

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**LİDAR NOKTA BULUTLARININ SEMANTİK SEGMENTASYONU İÇİN
DERİN ÖĞRENME TABANLI İYİLEŞTİRİLMİŞ POINTNET++ MİMARİSİ**

DOKTORA TEZİ

Zeynep AKBULUT

**MART 2023
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**LİDAR NOKTA BULUTLARININ SEMANTİK SEGMENTASYONU İÇİN
DERİN ÖĞRENME TABANLI İYİLEŞTİRİLMİŞ POINTNET++ MİMARİSİ**

Zeynep AKBULUT

ORCID : - - -

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

Tezin Enstitüye Verildiği Tarih : 24 / 02 / 2023

Tezin Savunma Tarihi : 31 / 03 / 2023

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

Trabzon 2023

ÖNSÖZ

“LiDAR Nokta Bulutlarının Semantik Segmentasyonu İçin Derin Öğrenme Tabanlı İyileştirilmiş PointNet++ Mimarisi” adlı bu çalışma, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında Doktora Tezi olarak hazırlanmıştır.

Tez çalışmam sürecinde danışmanlığımı üstlenen, çalışma prensiplerini benimsediğim, değerli fikirleri ve önerileriyle çalışmalarına yön veren ve her türlü desteğini sağlayan değerli hocam Sayın Prof. Dr. Fevzi KARSLI'ya sonsuz teşekkürlerimi sunarım.

Orta Doğu Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü öğretim üyesi hocam Sayın Prof. Dr. Sinan KALKAN'a derin öğrenme konusunda kendimi geliştirmek için bana bilgi ve birikimlerinden faydalanma fırsatını vererek bir dönem boyunca Kovan Research Lab'da sunduğu imkanlar için kendisine ve laboratuvarında bana destek sağlayan tüm hocalarıma sonsuz teşekkürlerimi sunarım. Ayrıca Orta Doğu Teknik Üniversitesi Enformatik Enstitüsü öğretim üyelerinden hocam sayın Prof. Dr. Alptekin TEMİZEL'e ileri derin öğrenme konularında ve öğrencisi sayın hocam Dr. Cihan ÖNGÜN'e PointNet mimarisi hakkında verdikleri kıymetli bilgilerinden dolayı sonsuz teşekkürlerimi sunarım.

Doktora tez çalışmam boyunca değerli bilgi ve öngörülerinden yararlandığım hocam Sayın Dr. Öğr. Üyesi Mustafa DİHKAN'a sonsuz teşekkürlerimi sunarım. Tez izleme üyesi değerli hocam Dr. Öğr. Üyesi Mehmet ÖZTÜRK'e, jüri üyeleri Sayın Prof. Dr. Taşkın KAVZOĞLU ve Prof. Dr. Semih EKERCİN hocalarıma verdikleri kıymetli katkılardan dolayı teşekkürlerimi sunarım.

Her zaman yanımda olarak bu zorlu süreci benim için kolaylaştıran değerli arkadaşlarım başta Sayın Arş. Gör. Dr. Samed ÖZDEMİR'e, Dr. Öğr. Üyesi Hayrettin ACAR'a, Dr. Öğr. Üyesi Ziya USTA'ya ve Arş. Gör. Sebahat ŞİMŞEK'e sonsuz teşekkürlerimi sunarım. Ayrıca derin öğrenme ve programlama alanındaki tecrübesi ile hep yanımda olan arkadaşım çok kıymetli Efsun SEZER'e sonsuz teşekkürlerimi sunarım.

Hayatım boyunca hep yanımda olan başta canım annem Asiye AKBULUT ve canım babam Osman AKBULUT olmak üzere ailemin çok kıymetli üyelerinin her birine ayrı ayrı sonsuz teşekkürlerimi sunarım.

Zeynep AKBULUT
Trabzon 2023

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “LiDAR Nokta Bulutlarının Semantik Segmentasyonu İçin Derin Öğrenme Tabanlı İyileştirilmiş PointNet++ Mimarisi” 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 kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

31/03/2023

Zeynep AKBULUT

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	XI
KISALTMALAR DİZİNİ	XIII
1. GİRİŞ	1
1.1. Problemin Tanımı	3
1.2. Çalışmanın Amacı.....	4
1.3. Tezin Ana Hattı.....	4
2. LİTERATÜR TARAMASI	6
2.1. Yapay Zekadan Derin Öğrenmeye.....	6
2.2. Derin Öğrenme.....	9
2.3. Nokta Bulutlarında Derin Öğrenme	13
2.3.1. 3B Veri Temsilleri	13
2.3.1.1. Vokseller	15
2.3.1.2. Çoklu Görü.....	15
2.3.1.3. Nokta Bulutları.....	16
2.3.2. Farklı Temsillerde 3B Derin Öğrenme	17
2.3.2.1. Projeksiyon Tabanlı Yöntemler	18
2.3.2.2. Ayrıklaştırma Tabanlı Yöntemler	20
2.3.2.3. Nokta Tabanlı Yöntemler	20
2.4. Hava LiDAR Nokta Bulutları	23
2.5. Hava LiDAR Nokta Bulutlarında 3B Derin Öğrenme.....	26
2.5.1. Literatür Özeti	35
3. YÖNTEM VE VERİ SETİ	39

3.1.	Veri Setlerinin Tanıtımı	39
3.1.1.	Veri Seti 1: ISPRS 3B Semantik Etiketleme Benchmark	40
3.1.2.	Veri Seti 2: DALES	43
3.1.3.	Veri Seti 3: OpenGF	46
3.2.	PointNet Mimarisi	48
3.3.	PointNet++ Mimarisi	51
3.3.1.	PointNet++ Mimarisinin Parametre Seçimi	55
3.4.	FPS Yöntemi ile Nokta Bulutunun Alt Örneklenmesi	57
3.5.	PointNet++ Mimarisinin Nokta Örnekleme Stratejisi	60
3.6.	Optimum Komşuluk Arama Yarıçap Seçimi	60
3.7.	Adaptif Çerçeve Boyutu Seçimi	64
3.7.1.	Adaptif Çerçeve Boyutu Seçiminde 1. Yaklaşım	65
3.7.2.	Adaptif Çerçeve Boyutu Seçiminde 2. Yaklaşım	67
3.8.	Doğruluk Metrikleri	70
4.	BULGULAR VE İRDELEMELER	73
4.1.	ISPRS Veri Seti İçin Doğruluklar	74
4.1.1.	ISPRS Veri Seti Üzerinden Genel Bulgular	88
4.2.	DALES Veri Seti İçin Doğruluklar	89
4.2.1.	DALES Veri Seti Üzerinden Genel Bulgular	107
4.3.	OPENGF Veri Seti İçin Doğruluklar	108
4.3.1.	OpenGF Veri Seti Üzerinden Genel Bulgular	114
4.4.	Nokta Bulutu Özniteliklerinin Semantik Segmentasyona Etkisi	115
4.5.	Yöntemin Genelleştirme Kabiliyeti	118
5.	SONUÇLAR	122
6.	KAYNAKLAR	125
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

LİDAR NOKTA BULUTLARININ SEMANTİK SEGMENTASYONU İÇİN DERİN ÖĞRENME TABANLI İYİLEŞTİRİLMİŞ POINTNET++ MİMARİSİ

Zeynep AKBULUT

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Fevzi KARSLI
2023, 131 Sayfa

Bu çalışmada, hava LiDAR nokta bulutlarının semantik segmentasyonunda iç mekân nokta bulutları için tasarlanmış, nokta bulutlarını doğrudan işleyebilen ve bu alanda öncü bir 3B Derin Sinir Ağı (DNN) mimarisi olan PointNet++ kullanılmıştır. Öncelikli olarak PointNet++ mimarisi çoklu sınıf arazi örtüsü ve iki sınıflı zemin/zemin-üstü problemlerinin semantik segmentasyonu için büyük ölçekli hava LiDAR nokta bulutlarına uyarlanmıştır. Mimariyi değişken nokta yoğunluğuna karşı daha kararlı hale getirebilmek amacı ile mimarinin orijinal yığın toplama stratejisi yerine nokta yoğunluğuna adapte olabilen Adaptif 1 ve Adaptif 2 isiminde iki yeni yaklaşım önerilmiştir. Ayrıca, mimarinin farklı gruplama katmanlarını birleştiren yeni bir hibrit model geliştirilerek işleme süresi ve performansı açısından avantaj ve dezavantajları değerlendirilmiştir. Tez kapsamında, komşuluk arama yarıçap seçimini başlangıç değer için otomatize edebilen bir yaklaşım da önerilmiştir. Bunların yanı sıra, yoğunluk, geri dönüş sayısı ve dönüş numarası gibi ek ham özniteliklerin mimarinin performansı üzerine olan etkileri de irdelenmiştir. Önerilen yaklaşımların semantik segmentasyon performansları ISPRS Vaihingen, DALES, düzensiz DALES ve OpenGF nokta bulutu veri setleri üzerinde araştırılmıştır. Özellikle nokta yoğunluğu değişkenliğinin fazla olduğu OpenGF test veri setleri üzerinde orijinal mimariye göre ağırlıklı ortalama kesişim-birleşim oranı (mIoU) metriği Adaptif 1 yaklaşımı ile %17'ye ve Adaptif 2 yaklaşımı ile %11'e varan iyileşme göstermiştir. Adaptif 1 ve Adaptif 2 yaklaşımları sayesinde düzensiz DALES veri seti üzerinde mIoU doğruluklarında sırası ile %1 ve %3 performans artışı sağlanmıştır. Adaptif 1 ve Adaptif 2 yaklaşımlarının genelleştirme kabiliyetleri test edilerek orijinal mimariye göre doğruluk düzeylerinde sırasıyla yaklaşık %3 ve %5 oranında iyileşme sağladığı tespit edilmiştir. Bu yaklaşımlar sayesinde mimarinin deneme yanılma yöntemi ile parametre seçimine olan ihtiyacı büyük oranda ortadan kaldırılmıştır. Mimari, değişken nokta yoğunluğuna ve parametre seçimine karşı daha kararlı bir hale getirilmiştir.

Anahtar Kelimeler: Derin Öğrenme, LiDAR, Nokta Bulutu, Semantik Segmentasyon, PointNet++.

PhD. Thesis

SUMMARY

AN IMPROVED DEEP LEARNING BASED POINTNET++ ARCHITECTURE
FOR SEMANTIC SEGMENTATION OF LiDAR POINT CLOUDS

Zeynep AKBULUT

Karadeniz Technical University
Graduate School of Natural and Applied Sciences
Geomatics Engineering Department
Supervisor: Prof. Dr. Fevzi KARSLI
2023, 131 Pages

PointNet++, a 3D Deep Neural Network (DNN) architecture that can directly process point clouds and is designed for indoor point clouds, is used for the semantic segmentation of Airborne Laser Scanning (ALS) point clouds. Initially, the PointNet++ architecture is adapted to large-scale airborne LiDAR point clouds for multi-class land cover and binary ground/non-ground semantic segmentation tasks. Two new approaches, called Adaptive 1 and Adaptive 2, are proposed to make the architecture more robust against varying point densities by adapting to point density instead of using the original batching strategy. Furthermore, a new hybrid model that combines different grouping layers of the architecture is developed and evaluated in terms of processing time and semantic segmentation performance. In addition, an approach is proposed to automate the selection of the initial value for the neighborhood search radius. Also, the effects of additional raw attributes such as intensity, return number and number of returns on the performance of the architecture are investigated. The semantic segmentation performances of the proposed approaches are evaluated on ISPRS Vaihingen, DALES, irregular DALES, and OpenGF point cloud datasets. Specifically, on the OpenGF test datasets with high point density variation, the architecture's weighted average Intersection over Union (mIoU) accuracy has improved by up to 17% with the Adaptive 1 approach and 11% with the Adaptive 2 approach. Adaptive 1 and Adaptive 2 approaches have achieved performance increases of 1% and 3% in mIoU accuracy on the irregular DALES dataset, respectively. The results show that the Adaptive 1 and Adaptive 2 approaches improve the generalization ability of the PointNet++ architecture for mIoU by approximately 3% and 5%, respectively. These proposed approaches significantly reduce the need for trial-and-error parameter selection while making the architecture more robust against both point sampling and parameter selection.

Keywords: Deep Learning, LiDAR, Point Cloud, PointNet++, Semantic Segmentation.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. Derin öğrenme, temsilli öğrenme, makine öğrenme ve yapay zeka arasındaki ilişkiyi gösteren ve her bir teknoloji için örneklerin verildiği Venn şeması.....	7
Şekil 2. MLP katmanlarına örnek görseli Zhang vd. (2021)'den uyarlanmıştır.....	11
Şekil 3. 3B veri temsillerine DALES veri seti üzerinden bir örnek	14
Şekil 4. Farklı veri temsillerine göre nokta bulutlarında derin öğrenme yöntemlerinin sınıflandırılması.....	18
Şekil 5. Nokta bulutunun semantik segmentasyonunda noktasal MLP yöntemlerin kronolojik sıralaması Guo vd. (2021b)'den uyarlanmıştır	22
Şekil 6. LiDAR ile haritalama örneği Habib (2017)'den uyarlanmıştır	24
Şekil 7. ISPRS 3B semantik etiketleme benchmark veri setinin eğitim ve test verisi nokta sayıları ve her bir sınıf için nokta dağılım oranları	41
Şekil 8. ISPRS 3B Vaihingen semantik benchmark eğitim verisi ve altta kNN ile oluşturulan eğitim veri seti için üç örnek	42
Şekil 9. Eğitim ve validasyon veri setindeki sınıf dağılımları.....	42
Şekil 10. DALES veri setine ait eğitim ve test nokta bulutlarının sınıf bazındaki nokta sayıları ve dağılımları	44
Şekil 11. DALES eğitim verisi setine ait örnek bir nokta bulutu	45
Şekil 12. DALES veri seti için validasyon ve eğitim veri setlerine ait dağılım oranları.....	45
Şekil 13. Eğitim, test ve validasyon veri setleri için nokta sayıları ve dağılım oranları	47
Şekil 14. OpenGF veri setine ait farklı arazi türlerinden seçilmiş örnek eğitim nokta bulutları.....	48
Şekil 15. PointNet mimarisi Qi vd. (2017a)'dan uyarlanmıştır.....	49
Şekil 16. PointNet++ mimarisi Qi vd. (2017b)'den uyarlanmıştır	52
Şekil 17. Yoğunluğa uyumlu gruplama katmanları Qi vd. (2017b)'den uyarlanmıştır a) MSG b) MRG	54
Şekil 18. PointNet++ katmanlarında rastgele ve FPS yöntemi ile alt örneklenen nokta bulutları.....	59
Şekil 19. ISPRS veri setinde farklı arama yarıçapları için E λ sonuçları	63
Şekil 20. DALES veri setinde farklı arama yarıçapları için E λ sonuçları	63
Şekil 21. Adaptif 1 yaklaşımında çerçeve içine düşen nokta sayılarındaki değişim	66
Şekil 22. Adaptif 2 çerçeve belirleme stratejisi için oluşturulan PDF dağılımı	68
Şekil 23. ISPRS Benchmark veri setinden seçilen örnek bir alan üzerinde adaptif çerçeve boyutu belirleme işlemi	69

Şekil 24. IoU metriğinin görsel ifadesi	72
Şekil 25. 15×15 m çerçeve boyutu kullanılarak orijinal PointNet++ mimarisi ile elde edilen semantik segmentasyon sonuçları.....	76
Şekil 26. Semantik segmentasyon sonucunda bulunan hatalı ve doğru noktalar	77
Şekil 27. Model 1 için ISPRS semantik segmentasyon sonuçları	84
Şekil 28. Model 1 sonucunda tespit edilen hatalı ve doğru noktalar	85
Şekil 29. ISPRS veri seti üzerinde Adaptif 1 ve Adaptif 2 yaklaşımlarının semantik segmentasyon sonuçları.....	87
Şekil 30. Adaptif 1 ve Adaptif 2 yaklaşımları ile hatalı ve doğru tespit edilen noktalar	88
Şekil 31. DALES veri seti üzerinde uygulanan dört model için elde genel doğruluk değerleri.....	97
Şekil 32. DALES verisi için semantik segmentasyon sonuçları ve hatalı tespitler	98
Şekil 33. Orijinal, Adaptif 1 ve Adaptif 2 (30×30) PointNet++ mimarilerinin düzensiz DALES veri setleri üzerindeki GD ve ağırlıklı ortalama IoU doğruluklarının karşılaştırılması.....	102
Şekil 34. Orijinal yaklaşım, Adaptif 1 ve Adaptif 2 PointNet++ mimarilerinin DALES ve düzensiz DALES veri setleri üzerindeki ağırlıklı ort. IoU doğruluklarının karşılaştırması	103
Şekil 35. Düzensiz DALES veri setinde Adaptif 1 yaklaşım sonuçları	104
Şekil 36. Düzensiz DALES veri setinde Adaptif 2 yaklaşım sonuçları	105
Şekil 37. Test 1 verisinde zemin ve zemin-üstü noktalarında elde edilen hatalı sonuçlar.....	110
Şekil 38. Test 2 veri setinde zemin ve zemin-üstü noktalarında elde edilen hatalı sonuçlar.....	111
Şekil 39. Test 2 gürültüsüz veri setinde zemin ve zemin-üstü noktalarında elde edilen hatalı sonuçlar	113
Şekil 40. OpenGF veri setinin Uygulama 1, Uygulama 2 ve Uygulama 3 modelleri için Test 1, Test 2 ve Test 2_ gürültüsüz test veri setleri üzerinde elde edilen genel doğrulukları	114
Şekil 41. Düzensiz DALES verisi üzerinde eğitilen mimarilerin ISPRS test verisi üzerindeki test sonuçları	120

TABLÖLAR DİZİNİ

Sayfa No

Tablo 1. Orijinal PointNet++ veya modifiye edilmiş PointNet++ algoritmasını kullanan araştırmacıların farklı veri setleri üzerinde elde ettikleri doğruluklar	38
Tablo 2. OpenGF veri setine ait bilgiler	46
Tablo 3. PointNet++ mimarisinin semantik segmentasyon modeline ait varsayılan geometrik ve ağ hiper-parametreleri.....	56
Tablo 4. FPS pseudo kod Li vd. (2022)'den uyarlanmıştır.....	58
Tablo 5. Değiştirilen nokta kopyalama stratejisine ait pseudo kod	60
Tablo 6. Dört sınıflı bir problemde Sınıf 1 için hata matrisi örneği	71
Tablo 7. Kullanılan bilgisayara ait yazılım ve donanım bilgileri	73
Tablo 8. Farklı çerçeve boyutlarının mimarinin ISPRS 3B Semantik Etiketleme veri seti üzerindeki doğruluklara olan etkileri	75
Tablo 9. Komşuluk arama yarıçapının mimariye olan etkisinin ISPRS veri seti üzerinde irdelenmesi.....	78
Tablo 10. Orijinal nokta örnekleme stratejisi ile değiştirilmiş nokta örnekleme stratejisinin karşılaştırılması	79
Tablo 11. Farklı girdi nokta sayılarının ISPRS 3B Semantik Etiketleme veri seti üzerinde elde edilen doğruluklara etkisi	81
Tablo 12. nsample parametresinin ISPRS 3B Semantik Etiketleme verisi üzerinde etkileri.....	83
Tablo 13. Adaptif çerçeve boyutu yaklaşımları ile orijinal mimarinin karşılaştırılması.....	85
Tablo 14. MRG katmanı için DALES test veri seti üzerinde girdi nokta sayısı ve npoints parametresinin semantik segmentasyon doğruluğu üzerine etkileri.....	91
Tablo 15. MRG, MSG+MRG hibrit yöntemin DALES test veri seti üzerindeki doğrulukları	93
Tablo 16. 250×250 m ve 100×100 m tile boyutlarının MRG katmanı (Model 1, Model 2) ve Hibrit Model 1 ve 2 üzerindeki test doğrulukları.....	95
Tablo 17. DALES veri seti üzerinde Adaptif 1 ve Adaptif 2 yaklaşımları ile elde edilen doğruluklar.....	99
Tablo 18. Alt örneklenmiş düzensiz_DALES veri seti.....	100
Tablo 19. Düzensiz_DALES veri seti üzerinde sabit çerçeve boyutu ve önerilen adaptif çerçeve boyutu yaklaşımları ile elde edilen doğruluklar	101
Tablo 20. Uygulama 1, Uygulama 2 ve Uygulama 3 için girdi parametreleri.....	109

Tablo 21. Test 1 verisi için elde edilen doğruluklar	110
Tablo 22. Test 2 verisi için elde edilen doğruluklar	111
Tablo 23. Test 2 gürültüsüz verisi için elde edilen doğruluklar	112
Tablo 24. Ek öznitelikler ile DALES veri seti elde edilen semantik segmentasyon doğrulukları	115
Tablo 25. Ek öznitelikler ile OpenGF veri seti elde edilen semantik segmentasyon doğrulukları	116
Tablo 26. DALES ve ISPRS veri setleri için sınıf eşleştirmeleri	118
Tablo 27. Mimarinin genelleştirme test sonuçları	119
Tablo 28. Genelleştirme sonuçlarının üç yöntem için ISPRS veri seti üzerinde her bir sınıf için karşılaştırması.....	120



KISALTMALAR DİZİNİ

1B	: Bir Boyutlu
2B	: İki Boyutlu
2,5B	: İki Buçuk Boyutlu
3B	: Üç Boyutlu
AI	: Yapay Zekâ (Artificial Intelligence-AI)
ALS	: Airborne Laser Scanning (ALS)
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
CNN	: Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
DALES	: Dayton Annotated LiDAR Earth Scan
DBSCAN	: Density-Based Clustering Applications with Noise
DNN	: Derin Sinir Ağı (Deep Neural Network)
DT	: Karar Ağaçları (Decision Trees)
FP	: Öznitelik Yayma Katmanı (Feature Propagation Layer-FP)
FPS	: En Uzak Nokta Örnekleme (Farthest Point Sampling)
GD	: Genel Doğruluk
GPU	: Graphics Processing Unit
IoU	: Kesişim-Birleşim Oranı (Intersection over Union)
ISODATA	: Iterative Self-Organizing Data Analysis Technique
ISPRS	: Uluslararası Fotogrametri ve Uzaktan Algılama Topluluğu (International Society of Photogrammetry and Remote Sensing)
LiDAR	: Işık Tespiti ve Ölçümü (Light Detection and Ranging)
MLP	: Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
MRG	: Çoklu Çözünürlük Gruplama (Multi-Resolution Grouping)
MSG	: Çoklu Ölçek Gruplama (Multi-Scale Grouping)
PDF	: Olasılık Yoğunluk Fonksiyonu (Probability Density Function)
RF	: Rastgele Orman (Random Forest)
RGB	: Kırmızı, Yeşil, Mavi (Red, Green, Blue)
SA	: Dizi Özetleme (Set Abstraction)
SAM	: Sayısal Arazi Modeli
SVM	: Destek Vektör Makineleri (Support Vector Machines)
SYM	: Sayısal Yükseklik Modeli

1. GİRİŞ

Hava LiDAR (Light Detection and Ranging) nokta bulutları, Sayısal Arazi Modeli (SAM), 3B şehir modelleri, peyzaj modeli üretimi için önemli bir veri kaynağıdır. Bu veriler kentsel alan planlama, afet yönetimi, yenilenebilir enerji potansiyel analizi gibi pek çok uygulama için gereklidir (Lin vd., 2022). Literatürde, 3B nokta bulutlarını semantik bilgi ile anlamlandırabilmek için kural tabanlı, klasik makine öğrenimi ve derin öğrenme yöntemleri gibi pek çok farklı yaklaşım geliştirilmiştir.

Geçtiğimiz yıllarda, uzaktan algılama ve fotogrametri alanlarında, hava LiDAR nokta bulutlarının otomatik sınıflandırılmasında kullanılan karar ağacı (Decision Trees-DT), destek vektör makineleri (Support Vector Machine-SVM) ve rastgele orman (Random Forest -RF) gibi makine öğrenimi yöntemlerinde, her bir nokta için bir dizi el yapımı öznitelikleri (hand-crafted features) hesaplanarak sınıflandırma işlemi gerçekleştirilmiştir. Ancak, bu yöntemlerin performansı büyük ölçüde çıkarılan el yapımı özniteliklerin temsil yeteneğine dayanmaktadır ve bununla birlikte makine öğrenimi modellerinin genelleme yetenekleri sığ mimarileri nedeniyle de sınırlıdır (Li vd., 2021).

Son yıllarda, derin öğrenme konuşma tanıma, görüntü semantik segmentasyonu ve doğal dil işleme gibi çok çeşitli alanlarda diğer makine öğrenimi modellerine göre üstün performans göstermiştir. Diğer makine öğrenimi yaklaşımlarından farklı olarak, derin öğrenme, eğitim süreci sırasında öznitelikleri doğrudan öğrenebilir ve öğrenme yeteneği başarılı sonuçların elde edilmesinin temel unsuru olarak kabul edilebilir (Li vd., 2021). Özellikle 3B nokta bulutu verilerinin sınıflandırma, semantik segmentasyon ve bölüm segmentasyonu için geliştirilen derin öğrenme ağlarında önemli bir artış olmuştur. Nokta bulutlarının derin öğrenme ile semantik segmentasyonu için yapılan çalışmalar ise girdi veri yapısına göre projeksiyon tabanlı, voksel tabanlı ve nokta tabanlı olmak üzere üç kategoride incelenebilir (Lin vd., 2022).

Nokta bulutlarını düzenli veri yapılarına dönüştürerek konvolüsyon sinir ağları (Convolutional Neural Network-CNN) kullanarak sınıflandırmak ya da semantik segmentasyonu gerçekleştirmek gereksiz işlem yükü eklemesinin yanı sıra bilgi kayıplarına da neden olmaktadır (Guo vd., 2021b). Özellikle voksel veri temsilleri yüksek bellek alanı gerektirirler ve derin öğrenme mimarileri ile bu verilerin işlenmesi ekran kartı donanımlarına da oldukça bağımlıdır. Bu yüzden 3B nokta bulutlarını herhangi bir düzenli

veri temsiline dönüştürmeden doğrudan işleyen mimariler ortaya çıkmıştır. Bu alanda PointNet (Qi vd., 2017a) öncü bir mimari olarak kabul edilmektedir. Ardından, 3B nokta bulutu sınıflandırması ve semantik segmentasyonu için PointNet++ (Qi vd., 2017b), RandlaNet (Hu vd., 2020) ve KPConv (Thomas vd., 2019) gibi çeşitli derin öğrenme mimarileri geliştirilmiştir. Ancak bu mimarilerin çoğu iç mekân nokta bulutları için tasarlanmıştır. İç mekân veri setlerinde nokta bulutları yüksek kaliteli CAD modellerden örneklenerek ya da derinlik sensörleri (depth sensor) kullanılarak oluşturulmaktadır. Bundan dolayı bu veri setleri hem yoğun hem de nispeten düzenli bir dağılıma sahiptir. Ayrıca, iç mekân nokta bulutlarındaki nesneler genel olarak benzer boyutlara sahip olmak ile birlikte sınıf dağılımları da nispeten dengelidir. Ancak dış mekân veri setlerinde, değişken nokta yoğunluğu ve sahne boyunca birbirinin üstünü örten noktaların oluşturduğu kapamadan dolayı nokta bulutları çok daha karmaşıktır (Liu vd., 2022).

Hava LiDAR nokta bulutlarında, nesne boyutları ve bir nesnenin veri seti içinde görülme sıklığı değişkenlik gösterdiğinden dolayı farklı sınıflar arasındaki nokta dağılımı oldukça dengesizdir. Bu duruma örnek verecek olursak, elektrik direkleri hem çok az sayıda nokta ile temsil edilmekte hem de nokta bulutu veri setleri içerisinde karşılaşılma sıklığı oldukça düşük olabilmektedir. İç mekân nokta bulutlarında elde edilen başarılı sonuçlardan dolayı, bu alanda geliştirilen derin öğrenme mimarilerinden bazıları, uzaktan algılama ve fotogrametri alanındaki dış mekân nokta bulutlarına uyarlanmıştır. İç mekân nokta bulutlarıyla karşılaştırıldığında, büyük boyutlu objeler içeren LiDAR gibi dış mekân nokta bulutları çok daha büyük ölçekli sahneler içermesinden dolayı büyük bir veri hacmine yol açar. Bu alanda yapılan bazı çalışmalar bilgisayarla görme alanından türettikleri derin öğrenme modellerini hava LiDAR nokta bulutlarının semantik segmentasyonu için adapte etmişlerdir (Schmohl ve Sörgel, 2019; Winiwarter vd., 2019). Diğer çalışmalar ise, hava LiDAR nokta bulutlarının karakteristik özelliklerini yakalayabilmek adına ya PointNet mimarisini baz alarak geliştirilen mimariler ya da yeni yöntemler (Li vd., 2020; Wen vd., 2020) önermişlerdir (Li vd., 2021).

3B nokta bulutlarının herhangi bir düzenli veri temsiline dönüştürmeden doğrudan sınıflandırılması, semantik segmentasyonu işlemlerinde öncü kabul edilen PointNet ve özellikle buna bağlı olarak geliştirilen PointNet++ mimarisi, her ne kadar iç mekân nokta bulutları için yüksek genelleştirme kabiliyetine sahip olsa da bu mimarinin hava LiDAR nokta bulutlarına uyarlanması oldukça zor bir işlemdir. Hava LiDAR nokta bulutlarının iç mekân nokta bulutlarına kıyasla büyük ölçekli olması, sahne yapısının karmaşıklığı,

gürültü içermesi, objelerin birbirini kapaması, objeler arasındaki yükseklik ve geometrik farklılıklar, değişken nokta yoğunluğu ve homojen olmayan nokta örnekleme ve penetrasyon gibi nedenler bu işlemi zorlaştıran etkenlerdir. Mimarinin, hava LiDAR nokta bulutlarında etkin ve verimli bir şekilde kullanılabilmesi veriden kaynaklı zorluklar ile başa çıkabilmesini gerektirmektedir. Bu zorluklar hem verinin üretim metot farklılıklarından kaynaklanan bilgi çeşitliliği hem de nokta bulutunun düzensiz, değişken nokta yoğunluğuna sahip olması gibi yapısal zorluklardır.

1.1. Problemin Tanımı

Derin öğrenme uygulamalarında özellikle iki boyutlu (2B) görüntüler için geliştirilen modellerdeki ilerlemeler sayesinde birçok disiplin, kullandıkları bu modellerden çok yüksek doğruluklar ile başarılı sonuçlar elde etmektedirler. Ancak bu modellerin 3B alanlara uygulanması, 2B alanındaki uygulamaları kadar başarılı olamamaktadır. Bu yüzden son birkaç yıldır 3B derin sinir ağları ile nokta bulutlarının sınıflandırılması ve semantik segmentasyonu konularına olan ilgi, nokta bulutlarının doğası gereği düzensiz ve sırasız olmasından kaynaklanan uygulama belirsizliklerinden dolayı oldukça fazladır. Birçok araştırmacı özellikle iç mekân nokta bulutlarının sınıflandırılması, semantik ve parça segmentasyonu için çok sayıda 3B derin sinir ağı mimarileri tasarlamışlardır. Bu alandaki gelişmeler fotogrametri ve uzaktan algılama topluluğu tarafından, bu mimarilerin hava LiDAR gibi büyük ölçekli nokta bulutu verilerine uygulanabilirliğinin araştırılmasına sebep olmuştur. Böylece son birkaç yıldır fotogrametri ve uzaktan algılama alandaki çalışmalar, 3B derin sinir ağları ile hava LiDAR nokta bulutlarının sınıflandırılması ve semantik segmentasyonu konularına yoğunlaşmıştır.

İç mekân nokta bulutları için tasarlanan 3B derin sinir ağlarından fotogrametri ve uzaktan algılama alanı için uyarlama yapılan çalışmalar incelendiğinde, pek çok çalışmada kullanılan mimarinin büyük ölçekli nokta bulutu için uyarlanmadan iç mekân nokta bulutları için varsayılan (default) parametreler ile kullanıldığı görülmektedir. Mimarilerin öznetelik çıkarımı için gereken geometrik parametrelerini ise deneme yanılma yöntemi ile belirlemelerinden dolayı da çok sayıda parametre içeren bu kompleks mimarilerin her bir parametresi için tekrar tekrar çalıştırılması çok fazla işlem gücü gerektiren ve zaman alıcı bir işlem haline dönüşmüştür. Ayrıca, hava LiDAR verilerinin doğası gereği büyük ölçekli olması, nokta yoğunluğunun hem veri kümesi için hem de veri kümeleri arasında

değişkenlik gösterdiği gerçeklerini ve genelleştirilebilir olmaları gerektiğinin bugüne kadar yapılan çalışmalarda dikkate alınmaması ise bu alandaki başlıca eksikliklerdir. Dahası, derin öğrenme çok sayıda veri gerektirdiğinden dolayı son zamanlarda farklı kaynaklardan üretilen verilerin birleştirilerek daha büyük eğitim verilerinin hazırlandığı düşünüldüğünde, değişken nokta yoğunluğu problemi daha da belirgin hale gelmiş ve bu sorun ile başa çıkabilecek bir mimarinin gereksinimi ise kaçınılmaz olmuştur.

1.2. Çalışmanın Amacı

Nokta bulutlarını direkt işleyerek sınıflandıran ya da semantik segmentasyonunu gerçekleştiren 3B derin öğrenme mimarilerinde girdi nokta bulutunun yoğunluğu, çıkartılan özneteliklerin kalitesini doğrudan etkileyerek mimarinin performansını ve genelleştirme kabiliyetini belirleyen önemli bir faktördür. Bu nedenle tez çalışması kapsamında, iç mekân nokta bulutları için tasarlanan uçtan uca bir 3B derin sinir ağı olan PointNet++ mimarisi hava LiDAR nokta bulutlarına uyarlanırken çerçeve boyutu parametresini, bu verilerin değişken nokta yoğunluğuna sahip olduğu dikkate alınarak nokta yoğunluğuna adapte edebilecek Adaptif 1 ve Adaptif 2 yaklaşımları PointNet++ mimarisine entegre edilmiştir. Önerilen Adaptif 1 ve Adaptif 2 yaklaşımları ile mimarinin değişken nokta yoğunluğu problemine karşı daha kararlı hale getirilmesi amaçlanmıştır. Nokta yoğunluğuna dayalı geliştirilen adaptif yaklaşımlar sayesinde mimarinin genelleştirme yeteneğinin artırılması, daha fazla benzersiz nokta ile beslenmesi ve sınıf dengesizliği probleminin de azaltılması hedeflenmektedir.

1.3. Tezin Ana Hattı

Tez, Bölüm 2’de literatür taraması başlığı altında derin öğrenmenin temelleri, 3B veri temsilleri ve bu veri temsillerine dayalı olarak geliştirilen derin öğrenme yaklaşımları, hava LiDAR nokta bulutlarının özellikleri ve çalışma prensibi, bu verilerin avantaj ve dezavantajlarının irdelenmesi ve son olarak hava LiDAR nokta bulutlarının semantik segmentasyonunda literatür araştırmasını içerecek şekilde tasarlanmıştır. Bölüm 3’te veri setleri tanıtılmış, metot açıklanarak parametreleri tanıtılmış, optimum komşuluk arama yarıçap yöntemi ve son olarak geliştirilen yaklaşımlar tanıtılmıştır. Bölüm 4 bulgular ve

irdelemeleri, kullanılan bilgisayarın yazılım ve donanım bilgilerini, doğruluk metriklerinin tanıtımını, her bir veri setine dair elde edilen sayısal ve görsel sonuçları içerecek şekilde tasarlanmıştır. Son olarak Bölüm 5’te ise çalışmanın sonuçları verilmiştir.




2. LİTERATÜR TARAMASI

Bu bölüm derin öğrenmenin temelini, nokta bulutlarında derin öğrenme çalışmalarını, kullanılan 3B veri temsillerini ve her bir veri temsiline dayalı geliştirilen yaklaşımları, hava LiDAR nokta bulutlarının çalışma prensibi ve derin öğrenme uygulamalarındaki zorlukları ve bu verilere dayalı geliştirilen yaklaşımları içerecek şekilde aşağıdaki gibi tasarlanmıştır.

Bölüm 2.1’de, öncelikli olarak yapay zekâ, makine öğrenimi ve derin öğrenme kısaca tanıtılmış, aralarındaki ilişki hakkında bilgi verilmiş ve derin öğrenmeye motive eden olgulardan bahsedilmiştir. Bölüm 2.2.’de, derin öğrenmenin temel çalışma prensibi basitçe anlatılmıştır. Bölüm 2.3’te nokta bulutlarının derin öğrenme ile semantik segmentasyonu işlemi tanımlanarak, Bölüm 2.3.1.’de 3B veri temsilleri alt bölümler halinde açıklanmış ve 2.3.2’de bu veri temsillerine dayalı olarak bugüne kadar geliştirilen yaklaşımlar alt bölümler halinde açıklanarak üstünlük ve zayıflıkları özetlenmiştir. Bölüm 2.4.’te hava LiDAR nokta bulutları tanıtılarak bu verilerin avantaj ve dezavantajları irdelenmiş, derin öğrenme ile semantik segmentasyonundaki zorluklarından bahsedilmiştir. Bölüm 2.5’te hava LiDAR nokta bulutlarının derin öğrenme ile semantik segmentasyonu için literatür bilgileri verilerek bölüm özetlenmiştir.

2.1. Yapay Zekadan Derin Öğrenmeye

Günümüzde yapay zekâ (artificial intelligence-AI), çok sayıda pratik uygulamaları ve aktif araştırma konularına sahip gelişmekte olan bir alandır. Rutin işlerin otomatize edilmesi, konuşma ve görüntülerin anlamlandırılması, tıp alanında teşhis ve temel araştırma alanlarını desteklemek için akıllı yazılımlardan yardım alınmaktadır (Goodfellow vd., 2016). Yapay zekanın yıllar içerisindeki farklı formları kısaca özetlenecek olursa bunlar makine öğrenme, temsil öğrenme ve son olarak derin öğrenmedir. Yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki aşağıda Şekil 1’de gösterilmiştir.



Şekil 1. Derin öğrenme, temsilli öğrenme, makine öğrenme ve yapay zeka arasındaki ilişkiyi gösteren ve her bir teknoloji için örneklerin verildiği Venn şeması (Goodfellow vd., 2016)

Geçmişte yapılan bazı yapay zekâ çalışmaları, gerçek dünya problemlerini bir dizi sabit kod ile (hard-code knowledge) ile çözmeye çalışmıştır. Ancak, ön tanımlı kurallara dayanan bilgi tabanlı yapay zekâ yaklaşımlarında, dünyayı doğru bir şekilde tanımlayabilecek kadar kompleks kurallar oluşturmak mümkün değildir. Bu yüzden yeni geliştirilecek yapay zekâ sistemlerinde, sistemin ham verideki örüntüleri (pattern) çıkartarak kendi bilgisini/tecrübesini oluşturması beklenmiştir. Bunun sonucunda da makine öğrenme ortaya çıkmıştır. Makine öğreniminin tanıtılması, bilgisayarların gerçek dünya bilgisi içeren problemleri çözmesine ve öznel kararlar vermesine olanak sağlamıştır (Goodfellow vd., 2016).

Makine öğreniminde, sistemin karar verebilmesi için araştırmacılar tarafından tanımlanan özniteliklere ihtiyaç duyulur. Makine öğrenimi, “nereye” bakılacağı ve “neyin” aranacağı konusunda sistemin manuel olarak eğitilmesini gerektirir. Makine öğrenmesi sistemleri, kesin bir görüş birliği olmamakla birlikte denetimli, denetimsiz ve yarı denetimli öğrenme olarak üç ana gruba ayrılabilir. Denetimli öğrenmede amaç, X girdilerini Y etiketleriyle eşleyen bir fonksiyonu öğrenmektir. Sistemin eğitimi için etiketli veri gereklidir ve amaç etiketsiz veriyi başarılı bir şekilde etiketlemektir. Sınıflandırma, regresyon, obje algılama, semantik segmentasyon ve görüntü altyazısı oluşturma (image captioning) denetimli öğrenmeye bazı örneklerdir. Sistemin başarısı, etiketli verilerin varlığından dolayı, test sonucu elde edilen etiketler ile gerçek etiketlerin karşılaştırılması ile kolayca ölçülebilir. Ancak çoğu zaman verilerin insanlar tarafından manuel olarak

etiketlenmesi veya bu işlemin ekstra kaynaklar gerektirmesi yöntem için önemli bir sınırlamadır. Denetimsiz öğrenmede amaç, verilerin altında yatan bazı gizli yapıları öğrenmektir. Burada sistem herhangi bir etiket kullanmamaktadır. Amaç, belirlenen iş kapsamında çözüme ulaşmak için verilen ham girdi verilerinden anlamlı bir yapı öğrenmektir. Kümeleme, boyut indirgeme, öznitelik öğrenme, yoğunluk tahmini ve yeni veri oluşturma denetimsiz öğrenmeye bazı örneklerdir. Etiketli verilere ihtiyaç duyulmadığından, sistemde kullanılabilecek kadar iyi biçimlendirilmiş herhangi bir veri, girdi olarak kullanılabilir. Eğitim verilerini bulmak ve veri kümeleri oluşturmak ucuz ve kolaydır. Bununla birlikte, hiçbir etiket olmadığı için, sistemin başarısını ölçmek oldukça zor hatta bazen imkansızdır. Yarı denetimli öğrenme, verilerin yalnızca küçük bir kısmının etiketlendiği, denetimli ve denetimsiz öğrenmenin hibrit bir yaklaşımıdır. Etiketlenmemiş verileri etiketlemek çok pahalı veya zorlayıcı olduğunda, etiketlenmiş verilerin küçük bir kısmı, denetimsiz sınıflandırma işlemleri için daha iyi bir rehberlik sağlayabilir (Öngün, 2021). Geleneksel makine öğrenimi yaklaşımlarından denetimsiz öğrenmeye örnek olarak ISODATA (Iterative Self-Organizing Data Analysis Technique) ve k-means ya da DBSCAN (Density-Based Clustering Applications with Noise) gibi kümeleme (clustering) algoritmaları örnek olarak verilebilir. Denetimli öğrenme için ise örnek olarak karar ağaçları ve SVM verilebilir.

Makine öğrenmenin performansı yoğun bir şekilde sisteme verilen verinin temsiline (representation) dayanır. Bu temsildeki her bir bilgi öznitelik (feature) olarak isimlendirilir. Birçok yapay zekâ görevi/işi, ilgili görev için tasarlanan doğru öznitelik setlerinin çıkartılması ve bunların basit bir makine öğrenme algoritmasına verilmesi ile çözülebilir. Ancak pek çok görev/iş için hangi özniteliklerin çıkartılması gerektiğini bilmek zor bir işlemdir. Bu problemin bir çözümü, makine öğrenimini çıktıyı temsilden öğrenmenin yanı sıra temsilin kendisini de keşfederek kullanmaktır. Bu yaklaşım temsil öğrenme olarak bilinir. Öğrenilen temsiller, el ile tasarlanmış temsiller ile kıyaslandığında genellikle daha iyi performans gösterirler. Bu yöntem, minimal insan müdahalesi ile AI sistemlerinin hızlı bir şekilde yeni görevlere adapte edilebilmesine olanak tanımaktadır. En temel örneği otokodlayıcılarıdır. Otokodlayıcılar, bir kodlayıcı fonksiyonu ile girdi veriyi farklı bir temsile dönüştürür ardından çözümleyici (decoder) fonksiyonu ile temsili orijinal formata dönüştürür. Öznitelikleri veya öznitelik öğrenme algoritmalarını tasarlarlarken amaç genellikle gözlemlenen veriyi açıklayabilecek varyasyon faktörlerini (factors of variation) ayırt etmektir. Örneğin bir araç görüntüsünün analizinde, aracın konumu, rengi, güneşin

açısı ve parlaklığı varyasyon faktörleridir. Gerçek dünyadaki yapay zekâ uygulamalarının en büyük zorluğu varyasyon faktörlerinin pek çoğunun gözlemlenebilen tüm verileri etkilemesidir. Örneğin, kırmızı bir aracı temsil eden görüntüdeki pikseller karanlıkta siyaha yakın değerler alabilecektir. Pek çok uygulama, varyasyon faktörlerinin ayrıştırılmasını ve işe yaramayanlarının göz ardı edilmesini gerektirir. Böylesi yüksek seviyeli ve soyut özniteliklerin ham veriden çıkartılması oldukça zordur. Varyasyon faktörlerinin çoğu, yalnızca sofistike ve neredeyse insan seviyesinde bir veri anlayışı ile tanımlanabilir. Bir temsili elde etmek orijinal sorunu çözmek kadar zor olduğunda temsil öğrenme ilk bakışta yeterli olamamaktadır. Derin öğrenme, temsil öğrenmedeki bu ana problemi, diğer daha basit temsiller cinsinden ifade edilen temsilleri kullanarak çözer. Derin öğrenme, bilgisayarın basit kavramlardan karmaşık kavramlar oluşturmaya olanak sağlar. Derin öğrenmeyi motive eden zorluklar arasında, makine öğrenimi problemlerinin verilerde boyut sayısı fazla olduğunda oldukça zor olması yani boyutluluk laneti olarak bilinen olgu, yerel sabitlik ve pürüzsüzlük sayılabilir. Derin öğrenmenin en temel örneği ileri beslemeli derin ağ (feedforward deep network) veya çok katmanlı algılayıcıdır (Multilayer Perceptron-MLP) (Goodfellow vd., 2016).

2.2. Derin Öğrenme


Bir yapay zekâ yaklaşımı olan derin öğrenme, spesifik olarak bilgisayar sistemlerinin tecrübe ve veriler ile gelişmesine olanak sağlayan bir makine öğrenimi türüdür. Özel bir makine öğrenimi türü olan derin öğrenme, her bir kavramın daha basit kavramlarla ilişkili olarak tanımlandığı ve daha soyut temsillerin daha az soyut olanlar ile hesaplandığı, iç içe geçmiş bir kavramlar hiyerarşisi olarak dünyayı temsil etmeyi öğrenerek büyük güç ve esneklik sağlamaktadır. Derin öğrenme alanında görülen trendler üç ana başlık altında ele alınabilir. Bunlardan birincisi, erişilebilir eğitim verilerinin artmasına bağlı olarak derin öğrenmenin daha kullanılabilir hale gelmesi; ikincisi, yazılım ve donanım alanındaki atılımların bir sonucu olarak model boyutlarının büyümesi ve bu sayede derin öğrenmenin iyileşmesi; son olarak, zaman içerisinde derin öğrenmenin daha karmaşık uygulamalarda git gide daha yüksek doğruluk elde etmesidir. Derin öğrenme yıllar içerisinde farklı isimlerde anılmıştır. 1940-1960'larda cybernetics, 1980-1990'larda connectionism olarak bilinirken, 2006 yılından itibaren de derin öğrenme olarak adlandırılmıştır. Derin öğrenme,

biyolojik sinir ağlarından ilham alması sebebiyle yapay sinir ağları (Artificial Neural Network-ANN) olarak da adlandırılmaktadırlar (Goodfellow vd., 2016).

Yapay sinir ağları, belirli bir iş için önemli olan gerekli öznelilikleri kendi kendine öğrenme ve daha fazla veri ile eğiterek iyileştirme yeteneğine sahiptir. Makine öğreniminde daha az veri, zaman ve hesaplama gücü ile başarılı modelleme arzu edilirken, yapay sinir ağları çok sayıda veri, uzun eğitim süreleri ve yüksek işlem gücü gerektirir. Yapay sinir ağları, karmaşık işlerde/görevlerde çoğunlukla klasik makine öğrenimi tekniklerinden daha iyi performans gösterdiğinden dolayı bu gereksinimler kabul edilebilir. Ayrıca, donanım ve algoritma optimizasyonlarındaki gelişmeler bu sınırlamaları hafifletmektedir. Yapay sinir ağları 50 yılı aşkın bir geçmişe sahipken, teknolojik gelişmelerin gereksinimlerini yeterince karşılamaya başlamasıyla son yıllarda popüler hale gelmiştir. Özellikle donanım alanındaki gelişmeler, daha fazla sayıda nod (node), katman (layer) ve karmaşık mimariye sahip ağların eğitilmesini mümkün kılmıştır. Bu daha derin ve daha karmaşık ağlar, yaygın olarak derin sinir ağları (Deep Neural Networks-DNNs) olarak adlandırılır (Öngün, 2021).

Derin öğrenme modellerinin en temel hali çok katmanlı algılayıcılardır. MLP'ler, fotoğraflarda nesne tanıma ve doğal dil işleme gibi temel makine öğrenme uygulamalarının en önemli bileşenidir. Birçok farklı fonksiyonları birleştirerek temsil edilmelerinden dolayı MLP'ler, ağ (network) olarak isimlendirilir. Ağ, fonksiyonların nasıl birleştirildiğini açıklayan bir zincir grafik ile ilişkilendirilir. Örneğin, x girdi verisi için birbirine zincirleme bağlı olan $f^{(1)}$, $f^{(2)}$ ve $f^{(3)}$ fonksiyonları birleştirilerek $f(x) = f^{(3)}(f^{(2)}(f^{(1)}(x)))$ oluşturulur. Sinir ağlarının en sık kullanılan formu olan bu zincir yapılarında; $f^{(3)}$ üçüncü, $f^{(2)}$ ikinci ve $f^{(1)}$ birinci katman olarak adlandırılır. Bu zincirin uzunluğu modelin derinliği olarak adlandırılır. MLP'nin son katmanı çıktı katmanı olarak isimlendirilir. Sinir ağı eğitimi sırasında, $f(x)$ 'i $f^*(x)$ ile eşleştirmek üzere çalıştırılırken eğitim verileri $f^*(x)$ 'in farklı eğitim noktalarındaki gürültülü, yaklaşık örneklerini sağlamaktadır. Her x örneğine bir $y \approx f^*(x)$ etiketi eşlik eder. Eğitim örnekleri, çıktı katmanının her x noktasında y 'ye yakın bir değer üretmesi gerektiğini doğrudan belirtirken, diğer katmanların nasıl davranması gerektiği eğitim verileri tarafından doğrudan belirtilmez. Öğrenme algoritması, istenen çıktıyı üretmek için bu katmanları nasıl kullanacağına karar verebilmek için, en iyi şekilde f^* fonksiyonuna yakınsayabilmek için bu katmanları nasıl kullanacağına karar vermelidir. Bu katmanların her biri için eğitim verileri istenen çıktıyı göstermediği için bu katmanlara gizli katmanlar denir. Sonuç olarak, bu ağlar sinirbilimiyle bağlantılı oldukları için

genellikle "sinirsel" olarak adlandırılır. Bu gizli katmanların boyutu modelin derinliğini belirler. Vektörün her ögesinin, bir nörona benzer bir rol oynadığı şeklinde yorumlanabilir. Katmanı bir tek vektörden vektöre dönüştüren bir işlev olarak düşünmek yerine, katmanın birçok birimden oluştuğunu ve her birimin paralel olarak hareket ettiğini düşünülebilir. Her birim, kendine özgü bir vektör-tek sayı işlevi temsil eder. Her birim, diğer birimlerden girdi alır ve kendi aktivasyon değerini hesaplar. Bu temsilleri hesaplamak için kullanılan $f^{(i)}(x)$ işlevlerinin seçimi de biyolojik nöronların hesapladığı işlevler hakkındaki sinirbilimsel gözlemlere dayanmaktadır. Ancak, ileri beslemeli ağılar, beyin fonksiyonlarının bir modeli olarak değil, istatistiksel genelleme elde etmek için tasarlanmış fonksiyon yaklaşımı makineleri olarak düşünmek daha doğru olacaktır (Goodfellow vd., 2016). MLP'nin girdi, gizli ve çıktı katmanlarına dair bir örnek Şekil 2'de gösterilmektedir.



Şekil 2. MLP katmanlarına örnek görseli Zhang vd. (2021)'den uyarlanmıştır

Şekil 2'de gösterilen çok katmanlı algılayıcıda, girdi katmanı sayısı 4 ve çıktı katmanı sayısı ise 3'tür ve ortadaki gizli katmanda 5 gizli birim (Hidden Units) bulunmaktadır. Girdi katmanı herhangi bir hesaplama içermediğinden, çok katmanlı algılayıcıda toplam 2 katman vardır. Gizli katmandaki nöronlar girdi katmanındaki girişlere tamamen bağlıdır. Çıktı katmanındaki nöronlar ve gizli katmandaki nöronlar da tamamen bağlıdır. Bu nedenle, çok katmanlı algılayıcının hem gizli katmanı hem de çıktı katmanı tamamen bağlı katmanlardır (Zhang vd., 2021).

$$h = \sigma(W_1x + b_1) \quad (1)$$

$$o = W_2h + b_2 \quad (2)$$

$$\hat{y} = \text{softmax}(o) \quad (3)$$

Denklem 1, 2 ve 3, bir yapay sinir ağı tarafından sınıflandırma işleminin nasıl gerçekleştirildiğini göstermektedir. Bu denklemler ile ağa verilen girdi verileri kullanılarak ağın gizli katmanındaki nöronların aktivasyonlarını hesaplanır ve son olarak aktivasyon fonksiyonu (softmax) ile sınıf olasılıkları tahmin edilir. Denklem 1’de görülen x vektörü, girdi verilerini temsil ederken h vektörü, gizli katmandaki nöronların aktivasyonlarını hesaplamak için kullanılır. Bu fonksiyonlar, nöronların girdilerinin ağırlıklı toplamını çıktı değerlerine dönüştürürken nonlinear dönüşüm yapmak için kullanılır. Girdi verileri x ile ağırlık matrisi W_1 arasında matris çarpımı gerçekleştirilerek ardından bias vektörü b_1 eklenir. Aktivasyon fonksiyonu σ (ReLU, Sigmoid, Tanh vb.) kullanılarak gizli katmanların nonlinear çıktılar üretmesi sağlanır. Denklem 2’de gizli katmandan gelen h vektörünü çıktı katmanındaki nöronların aktivasyonlarını hesaplamak için kullanılır. o fonksiyonu, çıktı katmanındaki nöronların aktivasyonlarını hesaplamak için kullanılır. Burada o vektörünü hesaplamak için, h vektörü ile ağırlık matrisi W_2 ile çarpıldıktan sonra bias vektörü b_2 eklenir. Denklem 3’te, çıktı katmanındaki nöronların aktivasyonları örneğin softmax aktivasyon fonksiyonuna girdi olarak verilir. Bu, çıktı nöronlarının sınıflar arasında bir olasılık dağılımı oluşturmasını sağlar. Gizli katmanlar $h_1 = \sigma(W_{1x} + b_1)$ ve $h_2 = \sigma(W_{2h_1} + b_2)$ olacak şekilde üst üste yığılarak çok katmanlı algılayıcılar oluşturulur (Zhang vd., 2021).

Çok katmanlı algılayıcılar, girdi verilerindeki karmaşık etkileşimleri, her bir gizli nöronun girdi verilerinin değerine bağımlı olması nedeniyle hesaplayabilir. Ayrıca, gizli düğümlerin istenilen herhangi bir hesaplama işlevini gerçekleştirebilmesi, örneğin mantıksal işlemleri gerçekleştirebilmesi mümkündür. Bunun yanı sıra, çok katmanlı algılayıcıların evrensel bir yaklaşımcı (universal approximator) olduğu yaygın olarak bilinmektedir. Bu, yeterli sayıda birim ve doğru ağırlık kümesiyle tek katmanlı bir sinir ağının bile herhangi bir fonksiyonu modelleyebileceği anlamına gelir. Ancak, geniş bir mimari ile bu fonksiyonu öğrenmek zor olabilir. Geniş olmaktan ziyade daha derin sinir ağları kullanılarak, fonksiyonlara daha kompakt bir şekilde yakınsanması mümkündür (Zhang vd., 2021).


2.3. Nokta Bulutlarında Derin Öğrenme

Nokta bulutlarında derin öğrenme işlemleri sınıflandırma, semantik segmentasyon ve bölüm/parça segmentasyon olmak üzere üç ana başlık altında incelenebilir. Sınıflandırma bütün bir girdi nokta bulutu için tek bir etiket belirleme işlemi iken, semantik segmentasyon girdi nokta bulutundaki tüm noktalar için ayrı ayrı etiket belirlenmesi işlemidir. Bölüm/parça segmentasyonu ise, bir objenin tüm alt parçalarının birer etiket atanması işlemidir. Bir uçağın gövdesi, kanatları, kuyruğu ve motorlarının ayrı ayrı etiketlenmesi bölüm/parça segmentasyonuna bir örnek olarak verilebilir. Nokta bulutları üzerinde uygulanan ilk derin öğrenme mimarileri CNN mimarilerinin görüntüler üzerinde elde ettiği başarıların ardından 3B nokta bulutlarının düzenli veri formatına (piksel, voksel) dönüştürülmesi ile başlamıştır. 2017 yılında PointNet mimarisinin geliştirilmesi ile de herhangi bir düzenli veri formatına dönüştürülmeden 3B nokta bulutlarının doğrudan kullanılarak derin öğrenme ile semantik segmentasyonu ve sınıflandırma işlemleri başlamıştır. Aşağıda literatür araştırmasında nokta bulutlarında derin öğrenme işlemlerinin nokta bulutlarının ham hali üzerinden gerçekleştirilebileceği gibi farklı temsiller üzerinden de uygulandığı çalışmalar özetlenmiştir. Bu bölümde, öncelikli olarak 3B veri temsilleri tanıtılarak ardından şimdiye kadar bu veri temsillerine dayalı geliştirilen yaklaşımların birbirlerine göre üstünlük ve zayıflıkları irdelenmiştir.

2.3.1.3B Veri Temsilleri

Görüntüleri temsil etmek için farklı renk uzayları olmasına rağmen çoğu çalışmada en çok kullanılan RGB renk uzayıdır. Temel olarak kırmızı, yeşil ve mavi renkler için yoğunluk değerlerine sahip bir 2B matris olmalarından dolayı RGB renk uzayları düzenli ve sıralı bir formattadırlar. Matristeki bir değere piksel denir ve pikseller bir renk alanının en küçük temsildirler. Her pikselin konumu statik olduğundan, pikseller arasındaki komşuluk bilgileri de statiktir ve bu bilgiler kolayca çıkarılabilirler. Ayrıca, piksel boyutu, piksel sayısı, piksellerin maksimum ve minimum değerleri ile temsil edilecek renk sayısı da veri içindeki tüm görüntüler arasında statiktir. Bu özellikleri göz önüne alındığında dünya çapında standart bir renk uzayı olan RGB renk uzayı kişiler/araştırmacılar tarafından rahatlıkla çalışılabilir (Öngün, 2021).

3B modellerin temsilinde ise, her 3B veri türünün artıları ve eksileri olduğu için belirli bir temsil tekniği öne çıkmaz. Optimum bir çözüm olmadığından, geliştiriciler kendilerine en uygun veri tipini seçerler. 3B veri toplama cihazları, 3B bilgileri yakalamak için farklı teknolojiler ve donanımlar kullanırlar. Cihazlar, gerçek dünya üzerinde farklı noktaların konumunu yüksek çözünürlüklü belirlemek için lazerleri, hareket bilgilerini yakalamak için derinlik sensörlerini, renk bilgileri için RGB sensörlerini vb. kullanırlar. Farklı tarama aletleri tarafından elde edilen ham 3B veri hem yapısal hem de özellikleri açısından değişken farklı biçimlerde gelir (Öngün, 2021). 3B verinin çeşitli temsilleri Ahmed vd. (2019) tarafından yapısal ve geometrik özelliklerine göre öklid yapıda ve öklid olmayan olmak üzere iki ana başlık altında sınıflandırılmıştır. Öklid yapıdaki veri temsillerine örnek olarak vokseller, RGB-D ve çoklu görüş; Öklid olmayan veri temsillerine nokta bulutları, ağ ve çizge verilebilir. 3B veri temsilleri Lin vd. (2022) tarafından girdi veri yapısına göre projeksiyon tabanlı, vekseller tabanlı ve nokta tabanlı olmak üzere üç kategoride ele alınmıştır.



Şekil 3. 3B veri temsillerine DALES veri seti üzerinden bir örnek

Derin öğrenme mimarilerinde genellikle kullanılan 3B veri temsilleri düzenli grid üzerinde tanımlanmış ve düzenli grid üzerinde tanımlanmamış veriler olarak ikiye ayrılabilir (Turgut, 2022). Literatüre göre, fotogrametri ve uzaktan algılama camiası tarafından yapılan çalışmalarda en çok kullanılan veri temsilleri düzenli grid üzerine tanımlanan veri temsillerinden voksel ve çoklu-görüş iken düzenli grid üzerinde

tanımlanmayan veri temsili ise nokta bulutlarıdır. Bu yüzden bu tez kapsamında bu üç veri temsili aşağıda üç ayrı bölümde tanıtılarak avantaj ve dezavantajları irdelenmiştir.

2.3.1.1. Vokseller

3B vokseller, ızgara tabanlı üç boyutlu bir koordinat sistemi ile altta yatan Öklid yapısını koruyan 3B hacimsel temsillerdir. 2B matris ile görüntü temsiline çok benzerler ve temel olarak 3B ikili matrislerdir. Matrisin her elemanı, karşılık gelen konumda bir birim küpün varlığını belirler. Örneğin bir nesne birim küpte ($32 \times 32 \times 32$) ikili matris ile temsil edilebilir bu durumda matrisinde ilk elemanı ($x=1/32$, $y=1/32$, $z=1/32$) konumundaki küpün varlığını temsil eder. 3B ikili matris yapısından dolayı voksellerin değiştirilmesi ve işlenmesi oldukça basittir (Öngün, 2021).

Yapısının basitliğine rağmen hem dolu hem de dolu olmayan bölgeler için veri depolaması ve boş alanlar için bellek kullanması açısından verimsizdirler. Bu durum vokselleri, gerçek dünya objelerini ya da gerçeğe yakın 3B modelleri yüksek çözünürlükte temsil etmek için ideal olmayan bir yapı haline getirir (Öngün, 2021). Vokseller ile çalışırken nokta bulutlarını bu veri yapısına çevirmek gerekir ancak burada vokal çözünürlüğünün ne olması gerektiği önemli bir parametredir. Turgut (2022) tarafından da belirtildiği gibi, çözünürlüğün yüksek seçilmesi durumunda veriye ait detaylar korunurken bellek problemi ve işleme süresi açısından bir dezavantaj oluşur. Çözünürlüğün düşük seçilmesi durumunda da bir vokal içine çok sayıda nokta denk gelebileceği için bu durumda da bilgi kayıpları meydana gelmektedir. Bu sorunlar dikkate alındığında vokseller, büyük ölçekli nokta bulutları ya da yüksek çözünürlüklü veriler için uygun olmamaktadırlar (Le ve Duan, 2018; Turgut, 2022). Yukarıda bahsedilen dolu olmayan vokal probleminin çözümü için farklı yaklaşımlar (Riegler vd., 2017; Wang vd., 2017; Klovov ve Lempitsky, 2017) geliştirilmiştir ancak ağdaki katman sayısı arttıkça bellek kullanım problemi devam etmektedir (Zhao vd., 2019b; Turgut, 2022).

2.3.1.2. Çoklu Görü

3B verilerin bir diğer temsili olan çoklu görü (multi-view), 3B obje için farklı bakış açılarından çekilen çoklu 2B görüntülerin bir kombinasyonu olarak sunulabilir. 3B verileri

bu şekilde temsil etmek, toplanan veriler üzerindeki gürültü etkisini, eksikliği (incompleteness), kapanma (occlusion) ve aydınlatma sorunlarını azaltmak için çoklu öznitelik setlerinin öğrenilmesine olanak tanır. Aynı nesnenin işlenmiş 2B çoklu görüntülerinden 3B verinin öğrenilmesi, her bir görünümü ayrı ayrı modelleyen bir fonksiyonu öğrenmeyi ve ardından tüm fonksiyonları 3B şeklin tamamını temsil edecek ve diğer 3B şekillere genellemeye izin verecek şekilde birlikte optimize etmeyi amaçlar. Bununla birlikte, 3B şekli modellemek için kaç görünümün yeterli olabileceği sorusu ise hala açıktır. 3B obje az sayıda görü ile temsil edildiğinde tüm 3B şeklin özellikleri yakalanamayabilir ve aşırı-uyuma (over-fitting) sorununa yol açabilirken çok fazla görü ise, gereksiz bir hesaplama yüküne neden olur (Ahmed vd., 2019). Bununla birlikte, iyi temsil edilen çoklu görüler ile öğrenmenin, 3B hacimsel verilerden öğrenmeye göre daha iyi performans gösterdiği kanıtlanmıştır (Su vd., 2015; Ahmed vd., 2019). Hem hacimsel hem de çoklu görü verileri, deformasyonların minimum olduğu rijit verileri analiz etmek için daha uygundur (Ahmed vd., 2019). Bu temsilin dezavantajları ise 3B geometrik özelliklerden yararlanamaması ve 3B'den 2B'ye dönüşümü için ön işlem (pre-processing) gerektirmesidir.

2.3.1.3. Nokta Bulutları

Nokta bulutları, 3B modelleri tanımlayan 3B koordinat sistemindeki noktalar kümesidir. Bir 3B model, (x, y ve z) eksenlerindeki konumunu tanımlayan üç değişkene sahip herhangi bir sayıdaki noktalar ile tanımlanabilir. Bu da veri yapısını basitleştirir yani örnek olarak bir model 1000 nokta ile temsil ediliyorsa, dosya nokta bulutunu tanımlayan (1000×3) bir matris içerir. Nokta bulutlarının 3D tarayıcılar tarafından çoğunlukla tercih edilmesi, robotik uygulamalar ve otonom sürüş arasında popüler olmasını sağlamaktadır. Diğer 3B temsil yöntemleri ile karşılaştırıldığında, nokta bulutlarının toplanması/yakalanması, görselleştirilmesi ve değiştirilmesi daha kolaydır (Öngün, 2021).

Ancak nokta bulutları ile çalışmak beraberinde çeşitli zorlukları da getirmektedir. Bu zorluklar Qi vd. (2017a) tarafından aşağıdaki gibi sınıflandırılmıştır.


- Düzensizdirler: Nokta bulutu, görüntülerdeki piksel dizilerinden veya hacimsel temsildeki voksel dizilerinden farklı olarak özel bir sıralamaya tabi olmayan noktalar dizisidir. Bu yüzden N adet 3B noktaların işleneceği bir mimari, girdi nokta bulutunun $N!$ permütasyonuna karşı değişmez olmalıdır.

- Noktalar arası ilişki: Noktalar birbirinden izole değildirler ve bir noktanın komşuları anlamlı bir alt küme oluşturur. Bundan dolayı da model, komşu noktalardan yerel yapıları yakalamalı ve bu yerel yapılar arasındaki ilişkileri sağlayabilmelidir.
- Dönüşüme karşı değişmezlik: Nokta bulutlarından öğrenilen temsillerin belirli dönüşümlere karşı değişmez olması gerekmektedir. Örnek olarak bir nokta bulutunu topluca döndürmek ve ötelemek nokta bulutunun hem global kategorisini hem de bu noktaların segmentasyonunu değiştirmemelidir.

2.3.2. Farklı Temsillerde 3B Derin Öğrenme

2B veriler üzerindeki derin öğrenme mimarilerinin sınıflandırma ve segmentasyon gibi bilgisayarla görme alanlarında elde ettiği başarıların ardından özellikle işlemci teknolojilerindeki gelişmeler ile 3B verilerin işlenebilirliğinin artması ve 3B verilere olan erişimin son yıllarda gelişen LiDAR, RGB-D kameraları ve çeşitli 3B tarayıcılara bağlı olarak kolaylaşması, 3B verilerin derin öğrenme ile sınıflandırılması ve semantik segmentasyonu işlemlerini önemli bir çalışma alanı haline getirmiştir.

3B nokta bulutu segmentasyonu hem global geometrik yapının hem de her bir noktanın ince detaylarının anlaşılmasını gerektirmektedir. Semantik segmentasyonun amacı verilen bir nokta bulutunu, noktaların semantik anlamlarına göre sınıf sayısına göre alt kümelere ayırmaktır. 3B veriler genellikle derinlik görüntüsü, nokta bulutları, mesh (ağ) ve hacimsel (voksel) gridler olmak üzere farklı formatlarda temsil edilebilirler (Guo vd., 2021b). Bu 3B veri temsilleri yukarıda Bölüm 2.3.1’de detaylıca açıklanmışlardır. 3B nokta bulutlarının bu veri temsillerine göre derin öğrenme ile semantik segmentasyonu projeksiyon tabanlı, ayırıklaştırma tabanlı, nokta tabanlı ve hibrit yöntemler olmak üzere dört kategoriye sınıflandırılabilir (Guo vd., 2021b). Bu sınıflandırma Şekil 4’te gösterilmiştir.



Şekil 4. Farklı veri temsillerine göre nokta bulutlarında derin öğrenme yöntemlerinin sınıflandırılması (Guo vd., 2021b)

Bölüm 2.3.2.1’de projeksiyon tabanlı yöntemler, 2.3.2.2’de ayrıklaştırma tabanlı yöntemler ve Bölüm 2.3.2.3’te nokta tabanlı yöntemlerden noktasal MLP yöntemleri açıklanmış, geliştirilen mimariler hakkında literatür bilgileri verilmiş ve son olarak bu yöntemlerin birbirine göre üstünlük ve zayıflıkları irdelenmiştir. Hibrit yöntemler, bu üç yaklaşımın farklı şekillerdeki kombinasyonu olduğundan dolayı ayrı bir bölüm olarak ele alınmamıştır.

2.3.2.1. Projeksiyon Tabanlı Yöntemler

Bu yöntemler 3B nokta bulutlarını çoklu-görüntü ya da küresel görüntüler gibi 2B bir düzleme dönüştürür. Çoklu görüntü tabanlı yöntemlerde nokta bulutları öncelikle birçok yönden sanal kameralar ile 2B düzlemlere aktarılır. 2B segmentasyon ağları (CNN, FCN) kullanılarak piksel başına sınıf etiketleri belirlendikten sonra nokta bu etiketler nokta bulutuna geri yansıtılarak segmentasyon işlemi tamamlanır. Literatürde pek çok araştırmacı projeksiyon tabanlı yöntemleri kullanarak nokta bulutlarının semantik segmentasyonu işlemini gerçekleştirmiştir (Boulch vd., 2017; Boulch vd., 2018; Kalogerakis vd., 2017; Lawin vd., 2017; Milioto vd., 2019; Tatarchenko vd., 2018; Wu vd., 2018; Wu vd., 2019).

Nokta bulutlarını raster formata dönüştürerek CNN mimarileri kullanan bazı çalışmalar her bir noktadan ayrı birer görüntü oluşturmaya da dayanır. Ardından bir noktanın ait olduğu sınıfın belirlenmesi o noktanın öznitelik görüntüsünün etiketinin atanması olarak tamamlanır. Bu yaklaşımı Hu ve Yuan (2016) zemin noktalarının sınıflandırılması probleminde kullanmışlardır. Her bir noktayı mekânsal çözünürlüğü 0,75 m olan 128×128 piksel görüntüler olarak oluşturmuşlardır. Her bir piksel içindeki noktaları Z_{min} , Z_{max} ve Z_{mean} değerleri ile temsil etmişlerdir. Yang vd. (2017) ise aynı yaklaşıma geometrik öznitelikleri (düzlemsellik, küresellik, yerden yükseklik, normal vektör varyansı) ve LiDAR yoğunluk verilerini de ekleyerek CNN mimarisi kullanmıştır. Zhao vd. (2018), aynı yaklaşımı 3,2, 6,4 ve 9,6 m komşuluk boyutlarında 32×32 piksellik görüntüler oluşturarak çok ölçekli olarak uygulamıştır. Ancak bu yöntemlerden zeminden olan yükseklik özneteliğini kullanan mimarilerin kullanılması bir Sayısal Yükseklik Modelinin (SYM) önceden üretilmesini gerektirir. Ayrıca bu yaklaşımlar, aynı bölge farklı nokta görüntülerinde çok kez görüleceği için gereksiz işlem hacmine yol açmaktadır (Winiwarter vd., 2019). Bazı araştırmacılar da farklı bir yaklaşım olarak tüm nokta bulutunu görüntüye dönüştürerek semantik segmentasyonunu gerçekleştirmişlerdir (Politz ve Sester, 2018; Rizaldy vd., 2018). Ancak bu tarz yaklaşımlarda görüntüler düşey projeksiyon kullanılarak üretildiği için temsillik 2,5B olacaktır. Bundan dolayı da bu yaklaşımlar daha çok objelerin birbirini örtmediği, penetrasyonun olmadığı basit alanlarda uygulanabilmekle sınırlıdır. Daha karmaşık alanlarda semantik segmentasyon yapabilmek için sınırlı temsil yeteneğine sahip bu tarz 2,5B yaklaşımlar yerine, LiDAR nokta bulutundan elde edilen tüm bilgilerden faydalanabilen 3B yaklaşımların kullanılması gerekmektedir. Bütün bu projeksiyon yaklaşımlar hangi özniteliklerin görüntüye aktarılacağı ile ilgili manuel seçim gerektirir (Winiwarter vd., 2019).

Projeksiyon tabanlı segmentasyon yöntemlerinde çoklu-görüntü kullanılması durumunda yöntemin performansı kamera konumu seçimine karşı oldukça hassastır. Her iki türdeki görüntüler için de objenin görüş hattının başka bir obje ile kapanma sorunu (occlusion) ile karşılaşılmaktadır. Üstelik, projeksiyon işlemi bilgi kayıplarına neden olduğu için bu yöntemler geometrik ve yapısal bilgilerden tamamen faydalanamamaktadır (Guo vd., 2021b).

2.3.2.2. Ayırıklaştırma Tabanlı Yöntemler

Genel olarak, ayırıklaştırma tabanlı yöntemler nokta bulutlarını düzenli hacimsel veri yapısına dönüştürerek kullanırlar (Guo vd., 2021b). Bu yöntemler, vokselleştirilen nokta bulutlarından üretilen yoğun gridleri 3B CNN ile işleyerek voksel tabanlı segmentasyon gerçekleştirir. Son olarak her bir voksel için elde edilen semantik etiketler voksel içindeki tüm noktalara atanarak segmentasyon işlemi tamamlanır (Huang ve You, 2016). Daha detaylı ve tutarlı semantik segmentasyon sonuçları elde etmek için bu modellere ek enterpolasyon katmanları da eklenmektedir (Long vd., 2015; Tchapmi vd., 2017). Literatürde pek çok araştırmacı ayırıklaştırma tabanlı yöntemler kullanarak nokta bulutları üzerinde semantik segmentasyon işlemi gerçekleştirmişlerdir (Graham vd., 2018; Maturana ve Scherer, 2015; Schmohl ve Sörgel, 2019; Wu vd., 2015). Bu yöntemler, değişken nokta sayılarına ve örnekleme sahip nokta bulutlarının eğitilmesinde esneklik tanımakla birlikte kullanılan voksel veri yapısı sayesinde nokta bulutundaki komşuluk ilişkilerini de korumaktadır. Bu sayede, ayırıklaştırma tabanlı yöntemlerle standart 3B konvolüsyonlar kullanılarak başarılı sonuçlar alınabilmektedir. Ancak, vokselleştirme işlemi doğası gereği geometrik hatalara neden olmasının yanı sıra bilgi kayıplarına da neden olur. Bunun yanı sıra, uygun voksel boyutunun seçilmesi kolay olmamakla birlikte, vokselleştirme adımında yüksek çözünürlük tercih edilmesi yüksek bellek kullanımına ve işleme süresinin uzamasına neden olurken, düşük çözünürlük seçilmesi durumunda da detay kaybı ile karşılaşilmektedir (Guo vd., 2021b).

2.3.2.3. Nokta Tabanlı Yöntemler


Nokta tabanlı yöntemler doğrudan düzensiz nokta bulutları üzerinde çalışır. Ancak, nokta bulutları düzensiz ve yapılandırılmamış olmasından dolayı standart CNN'leri doğrudan uygulamak mümkün değildir (Guo vd., 2021b). Bu amaçla, öncü bir çalışma olan PointNet (Qi vd., 2017a), paylaşımlı MLP'leri kullanarak her bir noktanın özniteliklerini ve simetrik pooling fonksiyonu kullanarak da nokta bulutunun global öznitelikleri öğrenmek amacı ile önerilmiştir. PointNet'in düzensiz nokta bulutlarının semantik segmentasyonunda gösterdiği başarının ardından, son yıllarda PointNet tabanlı pek çok derin öğrenme ağı literatüre girmiştir (Guo vd., 2021a; Hu vd., 2020; Qi vd., 2017b; Wang vd., 2020; Zhao

vd., 2021). Genel olarak, bu yöntemler noktasal MLP, noktasal konvolüsyon, RNN tabanlı ve çizge tabanlı yöntemlere ayrılabilir (Guo vd., 2021b).

Noktasal MLP Yöntemleri: Bu yöntemler genel olarak yüksek verimliliğinden dolayı paylaşımlı MLP'leri mimarilerinde temel birim olarak kullanırlar. Ancak paylaşımlı MLP'ler ile çıkartılan noktasal öznitelikler nokta bulutunun yerel geometrisini ve noktaların birbirleri ile karşılıklı etkileşimlerini yakalayamayabilir. Her bir noktanın daha geniş bir bağlamını ve daha detaylı yerel yapılarını yakalayabilmesine yönelik çeşitli mimariler önerilmiştir. Bu mimariler, komşuluk öznitelik pooling (neighboring feature pooling), dikkat-tabanlı toplama (attention-based aggregation) ve yerel-global öznitelik birleştirme (local-global feature concatenation) tabanlı olarak sınıflandırılabilirler (Guo vd., 2021b).

Komşuluk öznitelik pooling yöntemleri, yerel geometrik dokuları yakalayabilmek adına bu yöntemler her bir noktanın komşularından öğrendiği öznitelikleri birleştirirler. Özellikle PointNet++ noktaları hiyerarşik olarak gruplayarak ve git gide artan daha geniş yerel bölgelerden öğrenerek çalışmaktadır (Guo vd., 2021b). PointNet ve PointNet++'ın nokta bulutlarının semantik segmentasyonunda elde ettiği başarı sayesinde, literatürde pek çok nokta tabanlı model bu iki mimariye dayalı olarak çeşitli uyarlamalar ve değişimlerin yapılması ile geliştirilmiştir. Jiang vd. (2018), PointSIFT ismini verdikleri mimaride SIFT algoritmasından esinlenerek farklı yönlerden gelen öznitelikleri birleştirmek için PointNet++'a bir dizi yönelim encode eden katman eklemişlerdir. Zhao vd., (2019b) tarafından geliştirilen PointWeb ile, PointNet++'ın max veya ortalama pooling stratejileri yerel bağlamsal bilgileri daha iyi yakalayabilmek için uyarlanabilir öznitelik düzenleme modülü ile değiştirilmiştir (adaptive adjustment module). Bu modül sayesinde yerel bölgede her bir öznitelik diğer öznitelikler tarafından baskılanmakta ya da öne çıkarılmaktadır. Liu vd. (2021) PointCE mimarisi ile ağırlıklı olarak birkaç önemli ara özniteliğe odaklanarak bir dizi ölçekleme faktörü öğrenebileceği bir nokta bağlam kodlama modülü (point context encoding) önermişlerdir. Engelmann vd. (2018), PointNet++'ın gruplama katmanındaki küresel komşuluk stratejisini, k-means kümeleme ve k en yakın komşuluk yöntemleri ile değiştirmişlerdir. Hu vd. (2020), rastgele nokta örnekleme yöntemi (random point sampling) ve yeni bir lokal öznitelik birleştirme modülü (local feature aggregation module) ile büyük ölçekli nokta bulutlarının semantik segmentasyonu için RandLA-Net ismini verdikleri bir derin sinir ağı mimarisi oluşturmuşlardır. Semantic3D ve SemanticKITTI veri setleri üzerinde gerçekleştirdikleri testlerde güncel

semantik segmentasyon yöntemlerine göre daha hızlı ve yüksek doğrulukta sonuçlar elde ettiklerini belirtmişlerdir. RandLA-Net büyük ölçekli nokta bulutları için diğer yöntemler ile kıyaslandığında hem hesaplama süresi daha düşüktür hem de bellek kullanımı daha azdır. Ancak noktaları rastgele örneklediği için kritik noktaları göz ardı edebilmektedir ve bu da modelin performansını olumsuz olarak etkilemektedir. Üstelik RandLA-Net, yerel dokuları çıkarırken KNN en yakın komşuluk seçimi yöntemini kullanmaktadır. Ancak bu yöntem hava LiDAR nokta bulutları gibi nokta örnekleme değişkenlik gösterdiği nokta bulutlarında düşük yoğunluklu alanlarda komşuluk seçimi yapılırken çok geniş alanları kapsarken yüksek yoğunluklu alanlarda komşuluğun kapsadığı alan küçülmektedir. Bundan dolayı da KNN yaklaşımı, çıkartılan yerel dokular birbiri ile farklı ölçeklerde olacağından dolayı etkili bir yöntem değildir. Şekil 5'te nokta bulutlarının semantik segmentasyonu için tasarlanan noktasal MLP yöntemleri kronolojik olarak gösterilmektedir.



Şekil 5. Nokta bulutunun semantik segmentasyonunda noktasal MLP yöntemlerin kronolojik sıralaması Guo vd. (2021b)'den uyarlanmıştır

Diğer noktasal MLP yöntemlerinden dikkat tabanlı toplama yöntemleri segmentasyon doğruluklarını daha iyi hale getirebilmek için, nokta bulutu segmentasyonuna dikkat mekanizmasını Vaswani vd. (2017) (attention mechanism) eklemektedir. Literatürde pek çok araştırmacı dikkat tabanlı toplama yöntemi kullanarak nokta bulutlarının semantik segmentasyonunu gerçekleştirmiştir (Chen vd., 2019; Yang vd., 2019; Zhao vd., 2019a). Son olarak bir noktasal MLP yöntemi olan yerel-global öznitelik birleştirme yöntemlerinde, Zhao vd. (2019c) tarafından nokta bulutlarından yerel ve global bağlamı kapsayan bir permütasyona karşı değişmez PS²-Net önerilmiştir. Yine bu yöntemi kullanan mimarilerden EdgeConv (Wang vd., 2019) ise yerel bilgileri ve sahne seviyesindeki global öznitelikleri yakalayabilmek adına tekrarlamalı olarak üst üste eklenebilecek şekilde tasarlanmışlardır (Guo vd., 2021b).


Hem projeksiyon tabanlı yöntemler hem de ayırıklaştırma tabanlı yöntemler düzenli veri temsilleri sayesinde 2B görüntülere uygulanabilen mimarileri kullanabilmektedir. Ancak projeksiyon tabanlı yöntemler, 3B-2B dönüşümünden kaynaklı bilgi kayıpları tarafından sınırlandırılırken, ayırıklaştırma tabanlı yöntemler ise çözünürlüğün artması sonucu kübik olarak artan hesaplama süresi ve bellek kullanımı tarafından sınırlandırılır. Nokta bulutları ise, sahnelerle dair 3B bilgileri doğrudan sunması ve ön işleme gerektirmeden işlenebilir olmaları gibi avantajlara sahiptir. En sık araştırılan ve kullanılan yöntem olmasına rağmen nokta tabanlı yöntemler de nokta bulutlarının komşuluk ilişkilerinden yoksun olması ve bu ilişkilerin küresel komşuluk ya da kNN gibi yöntemler ile oluşturulmak zorunda olması tarafından sınırlandırılırlar (Guo vd., 2021b). Bu komşuluk ilişkilerinin çıkarılması hesaplama süresi bakımından maliyetli bir işlemdir.

Bu tez çalışmasında, noktasal MLP yöntemlerinden literatürde geliştirilen birçok mimari için öncü olarak kabul edilen PointNet++ mimarisi kullanılmıştır. Literatürde nokta bulutlarında derin öğrenme alanındaki mimarilerin çoğu PointNet ve PointNet++ mimarilerini temel alıp üzerine çeşitli düzenlemeler ya da eklemeler yapılarak yeni mimariler oluşturulduğu için bu tez kapsamında da PointNet++ mimarisi araştırılmıştır. Bu araştırma, mimarinin hava LiDAR nokta bulutları için genelleştirme kabiliyetini artırmanın yanı sıra büyük ölçekli hava LiDAR nokta bulutlarına uyarlanmasında dikkat edilmesi gereken çerçeve boyutu, girdi nokta sayısı, komşuluk arama yarıçap boyutu, komşuluktaki nokta sayısı parametrelerinin üzerine de yoğunlaşmıştır. Mimarinin genelleştirme kabiliyetini arttırabilmek adına Adaptif 1 ve Adaptif 2 isminde iki yeni yaklaşım önerilmiştir. Çerçeve boyutu seçimini tamamen otomatize eden Adaptif 1 ve başlangıç olarak verilen çerçeve boyutunu veri içindeki nokta yoğunluğuna adapte edebilen Adaptif 2 yaklaşımları mimariye entegre edilerek performansları araştırılmıştır. Komşuluk arama yarıçapını otomatize etmek için ön işlem gerektiren yeni bir yaklaşım önerilerek bu sayede yarıçap boyutunu deneme yanılma yöntemiyle belirlemekten kaçınılmıştır. Ayrıca, mimarinin mevcut katmanlarından hibrit yeni bir katman oluşturularak performans ve zaman bakımından maliyeti araştırılmıştır.

2.4. Hava LiDAR Nokta Bulutları

LiDAR; Sayısal Yükseklik Modeli (SYM) üretimi, karayolu, bina detayların çıkartılması, 3B şehir model üretimi, değişim analizi, hidrolojik modelleme ve ormancılık

uygulamaları gibi pek çok alanda sağladığı yoğun ve doğru yükseklik verileri sayesinde vazgeçilmez bir yöntem haline gelmiştir. Kısa sürede çok geniş alanların haritalanmasına olanak sağlaması nedeni ile LiDAR çoğunlukla hava platformlarında kullanılsa da yüksek detay gereksinimi olan yersel uygulamalarda sabit ve mobil yersel platformlara entegre edilerek de kullanılabilir. LiDAR kullanarak yükseklik verilerinin toplanması, diğer birçok tekniğe göre çeşitli avantajlara sahiptir. Bunların başında, ormanlık arazide zemin tespiti, yüksek mekânsal doğruluk ve aktif bir algılayıcı olması sayesinde karanlıkta da çalışabilmesi gelmektedir. Bu aktif uzaktan algılama tekniği, radara benzer bir prensiple çalışmaktadır ancak radyo dalgaları yerine lazer ışınını kullanmaktadır. LiDAR, yoğun, odaklanmış lazer ışınlarını gönderdikten sonra geriye dönen yansımaların sensör tarafından algılanarak, her bir lazer ışının gidiş dönüş süresini ölçmekte ve böylelikle sensör ve obje arasındaki mesafeyi tayin edebilmektedir. Hedef nesnelerin üç boyutlu koordinatları, gönderilen ve geri dönen lazer ışınının arasındaki zaman farkı, ışının hangi açı ile geldiği ve sensörün dünya üzerindeki mutlak konumu kullanılarak hesaplanır. LiDAR, dünya yüzeyinin ve özelliklerinin üç boyutlu temsillerini oluşturmak için kullanılabilen, nokta bulutu olarak adlandırılan, hassas coğrafi referanslı yükseklik noktalarından oluşan yoğun bir temsil üretir (Şekil 6). Birçok LiDAR sistemi, elektromanyetik spektrumun yakın kızılötesi bölgesinde çalışırken batimetrik amaçlı sistemler yeşil bantta çalışmaktadır (Dong ve Chen, 2017).



Şekil 6. LiDAR ile haritalama örneği Habib (2017)'den uyarlanmıştır

LiDAR nokta bulutu verileri x, y ve z koordinatlarının yanı sıra yoğunluk, dönüş numarası, dönüş sayısı, tarama yönü, sınıf bilgisi, GPS zamanı, nokta kaynağı hatta entegre kamera bulunması durumunda R, G, B ve IR gibi spektral bilgileri de içerebilir (Dong ve Chen, 2017).

Hava LiDAR nokta bulutlarının avantaj ve dezavantajları: Işık ile çalışan aktif bir sistem olarak lazer tarayıcılar, bulutlardan, sisten ve yoğun bitki örtüsünden penetre olamayabileceğinden dolayı zemini görebileceği açık bir görüş alanına ihtiyaç duyarlar. Lazer ışını yaprak döken ağaçların kanopilerinden özellikle kış aylarında kolaylıkla geçebilir. Ancak lazer ışını, yoğun iğne yapraklı ağaçların varlığında ve çok katmanlı yağmur ormanlarında zemine ulaşamaz. Tüm bu dezavantajlarına rağmen, hava lazer tarama sistemleri yüksek kaliteli dijital yükseklik modellerinin üretiminde çok etkili bir yöntem olarak ortaya çıkmıştır. Yükseklik verisi üretiminde diğer yöntemlere göre yüksek yoğunluklu ve yüksek doğrulukta veri üretimi, hızlı veri edinimi, çok yoğun olmayan kanopi penetrasyonu ve minimal arazi çalışmasına ihtiyaç duyması gibi avantajlara sahiptir (Vosselman ve Maas, 2010).

Hava LiDAR nokta bulutlarının derin öğrenme alanındaki zorlukları: Hava LiDAR nokta bulutu verileri düzensizdirler, nokta dağılımları ve yoğunlukları eşit değildir. Ayrıca kullanılan sensörün özelliğine, sensörün ısınmasına ve algılama yapılan yüzeyin yansıtıcılığı gibi nedenlere bağlı olarak gürültü/aykırı noktalar bulunabilmektedir. Değişken nokta yoğunluğu ise uçuş planında belirlenen bindirme oranı, hava koşullarına bağlı olarak hava platformunun uçuş planından sapması (öteleme, dönme, yükseklik değişimi) ve kullanılan sensördeki tarama mekanizmasından (salınlımlı ayna, dönen poligonal ayna, palmer tarayıcı vb.) kaynaklanabilmektedir. Buna ek olarak veride su, cam gibi saçılımın çok olduğu yüzeylerden dolayı boşluklar olabilmektedir. Nokta bulutlarında hem sınıf içi hem de sınıflar arası varyans oldukça yüksek olabilmektedir. Veri içindeki aynı objelerin boyutları farklılık gösterebileceği gibi farklı sayıda nokta ile temsil edilebilirler. Farklı objeler için örneklenen nokta sayıları da birbirlerine göre değişkenlik göstermektedir ve özellikle bazı objeler (elektrik hattı, araba, direk) çok az nokta ile temsil edilebilmektedir. Bu durum sınıflar arası dengesizliği hava LiDAR nokta bulutu verilerinde artırmaktadır. Tüm bu zorluklar hava LiDAR nokta bulutlarında derin öğrenme ile semantik segmentasyon işlemini karmaşık hale getirmektedir. Çünkü bu karmaşıklık herhangi bir veriden öğrenilen özneliliklerin başka bir veriyi temsil etmesini güçleştirmektedir.

2.5. Hava LiDAR Nokta Bulutlarında 3B Derin Öğrenme

Hava LiDAR nokta bulutlarında 3B derin öğrenme çalışmaları, PointNet ve PointNet++ mimarilerinin bu büyük ölçekli verilere uyarlanması ile başlamıştır. Bu çalışmalar, uçtan uca yaklaşımlar ve uçtan uca olmayan yaklaşımlar olmak üzere iki kategoriye ayrılabilir. Uçtan uca yaklaşımlar LiDAR nokta bulutuna ait X, Y ve Z koordinatları, yoğunluk, geri dönüş sayısı, geri dönüş numarası varsa R, G, B değerleri gibi ham bilgileri kullanarak sınıflandırma ya da semantik segmentasyon işlemlerini gerçekleştirir. Uçtan uca olmayan yaklaşımlar ise, bu bilgilere ek olarak ön işleme yaparak elle çıkartılan özniteliklerin de girdi öznitelik vektörüne eklenmesi ile sınıflandırma ve semantik segmentasyon işlemlerini gerçekleştirmektedirler.

Kada ve Kuramin (2021), PointNet++ ve KPConv mimarilerini kullanarak Almanya'nın Leipzig kentine ait 110 nkt/m^2 nokta yoğunluğuna sahip veri setinin semantik segmentasyonunu gerçekleştirmişlerdir. PointNet++ için dört farklı senaryo belirlemişlerdir. İlk senaryoda, PointNet++'ı ön tanımlı parametreleri ile eğitmişlerdir, ikinci senaryoda ise noktaların zeminden yüksekliği (height above ground) ve kabaca sınıflandırılmış sınıf etiketlerinden oluşan öznitelikleri 3B koordinatlara ekleyerek eğitmişlerdir. Üçüncü ve dördüncü senaryoda, PointNet++'ın ilk dizi özetleme (set abstraction-SA) katmanına küresel komşuluklara (3B) ek olarak silindirik komşuluk (2B) kullanılarak elde edilen lokal öznitelikler de eklenmiştir. Üçüncü senaryoda öznitelik olarak sadece zeminden yükseklik kullanılırken, dördüncü senaryoda hem zeminden yükseklik hem de kabaca belirlenen sınıf etiketlerini kullanmışlardır. Silindirik komşulukla elde edilen lokal özniteliklerin genel doğruluğa önemli bir katkısının olmadığını ifade etmişlerdir. Orijinal PointNet++ ile ikinci senaryo kıyaslandığında genel doğruluk yaklaşık %3 artmıştır. Silindirik komşuluğun eklendiği senaryo dörtte, senaryo ikiye göre genel doğrulukta %0,04 iyileşme görülürken; mIoU için en çok doğruluk artışını bina cephesi sınıfında %6, direk sınıfında %4 olarak elde etmişlerdir. Elektrik hattı ve zemin sınıfında sırası ile yaklaşık %4 ve %0,1 düşüş olurken diğer sınıflarda önemli bir değişim gözlemlenmemişlerdir.

Li vd. (2021) çalışmalarında PointNet++, SparseCNN ve KPConv mimarilerini Viyana ve Siemens olmak üzere iki farklı veri seti üzerinde karşılaştırmışlardır. Eğitim ve test veri setleri için yaklaşık 448 milyon ve 322 milyon nokta içeren Viyana veri setinde zemin, bina, bitki, su ve diğer olmak üzere beş sınıf bulunmaktadır ancak çalışmada su

sınıfını kullanmamışlardır. Diğer sınıfı içinde sokak ışıkları, banklar, küçük çalılıklar, araçlar, çöp kutusu gibi sokağa ait objeler bulunmaktadır. Siemens dataseti ise sadece enerji nakil hatlarını içeren bir veri setidir. PointNet++ mimarisi için (Winiwarter vd., 2019) tarafından hava LiDAR nokta bulutu için modifiye edilen PointNet++ mimarilerinden en yüksek doğruluk elde ettikleri 3 dizi özetleme katmanlı model ve parametrelerini kullanmışlar. Viyana dataseti üzerinde PointNet++, SparseCNN ve KPConv mimarileri için sırası ile %97,13, %98,12 ve %94,90 genel doğruluklar elde etmişlerdir. PointNet++'ın diğer mimarilere göre özellikle zemin ve zemine yakın diğer sınıfları ayırt etmekte zorluk çektiği sonucuna varmışlardır. Ancak bunun nedeninin PointNet++'da ilk katmanda kullandıkları komşuluk arama yarıçapının (1 m) diğer mimarilerdekine (SparseCNN ve KPConv için sırası ile 0,08 ve 0,2 m) oranla daha büyük olmasından kaynaklandığını belirtmişlerdir.

Chen vd. (2021) PointNet++ mimarisini ISPRS Vaihingen veri setine uyarlamışlardır. Orijinal mimaride lokal öznitelikler arama yarıçapı içerisinde kalan komşuluklardan elde edilirken yaptıkları değişimle bu noktalara ek olarak merkez noktanın da lokal öznitelikleri dikkate alarak tüm öznitelikleri birleştirmişlerdir. Ayrıca orijinal algoritmadaki cross-entropi yerine modifiye edilmiş focal loss fonksiyonu kullanmışlardır. Yaptıkları değişimler sayesinde genel doğruluğu %83,2 olarak elde etmişlerdir ve orijinal PointNet++ sonuçlarını %2 iyileştirmişlerdir. Özellikle elektrik hattı sınıfının F1 skorunu uyguladıkları yeni yaklaşımlar sayesinde orijinal PointNet++'a göre %57,9'dan %77'e çıkarmışlardır.

Brieche vd. (2019), ağaç sınıflandırması için PointNet++ mimarisini kullanmışlardır. Bu işlemi kayın ve ladin olmak üzere iki ağaç türü için Bavarian Ormanı Ulusal Park veri seti üzerinde gerçekleştirmişlerdir. Veri setini 60 m'lik kübik bloklara bölerek veri setlerini hazırlamışlardır. Eğitim aşamasında da çerçeve boyutunu (box size) 20×20 m kullanmışlardır. Genel doğrulukları %85 olarak elde etmişlerdir ve sonuçlarını rastgele orman algoritması ile karşılaştırmışlardır. Öznitelik tabanlı olarak eğittikleri RF algoritması ile kıyasladıklarında, PointNet++'ın sadece geometriyi kullanarak oldukça yüksek doğruluk ettiğini belirtmişlerdir.

Nurunnabi vd. (2021), PointNet mimarisinin ISPRS Vaihingen benchmark, DALES ve Dudelage olmak üzere üç farklı büyük ölçekli ALS nokta bulutları üzerinde hiper parametre seçiminin ağ üzerindeki etkilerini araştırmışlardır. PointNet'in, yığın sayısı (batch size), bloklara ayırma, blok içinden seçilen nokta sayısı gibi parametrelerin

seimine karřı olduka hassas olduėunu ortaya koymuřlardır. Blok boyutunu 5×5 m, 10×10 m ve 15×15 m setiklerinde ISPRS Vaihingen benchmark nokta bulutu zerinde 2048 girdi nokta sayısı ile elde ettikleri genel doėruluėun %67,7 (5×5 m) ile %72,8 (10×10 m) arasında deėiřtiėini belirlemiřlerdir. Nokta yoėunluėu 50 nokta/m² DALES veri setinde, ISPRS veri setinde elde ettikleri en iyi blok boyutu olan 10×10 m olan blok boyutunu kullanarak girdi nokta sayısı etkilerini 1024, 2048 ve 4096 nokta iin test etmiřlerdir. En yksek genel doėruluėu %91,5 ile 4096 girdi nokta sayısı ile etmiřlerdir. Son olarak nokta yoėunluėu 15 nokta/m² olan Dudelage veri seti zerinden de girdi vektr dizilerinin etkilerini 10×10 m blok boyutu ve 1024, 2048 ve 4096 girdi nokta sayıları iin ayrı ayrı test etmiřlerdir. En yksek genel doėruluėu blok iinden seilen 4096 nokta ile x, y, z, yoėunluk, dnř sayısı, yerden ykseklik, normalize x, y ve z bilgilerini kullanarak %95,8 olarak elde etmiřlerdir. Yaptıkları alıřmada, nokta yoėunluėu deėiřiminin nemli bir faktr olduėunu belirtmiřlerdir. Ayrıca, noktaların sınıflar arası daėılım dengesinin mimariye nemli etkisi olduėunu Dudelage ve DALES veri setlerinden elde ettikleri doėruluklar zerinden belirtmiřlerdir. Dudelage veri seti iin (4 sınıf iin) genel doėruluėu %95,8, DALES (9 sınıf iin) veri seti iin de %91,5 olarak elde etmiřlerdir. Yaptıkları alıřma, mimarinin parametrelerinin nokta bulutu zelliklerine gre ne kadar hassas olduėunu ortaya koymuřtur.

Rim vd. (2021), uyarlanmıř (adapted) PointNet++ mimarisinin rnekleme stratejisi olan en uzak nokta rnekleme (Farthest Point Sampling-FPS) yntemini rastgele rnekleme yntemi ile ek olarak da max pooling katmanını dikkat-tabanlı (attention) pooling katmanı ile deėiřtirmiřlerdir. Yaptıkları bu deėiřimlerin etkisini DALES ve Toronto-3D veri setleri zerinden orijinal PointNet++ ile hem alıřma zamanı hem de doėruluk deėerlerini dikkate alarak karřılařtırmıřlardır. Toronto-3D veri setinde hem sadece x, y, z koordinatları kullanarak hem de x, y, z, r, g, b deėerlerini kullanarak iki ayrı model eėitmiřlerdir. Bu veri setinde genel doėrulukları %72,55 ve %83,60 olarak elde etmiřlerdir. Girdi nokta bulutlarını 8192 olarak oluřturmuřlardır. DALES veri setinde sadece x, y, z koordinatlarını kullanarak %76,43 genel doėruluk ve mIoU metriėini ise %59,52 olarak elde etmiřlerdir. Orijinal PointNet++ ile ise genel doėruluk ve mIoU metriklerini sırası ile %95,7 ve %68,30 elde etmiřlerdir. Test zamanı olarak ise geliřtirdikleri model PointNet++'a gre neredeyse  katı daha hızlıdır.

Varney vd. (2020), DALES veri setini sundukları çalışmalarında, bu büyük ölçekli veri setini PointNet++ mimarisi ile sınıflandırmışlardır ve genel doğruluk ve ortalama IoU metriklerini sırası ile %95,7 ve %68,3 olarak elde etmişlerdir.

Shin vd. (2022), PointNet++ mimarisini kullanarak bina sınıfı için semantik segmentasyon işlemi gerçekleştirmişlerdir. PointNet++'ı, DALES veri seti üzerinde eğitip hem DALES hem de ISPRS Vaihingen veri setleri üzerinde ayrı ayrı test etmişlerdir. Çalışmada dönüş sayısı 2 olan noktaların dönüş sayısı özniteliklerinin binaların semantik segmentasyonu üzerine olan etkilerini 3 farklı uygulama üzerinden incelemişlerdir. DALES veri setini 50×50 m'lik alt parçalara (tile) bölerek işlemişlerdir. İlk olarak modeli DALES veri setinin tamamını tüm dönüş sayılarını kullanarak eğitmişlerdir. Daha sonra, DALES veri setini dönüş sayısı özniteliği sadece 2 olan noktalardan oluşacak şekilde rastgele %10 ve %50 oranında nokta sayısını azaltarak ikinci ve üçüncü modelleri eğitmişlerdir. DALES test veri setleri için maksimum genel doğrulukları üç uygulama için sırası ile uygulama 1 için %93,99, uygulama 2 için %90,59 ve uygulama 3 için %92,81 olarak elde etmişlerdir. ISPRS test veri setleri için ise 3 uygulamadan elde ettikleri maksimum genel doğruluklar uygulama 1 için %65,57, uygulama 2 için %47,54 ve uygulama 3 için ise %63,49 olarak elde etmişlerdir. Doğruluk değerleri incelendiğinde veri setinde azaltmaya gittiklerinde genel doğruluklarının düştüğü açıkça görülmektedir ancak uygulama 2 ve uygulama 1 için bina sınırları incelendiğinde dönüş sayısı 2 olan öznitelik sayesinde duyarlılık değerinin %5,31 arttığını belirtmişlerdir. DALES veri seti için eğittikleri modelin ISPRS benchmark test veri seti için doğruluğunun düşük olmasının gerekçesini iki veri arasındaki nokta yoğunluğu arasında ciddi fark olmasından kaynaklandığını belirtmişlerdir. Yaptıkları çalışmada, DALES veri seti üzerinde eğitilmiş modeli ISPRS veri seti üzerinde de test ederek genelleştirmeye çalışmışlardır.

Soilán, vd. (2019a), Actueel Hoogtebestand Nederland (AHN3, AHN2) veri seti üzerinde PointNet mimarisi ile hava LiDAR nokta bulutlarını sınıflandırmışlardır. Çalışmada üç farklı model kullanmışlardır. Model 1'de AHN3 veri setini kullanarak sadece zemin ve zemin olmayan noktaları x, y, z, yoğunluk, dönüş sayısı ve range bilgilerini kullanarak sınıflandırmışlardır. Model 2'de AHN3 veri setini sadece x, y, z koordinatlarını kullanarak ağaç, bina ve zemin sınıfları için eğitip hem AHN3 hem de AHN2 veri seti üzerinde test etmişlerdir. Model 3'te ise AHN3 veri setinde x, y, z koordinatlarını ve yoğunluk, dönüş sayısı, range bilgilerini kullanarak ağaç, bina, zemin sınıfları için sınıflandırma işlemini gerçekleştirmişlerdir. Yaptıkları çalışmada sınıfların içerdiği

noktalar arasında dengesizlikler olduğundan dolayı (unbalanced) köprü sınıfını zemin sınıfı ile birleştirerek ve su sınıfını veri setinden çıkartmışlardır. Model 2 ve 3'te bitki ve bina sınıflarının birbirine karıştığı görülmektedir. Model 1 için Fscore değerini 0,962, Model 2 için genel doğrulukları AHN3 ve AHN2 veri setleri için sırası ile %87,77 ve %84,98 olarak elde etmişlerdir. Model 3 için sınıflandırma genel doğruluğunu %87,37 olarak elde etmişlerdir. Özellikle Model 2 ve Model 3 sonuçları karşılaştırdıklarında, Model 3'e eklenen özniteliklerin modele anlamlı bir katkısının olmadığı sonucuna varmışlardır. PointNet mimarisinin nokta bulutunun sadece x, y, z üzerinden geometrisine odaklandığını belirtmişlerdir. AHN3 veri seti üzerinde eğittikleri modeli AHN2 veri seti üzerinde elde ettikleri yüksek doğrulukları üzerinden PointNet mimarisinin genelleştirilebilir olduğunu belirtmişlerdir. Orijinal PointNet mimarisinde nokta bulutunun 1×1 m bloklara bölünmekteyken bu parametreyi ALS nokta bulutu için iç mekân nokta bulutlarına göre ALS nokta bulutlarının yoğunluğunun düşük olması ve kapsadığı alanın daha büyük olmasından dolayı 10×10 m olarak değiştirmişlerdir. Ön işleme olarak da eğitim veri seti hazırlarken nokta bulutunu düzenli gridleme ile 25×25 m'lik parçalara bölmüşlerdir.

Winiwarter vd. (2019), PointNet++ mimarisi temeli üzerine kurulmuş olan alsNet derin öğrenme ağı ile ALS nokta bulutlarının semantik segmentasyonunda karşılaşılan sorunların çözülmesine yönelik bir çalışma yapmışlardır. Çalışmada ISPRS Vaihingen ve Vorarlberg veri setleri kullanılmıştır. PointNet++ mimarisine ek olarak yeni bir yığınlama (batching stratejisi) eklenmiş ve grouping katmanları için en uygun hiper-parametre araştırması yapmışlardır. Yığınlama stratejilerinde PointNet++'ın rastgele örneklem stratejisinin yerine, tüm nokta bulutu üzerinde düzenli aralıklarla örneklenen noktaların en yakın 200.000 komşusu bindirmeli olacak bir şekilde seçilerek eğitim aşamasının her bir iterasyonunda bu örneklem noktalarından elde edilen nokta bulutları tek tek işlenmiştir. Bunun yanı sıra, PointNet++'ın çoklu çözünürlük gruplama (multi-resolution grouping-MRG) katmanı için farklı arama yarıçapı, komşu nokta sayısı, MLP katman boyutu, eksiltme oranı, öğrenme oranı ve kayıp fonksiyonları vb. için en uygun hiper-parametreleri deneme yanılma ile belirlemişlerdir. AlsNet mimarisi ile ISPRS ve Vorarlberg veri setleri için elde ettikleri genel doğruluklar sırası ile %80,6 ve %82,6'dır. Ağ parametrelerini deneme yanılma yöntemi ile test etmek için beş farklı PointNet++ tabanlı mimari tanımlamışlardır. Vorarlberg veri setindeki dengesiz sınıf dağılımı problemi ile başa çıkabilmek için ana sınıfların (zemin, küçük bitki, orta bitki, yüksek bitki, bina ve su) standart sapmasını hesaplayarak bu değerin %20'si altında kalan veriyi eğitim verisinden

çıkartmışlardır. ISPRS veri seti küçük bir veri seti olduğu için bu işlemi atlamışlardır. Yaptıkları çalışmada, PointNet++ mimarisinden farklı olarak Vorarlberg eğitim veri setini hazırlarken nokta bulutunu KNN yöntemini kullanarak 200.000 nokta içeren parçalara bindirmeli olarak ayırmışlardır. Mimariyi, her bir parçalara ayrılan nokta bulutunu ardışık bir şekilde vererek 10 epok eğitmişlerdir. Çalışmada, ISPRS veri setinin eğitimi ile ilgili bilgi verilmemiştir. Vorarlberg veri setinde elde ettikleri sonuçlarda düşük bitki ve zemin sınıfının birbirine karıştığını gözlemlemişlerdir. Bunun nedeni olarak PointNet++ mimarisinin kullandığı FPS yönteminin bu iki sınıf arasında nokta örnekleyememesi olabileceğini belirtmişlerdir. Ancak, en yüksek doğruluğu elde ettikleri ID 3 numaralı mimarilerinde bile 200.000 noktayı FPS yöntemi ile ilk seviyede 8192 nokta ile alt örnekledikleri için ağın bu kadar az nokta ile böylesi büyük bir alanı iyi temsil edemeyeceği söylenebilir. Ardından 8192 noktanın 1 m komşuluğundan öğrenilen özniteliklerin 200.000 noktaya enterpole edilmesinden dolayı segmentasyon doğruluklarının düştüğü söylenebilir.

Öznitelik tabanlı çalışmalardan Özdemir ve Remondino (2019), nokta bulutunu derin öğrenme ile sınıflandırmak için öznitelik tabanlı bir mimari geliştirmişlerdir. Çalışmalarının ilk aşaması veri ön işleme aşamasıdır. Bu aşamada veriyi modellerine girdi olarak vermeden önce geometrik öznitelikleri (yerel düzlemsellik, dikey açı, yükseklik değişimi, anizotropi, küresellik, yüzey değişimi ve yerden yükseklik) çıkarmışlardır. Yine bu aşamada yerden yükseklik bilgisini elde edebilmek için SYM çıkarmışlardır. Girdi olarak nokta bulutunu komşu noktaları dikkate alabilmek için sıralı olarak (sequence) vermişlerdir. Ayrıca modele öznitelik olarak minimum X, Y, Z koordinatlarından diğer koordinatları çıkararak elde ettikleri koordinat farklarını da eklemişlerdir. Mimarileri bidirectional Long Short Term Memory, tamamen bağlı katmanlarından (fully connected layer-FCL) oluşmaktadır. Mimarilerini, ISPRS Vaihingen benchmark veri seti üzerinde hem 4 sınıf (çatı, bina cephesi, bitki ve yer seviyesi objeleri) üzerinden hem de 9 sınıf üzerinden olmak üzere iki farklı şekilde eğitmişlerdir. Bu iki eğitim sonucunda elde ettikleri genel doğruluklar ve F1 ölçütleri sırası ile %78,1, %77,6 ve %48,9, %41,2. Veriden, kullandıkları komşuluk arama yarıçapları içerisinde yeteri kadar komşusu olmayan noktaları elimine etmişlerdir. Çalışmalarında yarıçap ve nokta sayısı ile ilgili detaylar belirtilmemiştir.

Özdemir vd. (2021), hem fotogrametrik hem de LiDAR nokta bulutları üzerinde uçtan uca olmayan derin sinir ağı modeli geliştirerek X, Y, Z koordinatlarına ek olarak

yerel düzlemsellik, küresellik, düşey açı, zeminden yükseklik gibi özniteliklerini kullanarak semantik segmentasyon işlemi gerçekleştirmişlerdir. Bunlara ek olarak LiDAR nokta bulutlarına yoğunluk, geri dönüş sayısı, geri dönüş numarası ve fotogrametrik nokta bulutları için renk bilgilerini de kullanmışlardır. Nokta bulutlarında, her bir yerel komşuluk için öznitelikler çıkartılmış ve komşuluğun merkezine göre normalize edilmiş koordinatlar hesaplanarak her bir komşuluk koordinata sıralı 2B görüntü parçalarına (patch) haline getirilmiştir. Sonrasında bu görüntüler 2DCNN ile sınıflandırılmıştır. Aynı verileri bir de 3DCNN mimarisi ile gerçekleştirmişlerdir. Bunun için 2B görüntü parçalarını (örnek olarak 40×15) 3B görüntü parçalarına ($40 \times 5 \times 3$) dönüştürmüşlerdir. 3DCNN mimarisi ile genel doğrulukları ISPRS veri seti için %80,6, DALES veri seti için %93,4, LASDU veri seti için %83,7, Bordeaux veri seti için %93,8, 3DOMCity veri seti için ise %88,3 olarak elde etmişlerdir. TONIC ismini verdikleri mimarilerin zaman ve bellek kullanımı olarak diğer yöntemlere göre üstün olduklarını belirtmişlerdir ancak nokta bulutlarını voksel tabanlı olarak alt örnekledikleri için yüksek oranda nokta kayıpları olmuştur. Örneğin DALES veri setinin sadece %5,6'sı ve ISPRS veri setinin %20,3'ü kadarını kullanmışlardır. Bu alt örnekleme zaman ve bellek açısından mimarilerine üstünlük sağlamıştır. Ancak geliştirilen model öznitelik tabanlı olduğu için ön işlem ve zeminden yükseklik özneteliği için ise SAM üretimini gerektirmektedir. Bundan dolayı da eğitim sürecinden kazanılan zamanın bir kısmının ön işleme aşamasında harcandığını söylenebilir. Ayrıca 3DCNN tabanlı modellerini DALES veri seti üzerinde PointNet++ kıyasladıklarında %2,3 daha düşük genel doğruluk elde etmişlerdir. Genelleştirilebilir kabiliyetini artırmak için farklı veri setlerindeki nokta yoğunluğunu nispeten eşitlemek amacıyla alt örnekleme yapmışlardır.

Ma vd. (2022), PointNet++ mimarisini ISPRS Vaihingen veri setinden 500×600 m'lik bir alanda yola ait noktaları sınıflandırmak için kullanmışlardır. Öznitelik olarak X, Y, Z koordinatları, yoğunluk bilgilerinin yanı sıra hem görüntüden hem de nokta bulutundan ürettikleri dokuz geometrik öznitelikleri ve bu alana ait görüntüden elde edilen R, G, B bilgilerini kullanmışlardır. Hem altı sınıf için hem de yol ve yol olmayan iki sınıflı olarak ayrı ayrı eğitim gerçekleştirmişlerdir. Ayrıca modeli, ön işlem olarak zemin sınıfını kural tabanlı bir yöntem ile filtreleyerek elde ettikleri zemin noktalarını geometrik öznitelikleri kullanarak ve kullanmayarak da iki sınıflı olarak eğitmişlerdir. Elde ettikleri maksimum doğruluk, bütünlük ve kalite metriklerini ön işlemleri çıkarılan zemin noktaları ile yol ve yol olmayan 2 sınıflı eğitilen model ile %85,5, %73 ve %64,9 olarak elde

etmişlerdir. Ayrıca son dönemde önerilen RandLA-Net ile de hem süre hem de doğruluk olarak PointNet++'ı karşılaştırmışlar ve süre olarak PointNet++'a benzer olduğunu hatta PointNet++ ile daha yüksek doğruluk elde ettiklerini belirtmişlerdir. Nokta yoğunluğunu aşamalı olarak azalttıklarında dar yolların yoğunluk azaldıkça bulunamadığını gözlemlemişlerdir. Objelerin sınıflandırma performansının nokta yoğunluğu ile yüksek ilişkisi olduğunu belirtmişlerdir.

Kumar vd. (2019), çalışmalarında yersel lazer tarama veri seti kullanmışlardır ancak mimarinin parametrelerine ve katmanlarına yönelik irdelemeler ve detaylar vermelerinden dolayı bu bölümde bu çalışmaya yer verilmiştir. Semantic3D yersel lazer tarama veri seti üzerinde yoğunluk (intensity), yüzey normal vektörü, özdeğerler, özvektörler (1, 5, 10, 50, 100 ve 200 cm) ve ek olarak mekânsal nokta dağılımı öz niteliklerini (50 cm) farklı yarıçaplarda çıkartarak bu öz niteliklerin sınıflandırmaya olan etkilerini uçtan uca olmayan bir tam bağlantılı (fully connected) sinir ağı mimarisi üzerinde eğiterek elde ettikleri sonuçları PointNet++ ile karşılaştırmışlardır. Sonuç olarak ağırlıklı ortalama IoU (mIoU) metriğini kullanarak yaptıkları sonuç değerlendirmede kendi mimarileri ile PointNet++ mimarisine göre %10 daha yüksek sonuç elde etmişlerdir. Yaptıkları çalışmada veri setini iki farklı şekilde hazırlamışlardır. Bunlardan ilkinde veriyi rastgele bölerek eğitim, test ve doğrulama verileri oluşturmuşlardır. İkinci deneylerinde ise mekânsal olarak ikiye ayırarak eğitim ve test veri setlerini hazırlamışlardır. İkinci deneylerinde araba, düşük bitki ve tarayıcı hataları sınıflarını dikkate almamışlardır. Çalışmada 2D komşuluktaki en yüksek ve en düşük noktaların yükseklik farkı (range), normalize edilmiş yükseklik, nokta yüksekliklerinin varyansı, merkez nokta yüksekliğinin yükseklik farkına oranı (rank), komşuluktaki nokta sayısının hacmine oranı (points/volume) gibi öz nitelikleri 50 cm arama yarıçapı ile OPALS yazılımı kullanarak hesaplamışlardır. Kullandıkları sinir ağı mimarisi uygulama bir ve iki için sırası ile 5 ve 3 gizli katmandan oluşmaktadır. Karşılaştırma için ise, PointNet++'ın çoklu ölçek gruplama (Multi Scale Grouping-MSG) katmanını kullandıklarını ve arama yarıçapı olarak 0,25, 0,5, 1 ve 2 m kullandıklarını belirtmişlerdir. Bunun yanı sıra PointNet++'ın girdi olarak kullandıkları 200.000 noktayı ilk MRG katmanında 8192 nokta ile örneklemişlerdir. Bu nedenden dolayı birçok bilgi kayıplarının meydana gelmiş olması dolayısı ile elde ettikleri doğruluğun da düşük olması kaçınılmaz olmuştur. En yüksek doğruluğu, tüm arama yarıçaplarından çıkardıkları öz nitelikler, yoğunluk, mekânsal nokta dağılımı bilgilerini kullandıkları modellerinde elde ettiklerini belirterek bunun bir sonucu olarak da öz nitelik sayısı arttıkça sınıflandırma doğruluğu da

artmaktadır sonucunu çıkarmışlardır. Deney 1 için elde ettikleri mIoU değeri kendi mimarileri için %94 iken PointNet++ ile %84'te kalmıştır. Ancak bu doğruluk farkının, eğitim veri seti içerisindeki düşük sayıda nokta içeren sınıflardan elde edilen daha düşük doğruluklardan kaynaklandığını belirtmişlerdir. PointNet++ ile nokta sayısı fazla olan sınıflarda kendi mimarileri ile neredeyse eşit doğrulukta sonuçlar elde etmişlerdir. Ayrıca hata matrisi değerleri karşılaştırıldığında ise iki mimari arasında neredeyse bir fark olmadığı çalışmalarında bulunan Tablo 9 ve 8'de görülmektedir. Deney 2 için ise kendi mimarileri ve PointNet++ mimarileri arasındaki mIoU farkı %6'dır.

Zhang ve Fan (2022), hava LiDAR nokta bulutlarında çatı yüzeyleri için hem semantik hem de instance (objeleri bireysel olarak ayırma) segmentasyonu aynı anda gerçekleştirebilen RoofNet ismini verdikleri bir derin öğrenme mimarisini tasarlamışlardır. RoofNet, PointNet++ mimarisine dayalı olarak öznitelik çıkardıktan sonra bu öznitelikleri her iki segmentasyon işlemi için iki ayrı koldan işlemektedir. Semantik koldan gelen yüksek ve düşük seviyeli (high and low level) öznitelikleri birleştirmek için öznitelik birleştirme (feature fusion) modülü kullanmışlardır. Son olarak joint (bütünleşik) öznitelik öğrenme modülü ile de her iki koldan gelen öznitelikleri eş zamanlı olarak işlemişlerdir. Modellerini, RoofNTNU veri seti üzerinde eğitmişlerdir ve semantik segmentasyon için genel doğruluk ve mIoU metriklerinin sırası ile %96,4 ve %86,7 olarak elde etmişlerdir. PointNet++ mimarisi ile karşılaştırdıklarında genel doğrulukta %1 iyileşme elde etmişlerdir.

Soilán vd. (2019b), AHN3 ve ISPRS benchmark veri setleri üzerinde kural tabanlı yöntemler ile nokta ve görüntü tabanlı derin sinir ağlarından oluşan farklı metotların zemin filtreleme işlemi üzerindeki doğruluklarını karşılaştırmışlardır. Nokta tabanlı derin sinir ağı mimarisi olarak PointNet'i kullanmışlardır. AHN3 ve ISPRS benchmark veri setleri için F ölçütlerini sırası ile 0,962 ve 0,887 olarak elde etmişlerdir. X, Y, Z koordinatlarına ek olarak AHN3 veri seti için normalize edilmiş koordinatlar, yoğunluk, dönüş sayısı ve range öznitelikleri kullanmışlardır. Sonuç olarak kural tabanlı yöntemlerin el yapımı (handcrafted) özniteliklere bağlı olmasından dolayı genelleştirilmelerinin derin öğrenme yöntemlerine göre güç olduğunu belirtmişlerdir. PointNet mimarisi için ise her ne kadar görüntü tabanlı yöntemin (SegNet) doğruluğuna yakın olsa da geliştirilmesi gerektiğini belirtmişlerdir.

Qin vd. (2021), PointNet++ mimarini kullanarak OpenGF veri seti üzerinde zemin filtreleme işlemi gerçekleştirmişlerdir. Üç farklı test veri seti üzerinde modeli test ederek

Test 1 veri seti için %97,58, gürültü noktalar içeren Test 2 veri seti için %86,40 ve gürültüsüz Test 2 verisi için de %87,38 genel doğruluk elde etmişlerdir.

2.5.1. Literatür Özeti

Hava LiDAR nokta bulutlarının 3B derin öğrenme ile semantik segmentasyon çalışmalarına dair literatür incelendiğinde bugüne kadar yapılan çalışmaların çoğu PointNet ve PointNet++ mimarilerinin büyük ölçekli nokta bulutlarına uyarlanması şeklinde gerçekleştirilmektedir. Ancak bu uyarlamalarda mimarinin hiper parametrelerine dair bilgilerin verildiği çalışma sayısı oldukça sınırlıdır. Bu anlamda literatürdeki çalışmalarda, kullanılan çerçeve boyutu, girdi nokta sayısı ve FPS yöntemi ile alt örneklenen merkez nokta sayısı gibi parametrelerin kullanımına yönelik belirsizlikler ya da eksiklikler bulunmaktadır.

Diğer bir belirsizlik ya da eksiklik ise, PointNet++ mimarisinin eğitim verisi için yığınlar oluştururken $1,5 \times 1,5$ m'lik alanlar içinde kalan noktalardan örnekler oluşturmasıdır. Bu boyut ile dış mekân nokta bulutlarında temsil edilen alanlar nokta yoğunluğu fark etmeksizin anlamlı olmamakta ve bu da mimarinin performansını olumsuz etkilemektedir. Özellikle çerçeve boyutu parametresine değinerek optimum değer araması yapılan sadece bir çalışma Nurunnabi vd. (2021) tarafından PointNet mimarisi için mevcutken, Soilán vd., (2019a) de yine PointNet mimarisi için kullandığı parametre değerini belirtmiştir. Literatürde, PointNet++ mimarisindeki çerçeve boyutu parametresinden bahseden ise sadece bir çalışma (Briechele vd., 2019) bulunmaktadır. Kada ve Kuramin (2021) ise PointNet++ mimarisi için ön tanımlı parametreleri kullandığını belirtmiştir. Mimarinin nokta bulutundan yığın (batch) toplayan bu stratejisi aslında sabit bir çerçeve boyutu ile çalışmaktadır. Çerçeve boyutu seçimi deneme yanılma ile yapılmakta ve nokta yoğunluğu değişkenlik gösteren nokta bulutu verileri için uygun olmamaktadır.

Diğer yandan PointNet++ mimarisi çoklu-ölçekli (multi scale) ve çoklu-çözünürlüklü (multi resolution) olmak üzere iki farklı katmana sahiptir. Literatürde bu katmanlardan bahsederek bunlardan hangisinin kullanıldığına yönelik bilgi verilen sınırlı sayıda çalışma (Winiwarter vd., 2019; Kumar vd., 2019) mevcuttur. Bu da PointNet++ mimarisinin fotogrametri ve uzaktan algılama camiası tarafından özellikle mimarinin doğruluğunu

direkt etkileyen geometrik hiper-parametrelerinin şu ana kadar açık bir şekilde ifade edilmediğini göstermektedir.

Ayrıca yapılan çalışmalar incelendiğinde pek çok çalışmada doğrulama verisinden bahsedilmediği, hatta bazı çalışmalarda validasyon doğruluğunun test doğruluğuymuş gibi verildiği ve validasyon verisi ayrılmış ise de bunun oranına ve nokta dağılımlarına yönelik bilgilerden bahsedilmediği gözlemlenmiştir.

Literatürde karşılaşılan en büyük boşluk/eksiklik ise, objelerin sınıflandırma performansının nokta yoğunluğu ile yüksek ilişkisinin ortaya koyulmuş olmasına rağmen, PointNet++ mimarisi için bu probleme yönelik bir iyileştirme çalışmasının olmamasıdır. Özdemir vd. (2021) tarafından yapılan çalışmada, derin öğrenme mimarisinin genelleştirme yeteneğini arttırmak için alt örnekleme ile veri setinden nokta azaltıldığı görülmüştür.

Literatürde, mimarinin parametrelerinin nokta bulutu özelliklerine göre ne kadar hassas olduğunu ortaya koyan çalışmalar mevcuttur. Ancak tüm bu parametrelerin deneme yanılma ile büyük veri setleri üzerinde tekrar tekrar çalıştırılmasının oldukça zahmetli ve zaman alıcı bir işlem olduğu da belirtilmiştir. Literatürde, mimarinin genelleştirme yeteneğini ölçmek için bir veri seti üzerinde eğitilen modelin başka bir veri seti üzerindeki test doğruluğunun düşük olmasının gerekçesi olarak iki veri arasındaki nokta yoğunluk farkı gösterilmiştir. Özellikle bir veri setinde çok sayıda nokta bulutu parçaları (tile) bulunduğu düşünüldüğünde hem veri kümesi içi hem de veri kümeleri arasında nokta yoğunluğu değişmektedir. Bu da nokta yoğunluğu bölgesel olarak değişiklik gösteren hava LiDAR verilerinin derin öğrenme ile semantik segmentasyonunda parametre seçimi işlemini zorlaştırmakta ve genelleştirilme yeteneğini önemli derecede kısıtlamaktadır. Çünkü tüm veri seti için aynı parametrelerin kullanılması modelin yeterince öğrenememesine ya da yanlış öğrenmesine yol açabilmektedir. Ayrıca derin öğrenme uygulamalarında çok sayıda veri gerektiğinden dolayı son zamanlarda farklı kaynaklardan üretilen verilerin birleştirilerek nokta yoğunluğu heterojen verilerin elde edilmesi bu sorunu daha da artırmaktadır. Bu durum ise hava LiDAR nokta bulutlarının semantik segmentasyon işleminde genelleştirme yeteneğini arttırmak için farklı verilerdeki nokta yoğunluğu değişimleri ile başa çıkabilecek bir yönteme ihtiyaç olduğunu göstermektedir.

Bu tez çalışmasında, çok fazla sayıda parametresi bulunan PointNet++ mimari için, çerçeve boyutu parametresini nokta yoğunluğuna adapte ederek hem otomatize etmeye yönelik hem de mimarinin genelleştirme kabiliyetini arttırmaya yönelik Adaptif 1 ve

Adaptif 2 olmak üzere iki yeni yaklaşım önerilmiştir. Önerilen Adaptif 1 ve Adaptif 2 yaklaşımları mimariye entegre edilerek çerçeve boyutu parametresinin deneme yanılma yöntemine olan ihtiyacı Adaptif 1 yaklaşımı ile giderilmiş Adaptif 2 yaklaşımı ile de azaltılmıştır. Bu yaklaşımlar sayesinde mimarinin daha fazla benzersiz nokta ile beslenmesi sağlandığı için sınıf dengesizliği problemi de orijinal PointNet++ mimarisine göre azaltılmıştır. Diğer bir parametre olarak komşuluk arama yarıçap parametresi için nokta bulutu verisine özel başlangıç değeri hesaplayan bir yaklaşım önerilerek, mimarinin arama yarıçap seçimi için deneme yanılma yöntemine olan ihtiyacı giderilmiştir. Mimarinin mevcut MRG ve MSG katmanları detaylıca açıklanarak bu iki katmanın birleştirilmesi ile yeni bir hibrit katman oluşturulmuş ve MRG katmanı ile kıyaslanmıştır.

Literatür, PointNet++ mimarisini farklı veri setine uyarlayarak kullanan çalışmalar ile PointNet++ tabanlı geliştirilen yaklaşımlar dikkate alınarak Tablo 1’de özetlenmiştir.

Tablo 1. Orijinal PointNet++ veya modifiye edilmiş PointNet++ algoritmasını kullanan araştırmacıların farklı veri setleri üzerinde elde ettikleri doğruluklar

Çalışma	Mimari	Kullanılan öznitelikler	Veri seti	Semantik Segmentasyon	Genel Doğruluk (%)	mIo U/IoU
Kada ve Kuramin (2021)	Modifiye Pointnet++ ve 2D silindirik komşuluk	3B koordinatlar, yerden yükseklik ve kaba etiketler	Leipzig, Germany	Tüm sınıflar (bina, zemin, bitki, araba vb.)	96,8	70,2
Li vd., (2021)	Modifiye Pointnet++	3B koordinatlar, geri dönüş sayısı, geri dönüş numarası ve yoğunluk	Viyana, Avusturya	Zemin, bitki, bina ve diğer sınıfı	97,13	-
Chen vd. (2021)	Modifiye PointNet++	?	ISPRS Vaihingen Benchmark veri seti	Tüm sınıflar	83,2	-
Winiwarter vd. (2019)	Modifiye Pointnet++ (MRG)	X, Y, Z, yoğunluk, geri dönüş numarası, geri dönüş sayısı	ISPRS Vaihingen Benchmark veri seti	Tüm sınıflar	80,6	-
Winiwarter vd., (2019)	Modifiye Pointnet++(MRG)	X, Y, Z, yoğunluk, geri dönüş numarası, geri dönüş sayısı	Vorarlberg (Buchboden), Avusturya	Zemin, bina, su, diğer ve alçak, orta, yüksek bitki	82,6	-
Zhang ve Fan, (2022)	RoofNet (PointNet++ tabanlı)	X, Y, Z	RoofNTNU, Trondheim, Norveç	Çatı yüzeyi	96,4	86,7
Zhang ve Fan, (2022)	PointNet++	X, Y, Z	RoofNTNU, Trondheim, Norveç	Çatı yüzeyi	95,4	84,0
Shin vd., (2022)	PointNet++	X, Y, Z dönüş sayısı	DALES	Tüm sınıflar	93,99	52,84
Shin vd. (2022)	PointNet++	X, Y, Z dönüş sayısı	ISPRS benchmark	Tüm sınıflar	65,57	19,16
Briechele vd., (2019)	PointNet++	X, Y, Z	Bavarian Forest National Park	Ağaç türü (kayın ve ladin)	85	-
Rim vd., (2021)	Uyarlanmış PointNet++	X, Y, Z	DALES	Tüm sınıflar	76,43	59,52
Varney vd., (2020)	PointNet++	X, Y, Z	DALES	Tüm sınıflar	95,7	68,3
Qin vd. (2021)	PointNet++	Belirtilmemiş	OpenGF	Zemin-zemin üstü	97,58	95,75

3. YÖNTEM VE VERİ SETİ

Bu çalışmanın metodolojisi, iç mekân nokta bulutları için tasarlanan PointNet++ mimarisinin hava LiDAR nokta bulutuna uyarlanması, bu uyarlama yapılırken değişken nokta yoğunluğu problemi ile baş edebilen yeni yaklaşımların mimariye eklenerek mimarinin çerçeve boyutu parametresinin otomatize edilmesi, komşuluk arama yarıçap seçiminde başlangıç değeri belirlenmesi ve hiper-parametre araştırması üzerine kurulmuştur. Mimarının performans ve geliştirilme yeteneğinin araştırılması ise üç farklı veri seti üzerinde gösterilmiştir.

Bu bölümde, öncelikli olarak Bölüm 3.1’de tez kapsamında kullanılan üç farklı veri setine ait sınıf ve detaylı istatistik bilgileri alt bölümler halinde verilmiştir. Bölüm 3.2’de PointNet++ mimarisinin temelini oluşturan PointNet mimarisi açıklanarak ardından Bölüm 3.3.’de PointNet++ mimarisi ve çalışma prensipleri anlatılmıştır. Bölüm 3.4’te nokta bulutunun alt örneklemesinde kullanılan yöntem tanıtılmıştır. Bölüm 3.5’te Mimarısının nokta örnekleme stratejisine (sampling) yönelik uygulanan değişiklik anlatılmıştır. Bölüm 3.6’da mimari için başlangıç komşuluk arama yarıçapı belirleme yöntemi açıklanmıştır. Bölüm 3.7’de mimari için önerilen nokta yoğunluğuna adaptif iki farklı yaklaşım tanıtılmıştır. Son olarak Bölüm 3.8’de çalışmada kullanılan doğruluk metrikleri tanıtılmıştır.

3.1. Veri Setlerinin Tanıtımı


Hava LiDAR nokta bulutlarının semantik segmentasyonu için farklı yoğunluklarda (density), nokta sayılarında ve sınıflardan oluşan üç veri seti seçilmiştir. Bunlardan ilki, benchmark veri seti olmasından dolayı seçilen nispeten hem düşük ve değişken yoğunluklu hem de az sayıda noktadan oluşan 3B ISPRS Vaihingen veri setidir. İkincisi ise hem yüksek hem de nispeten homojen nokta yoğunluğuna sahip ve çok sayıda noktadan oluşan büyük ölçekli DALES veri setidir. Bu iki veri de 9 sınıftan oluşmaktadır. Son olarak seçilen OpenGF ise, değişken nokta yoğunluğuna ve arazi örtüsüne sahip zemin filtreleme işi için oluşturulmuş bir veri setidir. Bu veri setlerinin seçilme nedenlerinden birincisi, PointNet++ mimarisinin farklı alanlarda, farklı arazi türleri üzerinde ve farklı geometrik

özelliklerdeki hava LiDAR nokta bulutlarına uygulanabilirliğini hem iki sınıflı hem de çoklu sınıflı problemlerin çözümlerinde göstermektedir. Diğer bir neden ise mimari için önerilen değişken nokta yoğunluğuna adaptif yaklaşımların özellikle OpenGF ve ISPRS veri setleri üzerinde test edilebilmelerine olanak sağlamalarıdır. Son olarak ise, yine literatürde sıklıkla kullanılmasından dolayı önerilen yaklaşımların nispeten homojen ve yoğun bir veri seti üzerinde de test edilmek istenmesidir. Aşağıda bölüm 3.1.1’de ISPRS Vaihingen Benchmark, bölüm 3.1.2’de DALES ve bölüm 3.1.3’te OPENGf veri setlerine ait özellikler detaylıca verilmektedir.

3.1.1. Veri Seti 1: ISPRS 3B Semantik Etiketleme Benchmark


ISPRS 3D Semantik Etiketleme Benchmark veri seti, nokta bulutlarının sınıflandırılması çalışmalarında oldukça yaygın bir şekilde kullanılan bir deney (benchmarking) veri setidir (Niemeyer vd., 2014). Veri, Leica ALS50 LiDAR tarayıcı ile elde edilmiştir. Veri seti x, y, z koordinatları, geri dönüş sayısı, geri dönüş numarası ve yoğunluk bilgilerini içermektedir. Nokta bulutunda, eğitim veri seti için metre kareye ortalama 7,3 nokta düşerken test veri setinde bu değer ortalama 4,8’dir. Eğitim veri setinde toplam 753.876 test veri seti ise 411.722 noktadan oluşmaktadır. Test veri seti ayrı iki alandan oluştuğu için nokta yoğunlukları da test 1 ve test 2 alanı için ortalama olarak sırası ile 6,85 ve 11,66 nkt/m²’dir. Elektrik hattı, düşük bitki, geçirimsiz yüzey, araba, çit (bitkili ve bitkisiz), çatı, bina cephesi ve çalı (shrub) sınıflarından oluşan veri seti toplamda yaklaşık olarak 1,2 milyon nokta içermektedir. Eğitim nokta bulutunun bulunduğu alan yaklaşık olarak 102.849 m² iken test veri setinin bulunduğu alan 85.933 m²’dir.

Nokta bulutuna ait özellikler ve sınıflar arası nokta dağılımları eğitim ve test veri setleri için aşağıda Şekil 7’de verilmiştir.




Şekil 7. ISPRS 3B semantik etiketleme benchmark veri setinin eğitim ve test verisi nokta sayıları ve her bir sınıf için nokta dağılım oranları

Veri seti az sayıda noktaya sahip olması ve mekânsal olarak da küçük bir alanı kapsamasından dolayı eğitim verisi, düzenli olarak gridlere bölünmüş ve her bir grid merkezinin en yakın 20000 noktası k-en yakın nokta seçme yöntemi ile seçilerek alt bölümlere ayrılması ile oluşturulmuştur. Test verisine ise herhangi bir işlem uygulanmamıştır. Şekil 8’de eğitim verisinin tamamı ve bu veriden kNN ile oluşturularak bu çalışmada kullanılan eğitim veri setine ait üç örnek alan gösterilmiştir.



Şekil 8. ISPRS 3B Vaihingen semantik benchmark eğitim verisi ve altta kNN ile oluşturulan eğitim veri seti için üç örnek

Eğitim verisinin %15'i validasyon verisi için ayrılmıştır. Eğitim verisinden validasyon verisi ayırma işlemi, modelin performansını değerlendirirken ve optimize ederken hem daha doğru ve güvenilir sonuçların elde edilebilmesi hem de modelin farklı sınıflardaki örnekleri daha etkili bir şekilde öğrenmesine ve genelleme yeteneğinin geliştirilmesine katkı sağlayabilmesi adına her sınıfın veri seti içerisindeki dağılımını dikkate alarak gerçekleştirilmiştir. Bu oranlar Şekil 9'da gösterilmektedir.




Şekil 9. Eğitim ve validasyon veri setindeki sınıf dağılımları

Herhangi bir parametre için optimum değer arama işlemleri validasyon verisi üzerinde gerçekleştirilmiş ve en iyi epok modeli kaydedilmiştir. Ardından, en iyi model ile ilgili parametrenin test doğruluklarına olan etkileri irdelenmiştir.

3.1.2. Veri Seti 2: DALES

Dayton Annotated LiDAR Earth Scan (DALES) veri seti, nokta bulutlarının semantik segmentasyonu için oluşturulan büyük ölçekli bir hava LiDAR nokta bulutudur. 500×500 metrelik 40 adet ayrık nokta bulutlarından oluşan veri setinde metre kareye yaklaşık olarak 50 nokta düşmektedir. Veri setinde x, y, z koordinat bilgilerinin yanı sıra geri dönüş sayısı, dönüş numarası öznitelikleri de mevcuttur. Veri setinde zemin, bitki, araba, kamyon, elektrik hattı, çit, direk ve bina olmak üzere sekiz obje kategorisi bulunmaktadır. Zemin sınıfı, geçirimsiz yüzey, çimen ve çıplak araziden oluşurken bitki sınıfı ise ağaç, çalı, bitkili çit ve çalılıktan oluşmaktadır. Araba sınıfı otomobil, minibüs ve arazi türü (SUV) araçlardan oluşurken kamyon sınıfı ise yarı kamyon, kapalı kasa kamyonlar ve karavanlardan oluşmaktadır. Elektrik hattı sınıfı ise iletim ve dağıtım hatlarını kapsamaktadır. Direk sınıfı, elektrik hattı direkleri, ışık direkleri ve elektrik iletim kulelerinden oluşmaktadır. Çit (fence) sınıfı ise konut çitleri (bitkisiz) ve otoyol bariyer noktalarını içermektedir. Son olarak bina sınıfı ise konut, yüksek binalar ve depolara ait noktalardan oluşmaktadır (Varney vd., 2020).

Veri seti 10 km² bir alanı kapsamakta ve toplamda 505 milyon noktadan oluşmaktadır. Bu noktalardan 368.667.682 adet nokta eğitim verisine aitken 136.643.891 nokta test veri setine aittir. Nokta yoğunluğu ise, eğitim ve test veri setleri için sırası ile 50,9 ve 50 nkt/m²'dir. Eğitim ve test verileri hakkında ayrı ayrı her bir sınıf için içerdiği nokta sayıları ve dağılım oranları Şekil 10'da verilmektedir.




Şekil 10. DALES veri setine ait eğitim ve test nokta bulutlarının sınıf bazındaki nokta sayıları ve dağılımları

Uygulamada eğitim ve test veri setlerinin hazırlanması aşamasında DALES veri seti 250×250 m boyutlarında ve 100×100 m boyutlarında alt bölümlere ayrılarak iki ayrı veri seti oluşturularak kullanılmıştır. Şekil 11’de DALES veri setine ait 500×500 m boyutlarındaki eğitim nokta bulutuna ait örnek verilmiştir.



Şekil 11. DALES eğitim verisi setine ait örnek bir nokta bulutu

DALES veri seti üzerinden gerçekleştirilen uygulamalarda optimum parametre arama işlemleri için eğitim verisinin %20'si validasyon veri seti olarak ayrılmıştır. Ardından, en yüksek doğruluk değerine göre kaydedilen en iyi modelin, test verisi üzerinde elde ettiği doğruluklar üzerinden irdelemeler gerçekleştirilmiştir. Validasyon veri seti sınıf oranları dikkate alınarak ayrılmıştır ve bu oranlar Şekil 12’de gösterilmiştir.




Şekil 12. DALES veri seti için validasyon ve eğitim veri setlerine ait dağılım oranları

3.1.3. Veri Seti 3: OpenGF

OPENGF veri seti, derin öğrenme ile zemin filtreleme uygulamalarındaki veri eksikliğini gidermek amacı ile (Qin vd., 2021) tarafından, herkes tarafından erişilebilen ALS nokta bulutlarından toplanarak oluşturulan bir zemin filtreleme veri setidir. Bu büyük ölçekli veri seti, 47,7 km² alanda 542,1 milyon noktadan oluşmaktadır. OpenGF, metropol, küçük şehir, köy ve dağlık alanların bulunduğu çeşitli arazi türlerinden oluşmaktadır. Metropol alanlar, yoğun ve büyük binalar/yapılar ile nispeten düzlük bir zemin içermektedir. Küçük şehirler, orta boyutlu binaların/yapıların bulunduğu yer yer düz yer yer engebeli bir zemin içeren alanları kapsamaktadır. Köy alanları, birkaç binadan oluşan doğal zemin yapısındaki alanları içermektedir. Son olarak dağlık alanlar ise, farklı eğim oranlarındaki zemin üzerinde seyrek veya yoğun bitkili bölgeleri kapsamaktadır. OpenGF veri seti, 500×500 m boyutlarındaki nokta bulutlarından oluşmaktadır. Eğitim verisi 151 adet nokta bulutu (tile) içerirken doğrulama verisi ise 9 nokta bulutundan (tile) oluşmaktadır. Ayrıca test verisi için ise Test 1 ve Test 2 olmak üzere iki adet veri seti bulunmaktadır. Test 1 verisi, köy, küçük şehir ve dağlık bölgelerden oluşan 6,6 km²'lik bir alandır. Test 2 verisi ise, büyük binalar, çeşitli boyutlardaki çatılar, arabalar, bitki, yüksek ve düşük gürültü noktalarını içeren 1.1 km²'lik şehir alanlarını kapsayan bir veri setidir (Qin vd., 2021). Test 2 veri setini gürültüsüz olarak test edebilmek amacı ile de Test 2_gürültüsüz isimli yeni bir veri seti de gürültü noktaları atılarak oluşturulmuştur. OpenGF nokta bulutunun nokta yoğunlukları, zemin ve zemin olmayan sınıfların içerdiği nokta sayıları gibi detaylı bilgiler aşağıda Tablo 2 ve Şekil 13'te verilmektedir.


Tablo 2. OpenGF veri setine ait bilgiler

Sınıf/ Veri Seti	Eğitim		Test		Doğrulama	
	Nokta Sayısı	Oranı (%)	Nokta Sayısı	Oranı (%)	Nokta Sayısı	Oranı (%)
Gürültü	853.457	0,19	10.520	0,02	33.282	0,14
Zemin Üstü	271.641.670	58,56	29.358.087	55,33	17.855.137	70,76
Zemin	191.357.904	41,25	23.694.839	44,65	7.343.455	29,1
Toplam	463.853.031		53.063.446		25.231.874	
Ort. Nokta Yoğunluğu	12,3 nkt/m ²		6,3 nkt/m ²		11,2 nkt/m ²	
Std ±	7,35		7,78		0,85	
Min	0,58		1,03		5,41	
Max	24,55		22,70		7,11	
Alanı (m ²)	37.744.695		7.736.452		2.249.377	



Şekil 13. Eğitim, test ve validasyon veri setleri için nokta sayıları ve dağılım oranları

Eğitim verisine ait rastgele seçilen altı adet nokta bulutu verisi Şekil 14’te gösterilmektedir.




Şekil 14. OpenGF veri setine ait farklı arazi türlerinden seçilmiş örnek eğitim nokta bulutları

3.2. PointNet Mimarisi

PointNet, girdi olarak direkt nokta bulutlarını işleyen ve çıktı olarak ya tüm girdi noktaları için bir sınıf etiketi atayan ya da girdi noktalarının her biri için ayrı ayrı segment/bölüm etiketi atayan bütünleşik bir mimaridir (Qi vd., 2017a). Her ne kadar nokta bulutları basit temsile sahip olsalar da böylesi bir mimarinin tasarımında temel olarak iki zorluk ile karşılaşilmektedir. Bunlardan ilki modelin, girdisi olan nokta bulutlarının permütasyonuna karşı değişmez olması gerektiğidir. İkincisi ise, rijit dönüşümlere (öteleme, dönme) karşı da değişmez olması gerektiğidir. Bu sorunlarından ilkinin çözümü

için PointNet, sinir ağları ile oluşturulan simetrik bir fonksiyon olarak tasarlanmıştır. Böylece, girdi noktalarının sırasına karşı değişmez olması sağlanmıştır. Her bir nokta birbirinden bağımsız olarak dönüştürülebildiği için, nokta bulutlarına kolaylıkla afin ya da rijit dönüşümler uygulanabilmektedir. Bu yüzden veriyi mimaride işlemeden önce veriye bağımlı bir mekânsal dönüştürme ağı (spatial transformer network) eklenerek ikinci sorunun çözümü sağlanarak sonuçlar iyileştirilmeye çalışılmıştır. PointNet mimarisi tüm noktalardan gelen bilgileri toplayan simetrik bir fonksiyon olan max pooling katmanı, yerel ve global bilgileri birleştirme yapısı (local and global information combination structure) ve girdi noktalarını ve nokta özniteliklerini hizalayan iki ortak hizalama (joint alignment) ağı olmak üzere üç temel modüle sahiptir (Qi vd., 2017a). PointNet mimarisinin sınıflandırma ve semantik segmentasyon ağları Şekil 15’te gösterilmektedir.



Şekil 15. PointNet mimarisi Qi vd. (2017a)’dan uyarlanmıştır

Sınıflandırma ağı; n adet noktayı girdi olarak alır, girdilere ve özniteliklere dönüşüm uygular ve sonrasında nokta özniteliklerini max pooling katmanı ile toplar. Sınıflandırma ağının çıkışı k adet sınıf için k adet etiket puanı tahmin eder. Sınıflandırma ağının bir uzantısı olan segmentasyon ağı; global ve lokal öznitelikleri birleştirir, çıktı olarak her bir nokta için skor üretir. “mlp” multi-layer perceptron’u (çok katmanlı algılayıcı), parantez içindeki sayılar katman boyutlarını, n nokta sayısını ve m ise semantik alt sınıfları temsil etmektedir. Tüm katmanlarda yığın normalizasyonu (batch normalization) (Ioffe ve Szegedy, 2015) işlemi ReLU kullanılarak yapılmıştır. Sınıflandırma mimarisinin son mlp’inde dropout katmanları kullanılmıştır.

Qi vd. (2017a) nokta bulutlarında özellikle bu üç modülün seçilmesinin nedenlerini şu şekilde açıklamışlardır. Öncelikle simetrik bir fonksiyon olan max pooling katmanının tercih edilmesinin nedeni, modeli girdi permütasyonuna karşı değişmez yapabilmektir. Sınıflandırma işlemi için global öznitelikler yeterli olurken, semantik segmentasyon işleminde hem yerel hem de global bilgilere ihtiyaç vardır. Bu bilgileri birleştirilmek için yerel ve global bilgileri birleştirme yapısı tasarlanarak semantik segmentasyon ağında her bir noktanın sınıf etiketini tahmin ederken sınıflandırma ağından elde edilen global ve yerel özniteliklerin birleştirilmesi sağlanmıştır. Nokta bulutunun semantik etiketleme işleminin rijit dönüşüm gibi belirli dönüşümlere karşı değişmez olması ise ortak hizalama (joint alignment) ağı ile sağlanmaktadır. İlk hizalama ağında, mini bir PointNet ağı ile afin dönüşüm matrisi (T-Net) tahmin ettirerek, bu dönüşümü direkt girdi nokta bulutu koordinatlarına uygulamışlardır. Bu mini ağ ise büyük modele benzemekte ve temel modüller olan öznitelik çıkarımı, max pooling ve tam bağlantı katmanlarına sahiptir. İkinci bir öznitelik hizalama (feature alignment) matrisi ise, aynı işlemi farklı girdi nokta bulutlarından elde edilen öznitelikleri hizalamak için mini bir PointNet ağı ile tahmin ettirilir. Ancak öznitelik uzayındaki dönüşüm matrisi (64×64), mekânsal dönüşüm matrisinden (3×3) daha büyük boyutta olacağından dolayı optimize edilmesi zordur. Bundan dolayı da softmax eğitim kaybına (softmax training loss) düzenleme terimi (regularization term) eklenerek dönüşüm matrisinin ortogonal matrise yakınsaması sağlanmıştır. Ortogonal dönüşüme yakınsama sayesinde girdi verisindeki bilgi kayıplarının önüne geçilmiştir. Ekledikleri düzenleme terimi sayesinde modelin performansının arttığını ve optimizasyonunun daha dengeli olduğunu belirtmişlerdir.

PointNet mimarisi, max pooling sayesinde nokta bulutunun iskeletine denk gelen kritik nokta kümesini (critical point sets) öğrenmektedir. Bu kritik nokta kümesi ile de global şekil öznitelikleri (global shape feature) belirlenmektedir. Yaptıkları sağlamlık testlerinde önemsiz olan bazı noktaların kaybolması modelin çıkarttığı ana iskelet nokta bulutunu dolayısı ile de bu kayıpların global şekil özniteliklerini etkilemediğini ortaya koymuşlardır.

Teorik ve deneysel değerlendirme sonuçlarına bakıldığında mimarinin bu sorunların başarılı bir şekilde üstesinden geldiği ortaya konulmuştur. Görsel sonuçlar incelendiğinde ise, PointNet mimarisi girdi nokta bulutunu yaklaşık olarak objenin iskeletine karşılık gelen seyrek bir anahtar noktalar (key points) dizisi olarak özetlemeyi öğrenmektedir. Teorik analizler sonucunda aykırı noktalar (outliers) veya veri kayıplarına (missing data)


karşı sağlam bir mimari elde ettiklerini belirtmişlerdir. Mimari obje sınıflandırma, bölüm segmentasyonu (part segmentation) ve semantik segmentasyon uygulamaları için kullanılabilmektedir.

3.3. PointNet++ Mimarisi

PointNet mimarisinin tasarımı gereği herhangi bir yerel bağlamı yakalayamaması mimarinin aynı zamanda ötelemeye karşı değişmezliğini de kısıtlamaktadır. PointNet'in öznitelik öğrenimi tamamen noktaların global öklit koordinatlarına dayalı olarak gerçekleştirilmektedir. Bu da sahnenin geometrisi sabit kalsa bile nokta bulutunun ötelenmesi farklı global özniteliklerin çıkartılmasına sebep olur. Bu sorun tek bir obje için nokta bulutunun merkeze normalize edilmesi ile çözülebilirken birden fazla objenin bulunduğu sahnelerin nasıl normalize edileceği konusu açık değildir. PointNet'in bu kısıtlamalarını aşabilmek adına metrik uzaydan örneklenen noktaları işleyen bir hiyerarşik derin öğrenme ağı olan PointNet++ Qi vd. (2017b) tarafından tasarlanmıştır. PointNet++ mimarisinin arkasındaki temel fikir, yerel bölgelerde tekrarlamalı olarak PointNet mimarisini uygulamaktır. Ancak mimarinin aşması gereken iki temel problem vardır. Bunlar, nokta bulutunun nasıl parçalara ayrıştırılacağı (yerel bölgeler) ve yerel öznitelik öğrenicisi (local feature learner) ile yerel özniteliklerin nasıl özetleneceği problemleridir. Bu iki problem de yerel öznitelik öğrenicilerin ağırlıkları paylaşabilmesi için yerel bölgelere ayrılan nokta bulutundan ortak yapıların üretilmesini gerektirmesinden dolayı birbirleri ile ilişkilidir (Qi vd., 2017b).

Yerel bölgeler, girdi nokta bulutunun tamamını eşit olarak kapsayacak şekilde seçtiği merkez noktalar etrafındaki yarıçaplar ile oluşturulan komşuluk alanlarını temsil etmektedir. Bu merkez noktalar girdi nokta bulutundan, FPS alt örnekleme yöntemi ile seçilir. Bu sayede nokta bulutu bindirmeli olarak alt parçalara ayrıştırılmaktadır. Merkez belirlendikten sonra yerel bölgeleri oluşturmak için kullanılacak komşuluk arama yarıçaplarının belirlenmesi nokta bulutunun örneklemeindeki düzensizlikler nedeni ile zorlayıcı bir işlemdir. CNN mimarilerinde küçük ölçekli kernel kullanımı bu yöntemlerin doğruluğunu artırırken nokta bulutlarında küçük arama yarıçaplarının kullanılması nokta örnekleme yetersizliğinin olduğu durumlarda PointNet tarafından dokuların yeterince iyi yakalanamamasına neden olabilecektir. PointNet++ ile sağlanan en önemli katkılardan birisi çok ölçekli komşuluklardan yararlanarak hem sağlamlığı hem de detay yakalama

yeteneğini artırmaktır (Qi vd., 2017b). PointNet++'ın semantik segmentasyon ve sınıflandırma işlemleri için hiyerarşik öznetelik öğrenme mimarisi Şekil 16'da gösterilmektedir.



Şekil 16. PointNet++ mimarisi Qi vd. (2017b)'den uyarlanmıştır

N , nokta sayısını; d , koordinat boyutunu; C , nokta öznetelik boyutunu; K , komşuluktaki nokta sayısını, N^1 ve N^2 , alt örneklenen nokta sayılarını; C^1 ve C^2 yeni öznetelik vektörlerini temsil etmektedir.

Şekil 16'dan görüldüğü üzere, PointNet++ mimarisinin hiyerarşik yapısı bir dizi dizi özetleme (set abstraction-SA) seviyelerinden oluşmaktadır. Her bir seviyede, bir nokta dizisi işlenerek bir sonraki seviyede bu nokta dizisi daha az sayıda nokta ile temsil edilecek şekilde özetlenir. SA seviyesinin örnekleme (sampling layer) katmanı, gruplama (grouping layer) katmanı ve PointNet katmanı olmak üzere üç önemli katmanı bulunmaktadır (Qi vd., 2017b).

Örnekleme katmanı, girdi nokta bulutundan $\{x_1, x_2, \dots, x_N\}$ bir dizi noktayı $\{x_{i1}, x_{i2}, \dots, x_{im}\}$ FPS yöntemi (bölüm 3.4) ile seçer. Bu seçilen noktalar komşuluk arama yarıçaplarının merkez noktalarıdır.

Gruplama katmanı, örnekleme katmanından elde edilen merkez noktaların etrafındaki komşu noktaları bularak yerel bölgeleri oluşturur. Gruplama katmanının girdileri $N \times (d+C)$ girdi nokta bulutu ile $N^1 \times d$ merkez noktaların koordinatlarıdır. Gruplama katmanının çıktısı ise $N^1 \times K \times (d+C)$ boyutlarındaki yerel bölgelerdir. K


mimarideki n_{sample} parametresidir ve her bir komşuluk yarıçapı içinden seçilen nokta sayısını ifade eder. Eğer yarıçap içerisinde yeteri kadar nokta yoksa bu noktalar örneklenecek nokta sayısına ulaşana kadar kopyalanmaktadır. Eğer örneklenecek nokta sayısından daha fazla nokta varsa öklid mesafesine göre sıralanan noktalardan merkez noktaya en yakın noktalar seçilir. Böylece gruplar arasında nokta sayıları değişkenlik göstermesine rağmen bir sonraki PointNet katmanı ile sabit boyutlu öznitelik vektörleri çıkartılacaktır.

PointNet katmanı, bir mini-PointNet kullanarak yerel bölge dokularını öznitelik vektörlerine encode eder (encoding). Girdi verisi N^1 yerel bölgelerdir ve bunların her birisinin $N^1 \times K \times (d+C)$ boyutlardadır. Çıktı veri boyutu ise $N^1 \times (d+C^1)$ boyutlarındadır. Yerel bölgelerdeki nokta koordinatları merkez nokta koordinatlarına ötelenir: $x_i^{(j)} = x_i^{(j)} - \hat{x}^{(j)}$ $i=1, 2, \dots, K$ ve $j = 1, 2, \dots, d$ iken $\hat{x}, \hat{x}^{(j)} = \frac{1}{K} \sum_{i=1}^K x_i^{(j)}$ denkleminde hesaplanan merkez nokta koordinatlarını temsil etmektedir. Yerel dokuları öğrenmek için temel yapı bloğu olarak dönüşüm ağırları (T-Net) olmayan PointNet kullanılmıştır (Denklem 4).

$$f(x_1, x_2, \dots, x_n) = \gamma \left(\text{MAX}_{i=1, \dots, n} \{h(x_i)\} \right) \quad (4)$$

Burada γ ve h çok katmanlı algılayıcı (multi layer perceptron networks) ağlardır. PointNet fonksiyonu f , tüm yerel bölgelerde ağırlıkları paylaşmaktadır (weight-sharing).

Nokta bulutları düzenli bir nokta yoğunluğuna sahip olmadığı için, nokta yoğunluğunun fazla olduğu bölgelerden çıkartılan öznitelikler seyrek nokta yoğunluğuna sahip bölgelere genelleştirilemeyebilir. Tam tersi durumda da düşük nokta yoğunluğuna sahip verilerden eğitilen modeller de yüksek yoğunluklu nokta bulutlarındaki ince detayları yakalayamaz. Qi vd. (2017b) mimarinin nokta yoğunluğu değişimlerine karşı dayanıklılığını artırabilmek adına yoğunluğa uyum sağlayan iki adet PointNet katmanları önermişlerdir. Bu katmanlar nokta yoğunluğu değiştiğinde farklı ölçeklerden gelen öznitelikleri birleştirmeyi öğrenirler. Bunlar çoklu ölçek gruplama (multi scale grouping-MSG) ve çoklu çözünürlük gruplama (multi resolution grouping-MRG) katmanlarıdır (Şekil 18).



Şekil 17. Yoğunluğa uyumlu gruplama katmanları Qi vd. (2017b)'den uyarlanmıştır a) MSG b) MRG

MSG katmanında, çok ölçekli dokuları yakalamanın basit ve etkili bir yolu olarak farklı ölçeklere sahip gruplama katmanları uygulanır ve ardından her bir ölçeğin özniteliklerini çıkarmak için PointNet uygulanır. Farklı ölçeklerden gelen öznitelikler birleştirilerek çok ölçekli öznitelikler oluşturulur. Sonrasında ağ, çok ölçekli öznitelikleri birleştirmek için optimize edilmiş bir strateji öğrenmek için eğitilir. Bu işlem için, her bir girdi nokta bulutundaki noktalardan bir kısmı rastgele bir olasılık değeri ($[0, p]$, $1 \geq p$) ile atılır (drop out). Test aşamasında tüm noktalar işlenmektedir. MSG katmanı, her merkez nokta için büyük ölçekli komşuluklarda yerel PointNet çalıştırdığından hesaplama yükü fazladır. Özellikle en düşük seviyedeki merkez nokta sayısı fazla olduğu için hesaplama süresi ciddi biçimde artmaktadır. Bu yüzden hesaplama süresinden sakınmak için ve aynı zamanda da nokta bulutu dağılım özelliklerine göre uyarlanabilir bir şekilde bilgi toplama yeteneğini koruyabilen MRG katmanı Qi vd. (2017b) tarafından önerilmiştir.

MRG katmanında, her seviyedeki bölgelerin öznitelikleri iki vektörün birleşimidir. Şekil 18'de (b) ile temsil edilen MRG katmanında, soldaki L_i seviyesinden üretilen öznitelik vektörü L_{i-1} seviyesinden gelen özniteliklerin SA katmanı kullanılarak özetlenmesi ile oluşturulurken L_{i-1} seviyesindeki vektör doğrudan ham noktalardan (görselde sağdaki vektör) tek bir PointNet ile elde edilen özniteliklerden oluşturulur. Bu yöntemde nokta yoğunluğunun düşük olduğu durumlarda L_{i-1} seviyesinden gelen özniteliklerin kalitesi L_i seviyesine göre daha düşük olacaktır. Böylesi bir durumda L_i seviyesinden gelen öznitelik vektörü daha yüksek ağırlığa sahip olacaktır. Yerel bölgelerdeki nokta yoğunluğunun fazla olması durumunda ise ilk vektör daha düşük seviyelerde yinelemeli olarak daha yüksek çözünürlüklerde inceleme yapma yeteneğine sahip olduğundan, ince detaylara ait daha fazla öznitelik bilgisi sağlar. MSG'ye göre

kıyaslandığında öznitelik çıkarım stratejisi sayesinde hesaplama süresi olarak daha verimlidir (Qi vd., 2017b).

Bu katmanların her ikisi de nokta bulutunu alt örnekleyerek işlediği için semantik segmentasyon sürecinde bu katmanlarda üretilen öznitelik vektörlerinin orijinal girdi nokta bulutuna taşınması gerekmektedir. Çünkü semantik segmentasyonda tüm orijinal noktaların etiketlenmesi için bu noktalara öznitelik atanması gerekmektedir. Bu işlem öznitelik yayma katmanı (feature propagation layer-FP) kullanılarak alt örneklenmiş nokta bulutundan elde edilen özniteliklerin orijinal nokta bulutuna mesafe tabanlı enterpole edilmesi ile gerçekleştirilir. Öznitelik yayma seviyesinde, $N_1 \times (d+C)$ noktalardan L_i seviyesinde öğrenilen nokta öznitelik vektörleri L_{i-1} seviyesindeki nokta bulutuna enterpole edilir. Enterpolasyon işlemi k en yakın komşuluk tabanlı ters mesafe ağırlıklı ortalama (inverse distance weighted average) ile gerçekleştirilir (Denklem 5).

$$f^{(j)}(x) = \frac{\sum_{i=1}^k w_i(x) f_i^{(j)}}{\sum_{i=1}^k w_i(x)} \quad (5)$$

Burada $w_i(x) = \frac{1}{d(x, x_i)^p}$, $j = 1, \dots, C$ olarak temsil edilmektedir (Qi vd., 2017b).

L_{i-1} seviyesindeki noktalara enterpole edilen öznitelikler bu seviyede üretilmiş olan öznitelik vektörleri ile birleştirilir (skip link). Ardından, birleştirilmiş öznitelikler birim PointNet'ten (unit PointNet) geçirilerek her bir noktanın özneliğinin güncellenmesi için birkaç paylaşımlı tam bağlantılı (fully connected) katmanları ve son katman harici ReLU aktivasyon fonksiyonu uygulanır. Bu işlem tüm öznitelikler orijinal nokta bulutuna ulaşmaya kadar tekrar edilir. Son katman hariç tüm katmanlarda batch normalizasyon uygulanmıştır (Qi vd., 2017b). Pooling fonksiyonu ise varsayılan olarak max operatörü kullanılmaktadır. Kayıp fonksiyonu için cross entropi yöntemini kullanılmaktadır. Mimari, kayıpları minimize etmek için Adam (Kingma ve Ba, 2014) optimizasyon yöntemini kullanmaktadır.

3.3.1. PointNet++ Mimarisinin Parametre Seçimi

Mimarinin çok sayıda ayarlanabilir (tuneable) parametresi bulunmaktadır. Bunlar geometrik ve ağ ile ilgili hiper-parametreler olmak üzere iki şekilde sınıflandırılabilir

(Winiwarter vd., 2019). Geometrik hiper-parametreler girdi nokta sayısı, çerçeve boyutu, komşuluk arama yarıçapı (radius), komşuluktan örneklenen nokta sayısı (nsample) ve alt örneklenen nokta sayısıdır. Ağ hiper-parametreleri ise SA ve FP katmanlarındaki MLP boyutları, epok sayısı, pooling katmanı, eksiltme oranı, öğrenme oranı, azaltma oranı, girdi verisi eksiltme oranı, yığın sayısı ile optimizasyon, loss ve aktivasyon fonksiyonlarıdır.

Tablo 3. PointNet++ mimarisinin semantik segmentasyon modeline ait varsayılan geometrik ve ağ hiper-parametreleri

Geometrik hiper-parametreler	Girdi nokta sayısı	8192
	Çerçeve boyutu (m)	1,5×1,5×3,0
	FPS ile alt örneklenen nokta sayıları	1024, 256, 64, 16
	Komşuluk arama yarıçapları (m)	0,1, 0,2, 0,4, 0,8
	Komşuluktaki nokta sayısı	32
Hiper-parametreler	Yığın sayısı (batch size)	16
	SA için MLP katman boyutları	[32, 32, 64], [64, 64, 128], [128, 128, 256], [256, 256, 512]
	FP için MLP katman boyutları	[256, 256], [256, 256], [256, 128], [128, 128, 128, 128, k]
	Öğrenme oranı (lr)	0,001
	Eksiltme oranı (drop out)	0,5
	Azaltma oranı (DR)	0,7
	Girdi eksiltme katsayısı	0,875
	Pooling fonksiyonu	max
	Optimizasyon fonksiyonu	Adam
	Aktivasyon fonksiyonu	ReLU
	Loss fonksiyonu	Sparse softmax cross entropy
	Epok sayısı	201

Mimari, aşırı uyma problemlerinden kaçınmak için Srivastava vd. (2014) tarafından önerilen eksiltme (drop out) yöntemini kullanmaktadır. Eğitim esnasında, nöronlardan bazılarının bir hiper parametre olan p olasılığı ile aktif tutarak çalışmaktadır. Bu hiper parametrenin varsayılan değeri mimaride 0,5 olarak tanımlanmıştır. Ancak test aşamasında eksiltme yöntemi uygulanmamaktadır. Adam optimizasyon yöntemi için gerekli parametreler öğrenme oranı, β_1 , β_2 ve epsilon parametreleridir. Bu parametrelerden β_1 0,9, β_2 0,999 ve epsilon $1e^{-8}$ olarak kullanılmıştır. Öğrenme oranını kontrol

edebilmek için mimari eksponansiyel azalma yöntemini (exponential decay) kullanmaktadır. Mimari’de, başlangıçta 0,001 olarak belirlenen öğrenme oranı (LR) değeri belirli epoklarda eksponansiyel azalma yöntemi kullanılarak azaltılmış ve elde edilen yeni öğrenme oranı (decayed learning rate- LR_{DC}) değeri ile eğitim işlemine devam edilmiştir (Denklem 6).

$$LR_{DC} = LR \times DR^{GL_{stp}/DC_{stp}} \quad (6)$$

Denklem 3’te, mimarinin eksponansiyel azaltma yöntemi uygularken kullandığı hiper parametreler azalma oranı (decay rate- DR) ve azalma adımıdır (decay step- DC_{stp}). Eğitimin ne kadar ilerlediği GL_{stp} parametresi ile takip edilir. DC_{stp} ve DRparametrelerinin varsayılan değerleri semantik segmentasyon modeli için sırası ile 200000 ve 0,7’dir. Ayrıca mimaride, eğitim verisinden rastgele seçilen noktaları eksiltme (drop out) regularizasyonu da bulunmaktadır. Bu regularizasyon, her bir batch için 0-1 aralığından rastgele seçilen bir değer 0,875 katsayısı ile çarpımından elde edilen orana karşılık gelen sayıdaki noktanın yığından atılması (noktalar silinmemekte sadece seçilen noktaların koordinatları kümedeki ilk noktanın koordinatlarına eşitlenir) ile gerçekleştirilir.

3.4. FPS Yöntemi ile Nokta Bulutunun Alt Örneklenmesi

Geleneksel görüntü işleme alanında uzun yıllardan beri kullanılmakta olan En Uzak Nokta Örnekleme (Farthest Point Sampling-FPS) yöntemi, son yıllarda nokta bulutlarında derin öğrenme alanında yaşanan gelişmeler ile PointNet++ mimarisinin FPS yöntemini kullanarak nokta bulutlarından önemli detayları kaybetmeden başarılı bir şekilde alt örnekleme yapabilmesi sayesinde tekrardan popülerlik kazanmış bir yöntemdir. FPS yöntemi, her iterasyonda o ana kadar görmüş olduğu noktalara en uzak noktayı örnekleyen bir algoritmadır. Algoritma başlangıçta, ilk noktayı rastgele örnekledikten sonra, diğer tüm noktaların örneklenen bu noktaya olan Öklid mesafelerini hesaplar ve mesafeyi bir dizide saklar. Daha sonra, en büyük mesafeye sahip olan nokta, örneklenecek bir sonraki nokta olarak seçilir ve hesaplanan mevcut mesafe eski mesafeden küçükse mesafe dizisi güncellenir (Li vd., 2022).

FPS yönteminin iki önemli özelliği bulunmaktadır. Bunlardan birincisi yeni örneklenen noktadan uzak olan noktaların örneklenmek için yüksek önceliğe sahip olmasıyken ikincisi ise, her iterasyonda yalnızca bir nokta örnekleyerek bu noktaya en uzak noktayı belirlemek üzere mesafe hesaplamalarının yapılmasıdır. Bahsedilen ilk özellik sayesinde FPS, belirgin nokta özelliklerini yakalayabilmekte ve nokta yoğunluğu ne olursa olsun nokta bulutlarını tutarlı bir şekilde örnekleyebilmekteyken, her bir nokta için tek tek mesafe hesaplaması nedeniyle de işlem süresi uzundur ve büyük ölçekli nokta bulutlarına uygulanması kolay değildir (Li vd., 2022). FPS yönteminin örnekleme algoritmasına ait pseudo kod Tablo 4'te verilmektedir.


Tablo 4. FPS pseudo kod Li vd. (2022)'den uyarlanmıştır

```

Girdi: (N, D) Boyutlu Nokta Bulutu P; N nokta sayısı, D (D=3) boyut, n point örneklenecek nokta adedi.
# Mesafe Hesabı Başlangıç Değerleri
Mesafeler[N] = {1e10};
Örneklenen[n point] = {-1};
# Alt Örneklemeyi Başlat
örnek_idx = randint(0, N);
Örneklenen[0] = örnek_idx;
for i ← 1 to n point - 1
    # Mesafeleri Güncelle
    for j ← 0 to N-1
        mesafe = euclidean_dist (P[j, :], P[örnek_idx, :], D);
        if mesafe ≤ Mesafeler [j] then
            Mesafeler [j] = mesafe;
        endif
    endfor
    # Sıradaki Örneğe Geç
    örnek_idx = argmax(Mesafeler);
    Örneklenen [i] = örnek_idx;
endfor

```

FPS yönteminin, büyük ölçekli nokta bulutlarında kullanılmasına örnek olarak DALES veri setinden seçilen 30×30 metrelik örnek bir alan üzerinden FPS yönteminin farklı örneklem sayıları için PointNet++ mimarisinin çalışma prensibinden esinlenerek aşağıda Şekil 18'de gösterilmiştir.



Şekil 18. PointNet++ katmanlarında rastgele ve FPS yöntemi ile alt örneklene nokta bulutları

Çerçeve boyutu içinde kalan nokta sayısı, önce rastgele alt örneklene nokta sayısı (number of points) elde edilmektedir. Şekil 18 üzerinden anlatılacak olursa DALES veri setinden 30×30 m çerçeve boyutları içinde kalan nokta sayısı 42.250 noktayken rastgele örnekleme ile girdi nokta sayısı olan 16.384 nokta seçilir. Ardından mimarinin her bir katmanında bu değerler $\frac{1}{4}$ oranında FPS yöntemi ile alt örneklene nokta komşu noktalarından öznelilikler çıkartılır. Şekil 18’de bu duruma iki örnek verilmiştir. Örneklerden ilki, seçilen 16.384 noktanın, MRG katmanlarındaki birinci seviyede FPS ile 2048 noktaya ardından ikinci seviyede FPS ile $\frac{1}{4}$ oranında azaltılarak 512 noktaya alt örneklene nokta göstermektedir. İkinci örnek ise varsayılan değerler üzerinden MRG katmanlarındaki birinci seviyede FPS ile 1024 noktaya ardından ikinci seviyede FPS ile yine $\frac{1}{4}$ oranında azaltılarak 256 noktaya alt örneklene nokta göstermektedir. MRG katmanlarında alt örnekleme son seviyeye kadar $\frac{1}{4}$ oranında azaltılarak boyut indirgeme işlemi gerçekleştirilir. Bu değerler ilk örnek için 128 ve 32 olurken ikinci örnek için 64 ve 16 olmaktadır. Ancak bu nokta bulutları çok seyrek olmalarından dolayı görselde yer verilmemiştir. Npoints parametresi, sahneyi temsil eden noktalardır. Qi vd. (2017b), mimaride neden FPS yöntemini kullandıklarını, yapılan deneyler sonucunda sahneyi en iyi temsil eden ve sahneye en homojen olarak yayılım gösteren noktaların bu yöntem ile elde edilmesi olduğunu belirtmişlerdir. FPS yöntemi ile alt örnekleme yapmak, alt örneklene noktaların sahneye homojen yayılım göstermeleri, sahnedeki farklı sınıflara ait noktalardan

örnekler toplanabilmesi ve kritik noktaların tespit edilebilmesi sayesinde sınıf doğrulukları üzerinde oldukça etkili bir işlemdir.

3.5. PointNet++ Mimarisinin Nokta Örnekleme Stratejisi

PointNet++ mimarisi, sabit bir çerçeve içerisinde kalan noktalardan örneklenen girdi nokta sayısı (number of points) kadar noktayı, çerçeve içerisinde yeterli nokta olup olmadığına bakmaksızın rastgele bir şekilde ve noktaları birden çok kez kopyalayarak oluşturmaktadır. İç mekân nokta bulutları için tasarlanan mimarinin semantik segmentasyon uygulaması Qi vd. (2017b) tarafından ScanNet veri seti üzerinde uygulanmıştır. ScanNet veri seti incelendiğinde nokta yoğunluğunun bazı eğitim veri setlerinde yaklaşık 5000 nkt/m² ya da 8000 nkt/m² olduğu gözlemlenmiştir. Yani çok yüksek nokta yoğunluğuna sahip bir veri seti için uygulanabilir olan bu yaklaşım, zaten düşük nokta sayısına sahip hava LiDAR nokta bulutu verilerinin daha da az benzersiz nokta ile eğitilmesine neden olacaktır. Mimarinin bu stratejisi daha fazla benzersiz nokta görebilmesini sağlamak amacı ile değiştirilmiştir. Yeni stratejide, çerçeve içerisinde girdi nokta sayısı kadar nokta olması durumunda kopyalama işlemi gerçekleştirilmezken, girdi nokta sayısından az olması durumunda yeteri noktayı sağlayacak kadar nokta kopyalama işlemi yapılmaktadır. Bu kapsamda değiştirilen nokta kopyalama stratejisine ait pseudo kod Tablo 5’te verilmiştir.

Tablo 5. Değiştirilen nokta kopyalama stratejisine ait pseudo kod

If InputPts $\geq$ npoints:
New_pts = Rastgele_Nokta_Örnekle (InputPts, npoints, Kopyalama = Hayır)
Else:
Orj_pts = Rastgele_Nokta_Örnekle (InputPts, len(InputPts), Kopyalama = Hayır)
Copy_pts = Rastgele_Nokta_Örnekle (InputPts, npoints - len(InputPts), Kopyalama = Evet)
New_pts = Birleştir (Orj_pts, Copy_pts)
Endif

3.6. Optimum Komşuluk Arama Yarıçap Seçimi

PointNet++ mimarisi, düzensiz yapıdaki nokta bulutlarında derin öğrenme gerçekleştirebilmek amacı ile önceden tanımlanmış bir dizi yarıçap değerini kullanarak girdi nokta bulutu üzerinde yerel komşuluklar oluşturur ve bu komşulukta kalan noktalar

kullanılarak üretilen öznitelik vektörleri daha sonra sınıflandırma aşamasında kullanılır. PointNet++'ın nokta bulutlarından benzersiz özniteliklerin öğrenilmesinde, mimarinin SA katmanında kullanılan komşuluk yarıçapları büyük öneme sahiptir. İç mekân nokta bulutları için tasarlanan PointNet++ mimarisi, 1,5×1,5 m çerçeveler içinden örneklenen nokta bulutlarında 0,1, 0,2, 0,4 ve 0,8 m boyutlarındaki arama yarıçaplarını kullanmaktadır. Ancak söz konusu hava LiDAR nokta bulutları olduğunda mimarinin ön tanımlı yarıçap değerlerinin kullanılamayacağı açıktır. Bu nedenle, nokta bulutlarında en uygun komşuluk boyutu seçimi yöntemleri incelenerek mimari için uygun bir başlangıç arama yarıçapı belirlenmeye çalışılmıştır.

Bu bağlamda, geçtiğimiz yıllarda literatürde pek çok çalışmanın öznitelik çıkarımı uygulamalarında kullanılan Shannon entropiden uyarlanan Eigenentropy en uygun komşuluk boyutu seçimi yöntemi (Weinmann, 2016; Weinmann vd., 2015a) baz alınarak ISPRS Vaihingen ve DALES veri setleri üzerinde en uygun komşuluk yarıçapı belirleme işlemi gerçekleştirilmiştir. Eigenentropy temelli komşuluk seçimi, 3B nokta bulutlarından geometrik öznitelikler çıkarmak için uygun komşuluk seçimi için kullanılan bir yöntemdir. Bu yöntem, merkez noktası etrafındaki yerel bir komşuluk içindeki tüm noktaların 3B koordinatlarından 3B yapı tensörünü ve özdeğerlerini hesaplayarak öznitelik çıkarmak için uygun bir ölçek belirler. Bu yöntemin kullanılması ile belirlenen komşuluk boyutu ile daha ayırt edici, gürültüye ve veri değişkenliklerine karşı daha sağlam özniteliklerin çıkartılabileceği belirtilmiştir (Weinmann, 2016).

3B yapı tensörü (S_t), bir nokta bulutunun yerel geometrisini açıklayan bir matristir (Denklem 7 ve 8). Merkez olarak seçilen bir X noktasının komşuluğundaki k adet noktanın (X_i $i \in \{1, 2, \dots, k\}$) 3B koordinatları kullanılarak hesaplanır. Yapı tensörünün özdeğerleri, nokta bulutunun temel eksenleri boyunca yerel eğriliklerine karşılık gelir. Daha açık bir şekilde ifade etmek gerekir ise, elde edilen 3B yapı tensörü matrisinin özdeğerleri, nokta bulutunun seçilen merkez noktası etrafındaki yerel geometrisinin ana eksenlerine karşılık gelir. Özdeğerler, nokta bulutunun merkez noktasındaki eğriliklerin büyüklüğünü ve yönünü ifade eder. Yani, özdeğerler büyük olması, yerel komşuluktaki eğriliklerin daha büyük ve belirgin olduğunu ifade ederken, özdeğerlerin küçük olması, yerel komşuluktaki eğriliklerin daha küçük olduğunu ifade eder (Weinmann, 2015a).


$$S_t = \frac{1}{k+1} \sum_{i=0}^k (X_i - \bar{X}) (X_i - \bar{X})^T \quad (7)$$

$$\bar{X} = \frac{1}{k+1} \sum_{i=0}^k X_i \quad (8)$$

Eigenentropy, 3B yapı tensöründen elde edilen özdeğerlerin dağılımını ölçen bir skaler değerdir ve düşük bir E_λ değeri daha izotropik (tüm eksenlerde benzer özdeğerler) bir dağılımı, yüksek bir eigenentropy ise daha anizotropik (bir veya daha fazla eksenin özniteliklerinin benzersiz olması) bir dağılımı gösterir (Weinmann vd., 2015a). Eigenentropy ile en uygun komşuluk seçiminde önceden tanımlanan komşuluk boyutları için 3B yapı tensöründen elde edilen öznitelikler kullanılır. 3B yapı tensörü ile bir yerel komşuluğu tanımlama için kullanılabilecek λ_1 , λ_2 ve λ_3 olmak üzere üç özdeğer ($\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$) hesaplanır. Hesaplanan özdeğerler normalize edilerek $e_i = \lambda_i / \Sigma_\lambda$ ($i \in \{1,2,3\}$) toplamı bir'e eşit olan bir vektör (e_1, e_2, e_3) oluşturulur (Weinmann vd., 2015a; 2015b). Daha sonra bu özdeğer vektörü kullanılarak Weinmann vd. (2015a)'nın Shannon entropi formülünden uyarladıkları E_λ ile aşağıdaki şekilde hesaplanır (Denklem 9). Düşük bir E_λ değeri, yerel geometrinin nispeten homojen olduğunu ve özniteliklerin daha küçük bir ölçekte çıkarılabileceğini gösterirken, yüksek bir E_λ değeri daha karmaşık bir yerel geometriyi gösterir ve özelliklerin daha büyük bir ölçekte çıkarılması gerektiğini göstermektedir. Bu sayede belirli bir komşuluk arama yarıçapı için bu komşuluğun düzenliliği araştırılır. Bu işlem, önceden belirlenen tüm arama yarıçapları için ve nokta bulutunda bulunan tüm noktalar için gerçekleştirilir (Weinmann, 2016).


$$E_\lambda = - \sum_{i=1}^3 e_i \ln(e_i) \quad (9)$$

Çalışmada ISPRS 3B Semantik Etiketleme ve DALES veri setlerinde 0,5 m arama yarı çapından başlanarak 10 m yarıçapına kadar 0,5 metrelik adımlar ile belirlenen komşuluk arama yarıçapları (r_i ; $i = \{0.5, 1, 1.5, 2, \dots, 9.5, 10\}$) kullanılmıştır. ISPRS veri setinin tümü ve DALES veri setinden seçilen örnek nokta bulutları üzerinde KD-tree (Bentley, 1975) yöntemi ile bir arama ağacı yapısı oluşturularak her bir komşuluk boyutu için, nokta bulutlarındaki tüm noktaların belirlenen yarıçap içinde kalan noktaları tespit edilerek E_λ değerleri hesaplanmıştır. Tüm noktalar için komşuluk yarıçaplarında hesaplanan E_λ değerlerinin minimum olduğu komşuluk yarıçapı, $r_{opt} = \arg \min (E_\lambda(r))$ fonksiyonu ile belirlenmiştir (Weinmann, 2016). Şekil 19 ve Şekil 20'de sırası ile ISPRS ve DALES veri setleri için hesaplanan en uygun komşuluk yarıçapları verilmiştir.



Şekil 19. ISPRS veri setinde farklı arama yarıçapları için E_λ sonuçları

ISPRS veri seti için elde edilen sonuçlar incelendiğinde; en uygun komşuluk yarıçapının, en yüksek sayıda minimum eigenentropy değerine sahip olan 1 m olduğu belirlenmiştir. Bu sonuç, 3B nokta bulutunun geometrik özelliklerini en iyi şekilde yakalayacak ve en doğru öznetelik çıkarımını sağlayacak yarıçap boyutunun 1 m olduğunu göstermektedir.



Şekil 20. DALES veri setinde farklı arama yarıçapları için E_λ sonuçları

DALES veri seti için elde edilen sonuçlar incelendiğinde ISPRS veri setine benzer şekilde en uygun komşuluk yarıçapının 1 metre olduğu belirlenmiştir. DALES veri setinin, ISPRS veri setine oranla daha yüksek nokta yoğunluğuna sahip olması nedeni ile hesaplanan E_λ değerleri grafiğin 0,5-1,5 m yarıçapları arasına yığılmıştır. 0,5 m yarıçap için yaklaşık olarak 800.000 adet nokta minimum E_λ değerini sağlarken, yaklaşık olarak 1,4 milyon noktada 1 m yarıçap için minimum E_λ değeri elde edilmiştir.

Eigenentropy tabanlı en uygun komşuluk boyutu seçimi yöntemi doğası gereği düzensizliğin en düşük olduğu komşuluk boyutunu belirleyebilmektedir (Weinmann, 2016; Weinmann vd., 2015b). Bundan dolayı da çok boyutlu komşuluk seçimi yapmak için uygun bir yöntem olmayacaktır. Ancak yine de nokta bulutlarından öznitelik çıkartmak için iyi bir başlangıç noktası sağlayabileceği düşünülmüştür. Bu bölümde her iki veri seti için de elde edilen en uygun komşuluk yarıçapları, Qi vd. (2017b)'nin PointNet++ mimarisinde uyguladığı şekilde, her bir katman için iki kat artırılarak PointNet++ mimarisinin SA katman yarıçapları uygulamalarda 1, 2, 4 ve 8 m olarak seçilmiştir.

3.7. Adaptif Çerçeve Boyutu Seçimi

PointNet ve PointNet++ tabanlı mimariler, sabit bir çerçeve içinden bir dizi noktaları alır ve bu noktaları girdi noktaları olarak işler. Ancak çerçeve boyutu eğer küçük seçilir ise sahne hakkında yeteri bilgi elde edilemeyeceğinden dolayı noktalar doğru bir şekilde tanımlanamayabilir. Çerçeve boyutunun büyük seçilmesi durumunda ise küçük objeleri belirleyebilmek için her bir objeden yeteri sayıda nokta içermemesine neden olabilmektedir (Varney vd., 2020). Bu yüzden çerçeve boyutu modelin doğruluğunu etkileyen önemli bir parametre iken seçimi ise bu yöntem için sınırlayıcı bir faktördür. En uygun çerçeve boyutu, nokta yoğunluğuna ve kapsadığı alana bağlı ilgili nokta bulutuna özel optimum değerinin bulunması çok fazla deneme yanılma gerektirmektedir. Özellikle nokta yoğunluğu değişken, düzensiz veri setleri üzerinde sabit bir çerçeve boyutu ile alt örneklenen veriden çıkartılan örneklerin (sample) içerdiği nokta sayısı değişkenlik göstermektedir. Bu örnekler mimari için gereken girdi nokta sayısına (number of points=8192) ulaşabilmek için ya rastgele kopyalanarak çoğaltılır ya da rastgele alt örneklenerek azaltılır. Bu da mimarinin öğrendiği özniteliklerin geneli iyi temsil edememesine neden olarak mimarinin genelleştirebilir olmasını olumsuz etkilemektedir. Bu tez kapsamında, böylesi düzensiz nokta yoğunluğuna sahip nokta bulutlarından

örnekler (sample) oluştururken yoğunluk değişimi problemi ile başa çıkabilen ve mimarinin genelleştirme yeteneğini artırabilecek nokta yoğunluğuna bağlı Adaptif 1 ve Adaptif 2 olmak üzere iki adet yaklaşım önerilmiştir. Adaptif çerçeve boyutu yaklaşımları ile aynı zamanda çerçeve içerisine düşen nokta sayısı da daha sıkı bir şekilde kontrol edileceğinden dolayı mimarinin çok daha fazla benzersiz nokta ile eğitilmesine de olanak sağlanacaktır.

3.7.1. Adaptif Çerçeve Boyutu Seçiminde 1. Yaklaşım


İlk önerilen yaklaşımda adaptif çerçeve boyutu, mimari için gereken girdi nokta sayısı ile ilgili sahnenin nokta yoğunluğuna bağlı olarak hesaplanmıştır. Mimariye entegre edilen yoğunluk ve çerçeve boyutunun hesaplandığı fonksiyonlar ile aşağıdaki Denklem 10 ve Denklem 11 ile hesaplanmıştır.

$$P_d = T_{pts}/T_a \quad (10)$$

$$B_{sz} = \sqrt[2]{n_{pts}/P_d} \quad (11)$$

Burada P_d , nokta yoğunluğunu; T_{pts} , sahnedeki nokta sayısını; T_a , sahne alanını; B_{sz} , çerçeve boyutunu ve n_{pts} 'de mimarinin girdi nokta sayısını temsil etmektedir.

Bir örnek üzerinden açıklamak gerekirse; mimarinin girdi nokta bulutlarından (tile) bir tanesinin alanı (T_a) 84279 m^2 ve nokta sayısı (T_{pts}) 753876 ve n_{pts} parametresi de 8192 olsun. Bu durumda girdi nokta bulutunun yoğunluğu P_d , $8,94 \text{ nokta/m}^2$ ve en uygun çerçeve boyutu B_{sz} , 31 m olarak hesaplanacaktır (Şekil 21).



Şekil 21. Adaptif 1 yaklaşımında çerçeve içine düşen nokta sayılarındaki değişim

Bu yöntem mimarinin çerçeve boyutu parametresini tamamen otomatize etmesi açısından oldukça basit ve uygulanabilir bir yöntemdir. Ancak, çerçeve boyutunun nokta yoğunluğunun düşük olması durumunda aşırı büyümesi veya nokta yoğunluğunun yüksek olması durumunda aşırı küçülmesi sonucunda mekânsal bağlamın kaybolması problemine

neden olabilecektir. Nokta yoğunluğundaki aşırı değişimlere bağlı olarak Adaptif 1 yaklaşımında, çerçeve boyutundaki değişimlerin mekânsal bağlamı bozmaması adına girdi yığınlarındaki (batch) nokta bulutları normalize edilerek işlenmiştir.

3.7.2. Adaptif Çerçeve Boyutu Seçiminde 2. Yaklaşım


Çerçeve boyutunun, mimariye giren her veri setinden hesaplanan nokta yoğunluklarını dikkate alarak belirlenmesi, veri setinin aşırı yüksek ya da düşük yoğunluğa sahip olması durumlarında çerçeve boyutunun ani değişmesine ve mimarinin mekânsal bağlamı tutarlı bir şekilde yakalayamamasına neden olabilecektir. Bu sorunun çözümü için önerilen ikinci yaklaşımda, ilk yaklaşımdan farklı olarak bir başlangıç çerçeve boyutu kullanılmış ve bu çerçeve boyutu nokta yoğunluğuna uyarlanabilir hale getirilmiştir. Adaptif 2 yaklaşımında başlangıç çerçeve boyutu, Olasılık Yoğunluk Fonksiyonu (Probability Density Function-PDF) ile üretilen bir normal dağılımın kullanılması ile hesaplanan bir ölçek faktörünün kullanılması ile adaptif hale getirilmiştir.

En basit ifadesiyle, olasılık yoğunluk fonksiyonu, sürekli bir rasgele değişkenin aksine ayrık bir rasgele değişken için bir olasılık dağılımını tanımlayan istatistiksel bir ifadedir (Denklem 12). Normal dağılım, iyi bilinen çan eğrisi şeklini oluşturan yaygın bir PDF örneğidir. Olasılık yoğunluk fonksiyonu, olasılık teorisinde, örneklem uzayındaki herhangi bir örneğin değeri, rastgele değişkenin değerinin o örneğe eşit olacağına dair rölatif bir olasılık sağlayan bir fonksiyonu olarak tanımlanır. Daha net ifade etmek gerekirse, PDF, rasgele değişkenin belirli bir değer aralığına düşme olasılığını belirtmek için kullanılır. Bu olasılık, bu değişkenin PDF'sinin o aralıktaki integrali ile verilir. Aşağıdaki denklemde $f(x)$ ile temsil edilen PDF fonksiyonunun değişkenleri σ standart sapma, μ medyan ve x data'dan oluşmaktadır (Bertsekas ve Tsitsiklis, 2008).

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (12)$$

Öncelikle, PDF yöntemi ile doğru bir ölçekleme oluşturabilmek için eğitim sürecinde herhangi bir yığında (batch) bulunabilecek minimum (2^8) ve maksimum nokta sayıları (2^{18}) belirlenmiştir. Bu değerler doğrudan ölçeklemede kullanılamayacağı için 0 ile 1 arasında normalize edilmiştir. Bu dağılımın medyan (μ) değeri 0 olarak seçilirken standart sapması

(σ) 0,8 olarak belirlenmiştir. Ardından, tepe noktasına 0 değerinde ulaşan dağılım tersine çevrilerek dağılımın tepe noktasındaki değeri 0'a eşitlenmiştir (Şekil 22). Böylelikle çerçeve boyutunun, ölçek parametresi negatif ya da pozitif uçlara giderken artması sağlanmıştır. Oluşturulan dağılımın çerçeve boyutunu ölçekleyebilmesi için her bir yığın (batch) çerçeve içinde kalan nokta sayısı mimarinin npoints parametresinden çıkartılarak bu farkın pozitif olması durumunda npoints'e negatif olması durumunda da çerçeve içinde kalan nokta sayısına bölünmesi ile normalize edilmiştir. Elde edilen değer PDF dağılımında karşılık geldiği ölçek faktörü enterpolasyon yapılarak tespit edilmiştir. Elde edilen ölçek faktörü kullanılarak her bir yığındaki (batch'teki) çerçeve boyutu adaptif hale getirilmiştir.



Şekil 22. Adaptif 2 çerçeve belirleme stratejisi için oluşturulan PDF dağılımı

Adaptif 2 yaklaşımı ile çerçeve boyutunun belirlenmesinde uygulanan ölçekleme işlemi aşağıdaki Denklem 13 ile ifade edilmiştir.

$$S_{sz} = \begin{cases} (P_{cpts} - n_{pts})/n_{pts}, & P_{cpts} < n_{pts} \\ (P_{cpts} - n_{pts})/P_{cpts}, & P_{cpts} \geq n_{pts} \end{cases} \quad (13)$$

Burada, P_{cpts} çerçeve içinde kalan nokta sayısını, n_{pts} mimarinin npoints parametresini, S_{sz} ise varyasyon parametresini temsil etmektedir. Çerçeve boyutu ölçek faktörü S_{cf} , S_{sz} parametresinin PDF fonksiyonunda yerine konulması ile aşağıdaki şekilde elde edilir (Denklem 14).


$$Sc_f = f(S_{sz}) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{S_{sz}-\mu}{\sigma}\right)^2} \quad (14)$$

Elde edilen ölçek faktörü kullanılarak Adaptif 2 çerçeve boyutu aşağıdaki şekilde Denklem 15 ile hesaplanır;

$$Ba_{sz} = \begin{cases} [B_{sz} + (B_{sz} \times Sc_f)], S_{sz} < 0 \\ [B_{sz} - (B_{sz} \times Sc_f)], S_{sz} \geq 0 \end{cases} \quad (15)$$

Burada Ba_{sz} adaptif çerçeve boyutunu, B_{sz} başlangıç çerçeve boyutunu ifade etmektedir.

Bir örnek üzerinden açıklamak gerekirse; eğitim aşamasında 30×30 m çerçeve boyutları için PDF dağılımı da $\sigma = 0.8$ ve $\mu = 0$ için oluşturduğunu varsayalım. Bu çerçeve boyutları ile batch'ler oluşturulurken gelen nokta bulutlarından bir tanesinin içinde 3300 nokta olduğu (Pc_{pts}) ve n_{pts} parametresinin 8192 olarak verildiği varsayalım. Bu durumda $Pc_{pts} < n_{pts}$ olduğu için çerçeve boyutu, $S_{sz} = (Pc_{pts} - n_{pts})/n_{pts}$ ile hesaplanan varyasyon parametresi -0,597 değerini alacağı için ölçek faktörü Sc_f 0,377 olarak hesaplanacaktır. Bu durumda, adaptif çerçeve boyutu Ba_{sz} 42 m olarak hesaplanacaktır. Yeni çerçeve içerisinde 6400 nokta bulunacaktır. Şekil 23'te ISPRS Benchmark veri setinden seçilen örnek bir alan üzerinde adaptif çerçeve boyutu belirleme işlemi gösterilmiştir.



Şekil 23. ISPRS Benchmark veri setinden seçilen örnek bir alan üzerinde adaptif çerçeve boyutu belirleme işlemi

Geliştirilen Adaptif 2 stratejisi ile mimarinin hem tutarlı mekânsal bağlamlarda eğitilmesi sağlanmış hem de her bir yığında seçilen nokta bulutlarının yeterli sayıda nokta içermesi sağlanmıştır. Bu sayede mimari hem veri setleri arasında hem de veri seti içerisindeki nokta yoğunluğu değişimlerine karşı kararlı hale getirilmiştir.

Adaptif 2 yaklaşımının Adaptif 1 yaklaşımına göre avantajlarından birisi mekânsal ölçekten kopmayarak daha anlamlı sahneler ile mimariyi besleyebilmesidir. Diğer bir avantajı ise, büyük ölçekli nokta bulutu veri kümelerinin kendi içindeki nokta yoğunluğu değişimlerini de dikkate almasıdır.

3.8. Doğruluk Metrikleri

3B nokta bulutlarının semantik segmentasyonunda performans değerlendirmesi için en sık kullanılan metrikler genel doğruluk (GD), ortalama kesişim-birleşim oranı (Intersection over Union-IoU) ve ortalama sınıf doğruluklarıdır (Guo vd., 2021b). Tez kapsamında GD, IoU ve F1 ölçütü olmak üzere üç farklı metrik kullanılmıştır. IoU ve F1 ölçütleri her bir sınıf için hem ayrı ayrı hem de tüm sınıflar için ağırlıklı ortalama olarak (mIoU, mF1) hesaplanmıştır. IoU, özellikle semantik segmentasyon sonuçlarını değerlendirmede son yıllarda oldukça yaygın bir şekilde kullanılmaktadır. Çalışmada kullanılan diğer doğruluk ölçütü F1, kesinlik (precision) ve duyarlılık (recall) metriklerinin harmonik ortalaması olarak hesaplanmaktadır. F1 ölçüt hesabı için öncelikle kesinlik ve duyarlılık metrikleri hata matrisi yardımı ile hesaplanır. Kesinlik, i sınıfı olarak sınıflandırılan noktalardan ne kadarının gerçekte i . sınıfa ait olduğunu gösteren bir metriktir. Duyarlılık ise i sınıfına ait noktalardan ne kadarının i . sınıf olarak sınıflandırıldığının ölçütüdür. Tablo 6’da dört sınıflı bir problemin Sınıf 1 örneği için hata matrisi verilmiştir. Hata matrisi elemanları TP, FN, FP ve TN sırası ile Gerçek Pozitif, Hatalı Negatif, Hatalı Pozitif ve Gerçek Negatif’i temsil etmektedir.

Tablo 6. Dört sınıflı bir problemde Sınıf 1 için hata matrisi örneği

Gerçek değer	Tahmin edilen				
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4
	Sınıf 1	TP	FN	FN	FN
	Sınıf 2	FP	TN	TN	TN
	Sınıf 3	FP	TN	TN	TN
	Sınıf 4	FP	TN	TN	TN

TP, Sınıf 1'e ait olup sınıflandırıcı tarafından Sınıf 1 olarak sınıflandırılan noktaların kümesidir. FN, Sınıf 1'e ait olup ancak diğer üç sınıf olarak sınıflandırılan noktaları temsil etmektedir. FP, diğer sınıflara ait olup ancak Sınıf 1 olarak sınıflandırılan noktaları oluşturmaktadır. Son olarak TN ise, Sınıf 1'e ait olmayan ve yine sınıflandırıcı tarafından da Sınıf 1 olarak sınıflandırılmayan noktaları temsil etmektedir. Hata matrisi üzerinden kesinlik (Denklem 16), duyarlılık (Denklem 17) ve F1 (Denklem 18) metrikleri ile aşağıdaki gibi hesaplanmaktadır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (16)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (17)$$

$$F1 = \frac{2 \times \text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (18)$$

IoU, bir sınıfa ait doğru tahmin edilen noktaların ilgili sınıf olarak tahmin edilen noktalara oranı şeklinde aşağıda Denklem 19 ile gösterildiği şekilde hesaplanmaktadır. Diğer bir deyişle IoU, tahmin edilen noktaların gerçek veri ile olan kesişimlerinin, birleşimlerine oranlanması ile hesaplanmaktadır (Şekil 24). Bu oran da model sonuçlarının gerçeği ne kadar iyi temsil ettiği ile ilgili bilgi vermesinden dolayı son yıllarda IoU metriği ön plana çıkmıştır.



Şekil 24. IoU metriğinin görsel ifadesi

$$IoU = \frac{TP}{TP + FN + FP} \quad (19)$$

Semantik segmentasyon doğruluklarının araştırılmasında standart bir metrik olarak kullanılan ağırlıklı ortalama IoU (mIoU), sınıf doğruluklarının ağırlıklı ortalaması olarak Denklem 20 ile hesaplanır. Burada N sınıf sayısını, w ise sınıf ağırlıklarını temsil eder.

$$mIoU = \frac{\sum_{i=1}^N w_i IoU_i}{N} \quad (20)$$

Son olarak çalışmada yöntemin performansını test etmek adına diğer bir doğruluk metriği olarak GD kullanılmıştır. GD, doğru bir şekilde sınıflandırılmış noktaların toplam nokta sayısına olan oranı olarak hesaplanmaktadır. Özellikle sınıflar arasında çok fazla eşitsizlik olması durumunda yanıltıcı olmasına rağmen diğer çalışmalar için kıyaslama yapabilmek adına aşağıda Denklem 21’de gösterildiği gibi hesaplanmıştır.

$$GD = \frac{(TP + TN)}{(TP + FN + FP + TN)} \quad (21)$$

Tez kapsamında belirtilen tüm doğruluklar segmentasyon sonuçlarının çoğunluk oylaması (majority voting) yapıldıktan sonraki etiketleri üzerinden değerlendirilen nihai doğruluklardır.

4. BULGULAR VE İRDELEMELER

Tez kapsamında hava LiDAR nokta bulutlarının PointNet++ mimarisi ile semantik segmentasyonunda bu mimarinin değişken nokta yoğunluğu problemleri ile başa çıkabilmesi için geliştirilen yeni yaklaşımların modelin böylesi verilere olan sağlamlığını ne kadar artırdığını adil bir değerlendirme ile araştırabilmek adına; öncelikli olarak orijinal PointNet++ mimarisi üzerinde Bölüm 3.2 Tablo 3 ile açıklanan bazı geometrik parametrelerin optimum değerleri Bölüm 3.1’de tanıtılan hava LiDAR nokta bulutları için doğruluklarına olan etkileri üzerinden araştırılmıştır. Son olarak geliştirilen Adaptif 1 ve Adaptif 2 çerçeve boyutu yaklaşımlarının bu veri setleri üzerinde test edilerek orijinal mimariye göre üstünlük ve zayıflıkları irdelenmiştir. Tez kapsamında gerçekleştirilen tüm PointNet++ uygulamaları için kullanılan bilgisayarın donanım ve yazılım bilgileri aşağıda Tablo 7’de verilmiştir.

Tablo 7. Kullanılan bilgisayara ait yazılım ve donanım bilgileri

İşlemci	intel i5 9400F
Bellek	32 GB
GPU	Geforce RTX 2060 6GB
İşletim Sistemi	Ubuntu 18.04
Python Versiyonu	2,7
Tensorflow Versiyonu	1.2
CUDA Versiyonu	8.0
cuDNN Versiyonu	7.3

Bu bölüm öncelikli olarak ISPRS benchmark veri setine ait doğruluk değerleri ve görsel sonuçların sunumu, ardından Bölüm 4.2’de DALES veri setine ait elde edilen doğrulukların irdelenmesi ve görsel sonuçların sunumu, Bölüm 4.3’te OpenGF veri seti için elde edilen doğruluk değerleri ve görsel sonuçlar verilmiştir. Ardından Bölüm 4.4’te DALES ve OpenGF veri setleri üzerinden yoğunluk, geri dönüş sayısı ve dönüş numarası bilgilerinin PointNet++ mimarisinin performansına etkileri araştırılmıştır. Son olarak

Bölüm 4.5 orijinal mimari ile tez kapsamında önerilen Adaptif 1 ve Adaptif 2 yaklaşımlarının genelleştirme kabiliyetlerinin karşılaştırılması şeklinde yapılandırılmıştır.

4.1. ISPRS Veri Seti İçin Doğruluklar

Bu bölümde gerçekleştirilen tüm uygulamalar için aksi belirtilmediği sürece kullanılan parametreler Bölüm 3.3.1 Tablo 3'te belirtilen parametrelerdir. Bu bölümdeki tüm uygulamalar PointNet++ mimarisinin MRG katmanı kullanılarak gerçekleştirilmiştir. Her bir modelin eğitim süresi ise yaklaşık olarak 55 dakika sürmüştür.

ISPRS benchmark veri seti üzerinde Uygulama 1, Uygulama 2, Uygulama 3, Uygulama 4, Uygulama 5 ve Uygulama 6 olmak üzere altı farklı uygulama gerçekleştirilmiştir. Uygulama 1, ISPRS semantik etiketleme veri seti için optimum çerçeve boyutunu araştırmak amacı ile gerçekleştirilmiştir. Uygulama 2, Uygulama 1'den elde edilen optimum çerçeve boyutunu kullanarak nokta bulutunun yerel bölgelere ayrılmasında ve öznitelik çıkarımında her bir katmanda kullanılan yarıçapların etkisini araştırmak amacı ile gerçekleştirilmiştir. Uygulama 3, orijinal mimarinin örnek (sample) oluştururken kullandığı nokta örnekleme stratejisini değiştirerek mimarinin daha fazla benzersiz nokta ile eğitilmesini sağlamak amacı ile düzenlenen yeni nokta örnekleme stratejisini (bölüm 3.5) test etmek amacı ile uygulanmıştır. Uygulama 4, mimarinin farklı girdi nokta sayılarına karşı performansını araştırmak amacı ile gerçekleştirilmiştir. Uygulama 5, yarıçap içinden örneklenen nokta sayısı (nsample) parametresinin mimarinin performansı üzerindeki etkilerini irdelemek amacı ile gerçekleştirilmiştir. Son olarak Uygulama 6, tez kapsamında önerilen Adaptif çerçeve boyutu yaklaşımlarının bu veri seti üzerindeki doğruluğunu test etmek amacı ile uygulanmıştır. Tüm uygulamalarda öğrenme oranı 20 epokta bir azaltılmıştır.

Uygulama 1: Veri setine özel optimum çerçeve boyutunu belirleyebilmek adına PointNet++ mimarisinin MRG katmanı üzerinde 10×10 , 15×15 , 20×20 , 25×25 ve 30×30 olmak üzere beş farklı çerçeve boyutu test edilmiştir. Tablo 8'de farklı çerçeve boyutlarına göre elde edilen doğruluklar ve mimariye ait parametreler verilmektedir. Diğer hiper-parametreler için Tablo 3'te sunulan varsayılan değerler kullanılmıştır.

Bu uygulamada ilk seviyedeki komşuluk arama yarıçapı Bölüm 3.6’da açıklanan optimum komşuluk arama yönteminin sonucu olan 1 m olacak şekilde seçilerek sonraki katmanlar için 2, 4 ve 8 m olarak kullanılmıştır.


Tablo 8. Farklı çerçeve boyutlarının mimarinin ISPRS 3B Semantik Etiketleme veri seti üzerindeki doğruluklara olan etkileri

Log	Model 1		Model 2		Model 3		Model 4		Model 5	
Çerçeve Boyutu (m)	10×10		15×15		20×20		25×25		30×30	
Girdi nokta	8192		8192		8192		8192		8192	
Batch size	16		16		16		16		16	
Yarıçap (m)	1, 2, 4, 8		1, 2, 4, 8		1, 2, 4, 8		1, 2, 4, 8		1, 2, 4, 8	
npoints	1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ ÖLÇÜT	F1	IoU	F1	IoU	F1	IoU	F1	IoU	F1	IoU
Elektrik H.	0,54	0,37	0,64	0,47	0,50	0,34	0,47	0,31	0,35	0,21
Düşük Bitki	0,70	0,54	0,73	0,58	0,63	0,46	0,66	0,49	0,69	0,53
Geçirims. Y.	0,80	0,67	0,83	0,71	0,78	0,64	0,81	0,69	0,78	0,64
Araba	0,58	0,41	0,57	0,40	0,65	0,49	0,66	0,49	0,49	0,32
Çit	0,25	0,14	0,26	0,15	0,11	0,06	0,17	0,09	0,13	0,07
Çatı	0,93	0,87	0,93	0,87	0,92	0,86	0,91	0,84	0,89	0,80
Bina Ceph.	0,54	0,37	0,59	0,42	0,58	0,41	0,54	0,37	0,56	0,39
Çalı	0,51	0,34	0,47	0,31	0,45	0,29	0,46	0,30	0,42	0,27
Ağaç	0,77	0,63	0,79	0,65	0,80	0,67	0,79	0,66	0,78	0,64
Ağr. Ort.	0,77	0,64	0,79	0,66	0,75	0,61	0,76	0,62	0,75	0,60
GD (%)	76,93		78,75		75,60		76,54		74,66	


ISPRS 3B Semantik Etiketleme veri seti için en yüksek genel doğruluk, F1 ölçütü ve IoU metrik değerleri 15×15 m çerçeve boyutu ile sırası ile %78,75, %79 ve %66 olarak elde edilmiştir. Özellikle IoU metriği üzerinden değerlendirildiğinde 15 m’den sonra en yüksek doğruluk 10×10 m çerçeve boyutu için elde edilmiştir. Çerçeve boyutunun 10×10 m ile 30×30 m arasındaki değişimi, mimarinin performansını yaklaşık olarak bu veri seti üzerinde genel doğruluk için %4 ve IoU doğruluğu için %6 aralığında değiştirmektedir. Bu sonuçlar mimarinin çerçeve boyutu seçimine karşı hassas olduğunu göstermektedir. En yüksek doğruluğun elde edildiği Model 2’ye ait semantik segmentasyon sonuçları Test 1

ve Test 2 için aşağıda Şekil 25'te verilmektedir. Ayrıca Şekil 26'de doğru ve yanlış etiketlenen noktalar verilmektedir.

Model 2'ye ait hata matrisi incelendiğinde düşük bitki sınıfı mimari tarafından en fazla sırası ile geçirimsiz yüzey sınıfı ve çalı sınıfı ile karıştırılmıştır. Düşük bitkinin en çok karıştığı sınıflardan bir diğeri de çalı sınıfı olmuştur. Çit sınıfının ise en fazla düşük bitki ve çalı sınıfları ile karıştırıldığı gözlemlenmiştir. Çatı sınıfındaki en büyük hatalar ise düşük bitki ve ağaç sınıfında meydana gelmiştir. Ağaç sınıfındaki hatalar ise en fazla ve belirgin bir şekilde çalı sınıfında meydana gelmiştir. Bina cephesi sınıfındaki hatalar ise sırası ile çatı, çalı ve ağaç sınıfında gerçekleşmiştir.



Şekil 25. 15x15 m çerçeve boyutu kullanılarak orijinal PointNet++ mimarisi ile elde edilen semantik segmentasyon sonuçları



Şekil 26. Semantik segmentasyon sonucunda bulunan hatalı ve doğru noktalar

Uygulama 2: PointNet++ mimarisi her bir katmanda önceden belirlenen yarıçaplar ile öznelilikler çıkartmaktadır. Yarıçaplar, verinin nokta yoğunluğu ve kullanılan çerçeve boyutu parametreleri dikkate alınarak belirlenmelidir. İlk katmanda çok büyük yarıçap kullanmak ince detayların kaybolmasına neden olabileceği gibi son katmanda çok küçük yarıçap kullanmak ise sahne hakkında yeterli bilgilerin çıkarılamamasına sebebiyet verecektir. Bu yüzden, yarıçap parametresinin önemini araştırmak için MRG katmanı kullanılarak Uygulama 2 gerçekleştirilmiştir. Farklı yarıçap kombinasyonlarından oluşan altı ayrı model eğitilerek test verisi üzerinde modellerin performansları karşılaştırılmıştır. Modellere ait parametre bilgileri ve elde edilen doğruluklar Tablo 9’da verilmektedir.

Tablo 9. Komşuluk arama yarıçapının mimariye olan etkisinin ISPRS veri seti üzerinde irdelenmesi

Log	Model 1		Model 2		Model 3		Model 4		Model 5		Model 6	
Çerçeve Boyutu (m)	15×15		15×15		15×15		15×15		15×15		15×15	
Girdi nokta	8192		8192		8192		8192		8192		8192	
Batch size	16		16		16		16		16		16	
Yarıçap (m)	1, 2, 4, 8		1, 2, 3, 6		0.5, 1, 4, 8		0.5, 1, 2, 8		1, 3, 5, 8		2, 3, 5, 8	
npoints	1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ÖLÇÜT	F1	IoU	F1	IoU	F1	IoU	F1	IoU	F1	IoU	F1	IoU
Elektrik H.	0,64	0,47	0,51	0,34	0,21	0,12	0,12	0,06	0,38	0,23	0,59	0,42
Düşük Bitki	0,73	0,58	0,71	0,55	0,63	0,46	0,63	0,46	0,70	0,54	0,73	0,57
Geçirims. Y	0,83	0,71	0,83	0,72	0,71	0,54	0,77	0,62	0,83	0,71	0,84	0,72
Araba	0,57	0,40	0,43	0,27	0,33	0,19	0,47	0,30	0,51	0,34	0,61	0,44
Çit	0,26	0,15	0,30	0,17	0,21	0,11	0,07	0,04	0,25	0,14	0,27	0,15
Çatı	0,93	0,87	0,91	0,84	0,88	0,78	0,84	0,73	0,92	0,86	0,92	0,85
Bina Ceph.	0,59	0,42	0,59	0,42	0,47	0,31	0,42	0,26	0,58	0,41	0,59	0,42
Çalı	0,47	0,31	0,42	0,27	0,42	0,26	0,45	0,29	0,45	0,29	0,47	0,31
Ağaç	0,79	0,65	0,78	0,64	0,71	0,55	0,74	0,59	0,79	0,65	0,78	0,65
Ağr.Ort.	0,79	0,66	0,77	0,64	0,70	0,54	0,71	0,56	0,77	0,64	0,78	0,65
GD (%)	78,75		77,35		69,67		70,56		77,51		78,35	

Komşuluk arama yarıçapı için optimum değerlerin arandığı Uygulama 2’de en yüksek doğruluklar 1, 2, 4, ve 8 m ile Model 1’de elde edilmiştir. En düşük doğruluklar ise Model 3 ve Model 4’te elde edilmiştir. Bu modellerin düşük doğruluklar elde etmesinin temel nedeni ilk seviyede kullanılan yarıçap boyutunun 0,5 m olmasıdır. ISPRS 3B Semantik Etiketleme test veri setinin ortalama yoğunluğu her ne kadar ortalama olarak 4,8 nokta/m² olsa da nokta örnekleme homojen olmadığı için yer yer bu yoğunluk değeri daha düşük olduğundan dolayı bu kadar küçük bir komşulukta anlamlı özneteliklerin çıkartılmasına yetecek kadar nokta bulunmaması mimariye olumsuz etkilemiştir. Model 1, Model 2, Model 5 ve Model 6 incelendiğinde ilk seviyede 1 m ve 2 m arama yarıçapının kullanılmış olmasının elde edilen doğrulukları artırmış olması yukarıdaki çıkarımı doğrulamaktadır. Mimari için başlangıç yarıçapının büyük olması daha yüksek doğrulukların elde edilmesini sağlamıştır. Model 1 ve Model 2 incelendiğinde son iki

seviyedeki arama yarıçaplarının azaltılması özellikle bina gibi büyük objelere ve sahnenin genel yapısına ait yerel bağlamların iyi yakalanamamasına neden olduğu için doğrulukları olumsuz etkilediği söylenebilir. Özellikle Model 6'da Model 1'e yakın değerler elde edilmiştir. Buradan çıkan sonuç ile de yarıçap içerisinde örneklenen nokta sayısının da önemi anlaşılmaktadır. Altı model üzerinden, mimarinin yarıçap parametre seçimine karşı ne kadar hassas olduğu da modeller arasında genel doğruluk ve IoU metrikleri arasında %9 ve %12 değişimleri üzerinden görülmektedir.

Uygulama 3: PointNet++ mimarisinin nokta örnekleme (sample) stratejisi Bölüm 3.4'te açıklanmıştır. Orijinal mimaride uygulanan yaklaşım, zaten düşük nokta sayısına sahip ISPRS 3B Semantik Etiketleme veri setinin daha az nokta ile eğitilmesine neden olacaktır. Mimarinin bu stratejisi daha fazla benzersiz nokta görebilmesini sağlamak amacı ile değiştirilmiştir. Yeni nokta örnekleme stratejinin etkisini MRG katmanı üzerinde irdelemek amacı ile Uygulama 3 gerçekleştirilmiştir. MRG katmanına ait detaylar test doğrulukları ile aşağıda Tablo 10'da sunulmaktadır. Model 1 orijinal PointNet++ mimarisinin örnekleme stratejisini temsil ederken Model 2 ise değiştirilen nokta örnekleme stratejisini temsil etmektedir.

Tablo 10. Orijinal nokta örnekleme stratejisi ile değiştirilmiş nokta örnekleme stratejisinin karşılaştırılması

Log	Model 1		Model 2	
Çerçeve Boyutu (m)	20×20		20×20	
Girdi nokta	8192		8192	
Batch size	16		16	
Nokta_kopy	Var (orj)		Yok	
Yarıçap (m)	1, 2, 4, 8		1, 2, 4, 8	
Npoints	1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ ÖLÇÜT	F1	IoU	F1	IoU
Elektrik Hattı	0,50	0,34	0,51	0,34
Düşük Bitki	0,63	0,46	0,69	0,52
Geçirimsiz Y.	0,78	0,64	0,82	0,70
Araba	0,65	0,49	0,61	0,44
Çit	0,11	0,06	0,17	0,10
Çatı	0,92	0,86	0,92	0,85
Bina Ceph.	0,58	0,41	0,58	0,41
Çalı	0,45	0,29	0,46	0,30
Ağaç	0,80	0,67	0,79	0,65
Ağırlıklı Ort.	0,75	0,61	0,77	0,63
GD (%)	75,60		77,03	
Eğitim süresi	55 dk		54 dk	

Orijinal mimaride, çerçeve içinden seçilen 8192 nokta örneklenirken bu kadar noktanın kutu içerisinde olup olmadığını göz ardı ederek noktaları rastgele kopyalayarak 8192 örneklenmekteyken düzenlenen yeni yaklaşım ile çerçeve içerisinde 8192 nokta varsa kopyalama yapılmamakta, yoksa girdi nokta sayısı tamamlanıncaya kadar rastgele kopyalama işlemi yapılmaktadır. Sadece nokta kopyalamayı düzelterek mimarinin genel doğruluğunda yaklaşık %1,5 iyileşme elde edilirken mIoU ve F1 ölçütünde %2 performans artışı gözlenmiştir. İki model de 201 epok boyunca eğitilmesine rağmen Model 2’de en iyi eğitim doğruluğuna 40 epok daha erken ulaşılmıştır.

Uygulama 4: Mimariye girdi olarak verilen, yani sahneyi temsil eden nokta sayısı parametresinin mimarinin üzerindeki etkileri ISPRS veri seti üzerinde test edilmiştir. Çünkü mimarideki tüm katmanlar boyunca girdi olarak verilen bu nokta bulutu, mimarinin katmanları boyunca $\frac{1}{4}$ oranında azaltılarak her bir ilerleyen katmanda daha az nokta ile temsil edilecektir. Bu yüzden girdi nokta bulutu sahneyi ya da topografyayı ne kadar iyi temsil eder ve kapsar ise FPS yöntemi ile örneklenen noktalardan mimarinin nokta bulutuna ait özniteliklerini çıkarma işlemi de o kadar anlamlı olacak ve semantik segmentasyon sonuçları iyileşmiş olacaktır. Bundan dolayı, girdi nokta sayısı parametresinin mimarinin performansı üzerindeki etkilerini araştırmak amacı ile orijinal mimari kullanılarak dört farklı modeller eğitilmiş ve ISPRS 3B Semantik Etiketleme veri seti için optimum girdi nokta sayısı belirlenmiştir (Tablo 11).

Tablo 11. Farklı girdi nokta sayılarının ISPRS 3B Semantik Etiketleme veri seti üzerinde elde edilen doğruluklara etkisi

Log	Model 1		Model 2		Model 3		Model 4	
Çerçeve Boyutu (m)	15×15		15×15		15×15		15×15	
Girdi nokta	1024		2048		4096		8192	
Batch size	16		16		16		16	
Yarıçap (m)	1, 2, 4, 8		1, 2, 4, 8		1, 2, 4, 8		1, 2, 4, 8	
npoints	1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ ÖLÇÜT	F1	IoU	F1	IoU	F1	IoU	F1	IoU
Elektrik H.	0,09	0,05	0,24	0,14	0,41	0,26	0,64	0,47
Düşük Bitki	0,68	0,52	0,65	0,49	0,70	0,54	0,73	0,58
Geçirims.Y.	0,85	0,74	0,81	0,68	0,82	0,70	0,83	0,71
Araba	0,32	0,19	0,56	0,39	0,61	0,44	0,57	0,40
Çit	0,20	0,11	0,21	0,12	0,27	0,15	0,26	0,15
Çatı	0,91	0,83	0,93	0,87	0,92	0,86	0,93	0,87
Bina Ceph.	0,52	0,35	0,55	0,38	0,58	0,41	0,59	0,42
Çalı	0,36	0,22	0,44	0,28	0,46	0,30	0,47	0,31
Ağaç	0,77	0,63	0,80	0,66	0,79	0,65	0,79	0,65
Ağr.Ort.	0,77	0,63	0,76	0,63	0,78	0,64	0,79	0,66
GD (%)	77,92		76,31		77,70		78,75	

Tablo 11 incelendiğinde, her üç doğruluk metriği için de en yüksek doğruluk değerleri, mimarinin semantik segmentasyonu modeli için varsayılan parametresi olan 8192 nokta ile elde edilmiştir. Model 4'ün en yüksek doğruluğa sahip olarak öne çıkmasının nedeni olarak daha fazla nokta kullanmanın ağa ayrıştırma, daha fazla bilgi ve daha iyi bir öznitelik temsili sağladığı söylenebilir. IoU metrikleri üzerinden değerlendirildiğinde en yüksek ikinci doğruluk ise %64 ile 4096 girdi nokta sayısı ile elde edildiği görülmüştür. 1024 girdi nokta sayısı ile elde edilen mIoU doğruluğunun %63 ve genel doğruluk değerinin de elde edilen ikinci en yüksek doğruluk değeri olması ise temel olarak yüksek sayıda nokta ile temsil edilmekte olan düşük bitki, geçirimsiz yüzey, çatı ve ağaç sınıflarında elde edilen görece yüksek doğruluklardan kaynaklanmaktadır. Burada karşılaşılan bu ilginç durum ise; sahnenin düşük sayıda nokta ile temsil edilmesi sayesinde zemin, çatı yüzeyi gibi nokta bulutu içindeki ağırlığı yüksek olan sınıfların aynı zamanda eğitim aşamasında da yüksek ağırlıklara sahip olmasına ve bunun bir sonucu olarak da mimarinin özellikle bu sınıfları ayırt edebilecek özniteliklere daha fazla ağırlık vermesi ile

açıklanabilecektir. İfade edilen bu durum, az sayıda nokta ile temsil edilen elektrik hattı, çit ve araba sınıflarından elde edilen düşük doğrulukları da açıklamaktadır. Çünkü, mimari bu sınıflara ait çok az sayıda nokta gördüğü için bu sınıfların eğitimdeki ağırlıkları da daha düşük olmaktadır. Bunun neticesinde de az sayıda nokta ile temsil edilen sınıfların özniteliklerini mimari öğrenememiştir. Ancak mimari yeteri kadar nokta ile beslendiğinde bu sorunun da ortadan kolaylıkla kaldırılabilceği de görülmektedir.

ISPRS veri setinde özellikle girdi nokta sayısının artmasına rağmen genel doğruluklar bakımından iyileşmeler %1 seviyelerinde kalmıştır. Bu durumun bir nedeni olarak PointNet mimarisi üzerinden Qi vd. (2017a) tarafından yapılan sağlamlık testlerinde önemsiz olan bazı noktaların kaybolmasının modelin çıkarttığı ana iskelet nokta bulutunu dolayısı ile de bu kayıpların global şekil özniteliklerini etkilemediği çıkarımları sunulabilir. ISPRS veri setinin nokta yoğunluğu düşük olduğundan 15×15 m bir çerçeve boyutuna ortalama olarak eğitim veri set için 1643 nokta ($15 \times 15 \times 7,3$) test veri seti için ise 1080 nokta ($15 \times 15 \times 4,8$) düşmektedir. Dolayısı ile ISPRS veri seti için girdi nokta sayısının artırılması, hem eğitim nokta sayısının az olmasından dolayı hem de yoğunluğunun düşük olmasından dolayı çıkartılan özniteliklerin kalitesini yeterince artırmadığını göstermektedir. Bu duruma yol açan bir diğer neden ise mimarinin veri eksiltme katsayısı (0,875) olabilir. Örnek olarak veri eksiltme oranı, Model 1'e göre girdi nokta sayısının arttığı Model 2'de rastlantısal bir şekilde daha büyük geldiğinden dolayı daha fazla benzersiz nokta eksiltmesi sonucunda doğruluk değeri yaklaşık %1 civarında düşüş göstermiş olabilir. Bu parametrenin mimariye olan etkileri, daha büyük veri setleri üzerinde değerlendirildiğinde daha anlamlı yorumlar yapmak mümkün olacaktır (Bölüm 4.2).

Uygulama 5: PointNet++ mimarisinin bir diğer geometrik parametresi ise komşuluk arama yarıçapları içerisinde örneklenen nokta sayısını temsil eden nsample parametresidir. Bu parametre de diğer parametreler gibi nokta bulutundan farklı ölçeklerde çıkartılan özniteliklerin kalitesini belirlemede oldukça etkilidir. Bu parametre aslında hem arama yarıçapı ile hem de nokta yoğunluğu ile ilişkilidir. Arama yarıçapının küçük olduğu yerlerde nokta yoğunluğu da düşük ise yeteri kadar nokta toplanamadığından anlamlı özniteliklerin çıkartılması mimari tarafından mümkün olmayacaktır. Bu yüzden komşuluktaki nokta sayısı parametresinin nokta yoğunluğu dikkate alınarak belirlenmesi gerekmektedir. Bu parametrenin etkisini araştırmak için üç farklı model eğitilmiştir. Her üç

model de girdi nokta sayısı 8192 ve çerçeve boyutu 15×15 m kullanılarak eğitilmiştir (Tablo 12).


Tablo 12. nsample parametresinin ISPRS 3B Semantik Etiketleme verisi üzerinde etkileri

Log	Model 1		Model 2		Model 3	
nsample	64, 64, 64, 64		32, 64, 128, 256		64, 64, 64, 64	
Batch size	16		16		16	
Yarıçap (m)	2, 3, 5, 8		1, 2, 4, 8		1, 2, 4, 8	
npoints	1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ ÖLÇÜT	F1	IoU	F1	IoU	F1	IoU
Elektrik H.	0,41	0,26	0,62	0,45	0,52	0,35
Düşük Bitki	0,75	0,60	0,71	0,55	0,74	0,59
Geçirims.Y.	0,87	0,76	0,80	0,67	0,84	0,72
Araba	0,67	0,50	0,59	0,42	0,33	0,20
Çit	0,30	0,17	0,22	0,12	0,27	0,16
Çatı	0,91	0,84	0,93	0,87	0,92	0,86
Bina Ceph.	0,58	0,41	0,59	0,41	0,57	0,40
Çalı	0,47	0,31	0,48	0,31	0,44	0,28
Ağaç	0,78	0,64	0,80	0,67	0,78	0,64
Ağr. Ort.	0,79	0,67	0,78	0,64	0,78	0,66
GD (%)	79,36		77,35		78,44	


Tablo 12 incelendiğinde, en yüksek genel doğruluk ve ortalama F1 ve IoU doğrulukları Model 1 ile elde edilmiştir. Sınıf bazında incelendiğinde çatı ve elektrik hattı harici tüm sınıflarda yine Model 1 ile en yüksek doğruluklar elde edilmiştir. Model 1 ve Model 3'te kullanılan yarıçaplar Tablo 12'de görüleceği üzere ilk katman için farklıdır. Burada, nokta yoğunluğunu dikkate alarak yarıçap ve örneklenen nokta sayısı (nsample) parametrelerinin birlikte düşünülmesi gerektiğini göstermek amaçlanmıştır. Nokta yoğunluğu nispeten düşük olan ISPRS veri setinde ilk katmanda 1 m yarıçap ile komşuluk arandığında (Model 3), bu yarıçap içerisine ilk katman için belirlenen 64 benzersiz nokta düşmemektedir ve bu da modelin bu sayıyı sağlaması için kopya nokta üreteceği anlamına gelmektedir. Ancak Model 1'de ilk katmanda 2 m arama yarıçapı ile komşu noktalar seçildiğinde bu yerel bölgeye çok daha fazla benzersiz nokta düştüğünden daha anlamlı öz niteliklerin çıkarılması sağlanmıştır. Bu sonuç Model 2'de nsample parametresinin nokta

yoğunluğunu dikkate almadan artırılmasının mimariyi olumsuz etkilediği sonucu ile de desteklenmektedir.

Özellikle ISPRS 3B Semantik Etiketleme veri seti gibi nokta yoğunluğu nispeten düşük olan nokta bulutlarında 1 m yarıçap içine düşen nokta sayısı düşük olduğundan dolayı nsample parametresini artırmanın modelin doğruluğuna herhangi bir katkısının olmadığı da Model 2 sonuçlarında gözlemlenmiştir. Dahası, mimari için özellikle ilk seviyedeki komşuluk arama yarıçapı ve nsample parametrelerini belirlerken nokta yoğunluğunun da dikkate alınarak birlikte değerlendirilmeleri, daha yüksek doğrulukların elde edilmesine olanak sağlayacaktır. Model 1'e ait semantik segmentasyon sonuçları Test 1 ve Test 2 için aşağıda Şekil 27'de verilmektedir. Ayrıca etiketlenen hatalı ve doğru noktalar Şekil 28'de gösterilmektedir.



Şekil 27. Model 1 için ISPRS semantik segmentasyon sonuçları



Şekil 28. Model 1 sonucunda tespit edilen hatalı ve doğru noktalar

Uygulama 6: Tez kapsamında geliştirilen nokta yoğunluğuna adaptif çerçeve boyutu yaklaşımları ile orijinal PointNet++ mimarisinin Uygulama 1’de elde edilen en iyi modeli karşılaştırılmıştır. Önerilen yaklaşımlar ile elde edilen sonuçlar orijinal PointNet++ mimarisi (Uygulama 1 Model 2) ile kıyaslandığında ISPRS 3B Semantik Etiketleme test veri seti üzerinde birbirlerine oldukça yakın sonuçlar elde etmişlerdir (Tablo 13).


Tablo 13. Adaptif çerçeve boyutu yaklaşımları ile orijinal mimarinin karşılaştırılması

Log	Model 1		Model 2		Model 3		Uygulama 1	
Çerçeve Boyutu (m)	Adaptif 1		Adaptif 2 (15×15)		Adaptif 2 (20×20)		15×15	
Girdi nokta	8192		8192		8192		8192	
Batch size	16		16		16		16	
Yarıçap (m)	0,1, 0,2, 0,4, 0,8		1, 2, 4, 8		1, 2, 4, 8		1, 2, 4, 8	
Npoints	1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ ÖLÇÜT	F1	IoU	F1	IoU	F1	IoU	F1	IoU
Elektrik H.	0,41	0,26	0,44	0,28	0,31	0,14	0,64	0,47
Düşük Bitki	0,70	0,54	0,67	0,50	0,66	0,49	0,73	0,58
Geçirims. Y.	0,82	0,70	0,81	0,68	0,81	0,68	0,83	0,71
Araba	0,61	0,44	0,59	0,42	0,56	0,39	0,57	0,40
Çit	0,27	0,15	0,13	0,07	0,21	0,12	0,26	0,15
Çatı	0,92	0,86	0,92	0,85	0,93	0,87	0,93	0,87
Bina Ceph.	0,58	0,41	0,56	0,39	0,55	0,38	0,59	0,42
Çalı	0,46	0,30	0,46	0,30	0,44	0,28	0,47	0,31
Ağaç	0,79	0,65	0,79	0,65	0,80	0,65	0,79	0,65
Ağr.Ort.	0,78	0,64	0,76	0,63	0,79	0,66	0,79	0,66
GD (%)	77,70		76,48		76,31		78,75	


Tablo 13 incelendiğinde orijinal mimari ile adaptif yaklaşımlar arasında genel doğruluk en fazla yaklaşık %2 ve mIoU için maksimum %3 fark olmasına rağmen deneme yanılma yapılarak optimum parametrelerin elde edilmesi için harcanacak süre düşünüldüğünde adaptif yaklaşımların oldukça efektif olduğu söylenebilir. Uygulama 1 Model 3'te (20×20 m) elde edilen orijinal mimari sonuçları ile Adaptif 2 yaklaşımında 20×20 m (Model 3) sonuçları incelendiğinde önerilen yaklaşımın orijinal mimariye göre tüm doğruluk metriklerinde üstünlük sağladığı görülmektedir. Bu üstünlükler F1 ve mIoU metriklerinde elde edilen doğruluk artışı %5 iken ve genel doğruluk için artış yaklaşık %1 olmuştur. Adaptif yaklaşım 1 ve adaptif yaklaşım 2 ile ISPRS veri seti üzerinde orijinal sabit çerçeve boyutlu yaklaşım ile elde edilen en iyi modele kıyasla daha yüksek doğruluk değerleri elde edememiş olsa da segmentasyon sonuçları adaptif yaklaşım 2'nin veri içerisindeki değişken nokta yoğunluğu problemi ile başa çıkarak mimarinin çerçeve boyutu parametresine karşı daha sağlam hale getirildiğini göstermektedir.

Hata matrisi incelendiğinde Adaptif 2 yaklaşımında karşılaşılan hatalar en çok düşük bitki, geçirimsiz yüzey ve çalı sınıflarının birbiri ile karıştırılmasından kaynaklandığı görülmüştür. Ağaç sınıfında neredeyse %20 oranında çalı olarak sınıflandırıldığı görülmüştür. Genel olarak hem orijinal mimari için hem de adaptif yaklaşımlarda karşılaşılan hatalar bu sınıflar arasında meydana gelmektedir. Bu anlamda ISPRS veri setinde birbirine yakın sınıfların farklı etiketler ile temsil edilmesi böylesi küçük bir veri setinde mimari açısından yanıltıcı olmaktadır.

Adaptif 1 ve Adaptif 2 (20×20m) yaklaşımları ile elde edilen semantik segmentasyon sonuçları Şekil 29 ve hatalı nokta tespitleri Şekil 30'da gösterilmiştir.



Şekil 29. ISPRS veri seti üzerinde Adaptif 1 ve Adaptif 2 yaklaşımlarının semantik segmentasyon sonuçları



Şekil 30. Adaptif 1 ve Adaptif 2 yaklaşımları ile hatalı ve doğru tespit edilen noktalar

4.1.1. ISPRS Veri Seti Üzerinden Genel Bulgular

ISPRS 3B Semantik Etiketleme veri seti için mimari üzerinde gerçekleştirilen uygulamalar incelendiğinde elde edilen bulgular aşağıdaki gibi sıralanabilir:

- Öznitelik çıkarımı için mimarinin ilk katmanında küçük yarıçap kullanmanın mimarinin performansını olumsuz etkilediği gözlemlenmiştir. Elde edilen sonuçlar üzerinden, özellikle nokta yoğunluğu düşük veri setlerinde öznitelik çıkarımı için başlangıç yarıçapı olarak 1 m altında yarıçap önerilmemektedir.
- İlk seviyedeki yarıçap boyutu ve örneklenen nokta sayısı parametreleri nokta yoğunluğuna bağlı olarak seçilmesi mimarinin performansını olumlu yönde etkileyecektir.
- Optimum komşuluk arama yarıçapı yönteminin kullanılmasıyla başlangıç seviyesindeki yarıçap boyutunun belirlenmesi ve sonraki katmanlarda yarıçapın orijinal mimariye uygun olarak, ilk katmandaki yarıçapın iki katı olarak artırılması elde edilen en yüksek performans kazanımı ve deneme yanılmayı

azaltması nedenlerinden dolayı gelecekte yapılacak çalışmalar için tavsiye edilmektedir.

- Yarıçap boyutunun büyük seçildiği durumlarda nsample parametresi de hem nokta yoğunluğu hem de kullanılan bilgisayarın işleme kapasitesi dikkate alınarak büyük seçilebilir.
- Yarıçap boyutu, yarıçap merkez nokta sayısı (npoints), girdi nokta sayısı ve çerçeve boyutu parametreleri birbirleri ile doğrudan ya da dolaylı olarak ilişkili olduğundan dolayı birlikte değerlendirilerek belirlenmesi gereken parametrelerdir.
- Nokta örnekleme stratejinin değiştirilmesi ile mimarinin daha fazla benzersiz nokta ile eğitilmesine olanak sağlanmıştır.
- Önerilen adaptif yaklaşımların her ikisi de orijinal mimari için birçok deneme yanılma sonucu elde edilen doğruluklar ile karşılaştırıldığında özellikle IoU metrikleri arasındaki farkın az olmasından dolayı bu veri setinde de tercih edilebilir.
- Önerilen Adaptif 2 yaklaşım sonuçları ile mimarinin performansı çerçeve boyutu parametresine karşı daha hassas hale getirilmiştir.

ISPRS veri seti, nokta bulutlarının sınıflandırılması ya da semantik segmentasyonu işlemlerinin derin öğrenme ile gerçekleştirilmesi noktasında literatürde oldukça küçük bir veri seti olarak değerlendirilmektedir. Bundan dolayı da modele yönelik anlamlı olabilecek değişikliklerin yorumlanması açısından elverişli bir veri seti değildir. Bu yüzden hava LiDAR nokta bulutları üzerinde mimarinin ve özellikle önerilen yaklaşımların performanslarını değerlendirmek amacı ile benzer irdelemeler DALES veri seti üzerinde de gerçekleştirilmiştir.

4.2. DALES Veri Seti İçin Doğruluklar

Tez kapsamında DALES veri seti üzerinde Uygulama 1, Uygulama 2, Uygulama 3 ve Uygulama 4 olmak üzere dört farklı semantik segmentasyon işlemi gerçekleştirilmiştir. Uygulama 1, böylesi büyük ölçekli ve yoğun nokta bulutlarında PointNet++ mimarisinin uyarlanarak uygulanmasını ve bu uyarlamada mimari için girdi nokta sayısı ve npoints geometrik hiper-parametrelerinin modelin performansı üzerine etkilerini araştırmak için

gerçekleştirilmiştir. Uygulama 2, PointNet++ mimarisinde bulunan iki ayrı MRG ve MSG katmanlarının birleştirilerek yeni bir hibrit MSG+MRG yaklaşımın etkilerini araştırmak amacı ile uygulanmıştır. Yeni hibrit yaklaşımın etkileri hem elde edilen doğruluklar üzerinden ve hem de modelin çalışma süresi dikkate alınarak irdelenmiştir. Uygulama 3, büyük ölçekli hava LiDAR nokta bulutlarının eğitim, doğrulama ve test verilerinin hazırlanma aşaması olarak, büyük ölçekli nokta bulutlarının derin öğrenmede kullanılmadan önce alt bölümlere (tile) ayrılmasının önemini, mimarinin performansına olan etkileri üzerinden göstermek amacı ile gerçekleştirilmiştir. Son olarak Uygulama 4 ise, tez kapmasında önerilen adaptif çerçeve boyutu yaklaşımlarının orijinal sabit çerçeve boyutuna göre avantaj ve dezavantajlarının araştırılmasına yönelik olarak gerçekleştirilmiştir.

Bu bölümdeki uygulamalarda ilk seviyedeki komşuluk arama yarıçapı Bölüm 3.6’da açıklanan optimum komşuluk arama yönteminin sonucu olan 1 m olacak şekilde belirlenmiştir. Sonraki katmanların yarıçap değerleri ise başlangıç değerini iki katı alınarak 2, 4 ve 8 m olacak şekilde belirlenmiştir. Kullanılan parametreler aksi belirtilmediği sürece Tablo 3’teki parametrelerdir.

Uygulama 1: PointNet++ mimarisinin semantik segmentasyon modeli girdi nokta bulutlarından sabit bir çerçeve içerisinde n sayıda rastgele nokta örnekleyerek çalışmaktadır. Nokta bulutunun karakteristiğine bağlı olarak optimum çerçeve boyutunun seçilmesi, PointNet++ ve buna dayalı geliştirilen mimarilerin performansını hem doğrudan etkileyen hem de örneklenen nokta sayısı ve sınıf çeşitliliği gibi diğer parametreleri de dolaylı olarak etkileyen oldukça önemli bir parametredir. Optimum sabit çerçeve boyutunun bulunması ise çok sayıda deneme yanılma gerektiren oldukça zor ve zaman alıcı bir işlemdir. DALES veri setinin yoğun olması göz önüne alınarak sınıflar arası dengesizlik sorununu minimize edebilmek ve araziye yeterince iyi temsil edebilen anlamlı sahnelerin seçilebilmesi adına bu uygulamada çerçeve boyutu 30×30 m olarak seçilmiştir.

Girdi nokta sayısının (number of inputs) mimarinin performansına olan etkileri DALES veri seti üzerinde araştırılmıştır. PointNet++ mimarisinin semantik segmentasyon modelinde girdi nokta sayısı 8192 olarak işlenmektedir. Bu tez kapsamında, hem 8192 hem de 16384 girdi nokta sayısı ile eğitilen iki model üzerinden bu parametrenin etkileri araştırılmıştır. Kullanılan bilgisayarın bellek kapasitesi, bu değerlerin hesaplama verimliliğinden dolayı genellikle 2^n şeklinde artmasından dolayı daha yüksek değerler ile araştırılmasını sınırlandırmıştır. Bu uygulamada araştırılan diğer bir parametre ise npoints

parametresidir. PointNet++ mimarisinin semantik segmentasyon modelinde ilk katmanda 1024 olan npoints parametresi diğer katmanlarda $\frac{1}{4}$ oranında azaltılmaktadır. Bu tez çalışmasında da bu parametrenin hem varsayılan değerleri ile hem de ilk katmanda 2048'e artırılarak ile elde edilen doğruluklar üzerinden etkisi MRG katmanı kullanılarak araştırılmıştır. Tablo 14'te Model 1 ve Model 2'ye ait doğruluk değerleri ve parametre bilgileri verilmektedir.

Kullanılan mimariye yönelik geometrik parametrelerden girdi nokta sayısı, yarıçap (m), nsample ve her bir katmanda örneklenen nokta sayısı, çerçeve boyutları ile yığın sayısı hiperparametresi, her bir sınıf için ayrı ayrı elde edilen F1 ve IoU metrikleri ile genel doğruluk sonuçlarının yanı sıra eğitim süreleri ve en yüksek doğruluğun elde edildiği model için en iyi epok sayısı ve süreleri aşağıda Tablo 14'te verilmektedir. Uygulama 1'de kullanılan eğitim ve doğrulama veri setleri, DALES veri setinin 250×250 m alt bölümlere ayrılması ile hazırlanmıştır.

Tablo 14. MRG katmanı için DALES test veri seti üzerinde girdi nokta sayısı ve npoints parametresinin semantik segmentasyon doğruluğu üzerine etkileri

Log	Model 1		Model 2	
Çerçeve Boyutu (m)	30×30		30×30	
Girdi nokta s.	8192		16384	
Batch size	16		16	
Yarıçap (m)	1, 2, 4, 8		1, 2, 4, 8	
nsample	32, 32, 32, 32		32, 32, 32, 32	
Npoints	1024, 256, 64, 16		2048, 512, 128, 32	
Sınıf/ Ölçüt	F1	IoU	F1	IoU
Bilinmeyen	0,00	0,00	0,00	0,0014
Zemin	0,95	0,90	0,97	0,94
Bitki	0,89	0,80	0,92	0,84
Araba	0,31	0,18	0,42	0,27
Kamyon	0,00	0,00	0,00	0,00
Elektrik H.	0,66	0,50	0,86	0,76
Çit	0,05	0,03	0,28	0,16
Direk	0,00	0,00	0,26	0,15
Bina	0,88	0,79	0,93	0,87
Ağırlıklı Ort.	0,91	0,84	0,94	0,885
GD (%)	91,28		93,93	
Eğitim Süresi	10 s 20 dk		11 s 30 dk	
En iyi epok ve Süresi	185. epok; 9 s 37 dk		155. epok; 8 s 50 dk	

Tablo 14 incelendiğinde girdi nokta sayısının 8192'den 16384'e ve aynı zamanda alt örneklenen nokta sayısının da ilk katmanda 1024'ten 2048'e artırılması ile MRG katmanının tüm sınıflar üzerinde hem IoU hem de F1 metriklerinde daha yüksek doğrulukların elde edilmesini sağlamıştır. Nokta sayısı fazla olan sınıflardaki doğruluk artışının yanı sıra özellikle daha az nokta ile temsil edilen sınıflarda da önemli doğruluk artışları olmuştur. Özellikle araba, elektrik hattı, çit ve direk sınıflarındaki doğruluk artışı Tablo 14'te görülmektedir. Ayrıca Model 2 ile elde edilen F1 ve IoU metrikleri arasındaki farkın Model 1'e göre daha az olması, mimarinin sadece bu parametrelerin değiştirilmesi ile gerçek geometriye daha yakın tahminler gerçekleştirdiğini göstermektedir. Model 2 ile Model 1 kıyaslandığında F1 ölçütünün ağırlıklı ortalaması %91'den %94'e yükselirken ağırlıklı ortalama IoU doğruluğu %84'ten %88,5'e yükselmiştir. Model 1 ve Model 2'nin genel doğrulukları karşılaştırıldığında ise doğruluğun %91,28'den %93,93'e yükseldiği görülmüştür. Eğitim süreleri kıyaslandığında ise Model 2, Model 1'e göre 1 saat 10 dakika daha fazla sürede eğitilmiştir. Ancak Model 2'nin en iyi epok sayısına ve süresine ulaşması, diğer modele göre 30 epok daha erken ve yaklaşık 45 dakika daha erken gerçekleşmiştir.

Uygulama 2: PointNet++ mimarisinin iki ayrı katmandan oluştuğu Bölüm 3.3'te açıklanmıştır. MSG katmanının MRG katmanına göre daha yüksek doğruluk elde ettiği ancak daha yavaş olduğu Qi vd. (2017b) tarafından belirtilmiştir. Tez kapsamında bu iki katman birleştirilerek hibrit bir MSG+MRG model oluşturulmuştur. Yeni oluşturulan hibrit modelin üstünlükleri ve zayıflıkları, Uygulama 1'de kullanılan Model 1 yöntemine göre hem performans hem de eğitim süreleri göz önünde bulundurularak karşılaştırılmıştır. Orijinal MRG modeli için mimari dört adet SA katmanından oluşmaktadır. Bu nedenle orijinal mimari ile aynı katman sayısını korumak amacı ile Hibrit Model 1'de ilk MSG katmanında yarıçaplar [1, 2] olarak seçilmiş ve ardından 3 adet MRG katmanı sabit tutulmuştur. Bu 3 MRG katmanı için yarıçaplar 4, 8 ve 12 m olarak seçilmiştir. Burada son katman için yarıçapın 16 m yerine 12 m olarak seçilmesinin nedeni seçilen yarıçapın çerçeve boyutunu aşmamasını sağlamak içindir. Hibrit Model 2 ise, hem mimarinin MLP katman derinliğini azaltmak hem de Hibrit Model 1'deki son yarıçap ile haksız bir performans kazanımının sağlanıp sağlanmadığını kontrol etmek amacı ile Model 1'de seçilen yarıçaplar kullanılmıştır. MRG ve hibrit yaklaşımlar için elde edilen test doğrulukları Tablo 15'te gösterilmektedir. Eğitim ve doğrulama verileri, DALES veri setinin 100×100 m alt bölümlere ayrılması ile hazırlanmıştır.

Tablo 15. MRG, MSG+MRG hibrit yöntemin DALES test veri seti üzerindeki doğrulukları

Log	Model 1		Hibrit Model 1		Hibrit Model 2	
Çerçeve Boyutu (m)	30×30		30×30		30×30	
Yarıçap (m)	1, 2, 4, 8		[1, 2], 4, 8, 12		[1, 2], 4, 8	
nsample	32, 32, 32, 32		[32, 32], 32, 32,32		[32, 32], 32, 32	
MLP Katmanları	varsayılan		[[64, 64, 128] [64, 96, 128]], [64, 64, 128], [128, 128, 256], [256, 256, 512]		[[64, 64, 128] [64, 96, 128]], [64, 64, 128], [128, 128, 256]	
Npoints	1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64	
SINIF/ ÖLÇÜT	F1	IoU	F1	IoU	F1	IoU
Bilinmeyen	0,05	0,024	0,09	0,05	0,24	0,14
Zemin	0,96	0,93	0,97	0,95	0,97	0,94
Bitki	0,91	0,84	0,93	0,86	0,93	0,87
Araba	0,69	0,53	0,80	0,67	0,82	0,69
Kamyon	0,11	0,06	0,17	0,09	0,21	0,12
Elektrik H.	0,84	0,73	0,88	0,78	0,91	0,83
Çit	0,42	0,27	0,51	0,34	0,63	0,46
Direk	0,29	0,17	0,51	0,34	0,61	0,43
Bina	0,92	0,86	0,96	0,92	0,94	0,89
Ağırlıklı Ort.	0,93	0,88	0,95	0,91	0,95	0,90
GD (%)	93,90		95,51		95,05	
Eğitim Süresi	14 s 20 dk		14 s		13 s 16 dk	
En İyi Epok ve Süresi	190. epok; 13 s 36 dk		135. epok; süre: 9s 48 dk		155. epok; 10s 18 dk	

Model 1'e kıyasla, Hibrit Model 1 ve Hibrit Model 2 ile tüm sınıflarda daha yüksek doğruluklar elde edilmiştir. Model 1 ve Hibrit Model 1 karşılaştırıldığında, tüm sınıflar için ağırlıklı ortalama F1 ölçütü ve IoU metriklerinde sırası ile %2, %6 daha yüksek doğrulukların elde edildiği görülmektedir. Genel doğruluğun ise yaklaşık %2 iyileştiği gözlemlenmiştir. İlk katmanda çok daha fazla sayıda noktadan [1, 2] m komşuluk arama yarıçaplarında özneteliklerin elde edilmesinin katkısı Tablo 15'te tüm sınıflar üzerinde görülmektedir. Zemin sınıfı her ne kadar her üç yöntemde F1 ölçütü değeri %96 ve %97 gibi yüksek doğrulukta elde edilmiş olsa da hibrit yöntemlerin IoU metrik değerinin %95 ve %94 olması ve F1 ölçütü ve IoU arasındaki farklarının Model 1'e göre daha düşük olması hibrit yöntemlerin Model 1'e göre daha tutarlı olduğunu göstermektedir. Model 1'e kıyasla özellikle bina sınıfında hibrit yöntemlerdeki IoU doğruluğu %6'a varan iyileşme göstermiştir. Elektrik hattı sınıfı IoU metriği üzerinden değerlendirildiğinde %10 daha

yüksek sonuç ile elde edilirken, bitki sınıfı için IoU doğruluk artış miktarı en fazla %3 olmuştur. Hibrit modeldeki çit ve direk sınıflarındaki artış miktarı ise F1 ölçütü üzerinden hibrit modellerin her ikisi üzerinden değerlendirince en fazla %21 ve %32 olurken IoU metriği üzerinden doğruluk artışı %19 ve %26 olmuştur. Kamyon sınıfı ise nokta bulutunda çok az sayıda bulunmasından kaynaklı olarak her üç yöntemde düşük olmasına rağmen en yüksek doğruluklar hibrit model 2 ile elde edilmiştir. En iyi modele ulaştıkları epok sayıları ve süreleri hibrit yöntemler için birbirlerine oldukça yakın olduğu görülürken Model 1 bu iki yönteme göre daha yavaş çalışmıştır. Bu üç yaklaşımın eğitim süreleri, eğitim esnasında işletim sistemin arka plan işlemlerinden de etkileneneği için gerçek işlem süresini yansıtmamaktadır ancak fikir oluşturulması açısından paylaşılmıştır.

Hibrit Model 1 ve Hibrit Model 2 kıyaslandığında ise, hemen hemen aynı doğruluk değerlerinin elde edildiği görülmektedir. Hibrit model 1'de son katmanda 12 m yarıçap kullanılmasının sadece bina sınıfının F1 ve IoU doğruluklarını %2 ve %3 iyileştirdiği görülmektedir.


Uygulama 3: Büyük ölçekli hava LiDAR nokta bulutlarının derin öğrenme yöntemleri ile semantik segmentasyonunda bu veriler mekânsal olarak çok büyük alanları kapsayabileceklerinden dolayı eğitim verisi hazırlarken hem bilgisayar hesaplama gücü ve belleği açısından hem de modelin daha fazla örnek ile beslenmesini sağlamayabilmek adına bu verileri alt parçalara ayırarak işlemek gerekmektedir. Hava LiDAR nokta bulutlarının PointNet++ mimarisi ile semantik segmentasyonu görevinde, mimarinin rastgele nokta seçimi ile yığın (batch) toplamasından dolayı bu büyük ölçekli veri setlerinin alt bölümlere ayrılarak işlenmesi mimarinin daha fazla örnek ile eğitilmesine olanak sağlamaktadır. Bu durum, orijinalde 500×500 m olan DALES verisinin, 250×250 m ve 100×100 m boyutlarına alt bölümlendirilmiş iki farklı veri setleri üzerinde semantik segmentasyon işlemi gerçekleştirilerek araştırılmıştır. Adil bir karşılaştırma yapabilmek adına bu iki veri seti aynı parametreler ile eğitilmiş ve test edilmiştir. Uygulama hem uyarlanmış MRG katmanı kullanılarak hem de yeni hibrit model üzerinde test edilmiştir. İki veri seti için elde edilen doğruluklar aşağıda Tablo 16'da verilmektedir. Hibrit modeller için kullanılan MLP katmanları Uygulama 2 ile aynı derinlik ve genişliktedir.

Tablo 16. 250×250 m ve 100×100 m tile boyutlarının MRG katmanı (Model 1, Model 2) ve Hibrit Model 1 ve 2 üzerindeki test doğrulukları

Log	Model 1		Model 2		Hibrit Model 1		Hibrit Model 2	
Tile boyutu (m)	250×250		100×100		250×250		100×100	
Çerçeve Boyutu (m)	30×30		30×30		30×30		30×30	
Girdi nokta	8192		8192		8192		8192	
Batch size	16		16		16		16	
Yarıçap (m)	1, 2, 4, 8		1, 2, 4, 8		[1, 2], 4, 8,12		[1, 2], 4, 8,12	
nsample	32, 32, 32, 32		32, 32, 32, 32		[32, 32], 32, 32,32		[32, 32], 32, 32,32	
Npoints	1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ ÖLÇÜT	F1	IoU	F1	IoU	F1	IoU	F1	IoU
Bilinmeyen	0,00	0,00	0,05	0,024	0,01	0,005	0,09	0,05
Zemin	0,95	0,90	0,96	0,93	0,97	0,94	0,97	0,95
Bitki	0,89	0,80	0,91	0,84	0,92	0,84	0,93	0,86
Araba	0,31	0,18	0,69	0,53	0,62	0,45	0,80	0,67
Kamyon	0,00	0,00	0,11	0,06	0,00	0,00	0,17	0,09
Elektrik H.	0,66	0,50	0,84	0,73	0,85	0,75	0,88	0,78
Çit	0,05	0,03	0,42	0,27	0,41	0,26	0,51	0,34
Direk	0,00	0,00	0,29	0,17	0,31	0,18	0,51	0,34
Bina	0,88	0,79	0,92	0,86	0,95	0,90	0,96	0,92
Ağırlıklı Ort.	0,91	0,84	0,93	0,88	0,94	0,895	0,95	0,91
GD (%)	91,28		93,90		94,52		95,51	
Eğitim süresi	10 s, 20 dk		14 s, 20 d		10 s, 25 dk		14 s	
En iyi epok ve süresi	185. epok; 9 s 37 dk		190. epok; 13 s 36 dk		190. Epok; 9 s 50 dk		135. epok; süre: 9s 48 dk	


Büyük ölçekli nokta bulutlarının alt bölümlere (tile) ayrılmasının etkisi 250×250 m ve 100×100 m’lik nokta bulutu boyutları üzerinden irdelenmiştir. 100×100 m boyutlu veri seti üzerinde tüm sınıflar için elde edilen F1 ve IoU doğruluk değerleri, 250×250 m’lik veri seti ile elde edilen sonuçlara göre hem MRG katmanı için hem de hibrit model için daha yüksek doğrulukta elde edilmiştir. Ayrıca böylesi büyük nokta bulutlarını parçalara ayırarak işlemenin en büyük katkısının Tablo 18’den anlaşılabileceği üzere az sayıda nokta ile temsil edilen kamyon, araba, elektrik hattı, direk ve çit gibi sınıfların mimari tarafından görülebilirliğini artırdığı söylenebilir. Özellikle kamyon sınıfı için F1 ve IoU metrikleri 250×250 m’lik veri setinde her iki model için %0 çıkarken; 100×100 m’lik veri seti üzerinde MRG katmanı için sırası ile %11 ve %6; hibrit yaklaşım için %17 ve %9 olarak elde edilmiştir. Doğruluklar her ne kadar düşük elde edilmiş olsa da bu durum şunu

göstermektedir ki nokta bulutunun daha küçük parçalara ayrılarak işlenmesi durumunda mimarinin eğitim esnasında görebilecek olduğu sınıf çeşitliliği artmaktadır. Çünkü PointNet++ mimarisi eğitim aşamasında eğitim nokta bulutlarından rastgele seçtiği bir noktayı merkez kabul ederek bu nokta etrafına sabit boyutlu bir çerçeve yerleştirmekte ve bu çerçevenin içinden girdi nokta sayısı kadar rastgele nokta seçerek yığınlar (batch) oluşturur. Bunun sonucunda da tile boyutu arttıkça örnek toplayabilecek olduğu daha geniş bir alan olduğundan dolayı epok sayısı boyunca bu nokta bulutlarının (tile) tamamını kapsayacak kadar örnek toplayamamaktır. Bu sorunu çözmek için uygulanabilecek üç farklı yaklaşım sunulabilir. Bunlardan ilki bu tez kapsamında da uygulandığı üzere veriyi 250×250 m veya 100×100 m gibi daha küçük parçalara ayırmaktadır. İkinci bir yaklaşım olarak epok sayısı artırılarak mimarinin daha fazla nokta ile eğitilmesi sağlanabilir. Üçüncü bir yaklaşım olarak ise mimarinin eğitim aşamasında kullandığı yığın toplama stratejisi değiştirilebilir. Bu yaklaşımlardan epok sayısını artırma yaklaşımı, zaten uzun olan eğitim süresini daha da uzatacağı için çok tercih edilebilir bir yaklaşım değildir. Dahası bu yaklaşım, mimari rastgele nokta seçimi ile yığın oluşturmaya devam edeceği için az sayıda nokta içeren sınıfların yeterince görülebileceğini garanti edemez. Diğer yandan mimarinin rastgele yığın toplama stratejisinin düzenli bir yığın toplama stratejisi ile değiştirmek ise, mimarinin sürekli benzer hatta aynı örnekler ile eğitilmesine neden olarak aşırı-uyma ve genelleştirme problemlerine yol açacaktır. Ancak alt parçalara ayırma yaklaşımında dikkat edilmesi gereken önemli noktalardan bir tanesi çok küçük parçalara ayırarak mimarinin hareket alanının kısıtlanmaması gerektiğidir. Aksi halde sürekli aynı yığınlar ile eğitileceği için mimaride yine aşırı uyma problemi meydana gelmesi muhtemel olacaktır. Diğer bir önemli nokta ise, bu yöntemde de mimari daha fazla nokta ile eğitileceği için eğitim süresinin artacağıdır. Bu durum yapılan uygulamalardan da görüleceği üzere, 201 epok için 250×250 m'lik veri seti ile hibrit model 10 saat 25 dakikada eğitilirken; aynı epok sayısı için 100×100 m boyutlarındaki veri seti için eğitim 14 saat devam etmiştir. MRG katmanında ise bu durum, 100×100 m nokta bulutlarından oluşan veri ile eğitimin 4 saat daha uzun sürmesi ile sonuçlanmıştır. Hibrit modelde, 201 epok boyunca mimarinin en iyi doğruluğa ulaştığı epok sayısı ve süreleri incelendiğinde, 250×250 m'lik veri setinde bu değerler sırası ile 190. epok ve 9 saat 50 dakika iken, 100×100 metrelik veri setinde 135. epok ve 9 saat 48 dakika olmuştur. MRG katmanında ise bu fark eğitim süre farkına paralel olarak yaklaşık 4 saattir. Uygulanan dört model üzerinde elde edilen genel doğruluklar Şekil 31'de verilmektedir.



Şekil 31. DALES veri seti üzerinde uygulanan dört model için elde genel doğruluk değerleri

Bu dört model sonuçları bütün olarak değerlendirildiğinde, DALES veri setinin semantik segmentasyonu için en yüksek GD, ortalama F1 ve ortalama IoU doğruluk değerleri Uygulama 3 Tablo 16’da gösterilen Hibrit Model 2 ile elde edilmiştir. Ayrıca tüm sınıflar için en yüksek F1 ve IoU metrikleri yine Hibrit Model 2 ile elde edilmiştir. Hibrit Model 2’ye ait semantik segmentasyon sonuçları, referans verileri ve hatalı tespit edilen noktalar aşağıda Şekil 32’de örnek olarak beş adet test verisi üzerinden verilmektedir.



Şekil 32. DALES verisi için semantik segmentasyon sonuçları ve hatalı tespitler

Uygulama 4: Bu uygulamada tez kapsamında önerilen eğitim işlemi esnasında girdi nokta bulutunun özelliklerine göre çerçeve boyutunu adapte edebilen adaptif çerçeve boyutu yaklaşımları DALES verisi üzerinde test edilmiştir (Tablo 17).

Tablo 17. DALES veri seti üzerinde Adaptif 1 ve Adaptif 2 yaklaşımları ile elde edilen doğruluklar

LOG	Adaptif 1		Adaptif 2	
Çerçeve Boyutu (m)	Otomatik		30×30-Adaptif 2	
Girdi nokta	8192		8192	
Batch size	16		16	
Yarıçap (m)	0,1, 0,2, 0,4, 0,8		1, 2, 4, 8	
nsample	32, 32, 32,32		32, 32, 32,32	
Npoints	1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ ÖLÇÜT	F1	IoU	F1	IoU
Bilinmeyen	0,00	0,00	0,00	0,00
Zemin	0,96	0,93	0,97	0,94
Bitki	0,92	0,86	0,93	0,86
Araba	0,68	0,52	0,73	0,58
Kamyon	0,18	0,01	0,22	0,12
Elektrik H.	0,85	0,74	0,88	0,79
Çit	0,53	0,36	0,51	0,34
Direk	0,47	0,31	0,49	0,32
Bina	0,92	0,85	0,93	0,87
Ağr.Ort.	0,93	0,87	0,94	0,90
GD (%)	94,26		94,83	

Tablo 17 incelendiğinde, Adaptif 2 yaklaşımının Adaptif 1 yaklaşımına göre her üç doğruluma metriği için de daha yüksek sonuçlar elde ettiği gözlemlenmiştir. Her ne kadar genel doğrulukları birbirine oldukça yakın sonuçlar elde etmiş olsa da IoU metriğinde Adaptif 2 yaklaşımı %3 daha iyi performans göstermiştir. Her bir sınıf için ayrı ayrı incelendiğinde Adaptif 2 yaklaşımının çit sınıfı hariç diğer tüm sınıflar üzerinde daha yüksek doğruluk değerleri elde ettiği gözlemlenmiştir. Özellikle daha az nokta ile temsil edilen kamyon, direk ve araba sınıflarında Adaptif 2 yaklaşımının daha başarılı sonuçlar elde ettiği görülmektedir.

Bu yaklaşımları test etmek amacı ile yoğunluğu hem yüksek hem de nispeten düzenli olan DALES veri setinden rastgele seçilen bazı veri kümeleri octree yöntemi ile alt örneklenerek düzensiz_DALES veri seti oluşturulmuştur. Yeni oluşturulan veride alt örneklenen nokta bulutlarının yoğunlukları 1, 3, 5, 10, 12, 26 ve 32 nkt/m² gibi değişkenlik gösteren değerler almıştır. Elde edilen yeni düzensiz_DALES veri setinin ortalama nokta yoğunlukları, içerdikleri nokta sayıları ve azaltılma oranlarına dair detaylar Tablo 18’de verilmiştir.

Tablo 18. Alt örneklenmiş düzensiz_DALES veri seti

düzensiz_DALES	Eğitim verisi	Doğrulama verisi	Test verisi
Ort. nokta yoğunluğu	29,35 nkt/m ²	36,8 nkt/m ²	27,9 nkt/m ²
Nokta sayısı	170204607	53449465	76775729
Azaltma oranı (%)	~ 42	~ 28	~ 44

30×30 m ve 50×50 m olmak üzere iki farklı çerçeve boyutlarında düzensiz_DALES veri seti üzerinde MRG katmanı kullanılarak hem sabit çerçeve boyutlu orijinal PointNet++ mimarisi hem de adaptif yaklaşımların uygulandığı PointNet++ mimarileri eğitilerek elde edilen test doğrulukları Tablo 19’da verilmiştir. Bu uygulamada DALES veri seti 100×100 m boyutlarına ayrılarak kullanılmıştır.

Tablo 19. Düzensiz_DALES veri seti üzerinde sabit çerçeve boyutu ve önerilen adaptif çerçeve boyutu yaklaşımları ile elde edilen doğruluklar

LOG	MRG-sabit		MRG-sabit		MRG-Adaptif 1		MRG-Adaptif 2		MRG-Adaptif 2	
Çerçeve Boyutu (m)	30×30		50×50		Adaptif 1		30×30-Adaptif 2		50×50-Adaptif 2	
Girdi nokta	8192		8192		8192		8192		8192	
Batch size	16		16		16		16		16	
Yarıçap (m)	1, 2, 4, 8		1, 2, 4, 8		0,1, 0,2, 0,4, 0,8		1, 2, 4, 8		1, 2, 4, 8	
nsample	32, 32, 32,32		32, 32, 32,32		32, 32, 32,32		32, 32, 32,32		32, 32, 32,32	
Npoints	1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16		1024, 256, 64, 16	
SINIF/ÖLÇÜT	F1	IoU	F1	IoU	F1	IoU	F1	IoU	F1	IoU
Bilinmeyen	0,01	0,007	0,01	0,007	0,11	0,06	0,08	0,044	0,03	0,02
Zemin	0,96	0,92	0,89	0,81	0,97	0,94	0,97	0,94	0,96	0,93
Bitki	0,91	0,83	0,85	0,73	0,92	0,86	0,92	0,85	0,91	0,84
Araba	0,58	0,41	0,22	0,12	0,71	0,56	0,74	0,58	0,78	0,56
Kamyon	0,08	0,04	0,00	0,00	0,01	0,003	0,08	0,04	0,01	0,003
Elektrik H.	0,80	0,67	0,43	0,28	0,78	0,63	0,85	0,73	0,76	0,61
Çit	0,36	0,22	0,14	0,08	0,51	0,34	0,50	0,34	0,47	0,31
Direk	0,30	0,17	0,05	0,02	0,47	0,31	0,54	0,37	0,47	0,30
Bina	0,92	0,86	0,73	0,57	0,94	0,88	0,95	0,90	0,93	0,88
Ağr.Ort.	0,92	0,87	0,83	0,74	0,94	0,88	0,94	0,90	0,93	0,88
GD (%)	92,70		86,12		94,00		94,36		93,55	

Sabit çerçeve boyutuna kıyasla, önerilen adaptif çerçeve boyutu belirleme yöntemleri ile tüm sınıflarda daha yüksek doğruluklar elde edilmiştir. Önerilen yaklaşımlardan Adaptif 2 yaklaşımı (30×30 m) ile nokta bulutunda daha az nokta ile temsil edilen araba, elektrik hattı, çit ve direk sınıflarında sabit çerçeve boyutlu yaklaşıma göre (orijinal 30×30 m) F1 ölçütünde sırası ile %16, %5, %14 ve %24; IoU metriğinde %17, %6, %12 ve %20 doğruluk artışı sağlanmıştır. Zemin, bitki ve bina sınıfında Adaptif 2 yaklaşımı ile IoU metriğinde %2 ile %4 arasında daha yüksek doğruluklar elde edilmiştir. Önerilen adaptif 1 ve Adaptif 2 (30×30 m) yaklaşımları ile elde edilen genel doğruluklar orijinal yaklaşıma göre yaklaşık %2 daha yüksek elde edilmiştir. Adaptif 2 yaklaşımı (30×30) ile tüm sınıflar için ağırlıklı ortalama IoU değerinde %3 artış gözlemlenmiştir.


Ayrıca Adaptif 2 yaklaşımı için başlangıç çerçeve boyutu 50 m seçildiğinde de önerilen yöntem ile orijinal mimariye göre daha yüksek doğrulukların elde edildiği gözlemlenmiştir. Bu sonuç, Adaptif 2 yaklaşımının başlangıç çerçeve boyutunun hassas bir şekilde belirlenmesine ihtiyaç duymadığını göstermektedir. Çerçeve boyutu seçimine karşı mimarinin hassasiyetini gösterebilmek adına ayrıca orijinal mimari de 50×50m boyutlarındaki çerçeve boyutları ile test edilmiştir. Çerçeve boyutunun artırıldığı orijinal mimaride ağırlıklı ortalama F1, mIoU ve genel doğruluk değerleri model 1'e göre %9, %13 ve yaklaşık %7 daha düşük elde edilmiştir. Adaptif 2 yaklaşımı ile mimarinin optimum çerçeve boyutundan sapmaları daha iyi tolere edebildiği gözlemlenirken orijinal yaklaşımın bu sapmayı tolere etmekte zorlandığı görülmektedir. Şekil 33'te orijinal yaklaşım ile önerilen adaptif yaklaşımların GD ve ağırlıklı ortalama IoU doğruluk değerleri verilmektedir.



Şekil 33. Orijinal, Adaptif 1 ve Adaptif 2 (30×30) PointNet++ mimarilerinin düzensiz_DALES veri setleri üzerindeki GD ve ağırlıklı ortalama IoU doğruluklarının karşılaştırılması

Şekil 33 incelendiğinde önerilen her iki yöntemin de orijinal mimariye göre daha yüksek doğruluklar ile semantik segmentasyon görevini yerine getirdikleri görülmektedir. Adaptif 2 yaklaşımı ise veri içindeki değişken nokta yoğunluklarına göre kendini adapte edebilmesinden dolayı özellikle IoU metriği özelinde daha yüksek performans gösterdiğini söylenebilir. Son olarak, daha yüksek doğrulukların elde edildiği Adaptif 1 ve Adaptif 2


yaklaşımları ile orijinal PointNet++ mimarisi hem DALES hem de düzensiz_DALES verileri üzerinde test edilerek mimarilerin değişken nokta yoğunluğuna karşı sağlamlıkları IoU doğruluk değerleri üzerinden araştırılmıştır. Bu karşılaştırma grafiği Şekil 34'te verilmektedir.




Şekil 34. Orijinal yaklaşım, Adaptif 1 ve Adaptif 2 PointNet++ mimarilerinin DALES ve düzensiz_DALES veri setleri üzerindeki ağırlıklı ort. IoU doğruluklarının karşılaştırması

Şekil 34'te orijinal mimarinin eğitildiği modeller karşılaştırıldığında veri eksiltilerek değişken nokta yoğunluğuna getirilen model üzerinde ağırlıklı ortalama IoU metriğinde %1 düşüş gerçekleşmiştir. Bu doğruluk kaybı genel doğruluk ve F1 için de Tablo 19 ve Tablo 16 karşılaştırıldığında benzer seviyelerde olduğu gözlemlenmiştir. Adaptif 1 yaklaşımı ise DALES veri seti üzerinde orijinal yaklaşıma göre %1 daha düşük doğruluk vermiş olsa da nokta yoğunluğu değişkenliği artırıldığında orijinal yaklaşıma göre daha yüksek sonuçlar elde ettiği gözlemlenmiştir. Adaptif 2 yaklaşımının ise veri setindeki nokta yoğunluğu azaltılarak veri eksiltilmesine rağmen performansını koruduğu görülmektedir. Elde edilen sonuçlardan da anlaşılacağı üzere, önerilen yaklaşımların PointNet++ mimarisini veri içi ve veriler arasındaki nokta yoğunluğu değişimine karşı daha kararlı hale getirmesinin yanı sıra, tüm sınıflar için mimarinin doğruluğunu da artırmıştır. Nokta örnekleme bozulduğunda verinin de eksiltilmesi ile orijinal mimari ile %1 doğruluk kaybı yaşanırken Adaptif 2 yaklaşımı ile elde edilen doğruluklar korunmuştur.

Adaptif 1 ve Adaptif 2 çerçeve boyutu yaklaşımları için ile elde edilen semantik segmentasyon sonuçları aşağıda örnek test veri setleri üzerinden Şekil 35 ve 36'da verilmektedir.



Şekil 35. Düzensiz DALES veri setinde Adaptif 1 yaklaşım sonuçları



Şekil 36. Düzensiz DALES veri setinde Adaptif 2 yaklaşım sonuçları

Önerilen yaklaşımın veri içi ve veriler arası nokta yoğunluğu varyasyonuna karşı mimari daha kararlı hale getirmesine dair bir diğer örnek ise 100×100 tile boyutları ile orijinal DALES veri setinde eğitilen sabit çerçeve boyutlu mimariye (Uygulama 3 Model

2) göre alt örneklenmiş veriye rağmen kamyon ve elektrik hattı sınıfları hariç diğer tüm sınıflarda F1 ve IoU metriklerinde daha yüksek doğrulukların elde edilmesidir. Elektrik hattı sınıfında aynı IoU değeri elde edilmiştir. Veri kaybına rağmen, IoU değerleri karşılaştırıldığında ise bina sınıfında orijinal mimariye (Uygulama 3 Model 2) göre %2 iyileşme görülmüştür.

Ayrıca, Uygulama 1'deki orijinal DALES veri setinin 250×250 metre boyutlarındaki tilelar ile eğitilen model (model 1), Uygulama 4'te alt örneklenmiş düzensiz_DALES veri setinin 100×100 m tile boyutları ile eğitilen modele (MRG-sabit) göre tüm sınıflar için daha düşük doğruluk değerlerine sahiptir. Bu değerler verinin yaklaşık %40'ı atılmış olmasına rağmen elde edilen doğruluklardır. Bu sonuçlardan anlaşılabileceği üzere ALS nokta bulutlarını parçalara ayırarak işlemek mimarinin çok daha fazla nokta görmesini sağlamaktadır. Nokta sayısı fazla olan sınıflardaki iyileşmelerin yanı sıra bu yaklaşımın en büyük katkısının nokta sayısı az olan sınıflar üzerinde olduğu da gözlemlenmiştir. Mimari tarafından nokta sayısı az olan sınıfların eğitim aşamasında daha fazla görülmesi sonucunda segmentasyon doğrulukları kamyon, araba, çit, elektrik hattı ve direk sınıflarında artırılmıştır. Özellikle kamyon ve direk sınıflarının Uygulama 1 altında model 1'deki doğrulukları %0 iken; Uygulama 4 MRG-sabit modelinde %8 ve %30 olarak elde edilmiştir.

Hata matrisleri incelendiğinde mimarinin DALES veri setinde genel olarak orijinal mimarideki tüm modellerde zemin sınıfındaki hatalı tespitlerin büyük bir kısmını bitki ve bina sınıfları oluşturmaktadır. Araba sınıfının da en çok bitki sınıfı ile karıştığı gözlemlenmiştir. Kamyon sınıfındaki hatalı tespitler de çoğunlukla araba, bitki ve bina sınıfı olarak etiketlenmiştir. Elektrik hattı sınıfındaki hatalı tespitlerinde ağırlıklı olarak çatı ve bitki sınıfları ile karıştırıldığı gözlemlenmiştir. Çit sınıfının ise ağırlıklı olarak bitki sınıfı ile karıştırıldığı gözlemlenmiştir. Adaptif yaklaşımların hata matrisi incelendiğinde ise bu sınıf karışıklığının benzer karakteristikte olduğu tespit edilmiştir. Her iki yöntemde de göze çarpan en belirgin hata ise özellikle çok büyük ve düz çatılarda binaların merkezine doğru yaklaşıldıkça buradaki noktaların zemin olarak sınıflandırılmış olmasıdır. Bu durum OpenGF veri seti üzerinde de irdelenecektir.

4.2.1. DALES Veri Seti Üzerinden Genel Bulgular

DALES veri seti üzerinde gerçekleştirilen uygulamalar incelendiğinde mimari hakkında elde edilen genel bulgular aşağıdaki gibi sıralanabilir:

- Girdi nokta sayısı ve öznitelik çıkarımında merkez nokta sayısını da temsil eden npoints parametresinin artırılması sahnenin daha çok nokta ile temsil etmesine olan katkısından dolayı mimarinin performansını olumlu etkilemekte ve özellikle daha az nokta ile temsil edilen sınıfların daha yüksek doğruluklarda tespit edilmesine olanak sağlamıştır.
- Tez kapsamında önerilen hibrit yaklaşım sayesinde sadece ilk katmana MSG katmanının eklenmesi ile mimarinin performansının hem iyileştirildiği hem de F1 ve IoU metrikleri üzerinden sonuçların daha tutarlı olduğu gözlemlenmiştir. Semantik segmentasyon işlemindeki böylesi yüksek doğruluk kazanımları düşünüldüğünde ise eğitim süreleri arasındaki zaman farkı kabul edilebilir sınırlar içerisinde değerlendirilmiştir.
- Hibrit yaklaşım ve MRG katmanına ait semantik segmentasyon sonuçları karşılaştırıldığında hibrit yaklaşımın F1 ve IoU metrikleri üzerinden daha tutarlı olduğu görülmüştür.
- Nokta bulutlarının alt bölümlere ayrılarak işlenmesi sayesinde mimarinin az nokta ile temsil edilen sınıflardan nokta görme olasılığı artırıldığı için bu sınıflarda elde edilen doğrulukların iyileştirilebileceği gözlemlenmiştir. Ancak bu durumda eğitim süresi de artmaktadır.
- Veri eksilterek nokta yoğunluğu değişken hale getirildiğinde orijinal mimarinin performansının düştüğü ancak Adaptif 1 ve Adaptif 2 yaklaşımlarında doğruluğun korunduğu gözlemlenmiştir.
- Adaptif yaklaşım 2 Adaptif yaklaşım 1'e göre veri içindeki değişimlere adapte olmasından dolayı semantik segmentasyon görevini daha başarılı bir şekilde yerine getirmiştir.
- DALES veri seti üzerinde Adaptif 2 yaklaşımı ile daha yüksek doğruluk değerleri elde edilmiştir ancak eğitim süresinin daha uzun sürdüğü görülmüştür.
- Hibrit model ile Adaptif 2 yaklaşımı karşılaştırıldığında veri eksiltilmesine rağmen hemen hemen aynı doğrulukların elde edildiği görülmüştür.

- Orijinal PointNet++ mimarisi, verinin eksiltiyle düzensiz nokta yoğunluklu hale getirilmesine karşı sağlamlığını koruyamazken, Adaptif 2 yaklaşımı performansını korumaktadır.
- Nokta bulutlarının semantik segmentasyonu çalışmalarında öncü bir mimari olarak kabul gören PointNet++ mimarisi nokta yoğunluğu değişimlerine karşı daha sağlam hale getirilmiştir.
- Nokta örnekleme düşük olan sınıflarda elde edilen doğruluk artışı önerilen yaklaşım ile hava LiDAR nokta bulutlarında karşılaşılan ve düzeltilmesi mümkün olmayan sınıf dengesizliği (class imbalance) probleminin azaltılmasında da başarılı olduğunu göstermektedir.
- Adaptif 1 yaklaşımın sonuçlarının DALES verisine göre düzensiz_DALES verisi üzerinde daha yüksek sonuçlar elde etmesi, nokta yoğunluğu değişkenliğinin daha fazla olduğu durumlarda bu yaklaşımın daha yüksek doğruluklar elde edildiğini göstermektedir.
- Adaptif 2 yaklaşımı ile mimarinin optimum çerçeve boyutundan sapmaları daha iyi tolere edebildiği gözlemlenirken orijinal yaklaşımın bu sapmayı tolere etmekte zorlandığı görülmektedir.
- Mimarinin özellikle çok büyük ve düz çatılarda binaların merkezine doğru yaklaşıldıkça buradaki noktaları zemin olarak sınıflandırıldığı gözlemlenmiştir. Bunun nedeni olarak veride yeterince büyük yapıda bina bulunmaması ya da çerçeve boyutu parametresinin büyük bir yapıyı kapsayacak kadar geniş olmamasından kaynaklandığı düşünülmektedir.

4.3. OPENGF Veri Seti İçin Doğruluklar

Değişken nokta yoğunluğuna sahip veriler için önerilen nokta yoğunluğuna adaptif çerçeve boyutu seçimi yaklaşımlarının performansları OpenGF veri seti üzerinde zemin ve zemin üstü sınıflarının semantik segmentasyonu işlemi üzerinde test edilmiştir. Bu amaçla Uygulama 1, Uygulama 2 ve Uygulama 3 olmak üzere üç farklı semantik segmentasyon uygulaması gerçekleştirilerek Test 1, Test 2 ve Test 2_gürültüsüz nokta bulutları üzerindeki test doğrulukları üzerinden irdelenmeler gerçekleştirilmiştir. Uygulama 1, PointNet++ mimarisinin zemin filtreleme işlemi için böylesi büyük ölçekli nokta bulutları

üzerindeki uygulanabilirliğini göstermek amacı ile gerçekleştirilmiştir. Optimum çerçeve boyutu, veri setinin nokta yoğunluğu değişkenliğinin fazla olmasından dolayı araştırılmamıştır. Bu bölümde, değişken nokta yoğunluğuna sahip veri seti üzerinde, Adaptif 1 ve Adaptif 2 çerçeve boyutu seçimi yaklaşımlarını test etmek için Uygulama 2 ve Uygulama 3 gerçekleştirilmiştir. Orijinal PointNet++ mimarisi ile elde edilen sonuçlar, en iyi doğruluklar olarak kabul edilemeyeceğinden bu modellerin birbirine olan sayısal üstünlükleri yerine, Adaptif 1 için parametre aramaksızın elde edebileceği performans ve Adaptif 2 için Uygulama 1’de seçilen başlangıç çerçeve boyutunun nokta değişkenliğine adapte olma kapasitesinin değerlendirilmesi daha doğru bir yaklaşım olacaktır. Modellere ait hiper-parametreler aşağıda Tablo 20’de verilmektedir.

Tablo 20. Uygulama 1, Uygulama 2 ve Uygulama 3 için girdi parametreleri


Log	Uygulama 1	Uygulama 2	Uygulama 3
Model	PointNet++ (MRG)	Adaptif-PointNet++ (MRG)	Adaptif-PointNet++ (MRG)
Yarıçap (m)	1, 2, 4, 8	0,1, 0,2, 0,4, 0,8	1, 2, 4 ,8
Box size (m)	30×30	Adaptif 1	Adaptif 2 (30×30)
Girdi nokta sayısı	8192	8192	8192
npoints	1024, 256, 64, 16	1024, 256, 64, 16	1024, 256, 64, 16
nsample	32, 32, 32, 32	32, 32, 32, 32	32, 32, 32, 32
Batch_size	16	16	16

PointNet++ mimarisi ile zemin ve zemin-üstü noktalarının semantik segmentasyonu işleminde üç uygulama ile elde edilen sonuçlar, Test 1 verisi için Tablo 21’de, Test 2 verisi için Tablo 22’de ve Test 2_gürültüsüz verisi için Tablo 23’te verilmiştir. Mimari için eğitim süreleri yaklaşık 8 saat sürmüştür.

Tablo 21. Test 1 verisi için elde edilen doğruluklar

Test 1	PointNet++		Adaptif 1		Adaptif 2	
	F1	IoU	F1	IoU	F1	IoU
Gürültü	-	-	-	-	-	-
Zemin-üstü	0,94	0,88	0,96	0,92	0,96	0,93
Zemin	0,91	0,84	0,95	0,90	0,95	0,91
Ağırlıklı ort.	0,93	0,86	0,95	0,91	0,96	0,92
GD (%)	92,35		95,50		95,55	

Tablo 21’de Uygulama 1 ve Uygulama 3 incelendiğinde, Adaptif 2 yaklaşımının başlangıç verilen çerçeve boyutunu nokta yoğunluğuna göre adapte edilmesi sayesinde orijinal PointNet++ mimarisinin GD ve ağırlıklı ort. F1 ölçütü %3, mIoU doğruluğu ise %6 daha doğru tespit edilmiştir. Aynı yaklaşım ile mimarinin zemin üstü sınıfı için IoU doğruluğu %5, zemin sınıfı için ise IoU doğruluğu %7 daha yüksek doğrulukta tespit edilmiştir. Adaptif 1 yaklaşımı ise çerçeve boyutuna ilişkin hiçbir ön tanımlı parametre gerektirmemesi bakımından bu veri seti özelinde neredeyse Adaptif 2 ile aynı doğruluk değerlerini elde etmiştir. Ağırlıklı F1 ve IoU metrikleri karşılaştırıldığında Adaptif 1, Adaptif 2’ye göre sadece %1 daha düşük doğrulukta elde edilmiştir. Ayrıca orijinal mimarinin diğer yaklaşımlara kıyasla %6 ve %7 daha düşük IoU doğruluğu ile zemin noktalarını tespit etmekte zorlandığı gözlemlenmiştir. Aşağıda Test 1 veri setinden elde edilen sonuçlar Şekil 37’de gösterilmektedir. Sonuçlar, 1 m çözünürlüğündeki SAM üzerinde görselleştirilmiştir.




Şekil 37. Test 1 verisinde zemin ve zemin-üstü noktalarında elde edilen hatalı sonuçlar

Tablo 22. Test 2 verisi için elde edilen doğruluklar

Test 2	PointNet++		Adaptif 1		Adaptif 2	
	F1	IoU	F1	IoU	F1	IoU
Gürültü	0,00	0,00	0,40	0,25	0,42	0,27
Zemin-üstü	0,76	0,61	0,83	0,71	0,84	0,74
Zemin	0,81	0,68	0,79	0,66	0,86	0,75
Ağırlıklı ort.	0,78	0,64	0,81	0,69	0,85	0,74
GD (%)	78,06		81,33		83,54	

Tablo 22’de, gürültülü T2 veri seti için elde edilen sonuçlar incelendiğinde orijinal yaklaşıma göre her iki adaptif yöntem de daha yüksek doğruluk elde etmiştir. Adaptif 2 bu veri seti üzerinde diğer iki yaklaşıma göre daha yüksek sonuçlar elde etmiştir. Ancak verinin çok fazla gürültü ve büyük binalar içermesi bakımından modellerin doğruluk değerleri özellikle T1 veri setine göre kıyasla daha sınırlı kalmıştır. Özellikle zemin sınıfında Adaptif 1 yaklaşımı diğerlerine göre başarısız olurken orijinal mimari de zemin üstü sınıfında diğer iki adaptif yaklaşıma göre başarısız olmuştur. Şekil 38’de Test 2 veri setine ait semantik segmentasyon sonuçları sunulmaktadır.



Şekil 38. Test 2 veri setinde zemin ve zemin-üstü noktalarında elde edilen hatalı sonuçlar

PointNet++ mimarisinin çok büyük boyuttaki yapıları tespit etmede yaşadığı zorluklar arasında DALES veri setinden sonra OpenGF veri seti içinde bina sınıflarının


özellikle merkezine doğru zemin olarak sınıflandırıldığı görülmüştür. Bu veri özelinde çerçeve boyutunun orijinal mimariye küçük geldiği söylenebilir. Bu hatalar, orijinal mimari ile aynı başlangıç çerçeve boyutunu kullanan Adaptif 2 yaklaşımında da meydana gelmiştir ancak orijinal yaklaşıma göre bu hataların azaldığı da hem sayısal hem de görsel sonuçlardan görülmektedir. Bu da böylesi büyük binaların (200×200 m) bulunduğu bir alan için her ne kadar istenilen düzeyde olmasa da yöntemin orijinal yaklaşıma göre daha iyi sonuçlar ürettiğini göstermektedir. Bunun yanı sıra Adaptif 1 yaklaşımı ise aralarındaki en yüksek doğruluk ile optimum çerçeve boyutunun önemini açıkça göstermektedir.

Tablo 23. Test 2 gürültüsüz verisi için elde edilen doğruluklar

T2_gürültüsüz	PointNet++		Adaptif 1		Adaptif 2	
	F1	IoU	F1	IoU	F1	IoU
Gürültü	-	-	-	-	-	-
Zemin-üstü	0,74	0,59	0,89	0,80	0,85	0,73
Zemin	0,82	0,69	0,90	0,83	0,88	0,78
Ağr. Ort.	0,78	0,64	0,90	0,81	0,86	0,75
GD (%)	77,80		89,34		84,70	


Test veri setinden gürültüsüz noktaların atılması ile oluşturulan T2 gürültüsüz veri setinde en yüksek semantik segmentasyon doğrulukları Adaptif 1 yaklaşımı ile elde edilmiştir. Adaptif 1 yaklaşımı için GD, ağırlıklı ortalama F1 ve mIoU doğrulukları sırası ile %89,34, %90 ve %81 olarak elde edilmiştir. İkinci en yüksek performans değerleri ise Adaptif 2 yaklaşımı ile elde edilmiştir. Son olarak ise en düşük doğruluk değerleri sabit çerçeve boyutlu yaklaşım ile elde edilmiştir. Ancak bu aşamada orijinal mimari için optimum çerçeve boyutu aranmadığından orijinal mimarinin elde ettiği doğruluklar üzerinden doğrudan karşılaştırılması doğru bir yaklaşım olmayacaktır. Ancak önerilen adaptif yaklaşımlardan Adaptif 1'in tamamen otomatik bir şekilde ilk denemede bu veri seti üzerinde %89,34 doğruluk elde etmesi ve hatta diğer Test 1 ve Test 2 veri setlerinde de orijinal mimariye üstünlük sağlaması, çerçeve boyutu için deneme yanılmaya olan ihtiyacın bu veri özelinde giderildiğini göstermektedir. Ayrıca Adaptif 1 yönteminin sonucu, literatürde OpenGF veri setinin yayınlandığı orijinal makalede Qin vd. (2021)'in PointNet++ mimarisi ile Test 2 gürültüsüz veri seti üzerinde bulduğu %87,38 genel doğruluktan daha yüksek doğrulukta elde edilmiştir. Adaptif 2 ise böylesi büyük ve nokta

yoğunluğu değişkenliği fazla olan nokta bulutlarında Test 2 gürültüsüz veri seti için orijinal mimariye göre daha yüksek sonuçlar elde etmiştir. Elde edilen semantik segmentasyon sonuçları Şekil 39’da gösterilmiştir.



Şekil 39. Test 2 gürültüsüz veri setinde zemin ve zemin-üstü noktalarında elde edilen hatalı sonuçlar

Test 2 gürültüsüz veri setindeki sonuçlar incelendiğinde, binalar özelindeki hataların gürültülü veriye oranla her bir model için arttığı gözlemlenmiştir. Tablo 22 ve Tablo 23 karşılaştırıldığında, gürültünün çıkarılması ile en yüksek doğruluk artışı Adaptif 1 yaklaşımında meydana gelmiştir. Adaptif 2 ise gürültüsüz veri üzerindeki performanslarını ağırlıklı ortalama IoU üzerinden %1, GD üzerinden ise yaklaşık %2 iyileştirebilmiştir. Orijinal mimari yaklaşımında ise gürültünün çıkartılması sadece GD metriğini yaklaşık %2 iyileştirirken IoU doğruluğunda değişim olmamıştır. Aşağıdaki grafikte bu üç modelin Test 1, Test 2 ve gürültüsüz Test 2 veri setinde elde ettiği genel doğruluklar üzerinden gösterilmiştir (Şekil 40).



Şekil 40. OpenGF veri setinin Uygulama 1, Uygulama 2 ve Uygulama 3 modelleri için Test 1, Test 2 ve Test 2_gürültüsüz test veri setleri üzerinde elde edilen genel doğrulukları

4.3.1. OpenGF Veri Seti Üzerinden Genel Bulgular

Bu bölümden elde edilen bulgular özetlenecek olursa, Adaptif 1 yaklaşımı OpenGF veri seti üzerindeki nokta yoğunluklarına adapte olarak en yüksek doğruluğu elde etmiştir. Adaptif 2 yaklaşımı ise orijinal mimariye göre elde edilen sonuçları iyileştirmiştir. 3 modelin de temelinde aynı PointNet++ mimarisi kullanılmasına rağmen Adaptif 1 ve Adaptif 2 yaklaşımlarının mimarinin doğruluğunu artırmış olması PointNet++ mimarisi için çerçeve boyutu parametresinin önemini göstermektedir.

- Nokta yoğunluğu çok fazla değişkenlik gösteren OpenGF veri setinde Adaptif 1 yaklaşımı daha yüksek doğruluklar elde ettiğinden, çerçeve boyutunun böylesi veri setlerinde otomatik hesaplanarak çerçeve boyutu seçiminde deneme yanılmaya olan ihtiyacın giderildiği söylenebilir.
- Çok büyük boyutlardaki binaların bulunduğu bu veri setinde çatı merkezine doğru yapılan hatalar her iki adaptif yaklaşım ile de azaltıldığından, çerçeve boyutu seçiminin obje boyutları da dikkate alınarak seçilmesi gerektiği söylenebilir.
- Özellikle büyük binalarda meydana gelen hatalardan kaynaklı olarak üretilebilecek SAM'ın kalitesi olumsuz etkileneceği için mimari zemin filtreleme görevi için iyileştirilmeye ya da ek öz niteliklere ihtiyaç duymaktadır.

4.4. Nokta Bulutu Özniteliklerinin Semantik Segmentasyona Etkisi

Hava LiDAR nokta bulutu üretiminde kullanılan sensörler her bir lazer ışınının X, Y, Z koordinatlarına ek olarak lazer ışınının yol boyunca gerçekleştirdiği etkileşimi de yoğunluk, geri dönüş sayısı ve dönüş numarası gibi öznitelikleri de kaydetmektedir. Özellikle geri dönüş sayısı ve dönüş sayısı özniteliklerinden literatürde hem ağaçlık alanların tespiti hem de bina segmentasyonu çalışmalarında yaygın bir şekilde faydalanılmıştır. Bu nedenle, hava LiDAR nokta bulutlarının PointNet++ mimarisi ile semantik segmentasyonu işleminde X, Y, Z koordinatlara ek olarak yoğunluk (I), geri dönüş sayısı (RN) ve dönüş numarası (NoR) özniteliklerinin mimarinin performansı üzerine olan etkileri araştırılmıştır. Bu araştırma için tez kapsamında PointNet++ mimarisi için önerilen Adaptif 2 yaklaşımı kullanılmıştır. DALES veri seti için başlangıç çerçeve boyutu 25x25 m seçilmiştir. OpenGF için ise bu değer 30x30 m olarak seçilmiştir. X, Y, Z koordinatlarına ek olarak I, RN ve NoR özniteliklerinin eklenmesi ile öznitelik vektörü {x, y, z, I, RN, NoR} olacak şekilde eğitimler gerçekleştirilmiştir ve sadece X, Y, Z koordinatların kullanılması ile elde edilen doğruluklar ile karşılaştırılmıştır. DALES veri setinde yoğunluk özneliği bulunmadığı için bu veri için öznitelik vektörü {x, y, z, RN, NoR} olarak kullanılmıştır. Sırası ile DALES ve OpenGF veri setleri için elde edilen sınıf bazlı F1 ve IoU metrikleri ve genel doğrulukları aşağıda Tablo 24 ve Tablo 25’te sunulmuştur.

Tablo 24. Ek öznitelikler ile DALES veri seti elde edilen semantik segmentasyon doğrulukları

Sınıf/Ölçüt		Bilinm.	Zemin	Bitki	Araba	Kamy.	Elekt.H.	Çit	Direk	Bina	Ağr.Ort.	GD(%)
{X, Y, Z}	F1	0,01	0,97	0,93	0,73	0,11	0,88	0,52	0,51	0,92	0,94	94,05
{X, Y, Z, RN, NoR}	F1	0,12	0,97	0,93	0,80	0,04	0,86	0,55	0,54	0,93	0,94	94,31
{X, Y, Z}	IoU	0,004	0,94	0,87	0,58	0,06	0,79	0,35	0,34	0,86	0,896	94,05
{X, Y, Z, RN, NoR}	IoU	0,06	0,94	0,86	0,67	0,02	0,76	0,38	0,37	0,86	0,894	94,31

Özniteliklerin eklenmesi ile sadece bilinmeyen, araba ve çit sınıflarında IoU doğruluk değerlerinde yükseliş görülürken ağırlıklı ortalamalarda herhangi bir performans iyileştirilmesi gözlemlenmemiştir. Mimariye, RN ve NoR özniteliklerinin eklenmesinin performansı olumlu anlamda etkilediği söylenemez. RN ve NoR bilgilerinin eklendiği model için özellikle bitki sınıfı incelendiğinde F1 değerinin değişmediği IoU doğruluğunun ise %1 düştüğü gözlemlenmiştir.

Tablo 25. Ek öznitelikler ile OpenGF veri seti elde edilen semantik segmentasyon doğrulukları

	Sınıf/Ölçüt		Gürültü	Zemin-üstü	Zemin	Ağr. Ort.	GD(%)
Test 1	{X, Y, Z}	F1	-	0,96	0,95	0,96	95,55
	{X, Y, Z, I, RN, NoR}	F1	-	0,95	0,94	0,95	94,55
	{X, Y, Z}	IoU		0,93	0,91	0,92	95,55
	{X, Y, Z, I, RN, NoR}	IoU	-	0,91	0,88	0,90	94,55
Test 2	{X, Y, Z}	F1	0,42	0,84	0,86	0,85	83,54
	{X, Y, Z, I, RN, NoR}	F1	0,43	0,83	0,86	0,85	84,86
	{X, Y, Z}	IoU	0,27	0,73	0,75	0,74	83,54
	{X, Y, Z, I, RN, NoR}	IoU	0,27	0,71	0,76	0,73	84,86
Test 2_gürültüsüz	{X, Y, Z}	F1	-	0,85	0,88	0,86	84,70
	{X, Y, Z, I, RN, NoR}	F1	-	0,83	0,87	0,85	85,01
	{X, Y, Z}	IoU	-	0,73	0,78	0,75	84,70
	{X, Y, Z, I, RN, NoR}	IoU	-	0,70	0,77	0,73	85,01

Her üç test veri seti için de sonuçlar incelendiğinde, sadece X, Y ve Z koordinatlarını kullanarak F1 ve IoU metriklerinin ağırlıklı ortalama değerlerinde %1 ve %2 daha başarılı sonuçlar elde edilmiştir. Test 2 veri setindeki F1 değeri, her iki model için de aynı olduğundan bu durumun dışındadır.

Test 1 sonuçları incelendiğinde, mimarinin her iki model için de F1 ve IoU ölçütlerine göre oldukça yüksek bir performans elde ettiği gözlemlenmiştir. Ancak F1 ve IoU skorları, sadece X, Y, Z koordinatlarının model için zemin ve zemin-üstü sınıflarını ayırma işleminde yeterli olabileceğini göstermektedir. Sadece X, Y ve Z koordinatları ile eğitilen model zemin-üstü ve zemin için IoU değerinde sırası ile %3 ve %4 daha yüksek doğruluk değerlerine sahiptir.

Test 2 sonuçları incelendiğinde, ağırlıklı ortalama F1 skorunun her iki model için de aynı olduğu görülmektedir. Ağırlıklı ortalama IoU metriği ise sadece X, Y, Z koordinatlarının kullanıldığı durumda %1 daha yüksek elde edilmiştir. Gürültülü veriler üzerinde de yoğunluk, geri dönüş sayısı ve dönüş numarası kullanmanın mimariye anlamlı bir katkısının olmadığı gözlemlenmiştir. Hatta, ek bilgilerin eklenmesi bu veri seti üzerinde zemin üstü sınıfının IoU doğruluk değerinde %2 doğruluk kaybına sebep olmuştur.

Test 2 gürültüsüz veri setindeki sonuçlar değerlendirildiğinde sadece X, Y, Z koordinatları ile eğitilen model ile hem ağırlıklı ortalama F1 hem de ağırlıklı ortalama IoU metriklerinde sırası ile %1 ve %2 daha yüksek doğruluk değerleri elde edilmiştir. Özellikle zemin-üstü sınıfının IoU değeri ise yoğunluk, geri dönüş sayısı ve dönüş numarasının eklenmesi ile %3 düşüş göstermiştir.

Test 2 sonuçları incelendiğinde, sadece X, Y, Z bilgilerinin kullanıldığı durumun gürültüsüz Test 2 sonuçlarına göre daha düşük olduğu görülmektedir. Gürültü noktalarının çıkartılması ile F1 skorlarında zemin-üstü sınıfı için %1 zemin sınıfında ise %2 artış görülürken, F1 ve IoU metriklerinin ağırlıklı ortalama değerlerinde de %1 performans artışı olmuştur.

Mimarinin gürültü ile başa çıkabilmesinde yoğunluk, geri dönüş sayısı ve dönüş numarası özniteliklerinin bir katkısının olup olmadığı da Test 2 ve Test 2 gürültüsüz veri setlerinin performansları karşılaştırılarak irdelenmiştir. Gürültünün çıkartılması sadece X, Y, Z koordinatlarının kullanıldığı durumda zemin sınıfında IoU doğruluğunda %3 artış sağlamıştır. Zemin üstü sınıfı için ise bu değer aynı kalırken ağırlıklı ortalama ise %1 artmıştır. Ek özniteliklerin eklendiği modelde, zemin sınıfında %1 artış sağlanırken, zemin üstü sınıfı için %1 düşüş elde edilmiştir. Bu modelin ağırlıklı ortalama değerleri ise aynı kalmıştır. Bu sonuçlar sadece X, Y ve Z koordinatlarının kullanılması durumunda mimarinin hem gürültülü hem gürültüsüz verilerde daha iyi sonuçlar verdiğini göstermektedir. Ayrıca veriden gürültünün çıkartılmasına yine sadece X, Y, Z koordinatlarının kullanıldığı model daha pozitif tepki vererek performans artışı gösterirken, özniteliklerin ilave edildiği model gürültü noktalarının atılmasına hemen hemen tepkisiz kalmıştır denilebilir. GD (%) genel doğruluk yüzdesi ise her bir test koşulunda benzer sonuçlar vermektedir ve modelin nesneleri doğru bir şekilde tespit etmede başarılı olduğunu göstermektedir.

4.5. Yöntemin Genelleştirme Kabiliyeti

Mimarinin yeni veri setine uyum sağlayabilmesi, o mimarinin genelleştirilmesi açısından oldukça önemlidir. Mimarinin genelleştirme kabiliyeti, eğitim veri setinden tamamen farklı koşullarda ve farklı sensörler ile farklı nokta yoğunluğunda toplanmış ve farklı sınıfların bulunduğu test veri setleri üzerinde hem orijinal PointNet++ mimarisi için hem de önerilen Adaptif 1 ve Adaptif 2 yaklaşımları için araştırılmıştır. Genelleştirme kabiliyeti sadece çok sınıflı problemler için araştırılmıştır. Bu amaçla öncelikli olarak düzensiz DALES veri seti üzerinde eğitilen hem orijinal hem de adaptif yaklaşımların uygulandığı PointNet++ mimarileri ISPRS benchmark veri seti üzerinde test edilmiştir. ISPRS benchmark ve DALES veri setlerinde bazı sınıflar birbirinden farklılık göstermektedir. Örneğin ISPRS veri setinde bina yan yüzeyleri ve çatılar ayrı sınıf etiketlerine sahip iken DALES veri setinde bu sınıflar birleşik olarak bina sınıfında bulunmaktadır. Ayrıca DALES veri setindeki zemin sınıfı, ISPRS veri setinde geçirimsiz yüzey ve nispeten düşük bitki sınıfları ile temsil edilmektedir. Detaylı olarak sınıf farklılıkları ve içerdikleri nokta sayıları Bölüm 3.1.1 ve Bölüm 3.1.2’de görülmektedir. Bu yüzden test yapılmadan önce veri setlerindeki aynı objeleri temsil eden sınıf etiketlerinin birbirleri ile eşleştirilmesi gerekmektedir. DALES veri setindeki direk ve kamyon sınıfları ISPRS veri setinde karşılığı olmadığı için eşleştirilmemiştir. Bu eşleştirme aşağıda Tablo 26’da gösterilmektedir. DALES verisi için elde edilen genelleştirme test doğrulukları ise bütünleşik olarak Tablo 27’de gösterilmiştir. Orijinal PointNet++ mimarisinin genelleştirme yeteneği Bölüm 4.2. Uygulama 3 kapsamında en yüksek doğrulukların elde edildiği Hibrit Model 2’nin (Tablo 16) kullanılması ile araştırılmıştır.


Tablo 26. DALES ve ISPRS veri setleri için sınıf eşleştirmeleri

DALES	ISPRS
Zemin	Geçirimsiz yüzey ve düşük bitki
Bitki	Ağaç ve Çalı
Araba	Araba
Elektrik Hattı	Elektrik Hattı
Çit	Çit
Bina	Çatı ve bina cephesi

Tablo 27. Mimarinin genelleştirme test sonuçları

Eğitim Veri Seti	Test Veri Seti	Model	Genel Doğruluk (%)	Ağr. Ort. IoU (%)
düzensiz_DALES	ISPRS Vaihingen	PointNet++	82,27	74,28
		Adaptif 1 PointNet++	85,07	76,59
		Adaptif 2 PointNet++	87,20	78,63

Tablo 27 incelendiğinde adaptif çerçeve boyutu yaklaşımlarının her ikisinin de mimarinin sabit çerçeve boyutu yaklaşımına üstünlük sağladığı görülmektedir. Adaptif 1 yaklaşımının mimarinin varsayılan yaklaşımına olan üstünlüğü genel doğrulukları karşılaştırıldığında yaklaşık %3, ağırlıklı ortalama IoU doğrulukları karşılaştırıldığında ise %2,31 olmuştur. Adaptif 2 yaklaşımının orijinal yaklaşıma olan üstünlüğü ise genel doğruluk için yaklaşık %5, ağırlıklı ortalama IoU doğruluğu için ise %4,35 olmuştur. Adaptif 1 ve Adaptif 2 yaklaşımları karşılaştırıldığında ise Adaptif 2 yaklaşımının ISPRS test verisi üzerinde daha başarılı olduğu gözlemlenmiştir. Bu iki yeni yaklaşım karşılaştırıldığında ise Adaptif 2 ile hem GD hem de IoU doğruluklarında yaklaşık %2 daha yüksek doğruluklar elde edilmiştir. Aşağıda bu üç yöntem için elde edilen semantik segmentasyon sonuçları Şekil 41’de sunulmaktadır. Ayrıca aşağıda Tablo 28’de üç yöntem için sınıf bazlı F1 ve IoU doğrulukları verilmektedir.



Şekil 41. Düzensiz DALES verisi üzerinde eğitilen mimarilerin ISPRS test verisi üzerindeki test sonuçları

Tablo 28. Genelleştirme sonuçlarının üç yöntem için ISPRS veri seti üzerinde her bir sınıf için karşılaştırması

Model	Metrik	Zemin	Bitki	Araba	Elektrik Hattı	Çit	Bina	Ağr.Ort. (%)	GD(%)
PointNet++	F1	0,92	0,73	0,58	0,12	0,04	0,84	84	82,27
	IoU	0,85	0,58	0,40	0,07	0,02	0,73	74,28	
Adaptif 1 PointNet++	F1	0,94	0,73	0,39	0,10	0,08	0,85	85	85,07
	IoU	0,89	0,58	0,24	0,05	0,04	0,73	76,59	
Adaptif 2 PointNet++	F1	0,93	0,78	0,58	0,17	0,08	0,89	87	87,20
	IoU	0,87	0,64	0,40	0,10	0,04	0,80	78,63	

Genelleştirme sonuçları incelendiğinde, düzensiz_DALES veri seti üzerinde en yüksek doğrulukların Adaptif 2 yaklaşımı ile elde edildiği görülmektedir. Mimarının sabit çerçeve boyutu yaklaşımı ile en düşük doğruluklar elde edilmiştir. Orijinal yaklaşıma oranla önerilen her iki yaklaşım ile de daha yüksek doğruluklar elde edilmiştir. Adaptif 2 yaklaşımı ile orijinal yaklaş karşılaştırıldığında, özellikle bitki ve bina sınıflarında IoU doğrulukları %6 ve %7 daha yüksek elde edilmiştir. Bu sonuçlar, farklı sensörlerle toplanan farklı özelliklerdeki nokta bulutu verilerini işlemenin ne kadar zor bir işlem olduğunu ve bu zorluk ile başa çıkabilmek için etkili bir teknik kullanmanın önemini göstermektedir. Nokta tabanlı PointNet++ mimarisinin bu anlamdaki etkinliği oldukça yüksek sonuçlar sağlarken basitçe nokta yoğunluğuna adapte edilmiş örnekleme stratejileri ile performansı iyileştirilerek özellikle değişken nokta yoğunluğu problemine karşı daha kararlı hale getirilmiştir.

5. SONUÇLAR

Tez kapsamında PointNet++ mimarisi büyük ölçekli hava LiDAR nokta bulutlarının semantik segmentasyonu için ISPRS, DALES ve OpenGF olmak üzere üç farklı veri seti üzerinde hem çoklu sınıf arazi örtüsü hem de zemin ve zemin üstü olmak üzere iki sınıflı problemlerin çözümü işlemleri için uyarlanmıştır. Bu uyarlama öncelikli olarak orijinal mimari üzerinde her bir veri setine özel geometrik hiper parametrelerinin optimum değerlerinin bulunmasını kapsamaktadır. PoinNet++ mimarisini, nokta yoğunluğu değişkenlik gösteren hava LiDAR nokta bulutu verilerine uyarlarken mimariyi değişken nokta yoğunluğu problemine karşı daha sağlam hale getirmek için nokta yoğunluğuna uyum sağlayabilen Adaptif 1 ve Adaptif 2 çerçeve boyutu yaklaşımları önerilmiştir. Önerilen yaklaşımların performansları, dokuz sınıf etiketli ISPRS 3B Semantik Etiketleme, DALES, düzensiz_DALES ve son olarak zemin filtreleme nokta bulutu OpenGF test veri setleri üzerinde irdelenmiştir. Mimaride bulunan iki farklı gruplama katmanı MRG ve MSG modellerinden yeni bir hibrit model (MSG+MRG) geliştirilerek süre ve performans açısından üstünlük ve zayıflıkları değerlendirilmiştir. Mimarinin, nokta örnekleme stratejisi değiştirilerek çerçeve boyutu içinden seçilen benzersiz nokta sayısı artırılmış ve eğitim veri seti diğer nokta bulutlarına göre düşük olmasından dolayı ISPRS benchmark veri seti üzerinde denenerek mimarinin performansına olan etkileri hem sınıf bazında hem de genel doğruluk metrikleri ile değerlendirilmiştir. Ardından, X, Y ve Z koordinatlara ek olarak yoğunluk, geri dönüş sayısı ve dönüş numarası ek özniteliklerin eklenmesinin PointNet++ mimarisinin semantik segmentasyon modeline olan etkileri araştırılmıştır. Son olarak orijinal mimari ile Adaptif 1 ve Adaptif 2 yaklaşımlarının eklendiği iyileştirilmiş PointNet++ mimarilerinin genelleştirme kabiliyetleri test edilmiştir.

Tez kapsamında önerilen adaptif çerçeve boyutu yaklaşımları sayesinde mimari hem girdi nokta bulutunun yoğunluğuna adapte hale getirilmiş hem de bu adaptasyon sayesinde mimarinin daha fazla benzersiz nokta ile eğitilmesi sağlanmıştır. Özellikle nokta yoğunluğu değişkenliğinin fazla olduğu OpenGF veri setleri üzerinde mimarinin mIoU ve genel doğrulukları Adaptif 1 yaklaşımı ile %17 ve %12'ye varan iyileşme göstermiştir. Adaptif 1 yaklaşımının nokta yoğunluğu değişken hale getirilen düzensiz_DALES veri seti üzerinde mimarinin mIoU ve genel doğruluklarındaki performans artışı sırası ile %1 ve yaklaşık %2 olmuştur. Orijinal mimarinin Adaptif 2 yaklaşımı sayesinde OpenGF test veri

setleri üzerindeki performans artışı mIoU için %11 ve GD için %7'ye kadar iyileşme göstermiştir. Orijinal mimari Adaptif 2 sayesinde değişken nokta yoğunluklu düzensiz_DALES veri seti üzerinde GD için yaklaşık %2 performans artışı gösterirken mIoU metriği ise %3 daha yüksek elde edilmiştir. Ayrıca önerilen adaptif yaklaşımların PointNet++ mimarisini, veri içi ve veriler arasındaki nokta yoğunluğu değişimine karşı daha kararlı hale getirmesinin yanı sıra, sınıf bazında F1 ve IoU metrikleri incelendiğinde mimarinin doğruluklarını tüm sınıflar için artırdığı gözlemlenmiştir. Özellikle, veri seti içerisinde daha az nokta ile temsil edilen sınıflarda daha yüksek doğruluk değerleri elde edilmiştir. Bu durum önerilen yaklaşımların hava LiDAR nokta bulutlarında karşılaşılan sınıf dengesizliği probleminin azaltılmasında da başarılı olduğunu göstermektedir. Ayrıca mimarinin farklı veri setlerine uyarlamasında deneme yanılma işlemini ortadan kaldırdığı ya da azaltması sebebi ile de zaman açısından daha verimli olmaktadır. Üstelik, bu yaklaşımların PointNet++ mimarisine eklenmesi ile OpenGF gibi farklı kaynaklardan elde edilen farklı özelliklerdeki nokta bulut verilerinin birleştirilmesi ile oluşturulan veri setleri üzerinde orijinal mimariye göre daha yüksek doğruluk değerlerinin elde edilmesi, adaptif çerçeve boyutu yaklaşımlarının böylesi veri setleri için daha doğru bir strateji olduğunu göstermektedir.

Özellikle Adaptif 2 yaklaşımının mimarinin optimum çerçeve boyutundan sapmaları daha iyi tolere edebildiği gözlemlenirken orijinal yaklaşımın bu sapmayı tolere etmekte zorlandığı sonucuna ulaşılmıştır. Tez kapsamında yapılan genelleştirme test sonuçları orijinal mimari için IoU doğruluğu %74,28 iken, Adaptif 1 yaklaşımı için 76,59 ve Adaptif 2 yaklaşımının eklendiği iyileştirilmiş PointNet++ mimarisi için %78,63 olarak elde edilmiştir. Sonuçlar, önerilen Adaptif 1 ve Adaptif 2 yaklaşımları sayesinde hava LiDAR nokta bulutları üzerinde PointNet++ mimarisinin genelleştirme kabiliyetinin artırıldığını göstermektedir.

Sadece X, Y ve Z koordinatları ile eğitilen mimari ile X, Y ve Z koordinatlarına ek olarak yoğunluk, geri dönüş sayısı ve dönüş numarası bilgilerinin kullanılması ile eğitilen mimarilerin semantik segmentasyon doğrulukları karşılaştırıldığında bu özelliklerin PointNet++ mimarisine anlamlı katkılarının olmadığı gözlemlenmiştir. Uçtan uca bir yaklaşım benimsendiğinde, mimari için sadece X, Y, Z koordinatları kullanmanın hem zemin filtreleme hem de çoklu sınıflı hava LiDAR nokta bulutlarının semantik segmentasyonu görevlerinde yeterli olabileceği sonucuna varılmıştır.

PointNet++ mimarisinde bulunan iki ayrı grupta katmanının birleştirilmesi ile elde edilen yeni hibrit yaklaşım ile MRG katmanına göre hemen hemen aynı eğitim süresinde daha yüksek doğruluk değerleri elde edilmiştir. Hibrit model ile önerilen Adaptif 2 yaklaşımı karşılaştırıldığında veri eksiltilmesine rağmen hemen hemen aynı segmentasyon doğruluklarının elde edildiği görülmüştür.

Nokta bulutlarını direkt işleyen PointNet++ mimarisinde özellikle çerçeve boyutu, çerçeve boyutundan örneklenen girdi nokta sayıları, komşuluk arama yarıçap boyutları, komşuluktan örneklenen nokta sayıları ve katmanlar boyunca alt örneklenerek çıkartılan yerel bölge sayıları mimarinin performansını önemli derecede etkileyen parametrelerdir. Çünkü 3B sahneyi temsil edebilecek yeterli sayıda öznetelik toplanması bu parametreler ile ilişkilidir. Ayrıca bu parametreler birbirileri ile ilişkili olduğundan dolayı bu parametrelerin optimum değerlerinin belirlenmesi çok sayıda deneme yanılma gerektiren zaman açısından oldukça zahmetli bir işlemdir. Bu nedenle mimari, optimum parametre arama işlemlerinin otomatize edilmesi bakımından iyileştirmelere ihtiyaç duymaktadır.

6. KAYNAKLAR

- Ahmed, E., Saint, A., Shabayek, A. E. R., Cherenkova, K., Das, R., Gusev, G., Aouada, D. ve Ottersten, B., 2019. A survey on Deep Learning Advances on Different 3D Data Representations, arXiv preprint arXiv:1808.01462.
- Bentley, J. L., 1975. Multidimensional Binary Search Trees used for Associative Searching, Communications of the ACM, 18,9, 509-517.
- Bertsekas, D. ve Tsitsiklis, J. N., 2008. Introduction to probability (second edition), Athena Scientific.
- Boulch, A., Guerry, J., le Saux, B. ve Audebert, N., 2018. SnapNet: 3D Point Cloud Semantic Labeling with 2D Deep Segmentation Networks, Computers&Graphics, 71, 189-198.
- Boulch, A., le Saux, B. ve Audebert, N., 2017. Unstructured Point Cloud Semantic Labeling Using Deep Segmentation Networks, Eurographics Workshop on 3D Object Retrieval, Nisan, Lyon, Fransa, Bildiriler Kitabı, 3, 17-24.
- Briechle, S., Krzystek, P. ve Vosselman, G. 2019. Semantic Labeling of ALS Point Clouds for Tree Species Mapping Using the Deep Neural Network PointNet++, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences-ISPRS Archives, 42, 951-955.
- Chen, L. Z., Li, X. Y., Fan, D. P., Wang, K., Lu, S. P. ve Cheng, M. M., 2019. LSA.Net: Feature Learning on Point Sets by Local Spatial Aware Layer, arxiv: 1905.05442.
- Chen, Y., Liu, G., Xu, Y., Pan, P. ve Xing, Y., 2021. PointNet++ Network Architecture with Individual Point Level and Global Features on Centroid for ALS Point Cloud Classification, Remote Sensing, 13,3, 472.
- Dong, P. ve Chen, Q., 2017. LiDAR Remote Sensing and Applications, CRC Press.
- Engelmann, F., Kontogianni, T., Schult, J. ve Leibe, B., 2018. Know What Your Neighbors Do: 3D Semantic Segmentation of Point Clouds, In Proceedings of the European Conference on Computer Vision (ECCV) Workshops, Eylül, Münih, Almanya.
- Goodfellow, I., Bengio, Y. ve Courville, A., 2016. Deep Learning, MIT press.
- Graham, B., Engelcke, M. ve Van Der Maaten, L., 2018. 3D Semantic Segmentation with Submanifold Sparse Convolutional Networks, In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 9224-9232.
- Guo, M. H., Cai, J. X., Liu, Z. N., Mu, T. J., Martin, R. R. ve Hu, S. M., 2021a. PCT: Point cloud transformer, Computational Visual Media, 7,2, 187-199.

- Guo, Y., Wang, H., Hu, Q., Liu, H., Liu, L. ve Bennamoun, M., 2021b. Deep Learning for 3D Point Clouds: A Survey, IEEE Transactions on Pattern Analysis and Machine Intelligence, 43,12, 4338-4364.
- Habib, M. A., 2017. Virtual Surveyor based Object Extraction from Airborne LiDAR data. Doktora Tezi, The University of Texas at Arlington.
- Hu, Q., Yang, B., Xie, L., Rosa, S., Guo, Y., Wang, Z., Trigoni, N. ve Markham, A., 2020. RandLA-Net: Efficient Semantic Segmentation of Large-Scale Point Clouds. In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 11108-11117.
- Hu, X. ve Yuan, Y., 2016. Deep-Learning-Based Classification for DTM Extraction from ALS Point Cloud, Remote Sensing, 8,9, 730.
- Huang, J. ve You, S., 2016. Point Cloud Labeling Using 3D Convolutional Neural Network, 23rd International Conference on Pattern Recognition (ICPR), Aralık, Mexico, 2670-2675.
- Ioffe, S. ve Szegedy, C., 2015. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, In ICML, 448-456.
- Jiang, M., Wu, Y., Zhao, T., Zhao, Z. ve Lu, C., 2018. PointSIFT: A SIFT-like Network Module for 3D Point Cloud Semantic Segmentation, arXiv preprint arXiv: 1807.00652.
- Kada, M. ve Kuramin, D., 2021. ALS Point Cloud Classification Using PointNet++ and KPConv with Prior Knowledge, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences-ISPRS Archives, 46, 91-96.
- Kalogerakis, E., Averkiou, M., Maji, S. ve Chaudhuri, S., 2017. 3D Shape Segmentation with Projective Convolutional Networks, In Proceedings 30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 6630-6639.
- Kingma, D. P. ve Ba, J., 2014. Adam: A Method for Stochastic Optimization, arXiv preprint arXiv:1412.6980.
- Klokov, R. ve Lempitsky, V., 2017. Escape from Cells: Deep Kd-Networks for the Recognition of 3D Point Cloud Models, In Proceedings of the IEEE International Conference on Computer Vision, Ekim, Venedik, Italy, 863-872.
- Kumar, A., Anders, K., Winiwarter, L. ve Höfle, B., 2019. Feature Relevance Analysis For 3D Point Cloud Classification Using Deep Learning, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 4, 373-380.
- Lawin, F. J., Danelljan, M., Tosteberg, P., Bhat, G., Khan, F. S. ve Felsberg, M., 2017. Deep Projective 3D Semantic Segmentation, Proc. Int. Conf. Comput. Anal. Images Patterns, 95-107.

- Le, T. ve Duan, Y., 2018. PointGrid: A Deep Network for 3D Shape Understanding, In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 9204-9214.
- Li, J., Zhou, J., Xiong, Y., Chen, X. ve Chakrabarti, C., 2022. An Adjustable Farthest Point Sampling Method for Approximately-sorted Point Cloud Data, In 2022 IEEE Workshop on Signal Processing Systems (SiPS), 1-6.
- Li, N., Kahler, O. ve Pfeifer, N., 2021. A Comparison of Deep Learning Methods for Airborne Lidar Point Clouds Classification, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 14, 6467-6486.
- Li, W., Wang, F.D. ve Xia, G.S., 2020. A Geometry-Attentional Network for ALS Point Cloud Classification, ISPRS Journal of Photogrammetry and Remote Sensing, 164, 26-40.
- Lin, Y., Vosselman, G. ve Yang, M. Y., 2022. Weakly Supervised Semantic Segmentation of Airborne Laser Scanning Point Clouds, ISPRS Journal of Photogrammetry and Remote Sensing, 187, 79-100.
- Liu, H., Guo, Y., Ma, Y., Lei, Y. ve Wen, G., 2021. Semantic Context Encoding for Accurate 3D Point Cloud Segmentation, IEEE Transactions On Multimedia, 23, 2045-2055.
- Liu, M., Zhou, Y., Qi, C. R., Gong, B., Su, H. ve Angelov, D., 2022. LESS: Label-Efficient Semantic Segmentation for LiDAR Point Clouds, In IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2, 4.
- Long, J., Shelhamer, E. ve Darrell, T., 2015. Fully Convolutional Networks for Semantic Segmentation, In Proceedings of the IEEE conference on computer vision and pattern recognition, 3431-3440.
- Ma, H., Ma, H., Zhang, L., Liu, K. ve Luo, W., 2022. Extracting Urban Road Footprints from Airborne LiDAR Point Clouds with PointNet++ and Two-Step Post-Processing, Remote Sensing, 14, 3, 789.
- Maturana, D. ve Scherer, S., 2015. VoxNet: A 3D Convolutional Neural Network for Real-Time Object Recognition, IEEE International Conference on Intelligent Robots and Systems, Aralık, Hamburg, Almanya, Bildiriler Kitabı, 922928.
- Milioto, A., Vizzo, I., Behley, J. ve Stachniss, C., 2019. RangeNet++: Fast and Accurate LiDAR Semantic Segmentation, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Kasım, Macau, Çin, 4213-4220.
- Niemeyer, J., Rottensteiner, F. ve Soergel, U., 2014. Contextual Classification of Lidar Data and Building Object Detection in Urban Areas, ISPRS Journal of Photogrammetry and Remote Sensing, 87, 152-165.

- Nurunnabi, A., Teferle, F. N., Li, J., Lindenbergh, R. C. ve Parvaz, S., 2021. Investigation of PointNet for Semantic Segmentation of Large-Scale Outdoor Point Clouds, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Ekim, Karabük, Türkiye, 397-404.
- Öngün, C., 2021. Generation and Modification of 3D Models with Deep Neural Networks, Doktora tezi, Orta Doğu Teknik Üniversitesi, Ankara.
- Özdemir, E. ve Remondino, F., 2019. Classification of Aerial Point Clouds with Deep Learning, The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 42, 103-110.
- Özdemir, E., Remondino, F. ve Golkar, A., 2021. An Efficient and General Framework for Aerial Point Cloud Classification in Urban Scenarios Remote Sensing, 13,10, 1985.
- Politz, F. ve Sester, M., 2018. Exploring ALS and DIM Data for Semantic Segmentation Using CNNs, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 42,1, 347-354.
- Qi, C. R., Su, H., Mo, K. ve Guibas, L. J., 2017a. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation, Proceedings-30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 652-660.
- Qi, C. R., Yi, L., Su, H. ve Guibas, L. J., 2017b. PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space, Advances in Neural Information Processing Systems, 30.
- Qin, N., Tan, W., Ma, L., Zhang, D. ve Li, J., 2021. OpenGF: An Ultra-Large-Scale Ground Filtering Dataset Built upon Open ALS Point Clouds Around the World, IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, Haziran, Nashville, TN, USA, 1082-1091.
- Riegler, G., Ulusoy, A. O. ve Geiger, A., 2017. OctNet: Learning Deep 3D Representations at High Resolutions, In Proceedings-30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 6620-6629.
- Rim, B., Lee, A. ve Hong, M., 2021. Semantic Segmentation of Large-Scale Outdoor Point Clouds by Encoder-Decoder Shared MLPs with Multiple Losses, Remote Sensing, 13,16, 3121.
- Rizaldy, A., Persello, C., Gevaert, C. M. ve Oude Elberink, S. J., 2018. Fully Convolutional Networks for Ground Classification from Lidar Point Clouds, ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences, Haziran, Riva del Garda, İtalya, 4,2.
- Schmohl, S. ve 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, Haziran, Enschede, Hollanda, 4,2, 77-84.

- Shin, Y. H., Son, K. W. ve Lee, D. C., 2022. Semantic Segmentation and Building Extraction from Airborne LiDAR Data with Multiple Return Using PointNet++, Applied Sciences, 12,4, 1975.
- Soilán, M., Lindenbergh, R., Riveiro, B. ve Sánchez-Rodríguez, A., 2019a. PointNet for the Automatic Classification of Aerial Point Clouds, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 4,2, 445-452.
- Soilán, M., Riveiro, B., Balado, J. ve Arias, P. 2019b. Comparison of Heuristic and Deep Learning-Based Methods for Ground Classification from Aerial Point Clouds, International Journal of Digital Earth, 13,10, 1115-1134.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014. Dropout: A simple Way to Prevent Neural Networks from Overfitting, The Journal of Machine Learning Research, 15,1, 1929-1958.
- Su, H., Maji, S., Kalogerakis, E. ve Learned-Miller, E., 2015. Multi-view Convolutional Neural Networks for 3D Shape Recognition, IEEE International Conference on Computer Vision (ICCV), Aralık, Santiago, Şili, 945-953.
- Tatarchenko, M., Park, J., Koltun, V. ve Zhou, Q. Y., 2018. Tangent Convolutions for Dense Prediction in 3D, In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Haziran, Salt Lake City, UT, USA, 3887-3896.
- Tchapmi, L., Choy, C., Armeni, I., Gwak, J. ve Savarese, S., 2017. SEGCloud: Semantic Segmentation of 3D Point Clouds, International Conference on 3D Vision (3DV), Ekim, Qingdao, Çin, 537-547.
- Thomas, H., Qi, C. R., Deschaud, J. E., Marcotegui, B., Goulette, F. ve Guibas, L., 2019. KPConv: Flexible and Deformable Convolution for Point Clouds, In Proceedings of the IEEE International Conference on Computer Vision, Ekim, Seul, Güney Kore, 6410-6419.
- Turgut, K., 2022. Derin Öğrenme Yöntemleri Kullanarak 3B Geometri İşleme ve Uygulamaları, Doktora Tezi, Elektrik-Elektronik Mühendisliği, Eskişehir Osmangazi Üniversitesi, Eskişehir.
- Varney, N., Asari, V. K. ve Graehling, Q., 2020. DALES: A Large-Scale Aerial Lidar Data Set for Semantic Segmentation, IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, Haziran, Seattle, WA, USA, 717-726.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł. ve Polosukhin, I., 2017. Attention is All You Need, Advances in Neural Information Processing Systems, 30.
- Vosselman, G. ve Maas, H. G., 2010. Airborne and Terrestrial Laser Scanning, CRC press.
- Wang, P. S., Liu, Y., Guo, Y. X., Sun, C. Y. ve Tong, X., 2017. O-CNN: Octree-Based Convolutional Neural Networks for 3D Shape Analysis, ACM Transactions on Graphics, 36,4, 1-11.

- Wang, R., Albooyeh, M. ve Ravanbakhsh, S., 2020. Equivariant Maps for Hierarchical Structures, arXiv preprint arXiv:2006.03627.
- Wang, Y., Sun, Y., Liu, Z., Sarma, S. E., Bronstein, M. M. ve Solomon, J. M., 2019. Dynamic Graph CNN for Learning on Point Clouds, ACM Transactions on Graphics, 38,5, 1-12.
- Weinmann, M., 2016. Reconstruction and Analysis of 3D Scenes, Springer International Publishing.
- Weinmann, M., Schmidt, A., Mallet, C., Hinz, S., Rottensteiner, F. ve Jutzi, B., 2015a. Contextual Classification of Point Cloud Data by Exploiting Individual 3D Neighbourhoods, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Mart, Münih, Almanya, 2,3, 271-278.
- Weinmann, M., Urban, S., Hinz, S., Jutzi, B. ve Mallet, C., 2015b. Distinctive 2D and 3D Features for Automated Large-Scale Scene Analysis in Urban Areas, Computers and Graphics, 49, 47-57.
- Wen, C., Yang, L., Li, X., Peng, L. ve Chi, T., 2020. Directionally Constrained Fully Convolutional Neural Network for Airborne LiDAR Point Cloud Classification, ISPRS Journal of Photogrammetry and Remote Sensing, 162, 50-62.
- Winiwarter, L., Mandlbürger, G., Schmohl, S. ve Pfeifer, N., 2019. Classification of ALS Point Clouds Using End-to-End Deep Learning, Journal of Photogrammetry, Remote Sensing and Geoinformation Science, 87,3, 75-90.
- Wu, B., Wan, A., Yue, X. ve Keutzer, K., 2018. SqueezeSeg: Convolutional Neural Nets with Recurrent CRF for Real-Time Road-Object Segmentation from 3D LiDAR Point Cloud, IEEE International Conference on Robotics and Automation, Mayıs, Brisbane, QLD, Avustralya, 1887-1893.
- Wu, B., Zhou, X., Zhao, S., Yue, X. ve Keutzer, K., 2019. SqueezeSegV2: Improved Model Structure and Unsupervised Domain Adaptation for Road-Object Segmentation from a LiDAR Point Cloud, IEEE International Conference on Robotics and Automation, Mayıs, Montreal, QC, Kanada, 4376-4382.
- Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X. ve Xiao, J., 2015. 3D ShapeNets: A Deep Representation for Volumetric Shapes, In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Haziran, Boston, MA, USA, 1912-1920.
- Yang, J., Zhang, Q., Ni, B., Li, L., Liu, J., Zhou, M. ve Tian, Q., 2019. Modeling Point Clouds With Self-Attention and Gumbel Subset Sampling, IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Haziran, Long Beach, CA, USA, 3318-3327.
- Yang, Z., Jiang, W., Xu, B., Zhu, Q., Jiang, S. ve Huang, W., 2017. A Convolutional Neural Network-Based 3D Semantic Labeling Method for ALS Point Clouds, Remote Sensing, 9,9, 936.

- Zhang, A., Lipton, Z. C., Li, M. ve Smola, A. J., 2021. Dive into Deep Learning, arXiv preprint arXiv:2106.11342.
- Zhang, C. ve Fan, H., 2022. An Improved Multi-Task Pointwise Network for Segmentation of Building Roofs in Airborne Laser Scanning Point Clouds, Photogrammetric Record, 37,179, 260-284.
- Zhao, C., Zhou, W., Lu, L. ve Zhao, Q., 2019a. Pooling Scores of Neighboring Points for Improved 3D Point Cloud Segmentation, In IEEE International Conference on Image Processing (ICIP), Eylül, Taipei, Taiwan, 1475-1479.
- Zhao, H., Jiang, L., Fu, C. W. ve Jia, J., 2019b. PointWeb: Enhancing Local Neighborhood Features for Point Cloud Processing, In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Haziran, Long Beach, CA, USA, 5565-5573.
- Zhao, H., Jiang, L., Jia, J., Torr, P. ve Koltun, V., 2021. Point Transformer, Proceedings of the IEEE International Conference on Computer Vision (ICCV), Ekim, Montreal, QC, Kanada,16239-16248.
- Zhao, R., Pang, M. ve Wang, J., 2018. Classifying Airborne LiDAR Point Clouds via Deep Features Learned by a Multi-Scale Convolutional Neural Network, International Journal of Geographical Information Science, 32,5, 960-979.
- Zhao, Y., Birdal, T., Deng, H. ve Tombari, F., 2019c. 3D Point Capsule Networks, IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Haziran, Long Beach, CA, USA, 1009-1018.

ÖZGEÇMİŞ

İlköğretim eğitimini Yomra Merkez İlköğretim Okulu'nda ortaöğretim eğitimini ise Yomra Yabancı Dil Ağırlıklı Lise'de tamamladı. 2008 yılında Gümüşhane Üniversitesi Mühendislik Fakültesi Jeodezi ve Fotogrametri Mühendisliği Bölümü'nü kazandı. 2009 yılında ise İnşaat Mühendisliği Bölümü'nde Çift Anadal Programına kayıt yaptırdı. 2012 Haziran ayında Gümüşhane Üniversitesi, Mühendislik Fakültesi, Jeodezi ve Fotogrametri Mühendisliği Bölümü'nden hem Mühendislik Fakültesi hem de üniversite birincisi olarak mezun oldu. 2013 Haziran ayında İnşaat Mühendisliği Bölümünden mezun oldu. 2012-2013 eğitim-öğretim yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim dalında başladığı Yüksek Lisans programından 2015 yılında mezun oldu. 2016 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim dalında Doktora eğitimine başladı. 2013 Kasım ayında Araştırma Görevlisi olarak Gümüşhane Üniversitesi Harita Mühendisliği Bölümü'ne atandı ve bu görevine halen devam etmektedir. Araştırma alanları derin öğrenme, sınıflandırma, semantik segmentasyon ve nokta bulutlarıdır.