoding of cursor motion using a Kalman filter. In: *Advances in neural information processing systems*, pp 133- 140.
- Wulder, M. A., Masek, J. G., Cohen, W. B., Loveland, T. R., & Woodcock, C. E. (2012). Opening the archive: how free data has en-abled the science and monitoring promise of Landsat. *Remote Sens-ing of Environment*, Vol. 122: pp. 2–10.
- Xu, W., Kang, Z., & Jiang, T. (2009). Segmentation approach for terrestrial point clouds based on the integration of graph theory and region growing. *Joint Urban Remote Sensing Event*, Shanghai, China, 2009, pp. 1-8.
- Xu, Z., Shen, X., Cao, L., Coops, N.C., Goodbody, T.R.H., Zhong, T., Zhao, W.D., Sun, Q.L., Ba, S., Zhang, Z.N., & Wu, X.Q. (2020). Tree species classification using UAS-based digital aerial photogrammetry point clouds and multispectral imageries in subtropical natural forests. *International Journal of Applied Earth Observation and Geoinformation*, 92, 102173.
- Xu, Q., Yang, F., Hu, S., He, X., & Hong, Y. (2024). Tree Height–Diameter Model of Natural Coniferous and Broad-Leaved Mixed Forests Based on Random Forest Method and Nonlinear Mixed-Effects Method in Jilin Province, China. *Forests*, 15(11), 1922.
- Xue, B.L., Guo, Q., Otto, A., Xiao, J., Tao, S., & Li, L. (2015). Global patterns, trends, and drivers of water use efficiency from 2000 to 2013. *Ecosphere*, 6(10), 1-18.
- Yang, Q., Su, Y., Jin, S., Kelly, M., Hu, T., Ma, Q., Li, Y., Song, S., Zhang, J., Xu, G., Wei, J., & Guo, Q. (2019). The influence of vegetation characteristics on individual tree

- segmentation methods with airborne LiDAR data. *Remote Sensing*, 11(23), 2880-2897.
- Yang, W., Liu, Y., He, H., Lin, H., Qiu, G., & Guo, L. (2021). Airborne LiDAR and photogrammetric point cloud fusion for extraction of urban tree metrics according to street network segmentation. *IEEE Access*, 9, 97834-97842.
- Yi, L., Kim, V. G., Ceylan, D., Shen, I.-C., Yan, M., Su, H., Lu, C., Huang, Q., Sheffer, A., & Guibas, L. (2016). A scalable active framework for region annotation in 3d shape collections. *ACM Transactions on Graphics (TOG)* 35(6): 1–12.
- Yu, G., Wang, Q., & Zhu, X. (2011). Methods and uncertainties in evaluating the carbon budgets of regional terrestrial ecosystems. *Progress in Geography*, 30(1), 103-113.
- Yu, X., Hyyppä, J., Kukko, A., Maltamo, M., & Kaartinen, H. (2006). Change detection techniques for canopy height growth measurements using airborne laser scanner data. *Photogrammetric Engineering and Remote Sensing*, 72(12):1339–1348.
- Yu, J., Lei, L., & Li, Z. (2024). Individual tree segmentation based on seed points detected by an adaptive crown shaped algorithm using UAV-LiDAR data. *Remote Sensing*, 16(5), 825.
- Yousefhussien, M., Kelbe, D.J., Ientilucci, E.J., & Salvaggio, C. (2018). A multi-scale fully convolutional network for semantic labeling of 3D point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 143, 191-204.
- Zhang, J., & Lin, X. (2013). Filtering airborne LiDAR data by embedding smoothness constrained segmentation in progressive TIN densification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 81, 44-59.
- Zhang, K., Chen, S.-C., Whitman, D., Shyu M.-L., Yan, J., & Zhang, C. (2003). A progressive morphological filter for removing nonground measurements from airborne LIDAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 41(4), 871-882.
- Zhang, R., Li, G., Li, M., & Wang, L. (2018). Fusion of images and point clouds for the semantic segmentation of large-scale 3D scenes based on deep learning, *ISPRS J. Photogramm. Remote Sens.*, 143, 85-96.
- Zhao, D., Pang, Y., Li, Z., & Sun, G. (2013). Filling invalid values in a lidar derived canopy height model with morphological crown control. *International Journal of remote Sensing*, 34(13), 4526-4654.
- Zhao, D., Pang, Y., Liu, L.J., & Li, Z.Y. (2020). Individual tree classification using airborne LiDAR and hyperspectral data in a natural mixed forest of Northeast China. *Forests*, 11(3), 303.
- Zhao, X., Guo, Q., Su, Y., & Xue, B. (2016). Improved progressive TIN densification filtering algorithm for airborne LiDAR data in forested areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117, 79-91.

- Zhenyang H., Leyang W., Yao Y. Z., Shangshu C., & Yuanping X. (2019). Automatic morphological filtering algorithm for airborne lidar data in urban areas. *Appl. Opt.* 58, 1164-1173
- Zhong, H., Lin, W., Liu, H., Ma, N., Liu, K., Cao, R., & Ren, Z. (2022). Identification of tree species based on the fusion of UAV hyperspectral image and LiDAR data in a coniferous and broad-leaved mixed forest in Northeast China. *Frontiers in Plant Science*, 13, 964769.
- Zhu, X., Wang, T., Darvishzadeh, R., Skidmore, A.K., & Niemann, K.O. (2015). 3D leaf water content mapping using terrestrial laser backscatter intensity with radiometric correction. *Isprs Journal of Photogrammetry and Remote Sensing*, 110, 14-23.
- Zhugeng, D. U. A. N., & Huashun, X. I. A. O. (2011). Review of methods for forest parameter estimation with LiDAR. *Forest and Grassland Resources Research*, (4), 117.
- Zou, T., Yang, S., Zhang, Y., & Ye, M. (2020). Attention guided neural network models for occluded pedestrian detection. *Pattern Recognition Letters*, 131: 91–97.

8. EKLER

Bu tez çalışmasında kullanılan tüm R ve Google Colab ortamında yazılmış kodlara GitHub sayfam üzerinden erişebilirsiniz. Kodlar, ilgili açıklamalar ve kullanım yönergeleriyle birlikte paylaşılmıştır. İncelemek için aşağıdaki bağlantıyı ziyaret edebilirsiniz.

<https://github.com/tolga-odabas>



ÖZGEÇMİŞ

Tolga ODABAŞ, İlköğrenimini GSD Eğitim Vakfı İlköğretim Okulu'nda bitirdikten sonra lise eğitimini 2005 yılında İstanbul Bahçelievler Lisesi'nde tamamladı. 2007-2008 öğretim yılında Karadeniz Teknik Üniversitesi, Gümüşhane Mühendislik Fakültesi, Jeodezi ve Fotogrametri Mühendisliği Bölümü'nde Lisans eğitimine başladı. 2011 yılında aynı bölümden mezun oldu. Aynı yıl Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı'nda Tezli Yüksek Lisans programına başladı. 2018 yılında “*Hava LiDAR verilerinden rezervuar alanının otomatik çıkarımı: Kestel barajı örneği*” başlıklı Yüksek Lisans Tezi'ni tamamlamasının ardından doktora eğitimine başladı. 2014 yılından itibaren Artvin Çoruh Üniversitesi, Artvin Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Harita ve Kadastro Programı'nda Öğretim Görevlisi olarak görev yapmaktadır. Evli ve Öykü isimli bir kız çocuğu vardır.

M. ZEYBEK and T. ODABAŞ, “İHAlardan Elde edilen Nokta Bulutlarının Sınıflandırılması,” presented at the Uluslararası Artvin Sempozyumu, Artvin, 2018.

M. ZEYBEK and T. ODABAŞ, “Artvin Çoruh Üniversitesi Seyitler Kampüs Alanı Halihazır ve Ortomozaik Üretiminde İnsansız Hava Araçlarının (İHA) Kullanılması,” presented at the Uluslararası Artvin Sempozyumu, Artvin, 2018.