

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**NOKTA BULUTU İLE ELDE EDİLEN ALTYAPI
ELEMENLARININ SINIFLANDIRILMASINDA
MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
ALGORİTMALARININ PERFORMANSLARININ
DEĞERLENDİRİLMESİ**

Yalçın YILMAZ

DOKTORA TEZİ
Harita Mühendisliği Anabilim Dalı
Geomatik Programı

Danışman
Doç. Dr. Arzu SOYCAN

Temmuz, 2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

NOKTA BULUTU İLE ELDE EDİLEN ALTYAPI
ELEMANLARININ SINIFLANDIRILMASINDA MAKİNE
ÖĞRENMESİ VE DERİN ÖĞRENME
ALGORİTMALARININ PERFORMANSLARININ
DEĞERLENDİRİLMESİ

Yalçın YILMAZ tarafından hazırlanan tez çalışması 11/07/2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı Geomatik Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Arzu SOYCAN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Arzu SOYCAN, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Ercenk ATA, Üye
Yıldız Teknik Üniversitesi

Prof.Dr. Bihter EROL, Üye
İstanbul Teknik Üniversitesi

Prof. Dr. Burak AKPINAR, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Mahmut Oğuz SELBESOĞLU, Üye
İstanbul Teknik Üniversitesi

Danışmanım Doç. Dr. Arzu SOYCAN sorumluluğunda tarafımca hazırlanan Nokta Bulutu ile Elde Edilen Altyapı Elemanlarının Sınıflandırılmasında Makine Öğrenmesi ve Derin Öğrenme Algoritmalarının Performanslarının Değerlendirilmesi başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Yalçın YILMAZ

İmza



Bu çalışma, “Yıldız Teknik Üniversitesi Bilimsel Araştırma Proje Koordinatörlüğü’nün FBA-2022-4568” numaralı projesi ile desteklenmiştir.

Anneme, babama ve zamansız aramızdan ayrılan arkadaşım Serhat'a.



TEŞEKKÜR

Yıldız Teknik Üniversitesi'ne geldiğim günden bu zamana ve özellikle doktora çalışmalarım boyunca yardımlarını esirgemeyen ve yol gösteren değerli danışmanım Doç. Dr. Arzu SOYCAN'a, akademik çalışmaların yanı sıra, manevi desteğini esirgemeyen sayın hocam Prof. Dr. Metin SOYCAN'a gönülden teşekkür ederim. Tez izleme süresince değerli görüşlerini paylaşarak katkı sağlayan hocalarım Doç. Dr. Ercenk ATA ve Prof. Dr. Bihter EROL'a, savunma jürisinde yer alan Prof. Dr. Burak AKPINAR ve Doç. Dr. Mahmut Oğuz SELBESOĞLU hocalarıma da teşekkürü bir borç bilirim.

Akademik yolculuğum boyunca beni yalnız bırakmayan ve desteğini hissettiğim değerli çalışma arkadaşım Doç. Dr. Seda ÖZARPACI'ya, doktora süresi boyunca göstermiş olduğu katkılar ile tezimi daha güçlü kılmak için çaba harcayan Arş. Gör. Onur Can BAYRAK'a da ayrıca teşekkür ederim.

İnişlerin ve çıkışların olduğu yoğun doktora sürecinde kahrımı çeken, maddi ve manevi desteklerini esirgemeyen sabah akşam birlikte olduğum çalışma arkadaşlarım Dr. Batuhan KILIÇ, Dr. Alpay ÖZDEMİR, Dr. Mustafa Fahri KARABULUT, Dr. Barış SÜLEYMANOĞLU, Arş. Gör. Efe Turan AYRUK, Arş. Gör. İlay FARIMAZ ve Arş. Gör. Muhammed TURĞUT'a, ek olarak 7 yıl boyunca yanımda olan bütün mesai arkadaşlarım ve hocalarıma da teşekkür ederim. Ayrıca doktora çalışması içerisindeki arazi çalışmalarında yardımını esirgemeyen Harita Mühendisi Mustafa BAYRAK'a, özellikle son dönemde elinden gelen bütün desteği vermeye çalışan Harita Mühendisi Binali Bilal BEYTUT, Zübeyir Bilal ÇAKMAK ve Ayşe Sinem KALE ÇAKMAK'a gönülden teşekkür ederim.

Lisans eğitiminden bugüne kadar hep yanımda olan ve eksikliğini bir gün olsun hissetmediğim, benimle ağlayan benimle gülen değerli büyüğüm, abim Harita Mühendisi Murat ÇOLAKOĞLU'na ne kadar teşekkür etsem azdır. Tüm hayatım boyunca yanımda olan, aldığım her kararda arkamda duran canım ablam Sevgi YILMAZ ÇATALYÜREK'e sonsuz teşekkür ederim. Ayrıca bu yükü benimle omuzlayan tüm aileme teşekkür ediyorum .

Yalçın YILMAZ

İÇİNDEKİLER

SİMGE LİSTESİ	ix
KISALTMA LİSTESİ	x
ŞEKİL LİSTESİ	xii
TABLO LİSTESİ	xvii
ÖZET	xviii
ABSTRACT	xx
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	6
1.3 Hipotez	6
2 3B NOKTA BULUTU ELDE ETME YÖNTEMLERİ	7
2.1 LiDAR Sistemleri	7
2.1.1 Yersel Lazer Tarama Sistemleri	9
2.2 İHA Fotogrametrisi	13
3 SINIFLANDIRMA VE DOĞRULUK ANALİZİ	15
3.1 Sınıflandırma Yöntemleri	15
3.1.1 Piksel Tabanlı Sınıflandırma	15
3.1.2 Obje Tabanlı Sınıflandırma	16
3.1.3 Nokta Tabanlı sınıflandırma	16
3.2 Doğruluk Analizi	17
4 MAKİNE ÖĞRENMESİ	19
4.1 Makine Öğrenmesinin Temelleri	19
4.2 Makine Öğrenmesinin Yöntemleri	20
4.2.1 Denetimli Öğrenme	21
4.2.2 Denetimsiz Öğrenme	26

4.2.3	Pekiştirmeli Öğrenme	26
5	DERİN ÖĞRENME	28
5.1	Evrişim Katmanı	28
5.2	Aktivasyon Katmanı	29
5.3	Havuzlama Katmanı	31
5.4	Softmax Sınıflandırıcısı	33
5.5	Kayıp Fonksiyonu	33
5.6	Optimizasyon Algoritmaları	34
5.6.1	Stotastik Gradyan İniş Algoritması ile Kullanılan Hiperparametreler	35
5.7	Çekirdek Nokta Konvolüsyon (KPCnv)	36
6	VERİLERİN HAZIRLANMASI	39
6.1	Çalışma Alanı	39
6.1.1	Çalışma Alanı 1	39
6.1.2	Çalışma Alanı 2	40
6.2	Sınıflandırma için Verilerin Hazırlanması	42
6.2.1	YTÜ Hidrolik Laboratuvarı Verilerinin Etiketlenmesi	42
6.2.2	Britanya Kolumbiyası İçmesuyu Hattı Verilerinin Etiketlenmesi	44
6.2.3	Özelliklerin Çıkarılması	45
6.2.4	Eğitim ve Test Verilerinin Oluşturulması	48
6.2.5	Makine Öğrenmesi Sınıflandırıcılarına ait Parametrelerin Belirlenmesi	50
6.2.6	Derin Öğrenme Yöntemlerine ait Parametrelerin Belirlenmesi	51
7	ALTYAPILARIN SINIFLANDIRILMASI	53
7.1	YTÜ Hidrolik Laboratuvarı Verilerinin Makine Öğrenmesi Sınıflandırıcıları ile Sınıflandırılması	53
7.1.1	YTU Hidrolik Laboratuvarının Sınıflandırma Sonuçlarına Etki Eden Özelliklerin Belirlenmesi	65
7.2	Britanya Kolumbiyası İçmesuyu Hattı Verilerinin Makine Öğrenmesi Sınıflandırıcıları ile Sınıflandırılması	72
7.2.1	Britanya Kolumbiyası İçmesuyu Hattı Sınıflandırma Sonuçlarına Etki Eden Özelliklerin Belirlenmesi	84
7.3	YTÜ Hidrolik Laboratuvarı Verilerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması	91

7.4	Britanya Kolumbiyası İçmesuyu Hattı Verilerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması	98
8	BULGULAR VE TARTIŞMA	105
8.1	Makine Öğrenmesi Sınıflandırıcıları ile Elde Edilen Sınıflandırma Sonuçlarının Yorumlanması	105
8.2	Derin Öğrenme Yöntemi (KPCnv) ile Elde Edilen Sınıflandırma Sonuçlarının Yorumlanması	113
8.3	Derin Öğrenme ve Makine Öğrenmesi Sonuçlarının Karşılaştırılması	115
9	SONUÇ	117
	KAYNAKÇA	119
A	EKLER	129
	TEZDEN ÜRETİLMİŞ YAYINLAR	134

SİMGE LİSTESİ

g	Çekirdek Fonksiyonu
λ	Düzenlileştirme Avans Katsayısı
$f_t(x_i)$	Eklenmesi Gereken Yeni Ağaç Modeli
σ	Etki Mesafesi (KPCConv)
x_i	Girdi Noktaları
f_i	Girdi Noktalarına Karşılık Gelen Öznitelikler
W_k	Girdi ve Çıktı Boyutları Arasındaki Öznitelik Haritası
X_p, Y_p, Z_p	Kartezyen Koordinatlar
L	Kayıp Fonksiyonu
g_i	Kayıp Fonksiyonunun Birinci Türevi
h_i	Kayıp Fonksiyonunun İkinci Türevi
x_k	Küre İçindeki Noktalar
α	Öğrenme Hızı (Gradient Descent için)
n	Örnek Sayısı
$\sigma(z)_i$	Softmax Fonksiyonu
S	Tarayıcı ile Nesne Arasındaki Mesafe
y_i	Referans Etiket
$\hat{y}_i$	Tahmin Edilen Sınıf
Υ	Yaprak Düğüm

KISALTMA LİSTESİ

3B	3 Boyutlu
AdaBoost	Adaptive Boosting
ALS	Airborne LiDAR System
BIM	Building Information Model/Yapı Bilgi Modelleme
CAD	Computer Aided Design
CC	CloudCompare
CNN	Convolutional Neural Network/Evrişimli Sinir Ağı
CRF	Koşullu Rastgele Alan
DGCNN	Dynamic Graph Convolutional Neural Network/Dinamik Grafik Evrişimli Sinir Ağı
DL	Deep Learning
DÖ	Derin Öğrenme
GPS	Global Positioning System
IMU	Inertial Measurement Unit
ISODATA	Iterative Self Organizing Data Analysis Technique
İHA	İnsansız Hava Aracı
K-means	K-means clustering
KPConv	Kernel Point Convolution
Leaky ReLU	Leaky Rectified Linear Unit / Sızıntılı Düzeltilmiş Doğrusal Birim
LiDAR	Laser Imaging Detection and Ranging
LightGBM	Light Gradient-Boosting Machine
MEP	Mechanical, Electrical, Plumbing / Mekanik, Elektrik, Tesisat
ML	Machine Learning
MLC	Maximum Likelihood Classifier

MLP	Multilayer Perception
MLS	Mobile LiDAR System/Mobil LiDAR
MÖ	Makine Öğrenmesi
MRF	Markov Rastgele Alan
MSE	Mean Squared Error / Ortalama Karesel Hata
OBC	Object Based Classification/Obje Tabanlı Sınıflandırma
OOB	Out of bag
ReLU	Rectified Linear Unit/Düzeltilmiş Doğrusal Birim
RF	Random Forest/Rastgele Orman
SfM	Structure from Motion/Hareketten Yapı
SGD	Stochastic gradient descent
SHOT	Signature of Histograms of Orientations/Yönelim Histogramlarının İmzaları
SIFT	Scale-Invariant Feature Transform/Ölçekten Bağımsız Öznitelik Dönüşümü
SVM	Support Vector Machine/Destek Vektör Makineleri
UAV	Unmanned Aerial Vehicle
XGBoost	Extreme Gradient Boosting/Aşırı Gradyan Artırma
YLT	Yersel Lazer Tarayıcı
YTÜ	Yıldız Teknik Üniversitesi

ŞEKİL LİSTESİ

Şekil 2.1	Coğrafi konumlandırma prensibi ([37]'den düzenlenmiştir.)	9
Şekil 2.2	Yersel lazer tarayıcının çalışma prensibi.	10
Şekil 2.3	Leica RTC360 yersel lazer tarayıcı.	12
Şekil 2.4	İHA ile çekilen görüntülerden yoğun nokta bulutunun elde edilmesinde izlenen işlem adımları ([46, 50]'den düzenlenmiştir.)	14
Şekil 3.1	Karışıklık Matrisi	17
Şekil 4.1	Denetimli Öğrenme	21
Şekil 4.2	Karar Ağacı	22
Şekil 5.1	Evrişim İşlemi	29
Şekil 5.2	ReLU ve Sızıntılı ReLU karşılaştırması	31
Şekil 5.3	a) Maksimum havuzlama , b) Ortalama havuzlama	32
Şekil 5.4	Gradyan iniş ile optimizasyon	35
Şekil 5.5	KPConv ağ yapısı	38
Şekil 6.1	Yıldız Teknik Üniversitesi Davutpaşa Kampüsü İnşaat Fakültesi Hidrolik Laboratuvarı	40
Şekil 6.2	Yersel lazer tarayıcı ile elde edilen nokta bulutu	40
Şekil 6.3	Britanya Kolumbiyası içme suyu hattına ilişkin oluşturulan 3 boyutlu nokta bulutu.	41
Şekil 6.4	Britanya Kolumbiyası içme suyu hattına ilişkin oluşturulan 3 boyutlu nokta bulutu.	42
Şekil 6.5	3 boyutlu nokta bulutundan oluşturulan sınıflar (YTÜ Hidrolik Laboratuvarı	43
Şekil 6.6	3 boyutlu nokta bulutundan oluşturulan sınıflar (Britanya Kolumbiyası İçme Suyu Hattı)	44
Şekil 6.7	Her bir objenin sınıflandırılması için hesaplanan özellikler	46
Şekil 6.8	Farklı yarıçaplarda düzlemselliğin etkisi (a) $r=1m$, b) $r=0.50m$, c) $r=0.30m$, d) $r=0.10m$, e) $r=0.02m$) (YTÜ Hidrolik)	47
Şekil 6.9	Farklı yarıçaplarda düzlemselliğin etkisi (a) $r=1m$, b) $r=0.50m$, c) $r=0.30m$, d) $r=0.10m$, e) $r=0.02m$) (Britanya Kolumbiyası)	47
Şekil 6.10	Her bir senaryodaki eğitim ve test verileri içindeki sınıfların oransal dağılımı(YTÜ Hidrolik Laboratuvarı)	49

Şekil 6.11	Her bir senaryodaki eğitim ve test verileri içindeki sınıfların oransal dağılımı (Britanya Kolumbiyası)	50
Şekil 7.1	Her bir senaryo için sınıflandırıcılarının elde ettiği model doğrulukları	54
Şekil 7.2	Her bir senaryo için sınıflandırıcılarının elde ettiği F1-Skor değerleri	54
Şekil 7.3	S1 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	55
Şekil 7.4	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	56
Şekil 7.5	S2 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	57
Şekil 7.6	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	58
Şekil 7.7	S3 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	59
Şekil 7.8	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	60
Şekil 7.9	S4 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	61
Şekil 7.10	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	62
Şekil 7.11	S5 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	63
Şekil 7.12	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	64
Şekil 7.13	S1 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	66
Şekil 7.14	S2 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	67
Şekil 7.15	S3 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	68
Şekil 7.16	S4 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	69
Şekil 7.17	S5 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	70
Şekil 7.18	Her bir senaryo için sınıflandırıcılarının elde ettiği model doğrulukları	72
Şekil 7.19	Her bir senaryo için sınıflandırıcılarının elde ettiği F1-Skor değerleri	73

Şekil 7.20	S1 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	74
Şekil 7.21	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	75
Şekil 7.22	S2 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	76
Şekil 7.23	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	77
Şekil 7.24	S3 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	78
Şekil 7.25	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	79
Şekil 7.26	S4 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	80
Şekil 7.27	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	81
Şekil 7.28	S5 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	82
Şekil 7.29	a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma	83
Şekil 7.30	S1 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	86
Şekil 7.31	S2 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	87
Şekil 7.32	S3 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	88
Şekil 7.33	S4 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	89
Şekil 7.34	S5 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik	90
Şekil 7.35	Her bir senaryonun KPConv ile elde edilmiş model doğrulukları .	91
Şekil 7.36	Her bir senaryonun KPConv ile elde edilmiş F1-Skor değerleri . .	92
Şekil 7.37	S1 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	92
Şekil 7.38	a) KPConv ile sınıflandırma; b) Etiketli test verisi	93
Şekil 7.39	S2 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	94
Şekil 7.40	a) KPConv ile sınıflandırma; b) Etiketli test verisi	94

Şekil 7.41	S3 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	95
Şekil 7.42	a) KPConv ile sınıflandırma; b) Etiketli test verisi	96
Şekil 7.43	S4 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	96
Şekil 7.44	a) KPConv ile sınıflandırma; b) Etiketli test verisi	97
Şekil 7.45	S5 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	97
Şekil 7.46	a) KPConv ile sınıflandırma; b) Etiketli test verisi	98
Şekil 7.47	Her bir senaryo için KPConv ile elde edilen model doğrulukları .	99
Şekil 7.48	Her bir senaryo için KPConv ile elde edilen model doğrulukları .	99
Şekil 7.49	S1 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	100
Şekil 7.50	a) KPConv ile sınıflandırma; b) Etiketli test verisi	100
Şekil 7.51	S2 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	101
Şekil 7.52	a) KPConv ile sınıflandırma; b) Etiketli test verisi	101
Şekil 7.53	S3 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	102
Şekil 7.54	a) KPConv ile sınıflandırma; b) Etiketli test verisi	102
Şekil 7.55	S4 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	103
Şekil 7.56	a) KPConv ile sınıflandırma; b) Etiketli test verisi	103
Şekil 7.57	S5 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları	104
Şekil 7.58	a) KPConv ile sınıflandırma; b) Etiketli test verisi	104
Şekil 8.1	a) S1 senaryosunda en iyi sonuç veren sınıflandırıcı (XGBoost) ile doğru ve yanlış tahmin edilen noktalar; b) S5 senaryosunda en iyi sonuç veren sınıflandırıcı (XGBoost) ile doğru ve yanlış tahmin edilen noktalar	106
Şekil 8.2	a) S1 senaryosunda en iyi sonuç veren sınıflandırıcı (XGBoost) ile doğru ve yanlış tahmin edilen noktalar; b) S5 senaryosunda en iyi sonuç veren sınıflandırıcı (RF) ile doğru ve yanlış tahmin edilen noktalar	107
Şekil 8.3	YTÜ Hidrolik Laboratuvarı için oluşturulan S1, S2 ve S3 senaryolarının eğitiminde sınıflandırıcıların kullandığı ortak özelliklerin önem sıralaması	108

Şekil 8.4	YTÜ Hidrolik Laboratuvarı için oluşturulan S4 ve S5 senaryolarının eğitiminde sınıflandırıcıların kullandığı ortak özelliklerin önem sıralaması	109
Şekil 8.5	Britanya Kolumbiyası İçmesuyu Hattı için oluşturulan S1, S2 ve S3 senaryolarının eğitiminde sınıflandırıcıların kullandığı ortak özelliklerin önem sıralaması	111
Şekil 8.6	Britanya Kolumbiyası İçmesuyu Hattı için oluşturulan S4 ve S5 senaryolarının eğitiminde sınıflandırıcıların kullandığı ortak özelliklerin önem sıralaması	112
Şekil 8.7	a) S3 senaryosunda KPConv ile doğru ve yanlış tahmin edilen noktalar; b) S1 senaryosunda KPConv ile doğru ve yanlış tahmin edilen noktalar	113
Şekil 8.8	a) S4 senaryosunda KPConv ile doğru ve yanlış tahmin edilen noktalar; b) S3 senaryosunda KPConv ile doğru ve yanlış tahmin edilen noktalar	114
Şekil 8.9	YTÜ veri seti için derin öğrenme ve makine öğrenmesi yöntemlerinin sınıflandırma model doğruluklarının karşılaştırılması	115
Şekil 8.10	Britanya Kolumbiyası veri seti için derin öğrenme ve makine öğrenmesi yöntemlerinin sınıflandırma model doğruluklarının karşılaştırılması	116
Şekil A.1	S1 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)	129
Şekil A.2	S2 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)	129
Şekil A.3	S3 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)	129
Şekil A.4	S4 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)	130
Şekil A.5	S5 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)	130
Şekil A.6	S1 Eğitim ve Test (Britanya Kolumbiyası)	130
Şekil A.7	S2 Eğitim ve Test (Britanya Kolumbiyası)	131
Şekil A.8	S3 Eğitim ve Test (Britanya Kolumbiyası)	131
Şekil A.9	S4 Eğitim ve Test (Britanya Kolumbiyası)	132
Şekil A.10	S5 Eğitim ve Test (Britanya Kolumbiyası)	132
Şekil A.11	S5 senaryosuna ilişkin karışıklık matrisi (Britanya Kolumbiyası) .	133

TABLO LİSTESİ

Tablo 6.1	3 boyutlu nokta bulutundan oluşturulan sınıflar ve dağılımları . .	44
Tablo 6.2	3 boyutlu nokta bulutundan oluşturulan sınıflar ve dağılımları . .	45
Tablo 6.3	Her bir senaryoya göre oluşturulan eğim ve test nokta sayıları(YTÜ Hidrolik Laboratuvarı)	48
Tablo 6.4	Her bir senaryoya göre oluşturulan eğim ve test nokta sayıları (Britanya Kolumbiyası)	49
Tablo 6.5	Aşırı gradyan artırma için grid search parametreleri	50
Tablo 6.6	Hafif gradyan artırma için grid search parametreleri	50
Tablo 6.7	Rastgele orman için grid search parametreleri	50
Tablo 6.8	KPConv için kullanılan parameterler	51

Nokta Bulutu ile Elde Edilen Altyapı Elemanlarının Sınıflandırılmasında Makine Öğrenmesi ve Derin Öğrenme Algoritmalarının Performanslarının Değerlendirilmesi

Yalçın YILMAZ

Harita Mühendisliği Anabilim Dalı

Doktora Tezi

Danışman: Doç. Dr. Arzu SOYCAN

Üç boyutlu (3B) as-built modelleri, teknik altyapı projeleri kapsamında kentsel dinamiklerde önemli bir rol oynamaktadır. Dinamik kentsel alanlarda 3B veri analizinin sağlanması, tasarımdan imalata kadar inşaat süreçlerin izlenmesi ve yönetimi için avantajlar sağlamaktadır. Nokta bulutları, her bir noktanın konum ve renk bilgilerini içeren bir dizi 3B nokta kullanarak bir ortamı temsil eder. Bu noktalara anlamsal bilgi atamak, yani nokta bulutu sınıflandırması yapmak, 3B ortamın belgelenmesi ve izlenmesi için kritik öneme sahiptir. Her bir noktanın çok ölçekli geometrik özelliklerini kullanan makine öğrenimi (MÖ) sınıflandırıcıları ve derin öğrenme (DÖ) modelleri, nokta bulutu sınıflandırması için sıklıkla kullanılmaktadır. Bu çalışma, karmaşık altyapı alanlarında MÖ ve DÖ sınıflandırma performansını değerlendirmeyi ve hedef ortam farkındalığını tanımlamada en etkili olan geometrik özellikleri belirlemeyi amaçlamaktadır. Uygulama çalışması Yıldız Teknik Üniversitesi (YTÜ) Hidrolik Laboratuvarı ve Britanya Kolumbiyası İçmesuyu hattı gibi altyapı unsurlarını içeren iki farklı alanda gerçekleştirilmiştir ve her alan için 5 farklı senaryo oluşturulmuştur. Her iki alan için, Rastgele Orman (Random Forest-RF), Aşırı Gradyan Artırma (eXtreme Gradient Boosting Machines -XGBoost), Hafif Gradyan Artırma (Light Gradient Boosting Machines -LightGBM) MÖ sınıflandırıcıları ve çekirdek nokta konvolüsyonu (Kernel Point Convolution - KPConv) DÖ modelinin sınıflandırma performansları 5 farklı senaryo (S1, S2, S3, S4, S5) üzerinden irdelenmiştir. YTÜ Hidrolik Laboratuvarında RF,

XGBoost ve LightGBM ile gerçekleştirilen senaryo bazlı sınıflandırma doğrulukları sırasıyla; S1 (0.948, 0.963, 0.961), S2 (0.894, 0.935, 0.924), S3 (0.901, 0.941, 0.905), S4 (0.885, 0.935, 0.848) ve S5 (0.739, 0.840, 0.831) olarak elde edilmiştir. Britanya Kolumbiyası İçmesuyu hattında RF, XGBoost ve LightGBM ile gerçekleştirilen senaryo bazlı sınıflandırma doğrulukları; S1 (0.885, 0.871, 0.886), S2 (0.910, 0.898, 0.896), S3 (0.781, 0.769, 0.789), S4 (0.831, 0.815, 0.830) ve S5 (0.738, 0.661, 0.618) olarak elde edilmiştir. YTÜ Laboratuvarında KPConv ile gerçekleştirilen senaryo bazlı sınıflandırma doğrulukları sırasıyla; S1 (0.972), S2 (0.989), S3 (0.993), S4 (0.989), ve S5 (0.990) olarak bulunmuştur. Britanya Kolumbiyası İçmesuyu hattında KPConv ile gerçekleştirilen senaryo bazlı sınıflandırma doğrulukları sırasıyla; S1 (0.957), S2 (0.967), S3 (0.905), S4 (0.976), ve S5 (0.968) olarak elde edilmiştir. Makine öğrenmesi sınıflandırıcılarının sınıflandırma sonuçlarına göre YTÜ veri seti için genel olarak XGBoost üstünlüğü göze çarparken, Britanya Kolumbiyası veri setinde RF'nin daha fazla senaryoda üstün olduğu görülmüştür. Ayrıca, bu sınıflandırıcılar farklı yaklaşımlara sahip olsalar da, bu sınıflandırıcıların sınıflandırmada önemli olarak belirledikleri geometrik özelliklerde benzerlikler olduğu tespit edilmiştir. Her iki çalışma bölgesinin derin öğrenme ve makine öğrenme yöntemleri ile elde edilen doğruluk sonuçları kıyaslandığında bütün senaryolarda KPConv derin öğrenme modelinin sınıflandırma performansının oldukça üstün olduğu görülmüştür.

Anahtar Kelimeler: Derin öğrenme, makine öğrenmesi, altyapı sınıflandırma, rastgele orman, hafif gradyan artırma, aşırı gradyan artırma

ABSTRACT

Evaluation of the Performance of Machine Learning and Deep Learning Algorithms in the Classification of Infrastructure Elements Obtained With Point Cloud

Yalçın YILMAZ

Department of Geomatic
Doctor of Philosophy Thesis

Supervisor: Assoc. Prof. Dr. Arzu SOYCAN

Three-dimensional (3D) as-built models play a crucial role in urban dynamics within the scope of technical infrastructure projects. Enabling 3D data analysis in dynamic urban areas provides advantages for monitoring and managing construction processes, from design to production. Point clouds represent an environment using a set of 3D points, each containing location and color information. Assigning semantic information to these points, known as point cloud classification, is critical for documenting and monitoring 3D environments. Machine learning (ML) classifiers and deep learning (DL) models, which utilize multi-scale geometric features of each point, are frequently used for point cloud classification. This study aims to evaluate the performance of ML and DL classifiers in complex infrastructure areas and to identify the most effective geometric features for defining target environment awareness. The case study was conducted in two different areas involving infrastructure elements: the Hydraulic Laboratory at Yıldız Technical University (YTU) and the potable water pipeline in British Columbia, with five different scenarios created for each area. The classification performances of the Random Forest (RF), eXtreme Gradient Boosting Machines (XGBoost), Light Gradient Boosting Machines (LightGBM) ML classifiers, and the Kernel Point Convolution (KPConv) DL model were examined over five different scenarios (S1, S2, S3, S4, S5) for each area. In the YTU Hydraulic Laboratory, the scenario-based classification accuracies for RF, XGBoost, and LightGBM were as follows: S1 (0.948, 0.963, 0.961), S2 (0.894, 0.935, 0.924), S3 (0.901, 0.941,

0.905), S4 (0.885, 0.935, 0.848), and S5 (0.739, 0.840, 0.831). In the British Columbia potable water pipeline, the scenario-based classification accuracies for RF, XGBoost, and LightGBM were as follows: S1 (0.885, 0.871, 0.886), S2 (0.910, 0.898, 0.896), S3 (0.781, 0.769, 0.789), S4 (0.831, 0.815, 0.830), and S5 (0.738, 0.661, 0.618). The scenario-based classification accuracies with KPConv in the YTU Laboratory were as follows: S1 (0.972), S2 (0.989), S3 (0.993), S4 (0.989), and S5 (0.990). In the British Columbia potable water pipeline, the scenario-based classification accuracies with KPConv were as follows: S1 (0.957), S2 (0.967), S3 (0.905), S4 (0.976), and S5 (0.968). Based on the classification results of the ML classifiers, XGBoost generally showed superiority for the YTU dataset, while RF was more dominant in more scenarios for the British Columbia dataset. Moreover, despite having different approaches, these classifiers were found to have similarities in the geometric features they identified as significant for classification. When comparing the accuracy results obtained with DL and ML methods in both study areas, the classification performance of the KPConv DL model was found to be significantly superior in all scenarios.

Keywords: Deep learning, machine learning, infrastructure classification, random forest, eXtreme gradient boosting machine, light gradient boosting machines

Altyapı, bir toplumun veya ekonominin sorunsuz işleyişini sağlamak için gereken temel fiziksel ve organizasyonel yapılar ve tesisler bütünüdür. Ulaştırma sistemleri, su ve atık yönetimi, enerji dağıtımı ve telekomünikasyon gibi çeşitli temel hizmetler bu kapsamda değerlendirilir. Altyapı ayrıca, okullar, hastaneler ve acil durum hizmetleri gibi kamu hizmetlerini de içerir [1]. Altyapı projeleri, modern toplumların sürdürülebilirliği ve gelişimi için hayati öneme sahiptir. Bu projelerin tasarımı, inşası ve bakımı, yüksek düzeyde doğruluk ve detay gerektirir. Günümüzde, altyapı elemanlarının 3 boyutlu nokta bulutlarından sınıflandırılması, bu ihtiyaçları karşılamada önemli bir rol oynamaktadır. 3B nokta bulutları, gerçek dünya nesnelerinin yüksek çözünürlüklü dijital ikizlerini oluşturarak, mühendislerin ve planlayıcıların altyapıyı daha etkin bir şekilde tasarlamalarına, inşa etmelerine ve yönetmelerine olanak tanır. Bu, mühendislerin ve projeci ekiplerinin, altyapı projelerini daha verimli bir şekilde planlamalarına, uygulamalarına ve idare etmelerine imkan tanır. Nokta bulutlarından elde edilen sınıflandırma, yapıların ve arazilerin detaylı incelenmesine yardımcı olur, maliyet analizlerini daha doğru yapmaya olanak verir, tasarımdaki potansiyel hataları minimize eder ve bakım süreçlerini daha etkin hale getirir. Bu bağlamda, altyapı elemanlarının 3 boyutlu nokta bulutları ile sınıflandırılmasının önemi, hem teknik detayların iyileştirilmesi hem de genel proje yönetiminin optimizasyonu açısından açıkça ortadadır [2].

1.1 Literatür Özeti

Teknik altyapı ve inşaat projelerinde 3 boyutlu (3B) as-built modellerinin kullanımı son dönemde önemli bir yere sahiptir [2, 3]. Kentselleşmenin ayrılmaz bir parçası olan teknik altyapı projeleri, kent dinamikleri üzerinde büyük bir etkiye sahip olup, bu projelerin sağlayıcıdan kullanıcıya kadar tüm yaşam döngüsünü kapsayan bir bütünlük içinde gerçekleştirilmesi gerekmektedir. Bu doğrultuda, bu altyapı çalışmalarının etkinliğini artırmak için hassas 3B as-built modellerin

geliştirilmesi zorunludur. Geleneksel olarak, bu modeller manuel ölçümler (GNSS, total station vb. ekipmanlarla) ve bilgisayar destekli tasarım (CAD) yazılımları kullanılarak oluşturulabilir. Ancak, bu süreç iş gücü yoğun, zaman alıcı ve derin öğrenme uygulamaları için veri hazırlığı aşamasında hatalara açık bir yapıya sahiptir. Geleneksel yöntemler ile elde edilen verilerin yerine lazer tarayıcı ve görüntülerden elde edilen nokta bulutlarının kullanılması, nesnelerin şekli hakkında daha fazla 3B bilgi sağlamaktadır. Bu durum, son dönemde inşaat ve altyapı ile ilgili uygulamalarda noktalar bulutları kullanarak bilgi çıkarımının artan önemini açıkça ortaya koymaktadır [4].

Nokta bulutları, sahne anlama alanında popüler hale gelmiş olup, ölçülen nesne veya sahnenin noktalarına ait 3B konum, renk ve yoğunluk bilgilerini içermektedir. Nokta bulutlarındaki her bir noktaya anlamsal bilgi atama süreci, nokta bulutu sınıflandırması olarak tanımlanabilir. Geleneksel yöntemlerde, nokta bulutu sınıflandırması, her bir noktanın belirli kurallara göre tanımlanmasına dayanır [5]. Bu kurallar, düzenli yapılar için faydalı olsa da, karmaşık durumlar için yetersiz kalmaktadır [6]. Son yıllarda, makine öğrenmesi (Machine Learning - ML) ve derin öğrenme (Deep Learning - DL) tabanlı algoritmalar bu tür problemleri çözmede yaygın olarak kullanılmaktadır.

Literatürde makine öğrenmesi tabanlı 3B nokta bulutu çalışmaları kentsel, inşaat ve altyapı nesneleri üzerinden gerçekleştirilmiştir. Kentsel çalışmalarda genellikle zemin, binalar, ağaçlar, araçlar ve sokak gibi nesnelerin sınıflandırılmasına odaklanılmıştır. Bu tür nesnelerin sınıflandırılmasında komşuluk ve ölçek parametreleri büyük önem taşımaktadır. Parametre nokta bulutu çözünürlüğüne nispeten yakınsa (nispeten daha küçük arama yarıçapı), hesaplama süresini azaltır ancak farklı boyutlardaki nesneler için bilgi kaybına neden olur. Daha büyük (nispeten daha yüksek arama yarıçapı) bir parametre ise hesaplama süresini artırır ve daha küçük nesneler için bilgi kaybına neden olmaktadır. Bu nedenle, çalışmalar farklı ölçek ve komşuluk değerlerine bağlı olarak yapılmıştır [6–13]. Weinmann vd. [9] geometrik özellikleri kullanarak komşuluk parametrelerindeki değişimlerin ve komşuluk türlerinin 3 boyutlu nokta bulutu sınıflandırma üzerindeki etkisini incelemiştir. Çalışmalarında 3 boyutlu nokta bulutu sınıflandırma için doğrusal diskriminant analizi (Linear Discriminant Analysis - LDA), rastgele orman (Random Forest - RF) ve en yakın komşu (Nearest Neighbor - NN) algoritmaları kullanılmıştır. Komşuluk türü açısından silindirik komşuluk tipinin yersel veya mobil lazer tarama verileri için uygun olmadığını belirtilmiş ve kullanılan algoritmalar arasında RF algoritmasının tercih edilebilir olduğu tespit edilmiştir. Becker vd. [10] 3 boyutlu nokta bulutu sınıflandırma için RF ve hafif gradyan artırma makinesi (Light Gradient Boosting

Machine - LightGBM) sınıflandırıcılarını kullanarak geometrik özelliklerin ve renk bilgilerinin sınıflandırma sonuçları üzerindeki etkisini irdelemiştir. Çalışmada renk bilgisinin geometrik özelliklerle birlikte kullanılmasının sınıflandırma sonuçlarına olumlu yönde katkı sağladığı ifade edilmiştir. Shi vd. [13] kentsel 3B nokta bulutu sınıflandırması için LightGBM tabanlı bir algoritma önermişlerdir. Algoritmayı değerlendirmek için destek vektör makineleri (Support Vector Machines - SVM) ve RF ile karşılaştırmış ve önerilen yöntem sonuçlarının diğerlerine kıyasla daha iyi performans gösterdiğini tespit etmişlerdir. Duran vd. [11], insansız hava aracı (İHA) fotogrametrisi ve havadan LiDAR ile elde edilen iki farklı nokta bulutu veri kümelerinin sınıflandırılması için 9 makine öğrenme sınıflandırıcısı kullanmıştır. Çok katmanlı algılayıcı (Multilayer Perception - MLP) en iyi sınıflandırma sonucunu elde ederken, AdaBoost yöntemi ise başarısız bir performans göstermiştir. Perez-Perez vd. [14], ticari ve endüstriyel bina projelerine özgü nokta bulutu sahnelerinde yakın mesafedeki yapısal, mimari ve MEP (Mekanik, Elektrik, Tesisat) bileşenlerine semantik etiketler atamak için nokta bulutunun geometrik özelliklerini kullanan yeni bir yaklaşım önermişlerdir. Bu yöntem, Destek Vektör Makinesi (SVM), AdaBoost sınıflandırıcıları, Koşullu Rastgele Alan (CRF) ve Markov Rastgele Alan (MRF) optimizasyonlarının bir kombinasyonunu kullanarak hem semantik (örneğin, giriş, kolon, duvar, tavan, zemin, boru) hem de geometrik (örneğin, yatay, dikey, silindirik) özellikleri entegre etmektedir. Yöntem, genel olarak ortalama %90 doğruluk oranına ve tavan, duvar, boru, zemin, giriş ve kolon kategorileri için sırasıyla %99, %96, %87, %100, %89 ve %18 kategori doğruluğuna ulaşmıştır. Sonuç olarak, CRF ve MRF yöntemlerinin ardışık kullanımının, semantik etiketleme doğruluğunu önemli ölçüde artırılabilirliği vurgulanmıştır. Sevgen ve Abdikan [12], Weinmann vd. [9] çalışmasına benzer şekilde, komşuluk tanımı, çok ölçekli özellik çıkarımı ve büyük veri kümeleri için LightGBM sınıflandırıcısını kullanarak bir sınıflandırma analizi yapmıştır. Geleneksel makine öğrenmesi tabanlı yöntemlere göre daha başarılı sonuçların elde edildiğini ve geometrik özelliklerin seçiminin sonuçları olumlu yönde etkilediğini tespit etmişlerdir.

İnşaat ve altyapı üzerine gerçekleştirilen nokta bulutu sınıflandırma çalışmaları kentsel alanlara nazaran daha az ilgi görmüştür. Huynh vd. [15], Sidney Liman Köprüsü'nün koruyucu kaplamalarındaki bozulmaları değerlendirmek için hiperspektral görüntüleme ve çok sınıflı SVM kullanmış ve bu yöntemin kaplama ve erozyon arasında ayrım yapmada daha iyi sonuçlar verdiğini göstermişlerdir. Mansour vd. [16] altyapı ortamlarındaki nokta bulutlarını analiz etmek ve bölütlemek için komşuluk parametrelili SVM'nin kullanımını incelemiştir. 3B lazer tarayıcıları tarafından elde edilen altyapı nesnelerinin 3B nokta bulutlarının

otomatik semantik segmentasyonunun, SVM kullanılarak gerçekleştirilebileceğini ifade etmişlerdir. Çalışma altyapı nesnelerinin daha detaylı analiz ve işlenmesi için önemli bir adım niteliğindedir ve makine öğrenimi tekniklerinin bu alandaki uygulamalarını genişletme potansiyeline işaret etmektedir.

Derin öğrenme tabanlı 3B nokta bulutu sınıflandırma uygulamaları nokta tabanlı [17–20], grafik tabanlı [21, 22] ve voksel tabanlı[23] olmak üzere üç farklı şekilde yapılmaktadır. Nokta tabanlı yöntemler, şekil dönüştürme yerine nokta bulutunu doğrudan kullanmaktadır. Bu alanda göze çarpan çalışmalardan biri, Qi vd. [17] tarafından gerçekleştirilmiştir. Yazarlar noktaların permütasyon değişmezliğine dikkat ederek nokta bulutu verilerini doğrudan işleyen bir sinir ağı mimarisi olan PointNet'i kullanmıştır. PointNet'in 3 boyutlu sınıflandırma ve bölümlendirme görevleri için umut verici bir sinir ağı mimarisi olduğunu, %89.2 model doğruluğu ile diğer yöntemlere göre güçlü performans ve verimliliğe sahip olduğunu ifade etmişlerdir. Daha sonrasında noktaların yerel olarak toplanması nedeniyle PointNet'i hiyerarşik seviyelerde kullanan ve gelişmiş bir versiyonu olan PointNet++ önerilmiştir [18]. Wu vd. [24] 3B nokta bulutları için doğrudan nokta bulutları üzerinde derin konvolüsyonel ağların oluşturulmasına olanak tanıyan PointConv'u önermiştir. PointConv modelinde permütasyon ve öteleme değişmemekte ve düzensiz ve sırasız nokta bulutu verileri için uygunluğu artmaktadır. Bir başka model Thomas vd. [19] tarafından çekirdek nokta konvolüsyonu (Kernel Point Convolution - KPConv) olarak ortaya atılmıştır. Düzenli alt örnekleme stratejisi ve çekirdek noktalarını yerel geometriye uyarlama yeteneği sayesinde değişen nokta bulutu yoğunlukları için başarılı sonuçlar elde etmişlerdir. Hu vd. [20] büyük ölçekli nokta bulutlarında anlamsal segmentasyonu verimli bir şekilde gerçekleştirmek için rastgele nokta örnekleme ve yeni bir yerel özellik toplama modülü kullanmış ve hafif bir sinir mimarisi olan RandLA-Net modelini önermişlerdir. Perez-Perez vd. [25] altyapı elemanı sınıflandırması için bir evrişimli sinir ağı ve tekrarlayan bir sinir ağı kullanılarak nokta tabanlı bir yaklaşım sunmuşlardır. Çalışma, endüstriyel ve ticari binalardaki 83 odadan toplanan verilere dayanan altı sınıflı bir 3B nokta bulutu sınıflandırma analizini içermektedir. Grafik tabanlı ağlar 3B nokta bulutu sınıflandırma analizlerinde öne çıkan bir stratejidir. Bu ağlar, nokta bulutu verilerinden üretilen düğümleri analiz etmek için kullanılmakta ve türetilmiş grafikler içindeki yerel yapıların daha derin bir şekilde anlaşılmasını sağlamaktadır.

Xu vd. [26] çalışmalarında, SHOT (Yönelim Histogramlarının İmzaları) ve spin görüntüler gibi geleneksel şekil özelliklerini derin evrişimli sinir ağları (CNN) ile birleştirerek, 3B nokta bulutlarından boru bileşenlerini sınıflandırmak için özellik tabanlı bir derin öğrenme ağı önermişlerdir. Ağ, küresel ve

yerel özelliklerin ön işlenmesi için UnitNet ve FeatureNet, ardından özellik çıkarma ve sınıflandırma için FinalNet kullanılmıştır. Lazer taramalı nokta bulutlarından oluşan veri seti, yoğun MEP (Mekanik, Elektrik, Tesisat) sistemlerine sahip karmaşık sahnelerle odaklanmaktadır. Bu sahneler, gürültü ve eksik veri nedeniyle geleneksel algoritmalar için önemli zorluklar oluşturmaktadır. Önerilen yöntem, nokta bulutlarından hem küresel hem de yerel özelliklerin çıkarılmasıyla başlar. UnitNet, her noktanın küresel koordinatlarını işlerken, FeatureNet geleneksel şekil özelliklerini kullanarak her noktanın etrafındaki yerel geometrileri tanımlar. Bu özellikler daha sonra FinalNet'te birleştirilir ve derin CNN'ler özellik birleştirme ve sınıflandırma işlemlerini gerçekleştirir. Bu yaklaşım, geleneksel özellik tabanlı derin ağ kullanan bir kontrol deneyi ile karşılaştırılarak doğrulanmıştır. Sonuç olarak, önerilen yöntemin %98'in üzerinde sınıflandırma doğruluğuna ulaştığını, kontrol deneyinin ise yalnızca %84 doğruluğa ulaştığını belirtmişlerdir. Bu yüksek doğruluk, ağır karmaşık inşaat sahnelerinde boru bileşenlerini doğru bir şekilde tanımlama yeteneğini artıran sağlam özellik çıkarma ve birleştirme sürecine atfedilmektedir. Yöntem, özellikle as-built yapı bilgi modellerinin (Building Information Model-BIM) oluşturulmasında inşaat süreçlerinin dijitalleştirilmesinde verimliliği artırma ve elle müdahaleyi azaltma potansiyeli gösterdiğini belirtmişlerdir. Bu yaklaşımla, genellikle manuel giriş gerektiren, gürültülü ve eksik verilerle başa çıkmakta zorlanan geleneksel nokta bulutu işleme yöntemlerinin sınırlamalarını ele almışlardır. Geleneksel şekil özellikleri ve derin öğrenmeden yararlanarak önerilen bu ağı, inşaat bileşenlerinin sınıflandırılmasını otomatikleştirmek için güçlü bir araç sunmuşlardır ve nihayetinde inşaat projelerinde MEP sistemlerinin ve diğer kritik altyapı elemanlarının daha iyi yönetimini ve bakımını kolaylaştırdığını ileri sürmüşlerdir. Wang vd. [21] nokta bulutlarının temsilini iyileştirmek için küresel bir şekil yapısını yerel komşuluk bilgileriyle birleştiren dinamik bir grafik evrişimli sinir ağı (Dynamic Graph Convolutional Neural Network - DGCNN) yaklaşımını önermişlerdir. Yaklaşım, PointNet, PointCNN gibi yöntemler ile kıyaslanmış ve %84.1 model doğruluğu ile daha üstün sonuç almıştır.

Literatür taramasından görüldüğü üzere, makine öğrenimi sınıflandırıcıları (ML) ve derin öğrenme (DL) yöntemleri, inşaat ve altyapı sektörlerinde 3B veri sorunlarının çözümünde yaygın olarak kullanılmamaktadır. Ayrıca belirli geometrik özelliklerin kullanılması sınıflandırma süresini kısaltmakta ve işlem yükünü azaltmaktadır. Bu tür durumlar inşaat ve altyapı sektörleriyle ilgili çalışmalarda henüz yeterince vurgulanmamıştır. Weinmann vd. [27] çalışmasında geometrik özelliklerin 3B ortamda nesne türüyle ilişkilendirilmesine dair bilgiler yer almakla birlikte, bu alanlarda henüz kapsamlı bir çalışma gerçekleştirilmemiştir.

1.2 Tezin Amacı

Bu tezin amacı, 3B nokta bulutlarından makine öğrenimi (MÖ) ve derin öğrenme (DÖ) yöntemleri kullanılarak altyapı unsurlarının sınıflandırılması ve sınıflandırıcılardan bağımsız olarak altyapı sınıflandırmasında kullanılacak geometrik özelliklerden ortak değerlerin olup olmadığının araştırılmasıdır. Bu amaç doğrultusunda iki çalışma alanı seçilmiştir: Birincisi, YTÜ Davutpaşa Kampüsü'nde yer alan hidrolik laboratuvarının havalandırma sistemi; ikincisi ise Britanya Kolumbiyası'nda yer alan içmesuyu hattıdır. Her iki veri setinde de altyapı bileşenleri (boru, te, dirsek vb.) MÖ ve DÖ yöntemleri ile sınıflandırılacaktır. Bu süreçte, her iki veri seti için geometrik özelliklerin belirlenmesi ve sınıflandırmada kullanılacak sınıflandırıcı parametrelerinin ızgara arama yaklaşımı (grid search) ile optimize edilmesi hedeflenmiştir. En uygun parametreler belirlendikten sonra MÖ ve DÖ yöntemleri kullanılarak her iki çalışma alanındaki altyapı unsurları sınıflandırılacak ve doğruluk analizi ile sınıflandırıcıların sınıflandırma performansları karşılaştırılacaktır. Ayrıca makine öğrenmesi ve derin öğrenmenin altyapı sınıflandırma performansları değerlendirilecektir.

1.3 Hipotez

Bu tez;

- Makine öğrenmesi ve derin öğrenme yöntemleri nokta bulutlarından altyapı elemanlarının sınıflandırılmasında kullanılabilir,
- Farklı makine öğrenmesi yöntemleri aynı geometrik özellikleri, altyapı elemanlarının sınıflandırılmasında önemli özellik olarak tespit edebilir hipotezi üzerine kurulmuştur.

3B NOKTA BULUTU ELDE ETME YÖNTEMLERİ

Üç boyutlu nokta bulutu elde etme yöntemleri, modern teknoloji ve bilimsel araştırmalarda kritik bir rol oynamaktadır. Bu yöntemler, nesnelerin, yapıların ve çevresel özelliklerin hassas bir şekilde modellenmesini sağlar. Bu bölümde tez kapsamında kullanılmış olan yersel lazer tarayıcı (YLT) ve insansız hava aracı (İHA) fotogrametrisine değinilecektir.

2.1 LiDAR Sistemleri

LiDAR (Işık Algılama ve Mesafe Belirleme), ışık dalgalarını kullanarak nesne ve yüzeylerin mesafelerini belirlemek için kullanılan bir uzaktan algılama teknolojisidir. Temel olarak, bir LiDAR sistemi lazer ışını yayar; bu ışın, çevredeki nesnelere çarparak geri yansır. Yansıyan ışığın geri dönüş süresi ölçülerek nesnelerin konumu, mesafesi ve diğer özellikleri hakkında detaylı bilgiler elde edilir [28]. Böylece, LiDAR sistemleri ile yüksek yoğunluklu ve doğruluklu üç boyutlu (3B) veriler elde edilebilmektedir [29]. Lidar verileri, geniş alanlar için hızlı ve doğru 3B nokta verilerini yakalar; dahası, ışığın varlığından etkilenmezler ve bitki örtüsüne nüfuz edebilir ve orman örtüsünün altındaki zeminlere ulaşabilir [30]. Bu özellikler, arazi ölçümleri ve fotogrametri gibi geleneksel ölçüm yöntemlerinin dezavantajlarını aşmada büyük avantajlar sunar. LiDAR sistemlerinin yoğun bitki örtüsü altındaki yüzeyleri bile detaylı bir şekilde tespit edebilme yeteneği ve yüksek doğrulukta veri toplama kapasitesi, bu teknolojiyi haritalama, orman bilimi, jeoloji ve şehir planlaması gibi çeşitli alanlarda vazgeçilmez kılar [31]. Gelişen teknolojiye paralel olarak, farklı uygulama alanlarında yararlanılabilmesi amacıyla yersel, mobil ve hava tabanlı LiDAR sistemleri geliştirilmiştir [32].

LiDAR temelli ölçüm sistemleri, temel olarak Hava Tabanlı LiDAR (ALS), Mobil LiDAR (MLS) ve Yer Tabanlı LiDAR (TLS) olmak üzere üç ana kategoriye ayrılmaktadır. Bu üç sistemde kullanılan temel prensipler benzer olmakla birlikte, MLS ve ALS sistemleri, toplanan verileri GPS ve IMU gibi konum ve durum

sensörleri ile desteklenen hareketli bir platformdan (tekne, otomobil veya uçak gibi) toplar [33]. Yersel lazer tarayıcılar (TLS), sabit bir konumdan çevresindeki nesne ve yüzeylerin 3B dijital haritalarını oluşturmak için lazer ışını kullanmaktadır. Bu sistemler, elde edilen nokta bulutu verilerinin koordinatlandırılması amacıyla genellikle çevrelerinde belirlenmiş ve koordinatları önceden bilinen kontrol noktalarına yansıttıkları lazer ışınları aracılığıyla tarayıcının verilerini gerçek dünya koordinatlarına entegre etmek için kullanılır [34].

ALS (Airborne LiDAR System) teknolojisi, algılama görevlerini başarıyla tamamlamak ve kısa sürede geniş bir alan üzerinde son derece doğru yüzey bilgileri elde etmek amacıyla genellikle bir uçak platformu ile LiDAR'ı birleştirir. Geleneksel olarak ALS sistemleri, uçaklara ve helikopterlere monte edilen LiDAR sistemlerinden oluşur. Ancak son zamanlarda popülerlik kazanan UAV (İnsansız Hava Aracı) LiDAR sistemleri, daha düşük maliyetli olup erişilmesi zor alanlarda kullanım için idealdir. Araştırmacılar, bu sistemler aracılığıyla karmaşık coğrafi bölgelerde ve dar alanlarda detaylı veri toplamaktadır [35].


Mobil LiDAR sistemleri, araçlara monte edilerek konfigüre edilmiş, LiDAR sensörleri, GNSS birimleri, IMU ve mesafe ölçüm göstergeleri gibi çoklu yerleşik sensörlerle entegre bir mobil haritalama teknolojisidir. Bu sistemler, yüksek hızda geniş alanlardaki veri toplama kabiliyetleri sayesinde, profil tarama tekniklerini kullanarak ve hedef yüzeylerden yansıyan lazer darbelerinin yoğunluğunu analiz ederek konumlandırma, navigasyon, nesne tespiti ve algılama gibi fonksiyonları icra eder. Ayrıca, mimari ve cephe ölçümü, tünel araştırmaları, akıllı ulaşım sistemleri ve inşaat mühendisliği gibi çeşitli alanlarda üç boyutlu (3B) kentsel dijital modelleme görevlerini destekler [36].

Yukarıda da ifade edildiği gibi ALS/MLS sistemlerinde üç ana bileşen bulunur: a) bir lazer tarayıcı cihazı, b) GPS ve c) IMU bunların yanısıra bazı sistemlerde kameralarda entegre edilebilmektedir. Bu sistemlerin doğrudan coğrafi referanslandırılması (geo-referencing) mekanizması Şekil 2.1'de açıklanmıştır. Belirli bir P noktasına elde edilen tarama açısı α , tarama mesafesi d 'ye göre, koordinat sistemindeki konumu Eşitlik 2.1'de formüller yardımıyla belirlenebilir [37].

$$\begin{bmatrix} X_P \\ Y_P \\ Z_P \end{bmatrix} = R_M^{IMU}(\omega, \varphi, \kappa) \cdot \left(\begin{bmatrix} l_X \\ l_Y \\ l_Z \end{bmatrix} + \begin{bmatrix} L_X \\ L_Y \\ L_Z \end{bmatrix} + r_p^S(\alpha d) \cdot R_{IMU}^S(\Delta\omega, \Delta\varphi, \Delta\kappa) \right) + \begin{bmatrix} X_{GNSS} \\ Y_{GNSS} \\ Z_{GNSS} \end{bmatrix} \quad (2.1)$$

Eşitlik 2.1'deki, $[X_P, Y_P, Z_P]^T$ belirli bir haritalama sisteminde hedef P'nin

konumlandırma bilgisini sunar; $[X_{GNSS}, Y_{GNSS}, Z_{GNSS}]^T$ aynı haritalama sistemindeki GNSS anteninin konum bilgisini gösterir; w, f, k , haritalama koordinat sistemindeki IMU'nun dönüş, eğim ve sapma ayrıntılarıdır; $\Delta\omega, \Delta\varphi, \Delta\kappa$, tarayıcıları IMU ile uyumlu hale getiren yönlendirme açılarıdır (bore sight angles); α ve d , lazer darbelerinin geliş açısını ve atış aralığını belirtir; ve diğer parametreler sistem kalibrasyonu yoluyla tanımlanır.



Şekil 2.1 Coğrafi konumlandırma prensibi ([37]'den düzenlenmiştir.)


2.1.1 Yersel Lazer Tarama Sistemleri

Yersel lazer tarayıcılar, belirli bir yüzeyin üç boyutlu nokta bulutunu hızlı ve hassas bir şekilde elde etmeyi sağlayan önemli ölçüm yöntemlerinden biridir. Tarihsel olarak, yersel LiDAR teknolojisi, özellikle endüstriyel ve inşaat mühendisliği uygulamalarında, binaların ve arkeolojik alanların dış yüzeylerine ait üç boyutlu nokta bulutu verilerinin toplanmasında sıklıkla kullanılmaktadır [38]. Bu teknolojinin temel bileşenlerinden biri olan mesafe belirleme sistemi, yersel lazer tarayıcının etkinliğini artırmaktadır. Sistem, tarayıcıdan bir nesneye olan mesafeyi ölçmek için bir lazer mesafe ölçer (lazer ranger) kullanır. Çalışma prensibi, tarayıcının, sapma açısını dikey ve yatay yönlerde değiştirerek önceden ayarlanan

taranan alana bir lazer ışını göndermesine dayanır. Lazer ışını yolu üzerindeki bir yansıtıcı yüzeye çarptığında, alıcıya geri döner. Menzil ölçümünde kullanılan farklı yöntemler, tarayıcı ile nesne arasındaki mesafenin (S) hesaplanmasına olanak tanır. Son olarak, ışığın azimut (yatay) ve yükseklik (dikey) açılarına (α, β) göre yansıtıcı noktanın konumu (X_p, Y_p, Z_p), alet koordinat sistemine dayalı olarak Eşitlik 2.2 ile belirlenir [39].

$$X_p = S \cdot \cos\beta \cdot \cos\alpha, Y_p = S \cdot \cos\beta \cdot \sin\alpha, Z_p = S \cdot \sin\beta \quad (2.2)$$

Şekil 2.2’de yersel lazer tarayıcının çalışma prensibi gösterilmektedir.



Şekil 2.2 Yersel lazer tarayıcının çalışma prensibi.

Lazer tarayıcılarda kullanılan iki temel mesafe ölçüm yöntemi bulunmaktadır: uçuş süresi ('darbe bazlı - pulse-based' olarak da bilinir) ve faz bazlı. Her tarayıcı tipi, proje gereksinimlerine bağlı olarak farklı senaryolarda uygun uygulamalar sunar. Uçuş süresi tarayıcılarının gücü, çok daha uzun ölçüm aralıklarında ve azaltılmış sahte nokta gürültüsünde yatmaktadır. Öte yandan, darbe bazlı tarayıcılar ölçüm doğruluğu ve hız açısından önemli avantajlar sağlar. Bu teknik, bir lazer

enerjisi darbesinin seyahat süresinin kaydedilmesine dayanan klasik bir yöntemdir. Lazerin hızı çok kesin olarak bilindiğinden, yayılan darbenin gidiş-dönüş süresi kaydedildiğinde, mesafe Eşitlik 2.3 kullanılarak hesaplanabilir; burada c lazerin hızını, t ise lazerin gidiş-dönüş süresini temsil eder [40].

$$S = \frac{1}{2}.c.t \quad (2.3)$$

Yersel Lazer tarama ölçümlerinde iki temel tarama protokolü tanımlanabilir: tek tarama ve çoklu tarama. Tek tarama metodunda, lazer tarayıcı sabit bir konuma yerleştirilir ve yalnızca bir defa tarama gerçekleştirilir. Bu yöntem, süre açısından en verimli olsa da, elde edilen nokta bulutu nesnelerin yalnızca tek bir yüzeyini temsil eder. Çoklu tarama metodunda, nesnelerin çevresinde genellikle üç veya dört kez tarama yapılır. Bu yöntemde, farklı taramaların birleştirilmesi, sahnede yerleştirilmiş ve her tarama için ortak referans noktaları olan en az üç referans hedefin koordinatları kullanılarak gerçekleştirilen geometrik bir dönüşüm ile sağlanır [41]. Her tarama ile elde edilen nokta bulutu verileri tarayıcı merkezli yerel koordinat sistemini temsil eder. Tüm verilerin, “registration” kayıt olarak bilinen bir süreç aracılığıyla ortak küresel bir koordinat sistemine dönüştürülmesi gerekmektedir. Literatür çalışmalarında otomatik kayıt yöntemleri geliştirilmiş olmasına rağmen, genel uygulamalarda kayıt işlemi hala yarı otomatik olarak gerçekleştirilmektedir. Tipik olarak, registration İşleminin gerçekleştirilebilmesi için ölçüm yapılan alana yerleştirilen özel hedeflerin yaklaşık 3B konumları klasik ölçme yöntemleri ile tespit edilerek ilgili yazılımlara gerekli tanımlamaların yapılması gerekmektedir. Veri ön işleme adımı olarak ayrıca hareketli nesnelerden gelen noktalar, yansımalar veya sensör yapaylıkları gibi istenmeyen verileri kaldırmak için manuel veya otomatik filtrelemeyi de içerebilir. Bu geometrik entegrasyon, saha ölçüm sürelerini (tarama sayısına bağlı olarak) ve işlem adımlarını (hedef sayısına ve nokta bulutunda tespit yöntemine, yani otomatik veya manuel olarak gerçekleştirilen tespitlere bağlı olarak) artırmakla birlikte, nesnelerin üç boyutlu yapısının en kapsamlı tanımını sunar.

Bu tez çalışması kapsamında ilk çalışma bölgesine ait 3 boyutlu nokta bulutu verisinin elde edilmesi için Leica RTC360 yersel lazer tarayıcı sistemi kullanılmıştır (Şekil 2.3).



Şekil 2.3 Leica RTC360 yersel lazer tarayıcı.

Leica RTC360 yersel lazer tarayıcının teknik özellikleri aşağıda listelenmiştir:


- Tek oturumda 2 dakikadan daha az tarama süresi
- Gerçek zamanki veri birleştirme
- Hareket eden objelerin taramadan otomatik atılması
- 360 derece yatay, 300 derece düşey görüş açısı
- 0.5 m – 130 m mesafe aralığında tarama menzili
- Saniyede 2 milyon noktaya kadar tarama yapabilme
- 10 metre mesafede 3 farklı çözünürlük (3 mm/6 mm/12 mm)
- 18 saniye açısal doğruluk, 1 mm + 10 ppm mesafe doğruluğu,
- 10 metrede 1.9 mm 3B nokta doğruluğu
- 36 MP(megapiksel) kamera çözünürlüğü
- Ardışık oturumlar arası bağıl konum takibi
- 4 saate kadar batarya süresi.

2.2 İHA Fotogrametrisi

İHA fotogrametrisi, insan taşımayan, otonom veya manuel olarak yönlendirilebilen hava araçlarına entegre edilmiş kameralarla çekilen fotoğrafların kullanıldığı fotogrametrik süreci ifade eder. Bu süreç, İHA'lar tarafından toplanan görüntülerle gerçekleştirilir. Kameralarla donatılmış insansız hava araçları tarafından çekilen fotoğraflar üzerinden yürütülen fotogrametrik analizler, İHA fotogrametrisinin temelini oluşturur [42]. Geleneksel yöntemlere göre İHA kullanımı, hem esneklik hem de ekonomik açıdan büyük avantajlar sunmaktadır [43]. Geçmişte askeri amaçlar ile geliştirilen İHA'lar, ilk olarak [44] tarafından geomatik amaçlı kullanılmıştır.

İHA'lar ile farklı konumlardan çekilen ve örtüşen bir dizi görüntü kullanılarak 3 boyutlu nokta bulutu elde etmek için hareketten yapı (SfM) algoritması kullanılır. Bu algoritmada, kamera konumu, yönelim parametreleri ve sahne geometrisi, bir dizi örtüşen görüntüden otomatik olarak çıkarılan özellik noktalarına dayalı olarak yüksek yedeklilik içeren iteratif demet dengelemesi kullanılarak eşzamanlı olarak belirlenir [45, 46]. Bu işlemin gerçekleştirilmesinde yer kontrol noktasına ihtiyaç duyulmaz [47]. Örtüşen görüntülerde anahtar noktaların belirlenmesi sırasında, [48] tarafından geliştirilen Ölçek Değişmez Özellik Dönüşümü (SIFT) yöntemi yaygın olarak kullanılmaktadır. SIFT algoritmasının yardımıyla, örtüşen görüntülerdeki eşleşen özelliklerin tespiti ile sensör konumu ve yönelim geometrisi yeniden modellenir. Anahtar noktaların tespit edilmesinin ardından, seyrek demet dengeleme sistemi ile kamera pozisyonları tahmin edilir ve aynı zamanda seyrek nokta bulutu üretilir. Kamera pozisyonlarındaki hatalar, doğrusal olmayan en küçük kareler yöntemiyle minimize edildikten sonra, sahne geometrisini yeniden oluşturmak ve noktaların konumlarını hesaplamak için üçgenleme işlemi yapılır. SfM yaklaşımının klasik fotogrametriye göre en önemli avantajı, anahtar nokta tespitinden 3 boyutlu modellemeye kadar olan sürecin tamamen otomatik olmasıdır [47, 49]. Şekil 2.4'de İHA ile elde edilen görüntülerden yoğun nokta bulutunun üretim sürecini gösteren iş akış diyagramı gösterilmektedir.

Tez kapsamında ikinci veri seti olarak [51] tarafından çekilen İHA görüntüleri kullanılmış ve 3 boyutlu nokta bulutu bu görüntüler kullanılarak elde edilmiştir.



Şekil 2.4 İHA ile çekilen görüntülerden yoğun nokta bulutunun elde edilmesinde izlenen işlem adımları ([46, 50]’den düzenlenmiştir.)

3

SINIFLANDIRMA VE DOĞRULUK ANALİZİ

Uzaktan algılama ve coğrafi analiz bağlamında "sınıflandırma" terimi, görüntülerdeki piksellerin, nesnelerin veya noktaların niteliklerine göre kategorilere veya sınıflara ayrılması sürecini ifade eder. Bu nitelikler, spektral verileri (gözün veya sensörlerin gördükleri), dokusal bilgileri, uzamsal desenleri veya çeşitli görüntüleme işlemleriyle fark edilebilen diğer özellikleri içerebilir. Bu bölümde sınıflandırma yöntemlerine değinilecek, nokta bulutu sınıflandırması ve sınıflandırmanın doğruluk analizine ilişkin bilgiler verilecektir.

3.1 Sınıflandırma Yöntemleri

Sınıflandırma yöntemleri, üç ana başlıkla incelenebilir. Bunlar; piksel tabanlı sınıflandırma, obje tabanlı sınıflandırma ve nokta tabanlı sınıflandırmadır.

3.1.1 Piksel Tabanlı Sınıflandırma

Gözetimli sınıflandırma, belirlenen sınıflar için önceden seçilmiş eğitim alanlarından faydalanır. Eğitim verileri, algoritmanın görüntünün geri kalanındaki pikselleri sınıflandırması için kullanılır ve genellikle Maksimum Olabilirlik Sınıflandırıcısı (Maximum Likelihood Classifier, MLC) gibi algoritmalar uygulanır. MLC, her bir sınıfın her bantta normal dağılım gösterdiğini varsayar [52]. Gözetimsiz sınıflandırma ise, kullanıcı tarafından belirlenmiş sınıflar olmaksızın, algoritmanın kendi başına veri kümesinde doğal olarak oluşan grupları tanımlamasına izin verir. Bu yaklaşımda, K-means ve ISODATA (Iterative Self Organizing Data Analysis Technique) gibi algoritmalar, pikselleri spektral benzerliklerine göre otomatik olarak gruplar [53, 54].

Piksel bazlı sınıflandırmanın uygulamaları arasında arazi örtüsü ve kullanımı haritalarının oluşturulması, tarımsal alanların izlenmesi ve su kalitesi değerlendirmeleri bulunmaktadır. Ancak, bu yöntem, özellikle karışık piksellerin

ve spektral örtüşmenin olduğu durumlarda sınırlamalara sahiptir. Yüksek çözünürlüklü görüntülerde bir piksel içinde birden fazla nesne tipi bulunabilir, bu durum da sınıflandırma doğruluğunu azaltabilir. Bu tür sorunlar, spektral karışım analizi gibi yöntemlerle ele alınabilir; bu yaklaşım, bir piksel içindeki farklı materyallerin oranlarını tahmin ederek daha kesin sonuçlar elde etmeyi amaçlar [55].

3.1.2 Obje Tabanlı Sınıflandırma

Obje tabanlı sınıflandırmada (OBC), görüntülerdeki belirli nesneler veya objeler tanımlanarak sınıflandırma yapılır. Geleneksel piksel tabanlı tekniklerin aksine, OBC, benzer özelliklere sahip pikselleri gruplayarak daha büyük ve anlamlı "objeler" oluşturur. Bu yaklaşım, verileri daha anlamlı bir şekilde yorumlamayı sağlar, çünkü objeler gerçek dünya nesnelerinin daha doğru birer temsili olarak işlev görür [56]. Burada ilk adım olan segmentasyon süreci, benzerlik kriterlerine (renk, doku, yoğunluk) göre piksellerin objeler halinde gruplandırılmasını içerir ve bu işlem belirli bir algoritma veya istatistiksel yöntemle gerçekleştirilir [57]. Objeler oluşturulduktan sonra, çeşitli sınıflandırma teknikleri kullanılarak her bir obje, önceden tanımlanmış sınıflara atanır. Bu sınıflandırma, genellikle objenin spektral imzası, şekil, doku ve bağlamsal ilişkiler gibi özelliklerine dayanır. Özellikle, Rastgele Orman ve Destek Vektör Makineleri gibi algoritmalar, obje tabanlı sınıflandırma bağlamında sıkça kullanılan yöntemler arasında yer alır [58, 59]. OBC, tarım, orman yönetimi, kentsel planlama ve afet izleme gibi çeşitli alanlarda kullanılmaktadır. Tarım sektöründe, bitki örtüsü türlerinin ve sağlık durumlarının belirlenmesi, verim tahminleri yapılması gibi konularda kullanılırken; orman yönetiminde ağaç türlerinin sınıflandırılması, hasar tespiti ve biyolojik çeşitliliğin izlenmesi için önemli bir araçtır [60–62]. Kentsel bölgelerde ise, yapıların ve yüzey kaplamalarının sınıflandırılması, kentsel büyümenin izlenmesi ve planlama süreçlerinde önemli bilgiler sağlamaktadır [63].

3.1.3 Nokta Tabanlı sınıflandırma

Nokta tabanlı sınıflandırma, özellikle lazer tarama sistemleri (LiDAR) ve fotogrametri yöntemleriyle elde edilen nokta bulutu verilerinin analizinde yaygın olarak kullanılan bir yöntemdir. Bu yöntem, tekil pikseller veya nesneler yerine, noktaların kendilerine özgü özelliklerine dayanarak sınıflandırılmasını amaçlar. Noktalar, üç boyutlu koordinatlar (x , y , z) ve genellikle renk bilgileri (RGB) gibi özellikler içerir. Nokta tabanlı sınıflandırma yöntemleri, piksellerin en küçük birim olarak ele alındığı piksel tabanlı yaklaşımlara benzer bir şekilde çalışır, ancak

burada analiz edilen birimler noktalar olduğundan daha yüksek çözünürlükte ve detaylı bir sınıflandırma sağlanır [64]. Noktaya dayalı sınıflandırmada makine öğrenme ve derin öğrenme gibi çeşitli yöntemler ve algoritmalar kullanılmaktadır. Bu tez çalışması kapsamında kullanılan yöntemler ve bunlara ilişkin bilgiler Bölüm 4'te detaylı olarak anlatılacaktır.

3.2 Doğruluk Analizi

Bir makine öğrenmesi modelinin tahmin performansının değerlendirilmesi, sınıflandırmanın önemli bir parçasıdır. Literatürde, bir makine öğrenmesi sınıflandırıcısının tahmin performansını değerlendirmek için çeşitli ölçümler bulunmaktadır. Bu çalışmada doğruluk, kesinlik, duyarlılık ve F1-Skor, değerlendirme ölçütleri olarak kullanılmıştır. Bu değerler, gerçek sınıf ile tahmin edilen sınıf verilerinin bir matrisi olan hata/karışıklık matrisinden (Confusion matrix) elde edilir [65].

Karışıklık matrisi, sınıflandırma doğruluğunu ve hatalarını görselleştirmek için kullanılan temel araçlardan biridir. Karışıklık matrisi [66], bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmalar hakkında bilgi içeren bir kavramdır. Karışıklık matrisinin iki boyutu vardır; bir boyut bir nesnenin gerçek sınıfı tarafından indekslenir, diğeri ise sınıflandırıcının tahmin ettiği sınıf tarafından indekslenir. Şekil 3.1'de karışıklık matrisinin temel formu gösterilmektedir. Burada N_{ij} gerçekte C_i sınıfına ait olan ancak C_j sınıfı olarak sınıflandırılan örneklerin sayısını temsil eder [67].

		Tahmin			
		C_1	...	C_j ...	C_n
Gerçek	C_1	N_{11}		N_{1j}	N_{1n}
	$\vdots$			$\vdots$	
	C_i	N_{i1}	...	N_{ij} ...	N_{in}
	$\vdots$			$\vdots$	
	C_n	N_{n1}		N_{nj}	N_{nn}

Şekil 3.1 Karışıklık Matrisi

Karışıklık matrisi ile sınıflandırma sonucunun değerlendirilmesinde kullanılacak olan değerlendirme ölçütleri; doğruluk, duyarlılık, kesinlik ve F1-Skor hesaplanabilir. Bu ölçütler 0-1 arasında değer almaktadır. Bu metriklerde 1'e yakın değerler daha iyi sınıflandırma performansını, 0'a yakın değerler ise daha düşük sınıflandırma performansını göstermektedir [68].

Doğruluk, doğru tahminlerin, tüm tahminlere oranı olarak ifade edilmektedir ve Eşitlik 3.1 ile hesaplanmaktadır.

$$\text{Doğruluk} = \frac{\sum_{i=1}^n N_{ii}}{\sum_{i=1}^n \sum_{j=1}^n N_{ij}} \quad (3.1)$$

Kesinlik, her sınıf için doğru pozitif tahminlerin toplam pozitif tahminlere oranıdır ve Eşitlik 3.2 ile hesaplanmaktadır.

$$\text{Kesinlik}_i = \frac{N_{ii}}{\sum_{k=1}^n N_{ki}} \quad (3.2)$$

Duyarlılık, her sınıf için doğru pozitif tahminlerin gerçek pozitif örneklere oranıdır ve Eşitlik 3.3 ile hesaplanmaktadır.

$$\text{Duyarlılık}_i = \frac{N_{ii}}{\sum_{k=1}^n N_{ik}} \quad (3.3)$$

F1-Skor ise kesinlik ve duyarlılığın harmonik ortalamasıdır ve Eşitlik 3.4 ile hesaplanmaktadır.

$$F\text{-Skor}_i = \frac{2 \times \text{Kesinlik}_i \times \text{Duyarlılık}_i}{\text{Kesinlik}_i + \text{Duyarlılık}_i} \quad (3.4)$$

4

MAKİNE ÖĞRENMESİ

Makine öğrenmesi, çevredeki ortamdan öğrenerek insan zekasını taklit etmek için tasarlanmış, verileri akıllı eylemlere dönüştürmeyi amaçlayan bilgisayar algoritmalarının oluşturulmasına ve geliştirilmesine odaklanan disiplin olarak tanımlanır [69, 70]. Bu bölümde makine öğrenmesinin temeli, türleri ve yöntemlerine değinilecek, tez kapsamında kullanılan yöntemler detaylı şekilde açıklanacaktır.

4.1 Makine Öğrenmesinin Temelleri

Doğal insan davranışı olan öğrenme genel olarak, yeni davranışların, değerlerin, bilgilerin, becerilerin veya tercihlerin kazanılması ya da mevcut davranışların değiştirilmesiyle ilgilidir. Makine öğrenimi ise, doğal insan öğrenme sürecine paralel olarak, bilgisayarların kendi başlarına düşüncelerini ve öğrenmelerini sağlayan bir yapay zeka kategorisini temsil eder. Bilgisayarların eylemlerini daha doğru hale getirmek için bu eylemleri değiştirmeye odaklanır; bu bağlamda doğruluk, yapılan eylemlerin doğru sonuçlanma sıklığıyla ölçülür [71]. Yapay zekanın bir alt kategorisi olan makine öğrenmesi, verilerden öğrenme ve bu öğrenimleri yeni verilerde uygulama temeline dayanır.

Makine öğrenmesinin genel modeli, algorithmadan bağımsız olarak altı bileşenden oluşur. Bunlar;

- Verilerin toplanması ve hazırlanması,
- Özellik seçimi,
- Algoritma seçimi,
- Model ve parametre seçimi,
- Eğitim ve ,

- Performans analizi/değerlendirmesidir [64, 71, 72].

Makine öğrenmesinin temel kavramları, tanımlanan bir problemi çözmek için kullanılan bir prosedür seti olan algoritma, algortimanın verilerden öğrendiklerini temsil eden model, modelin öğrenmesi için kullanılan etiketli ve çeşitli özelliklere sahip olan eğitim verisi ve eğitilen modelin genelleme kabiliyetini değerlendirmek için kullanılan test verisidir. Modelin eğitimi, problem tanımında kullanılan veriye bağlıdır. Bu nedenle makine öğrenmesinde kullanılan verinin önemi büyüktür; verinin doğru ve problemle ilişkili olması gereklidir. Eğitim için kullanılan veri, tahmin için kullanılacak test verisinden büyük ölçüde farklılık gösterirse, elde edilecek tahminlerin doğruluğu olumsuz etkilenir. Bu tür olumsuz sonuçların oluşmaması için eğitim ve test verisinin doğru bir şekilde etiketlenmiş olması önemlidir [73].

Makine öğrenmesi, geniş bir uygulama sahasına sahip ve sürekli gelişen bir alandır. Örneğin, otonom teknolojileri, robotik teknolojileri, e-posta filtreleme, tıbbi tanı ve hastalık tahminleri, ses ve görüntü tanıma, finansal hizmetler (dolandırıcılık, kredi puanlama vb.) gibi birçok alanda sıkça kullanılmaktadır [71, 73, 74].

Güçlü matematiksel altyapısı nedeniyle karmaşık verilerin analizinde oldukça kullanışlıdır. Kullanıcıya ihtiyaç duyan, çözüm için kullanılacak parametrelerin doğrudan kullanıcı tarafından belirlendiği kural tabanlı sistemlerin aksine, çözüm için gerekli parametreleri etiketlenmiş eğitim verisi üzerinden kendisi otomatik olarak belirler [6].


4.2 Makine Öğrenmesinin Yöntemleri

Makine öğrenmesi, geçmiş deneyimlerden oluşan ve bu deneyimlenen verilerden geliştirilen bir dizi algoritmadır. Eğitim verileri üzerinde çalışır ve tahmin veya kararlar için kullanılır. Yapay zekanın alt kategorisi olan makine öğrenmesi, öğrenme yöntemlerine göre 3 alt kategoriye ayrılır.

- Denetimli Öğrenme (Supervised Learning),
- Denetimsiz Öğrenme (Unsupervised Learning),
- Pekiştirmeli Öğrenme (Reinforcement Learning) [75, 76].

4.2.1 Denetimli Öğrenme

Sınıflandırma problemlerinde en yaygın kullanılan tekniktir ve makineye kullanıcı tarafından üretilen bir sınıflandırma sisteminin öğretilmesine dayanır. Burada amaç, bir özellik dizi ile tanımlanan obje etiketini tahmin edebilen bir tahminci oluşturmaktır. Algoritma doğru çıktılar ile birlikte bir dizi özelliği girdi olarak alır ve hataları bulmak için gerçek çıktı ile düzeltilmiş çıktıyı karşılaştırarak öğrenir [77, 78]. Şekil 4.1’de denetimli öğrenmeye ilişkin bir görsel verilmiştir.




Şekil 4.1 Denetimli Öğrenme

Bu çalışma kapsamında rastgele orman (Random Forest), hafif gradyan artırma (Light Gradient-Boosting Machine) ve aşırı gradyan artırma (eXtreme Gradient Boosting) kullanılmıştır. Bu kısımda bu yöntemlere ilişkin detaylı açıklama verilecektir.

4.2.1.1 Rastgele Orman

Rastgele Orman (Random Forest-RF) algoritması [79], girdi veri setinden farklı örnekler kullanarak oluşturulan karar ağaçlarının sonuçlarını bir oylama tekniği ile birleştirerek girdi verilerinin sınıf sonucunu belirler (Şekil 4.2) . Algoritma, oluşturulacak karar ağaçlarının sayısı, bir düğümde göz önünde bulundurulabilecek maksimum özellik sayısı ve bir düğümün ne kadar detaylı bölünebileceğini gösteren minimum yaprak sayısı gibi girdi parametrelerini içerir. RF algoritması, temel olarak torbalama (bagging) ve güçlendirme (boosting) olmak üzere iki ana aşamadan oluşur. Her bir karar ağacı, orijinal veri setinden bağımsız olarak seçilen rastgele önyükleme (bootstrap) örnekleri kullanılarak inşa edilir. Bu süreç, torbalama (bagging) olarak adlandırılan bir yöntemle gerçekleştirilir ve amacı, modelin farklı veri yönlerini öğrenmesini sağlayarak genel tahmin yeteneğini artırmaktır. Torbalama yöntemi, veri setinden rastgele alt kümeler oluşturarak birden çok karar ağacının eğitilmesini sağlar. Her bir alt küme, aynı veri setinden seçilse de, rastgelelik nedeniyle birbirinden farklıdır. Bu süreç, modelin farklı veri özelliklerini öğrenmesine ve daha sağlam bir yapıya sahip olmasına olanak tanır. Karar ağaçlarında sınıf tahmini, çoğunluk oyu kavramına dayanarak yapılır. Sınıflandırma için, her bir karar ağacının çıktısı bir oydur. Bir veri noktası için en çok oyu alan sınıf, modelin tahmini olarak kabul edilir. Performans güçlendirme aşamasında ise, ardışık modeller oluşturulur ve en yüksek sınıflandırma doğruluğuna sahip karar ağacı seçilir.



Şekil 4.2 Karar Ağacı

Veri setinden seçilen örneklerin yaklaşık üçte biri, torba dışı (Out-of-Bag - OOB) örnekler olarak saklanır. Bu örnekler, herhangi bir karar ağacının oluşturulması sırasında kullanılmazlar. Bunun yerine, modelin doğruluğunu değerlendirmek için bir tür doğrulama seti olarak işlev görürler. Modelin eğitilmesi sırasında hiç kullanılmayan bu OOB örnekleri üzerinde yapılan tahminler, modelin genel performansının bir ölçütü olarak kullanılabilir [80]. Bu ölçüt bir sınıflandırma modelinin verinin doğru sınıfa ne kadar "güvenle" atandığını ölçen kenar fonksiyonu ile ölçütü ile belirlenir. Bu fonksiyon modelin doğru sınıfı ne kadar kesin bir şekilde "tercih ettiğini" gösterir. Kenar fonksiyonu;

$$mg(X, Y) = \text{Dogru sinif skoru} - \text{En yuksek yanlis sinif skoru} \quad (4.1)$$

Burada mg() kenar fonksiyonu, X girdi özelliklerini, Y ise gerçek sınıf etiketlerini temsil eder. Kenar değeri ne kadar yüksekse, modelin o veri noktasını doğru sınıfa atama konusunda o kadar emin olduğu anlamına gelir. RF modelinin genelleştirilmiş hatası;

$$PE^* = P_{X,Y}(mg(X, Y) < 0) \quad (4.2)$$

Bu yaklaşım, ayrı bir doğrulama veya test setine ihtiyaç duymadan modelin ne kadar iyi genelleme yaptığının bir göstergesi olarak değerlendirilebilir [79].

RO her nokta için geometrik özellikleri bir giriş vektörü (x) olarak alır, K sayıda ağaç oluşturur ve tahmin edilen sınıflar için sonuçların ortalamasını alır. K ağaç oluşturulduktan sonra ağaçlar $T(x)_1^K$, RF sınıflandırıcısı şu şekilde ifade edilebilir.

$$f_{ro}^K(x) = \frac{1}{K} \sum_{k=1}^K T(x) \quad (4.3)$$

4.2.1.2 Aşırı Gradyan Artırma

Aşırı gradyan artırma (eXtreme Gradient Boosting-XGBoost), gradyan artırma çerçevesi(Gradient Boosting Framework) temelinde güvenilir ve verimli bir makine öğrenimi olduğu kanıtlanmış, ölçeklenebilir bir topluluk tekniği olan bu algoritma [81], karar ağaçları kullanarak iteratif bir şekilde modelin performansını artırmayı hedefler. Temel amacı, bir dizi zayıf tahmin modelini, güçlü bir tahmin modeline dönüştürmektir.. Birden fazla karar ağacını bir araya getirerek çalışır. Her adımda, önceki tüm ağaçların tahminlerinin hatalarını düzeltmek için yeni bir ağaç eklenir. Bu süreç, belirlenen sayıda ağaç oluşturulana veya bir durdurma kriteri

karşılanana kadar devam eder. XGBoost, modelin karmaşıklığını kontrol etmek ve aşırı uyumu (overfitting) önlemek için L_1 (Lasso Regrasyonu) ve L_2 (Ridge Regrasyonu) düzenleme teknikleri içerir [82, 83]. L_1 (Lasso Regrasyonu), regresyon modelindeki özelliklerin ağırlıklarını sıfıra eğilimli hale getirerek, bazı özellikleri modelden tamamen çıkarabilen bir tür düzenleme (regularization) tekniğidir. Bu, modelin daha basit hale gelmesine ve aşırı uyumun (overfitting) önlenmesine yardımcı olur [84]. XGBoost algoritmasında bu değer α ile kontrol edilir ve α sıfır ile sonsuz aralığında değer alır. Bu parametrenin değeri arttıkça, modeldeki ağaçların dallarının ağırlıkları daha fazla sıfıra doğru itilir, bu da modelin daha basit ve genelleştirilmiş hale gelmesine yardımcı olur. L_2 düzenlemesi (Ridge Regrasyonu), ağaç yapısındaki yaprak düğümlerinin ağırlıklarına ikinci dereceden bir ceza uygulayarak kullanılır. Bu, modelin daha az karmaşık hale gelmesine ve aşırı uyumun azalmasına yardımcı olur [84]. XGBoost sınıflandırıcısında bu değer λ ile kontrol edilir ve λ sıfır ile sonsuz aralığında değer alır. Bu parametredeki değer artışı ile yaprak ağırlıkları üzerindeki düzenleme artar, bu da modelin daha robust olmasını sağlar. Algoritmanın temel çalışma prensibini gösteren eşitlikler aşağıda verilmiştir.

$$F = \{f(x) = w_{(x)}\} \quad (4.4)$$

Bu denklem x örneğinin bir yaprak düğüme atanmasını, w ise o yaprak düğümünün ağırlığı ifade etmektedir.

$$L(\Phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \Omega(f) = \Upsilon T + \frac{1}{2} \lambda \|w\|^2 \quad (4.5)$$

$$\Omega(f) = \Upsilon T + \frac{1}{2} \lambda \|w\|^2 \quad (4.6)$$

4.5 ve 4.6 denklemleri XGBoost sınıflandırıcısının amaç fonksiyonunu ifade etmektedir. Burada T yaprak düğüm sayısını, y_i referans etiketi, $\hat{y}_i$ tahmin edilen sınıfı, λ düzenleme avans katsayısını, Υ yaprak düğümü ile ilgili avans faktörünü ifade etmektedir.

Denklem iteratif olarak devam ettirildiğinde amaç fonksiyonu:

$$L^t = \sum_i l(y, \hat{y}_i^{t-1}) + f_t(x_i) + \Omega(f_t) \quad (4.7)$$

burada g_i kayıp fonksiyonunun birinci türevi ve h_i kayıp fonksiyonunun ikinci türevidir [83].

$$L^t \approx \sum_i [l(y, \hat{y}_i^{t-1}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) \quad (4.8)$$

Amaç fonksiyonunun minimum değerini elde etmek ve türevini 0'a eşitlemek için, tüm zayıf öğrenenler (I) için her bir yaprak düğümün ağırlığı aşağıdaki şekilde hesaplanır:

$$w_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (4.9)$$

Amaç fonksiyonu yerine konulduğunda, çözüm minimum kaybı Eşitlik 4.10'daki gibi ifade edilir [82]:

$$\tilde{L}^t = -\frac{1}{2} \sum_{j=1}^T \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} \quad (4.10)$$

4.2.1.3 Hafif Gradyan Artırma

Hafif gradyan artırma (Light Gradient-Boosting Machine-LightGBM), Microsoft tarafından yüksek boyutlu özelliklere sahip geniş veri setlerinde hızlı ve etkili tahmin sorunu çözümü için üretilen bir ağaç tabanlı yöntemdir. LightGBM, birbirine yakın ilişkili özellikleri (yani, veri setindeki değişkenleri) tespit edip, bu özellikleri "benzersiz özellik gruplarına" düzenler. Bu gruplama işlemi, her bir özellik için ayrı ayrı bölünme noktaları bulma ihtiyacını azaltır çünkü yakın ilişkili özellikler tek bir grup olarak değerlendirilir. Sonuç olarak, ağaç yapısında gerçekleştirilmesi gereken toplam bölünme sayısı azalır. Bu azalma, hem hesaplama süresini hem de gerekli bellek miktarını önemli ölçüde düşürür, çünkü algoritma artık daha az bölünme noktası üzerinde çalışmak zorundadır. LightGBM'in bu yaklaşımı, veri setlerinin daha hızlı ve daha etkin bir şekilde işlenmesini sağlayarak, büyük veri üzerinde makine öğrenimi uygulamalarının daha erişilebilir ve uygulanabilir olmasına katkıda bulunur [85]. LightGBM, modelin aşırı uyum (overfitting) riskini azaltmak ve modelin genelleme kabiliyetini artırmak için iki popüler düzenleme (regulation) teknikleri olan L_1 ve L_2 norm düzenlemesini kullanır. Bu teknikler, modelin karmaşıklığını kontrol ederek, modelin eğitim verisine fazla uyum sağlamasını ve böylece daha önce görmediği verilere iyi genelleme yapabilmesini sağlar. L_1 düzenlemesi özellik seçimi yaparken tercih edilirken, L_2 düzenlemesi model ağırlıklarını düzenleyerek daha stabil ve genelleme kabiliyeti yüksek modeller oluşturmak için kullanılır [85, 86].

LightGBM sabit bir ağaç modeliyle başlar ve ek ağaç modellerini sırayla eğiterek

kayıp fonksiyonunu en aza indirir:

$$Y_i^{(t)} = Y_i^{(t-1)} + f_{t(x_i)} \quad (4.11)$$

burada $Y_i^{(t)}$ yeni modeli, $Y_i^{(t-1)}$ önceki iterasyonun ağaç modelini ve $f_{t(x_i)}$ bir sonraki adımda eklenmesi gereken yeni ağaç modelini temsil eder, şu şekilde gösterilir:

$$f_t = \min L = \min \left(\sum_{i=1}^n l(y_i, Y_i) \right) \quad (4.12)$$

Burada L kayıp fonksiyonunu, y_i noktaların ve standart sapmaların etiketini ve Y_i ise i . örnek için tahmin edilen değerini temsil eder [69].

4.2.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, makine öğrenimi algoritmalarının etiketlenmemiş verilerden, veri setindeki yapıları, desenleri veya kümeleri öğrenmesini sağlayan bir yöntemdir [87, 88]. Denetimli öğrenmede model, hem girdi verilerini hem de karşılık gelen çıktıları (etiketleri) içeren bir veri kümesi üzerinde eğitilirken, denetimsiz öğrenme yalnızca girdi verileri ile ilgilenir. Etiketli veri olmadığı için, sistemden beklenen sonuçlar bilinmemektedir. Yani önceden tanımlanmış ön bilgi olmadan veri yapısının anlaşılması ve veriden anlamlı sonuçların çıkarılması için kullanılmaktadır. Etiketli verinin olmadığı, etiketlemenin imkansız olduğu veya etiketlemenin zaman alacağı durumlarda, zamandan tasarruf etmek için tercih edilebilir. Veriler içindeki ilişkilerin ve yapıların, bir etiketi tahmin etmekten daha önemli olduğu her alanda güçlü bir yöntemdir. Bu yöntemde modelin başarısı, veri setinin kalitesine ve seçilen algoritmanın veriye uygunluğuna bağlıdır. Bu yöntemin temel uygulamaları, kümeleme, boyut azaltma, derinlik analizi ve özellik çıkarımıdır. Kümeleme için; K-means [89], DBSCAN [90] (Density-Based Spatial Clustering of Applications with Noise), boyut azaltma için; temel bileşen analizi (PCA) [89, 91], doğrusal diskriminant analizi (LDA) [92], derinlik algılama için; izalasyon ormanı [93], özellik çıkarımı için; tekil değer ayrışımı (SVD) [91] gibi yöntemler bulunmaktadır.

4.2.3 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, çevreleriyle etkileşimde bulunarak ve farklı eylemlerle pozitif ve negatif ödülleri ilişkilendirerek, insanların öğrenme biçimine benzer teknikler kullanarak öğrenmeyi amaçlayan bir hesaplama yaklaşımıdır. Tipik olarak

bir pekiştirmeli öğrenme tabanlı sistem bir ajan olarak adlandırılır ve belirli bir zamanda alabileceği sabit sayıda eyleme sahiptir. Her eylemle ilişkilendirilmiş bir ödül veya ceza vardır. Yani yapılan işlemler için geri bildirim alınır, doğru adımlar için ödül, yanlış adımlar için ceza uygulanır. Sistemin amacı, bir dizi eylem boyunca kümülatif ödülü en üst düzeye çıkarmaktır. Ajan tarafından kazanılan bilgi, ajanın belirli bir durumla karşılaştığında hangi eylemlerin alınması gerektiğini belirleyen politikalar kümesi olarak temsil edilir [73, 94]. Pekiştirmeli öğrenme algoritmaları model tabanlı ve modelden bağımsız olmak üzere ikiye ayrılır. Model tabanlı bir algortmada, bir ajan denemelere güvenmez, bunun yerine önceden öğrenilmiş modeli kullanır. Modelden bağımsız yöntemler, etkileşimde bulundukları çevreden gelen bilgiler ve deneyimler ile öğrenirler. Bu nedenle sistem dinamikleri, çevre ile kurdukları çok sayıda etkileşim ile belirlenir [95]. Tez kapsamında denetimli öğrenme algoritmaları kullanıldığı için pekiştirmeli ve denetimsiz öğrenme detaylarına yer verilmemiştir.

5

DERİN ÖĞRENME


Derin öğrenme, pek çok katmanın belirli konfigürasyonlarla ve bir sırayla birleştirilerek oluşturduğu derin sinir ağlarını tanımlamak için kullanılan terimdir [96]. Çok katmanlı doğrusal olmayan işlem birimleri aracılığıyla öğrenen bir makine öğrenme stratejisidir [97]. 2012 yılında AlexNet modelinin [98] piyasaya sürülmesiyle birlikte, derin öğrenme modelleri giderek daha popüler hale gelmiştir. Bu modeller, büyük miktarda verinin olduğu uygulamalar için özellikle faydalıdır. Etiketli eğitim veri seti kullanılarak derin sinir ağ modeli, problemi ele almak üzere eğitilir ve test için hazır hale getirilir.

Derin öğrenme tekniklerinin belirgin bir özelliği, Rastgele Orman [79] gibi makine öğrenmesi sınıflandırıcılarının aksine özelliklerin otomatik olarak üretilmesidir. Geleneksel makine öğrenme yöntemlerine kıyasla, kavramların daha etkin bir şekilde soyutlanmasını ve hiyerarşik olarak düzenlenmesini sağlar [99]. Evrişimli sinir ağları (Convolutional Neural Networks (CNN)), farklı ölçeklerde evrişimsel filtreler kullanarak ayırt edici özellikleri otomatik olarak çıkartan, en yaygın derin öğrenme modelidir [100–104]. Model, eğitim veri setini kullanarak filtre ağırlıklarını ayarlar. Ağırlıklar, hata geri yayılımı (backpropagation) yöntemiyle optimize edilir [105]. Eğitim aşaması tamamlandıktan sonra konvolüsyon filtrelerinin ağırlıkları sabitlenir [98] ve bu ağırlıklar kullanılarak test veri seti üzerinde değerlendirme yapılmaktadır [96, 106]. Özellikle görüntü tanıma, nesne algılama ve sınıflandırma uygulamalarında kullanılmaktadır [107].

5.1 Evrişim Katmanı

Evrişim katmanı (Convolutional Layer), derin öğrenme modellerinde, özellikle de görüntü işleme ve tanıma görevlerinde yaygın olarak kullanılan bir katman türüdür. Bir evrişim işleminde, mevcut katmanla aynı derinliğe sahip ancak daha düşük bir uzaysal boyuta sahip 3 boyutlu bir ağırlık filtresi kullanılır. Bu filtreler, bir katmandan diğerine aktivasyon fonksiyonlarını eşlemek için kullanılır. Düzeltilmiş

doğrusal birim (Rectified Linear Unit/ReLU) [108] gibi bir aktivasyon fonksiyonu kullanıldıktan sonra, bir sonraki katmandaki gizli durumun değeri, filtredeki tüm ağırlıklar ile aynı boyuttaki uzamsal bölgenin nokta çarpımı ile hesaplanır [96, 109]. Yani filtre içerisinde kalan piksel değerleri filtre değerleri ile çarpılıp toplanır. Şekil 5.1’de evrişim işlemin gösterilmiştir.



Şekil 5.1 Evrişim İşlemi

Derin sinir ağları içinde evrişim katmanlarının ardışık kullanımı, çok katmanlı özellik çıkarımı ve daha yüksek seviyeli soyutlama sağlar, bu da modelin karmaşık veri yapılarıyla başa çıkabilme yeteneğini artırır [110]. Alt seviyedeki katmanlardan üst seviyedeki katmanlara gidildikçe ayırt etme özelliği artmaktadır. Üst seviye katmanlarda daha karmaşık yapılar elde edilebilirken, alt seviyelerde çizgi gibi basit özellikler (çizgi gibi) yakalanabilir. Bu basit özelliklerdeki formlar birleştirilerek sonraki katmanlar sayıları oluşturulabilir. Yani basit yapılar birleştirilerek daha karmaşık yapılar tanımlanabilir.

5.2 Aktivasyon Katmanı

Evrimsel sinir ağları içerisinde, non-lineer katmanlar, sıklıkla aktivasyon fonksiyonları olarak adlandırılır ve karmaşık veri desenlerini işlemek için büyük önem taşımaktadırlar. Modelin doğrusal olmayan yetenekler kazanması amacıyla doğrusal evrişimli katmanlar arasına yerleştirilirler. Evrişimli sinir ağlarında en çok kullanılan aktivasyonları, düzeltilmiş doğrusal birim fonksiyonu (ReLU) [109] ve sızıntılı düzeltilmiş doğrusal birim (Leaky ReLU)’dir [111]. Bunlara ek olarak, ikili sınıflandırmada kullanılan ve girdileri 0 ile 1 arasında değerlere eşleyen Sigmoid fonksiyonu ve Sigmoid fonksiyonuna benzer bir yapıya sahip ancak -1 ile +1 arasında

değer alan Hiperbolik Tanjant Fonksiyonu (Tanh) bulunmaktadır.


ReLU aktivasyon fonksiyonu, her katmanın çıktısına uygulanarak eşiklenmiş değerler oluşturur. Bu işlem, aktivasyon değerlerinin doğrudan bir sonraki katmana aktarılmasını sağlar, çünkü ReLU bir-bir eşleme yaptığı için katman boyutlarını değiştirmez. Geleneksel sinir ağlarında aktivasyonlar, lineer dönüşüm ve ağırlıklar matrisinin kombinasyonu ile oluşturulur, bu süreçte ReLU genellikle bir evrişim işlemi takiben uygulanır (Aggarwal, 2018). Ancak, ReLU katmanı evrişimli sinir ağlarının görsel temsillerinde açıkça belirtilmez [112].

ReLU fonksiyonu, pozitif bir girdi değerini doğrudan aynı değer olarak alırken, negatif değeri 0'a çevirir ve diğer katmana aktarır. Matematiksel olarak $f_x = \max(0, x)$ tanımlanan ReLU, 0'dan sonsuza değer almaktadır [113]. ReLU'nun negatif değerlere 0 ataması, eğitim sürecini hızlandırırken, eğitim başlangıcında önemli miktarda ölü nöronların oluşmasına sebep olabilir. Bu durum ağın öğrenme yeteneğini olumsuz etkileyebilmektedir [114].

[111] tarafından geliştirilen sızıntılı ReLU, ölü nöron olayını çözmek ve negatif değerleri eğitime dahil etmek üzere ReLU'nun bir varyantı olarak tasarlanmıştır. Sızıntılı ReLU'nun matematiksel modeli Eşitlik 5.1'de verilmiştir.

$$f_{(x)} = \begin{cases} x & \text{if } x \geq 0 \\ \alpha x & \text{if } x \leq 0 \end{cases} \quad (5.1)$$

Fonksiyon, girdi x sıfırdan büyük veya eşit olduğunda x olarak, x sıfırdan küçük olduğunda ise αx olarak tanımlanır, burada α genellikle 0.01 gibi küçük bir sabit değerdir [115]. Bu yapı sayesinde, negatif girdilerde bile nöronlar tamamen inaktif hale gelmez ve ağın daha etkin bir şekilde öğrenmesine olanak tanır. Şekil 5.2'de Relu ve sızıntılı ReLU karşılaştırmasına örnek bir grafik verilmiştir.



Şekil 5.2 ReLU ve Sızıntılı ReLU karşılaştırması

5.3 Havuzlama Katmanı

Havuzlama katmanı (Pooling layer), evrişimli sinir ağlarının (CNN) yapısal bir ögesidir ve genellikle evrişim katmanlarından sonra gelir. Bu katman, ağın özellik haritalarını küçültmek ve hesaplama yükünü azaltmak için kullanılır. Temel işlevi, girdi özellik haritasındaki bilgiyi yoğunlaştırarak daha az hassas, ancak daha genel bilgileri korumaktır [109].

İki ana tür havuzlama işlemi vardır: maksimum havuzlama (max pooling) ve ortalama havuzlama (average pooling). Maksimum havuzlama, bir özellik haritasındaki belirli bir pencere içindeki maksimum değeri alır ve bu maksimum değer, havuzlanmış çıktının ilgili elemanı olur [116]. Ortalama havuzlama ise, aynı pencere içindeki tüm değerlerin ortalamasını alır. Bu işlemler, özellik haritasının boyutlarını küçültürken temsil edilen bilginin önemli kısmını korumaya yardımcı olur.

Havuzlama katmanlarının kullanılmasının bir avantajı, elde edilen özelliklerin konumsal değişikliklere karşı daha dirençli olmasıdır. Örneğin, maksimum havuzlama, girdideki küçük kaymaların etkisini azaltır ve böylece modelin yer değiştirmelere karşı daha dayanıklı olmasını sağlar [106]. Bu, ağın daha genel ve esnek bir öğrenme yeteneğine sahip olmasına olanak tanır. Şekil 5.3'te havuzlama işlemine ait görsel sunulmaktadır.

a)

7	3	4	5
5	1	3	8
9	1	2	5
5	3	3	4



7	8
9	5

**Maksimum
Havuzlama**

b)

7	3	4	5
5	1	3	8
9	5	4	5
6	4	1	2



4	5
6	3

**Ortalama
Havuzlama**

Şekil 5.3 a) Maksimum havuzlama , b) Ortalama havuzlama
[117]'den uyarlanmıştır.

5.4 Softmax Sınıflandırıcısı

Softmax sınıflandırıcısı, çok sınıflı sınıflandırma görevlerinde yaygın olarak kullanılan bir aktivasyon fonksiyonudur. Bu fonksiyon, bir sinir ağının son katmanında yer alır ve nöronların çıktılarını, sınıf olasılıkları anlamına gelecek şekilde normalize eder. Bu normalizasyon, çıktıları 0 ile 1 arasında bir değere dönüştürür ve tüm çıktıların toplamı 1 olacak şekilde düzenler [118].

Softmax fonksiyonu, genellikle logitler olarak adlandırılan ham puanları alır ve her sınıf için bir olasılık hesaplar. Bu hesaplama, her bir çıktının üstelini alarak ve bu üstel değerlerin toplamına bölerek yapılır. Matematiksel olarak ifade edildiğinde softmax fonksiyonu şu şekildedir:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (5.2)$$

Burada z_i i'nci sınıf için logit, K toplam sınıf sayısıdır. Bu işlem, her bir sınıf için bir olasılık üretir, bu olasılıklar toplamda 1'e eşittir ve modelin tahminlerinin yorumlanmasını kolaylaştırır.

Softmax sınıflandırıcısının kullanımı, özellikle derin öğrenme modellerinde, modelin çeşitli sınıflar arasındaki seçimi daha kesin bir temele oturtmasına olanak tanır. Modelin güvenilirliği ve yorumlanabilirliği artırarak, daha karmaşık sınıflandırma problemlerinin üstesinden gelinmesine yardımcı olur [109].

5.5 Kayıp Fonksiyonu

Eğitim sürecinin temel amacı, eğitim veri setindeki olasılıkların dağılımı ile modelin tahmin ettiği dağılım arasındaki farkı en aza indiren bir parametre kümesi bulmaktır. Kayıp fonksiyonları, belirli bir sinir ağının eğitim sırasında hedeflediği ideale ne kadar yakın olduğunu ölçer. Kayıp fonksiyonu, çıktının gerçek veriden sapmasını belirlemek için kullanılır ve hatalar tüm veri seti boyunca ortalama alınır, toplanır ve sinir ağının idealine ne kadar yakın olduğunu gösteren tek bir sayı elde edilir. Kayıp fonksiyonları, sinir ağlarının eğitimini bir optimizasyon problemi olarak yeniden şekillendirmeye yardımcı olur. Bu parametreler genellikle analitik çözüme uygun değildir, ancak iteratif optimizasyon teknikleri sıklıkla iyi yaklaşımlar sağlayabilir [103, 109].

En yaygın kullanılan kayıp fonksiyonlarından biri Ortalama Karesel Hata (Mean Squared Error - MSE) fonksiyonudur. MSE, gerçek değerler ile tahmin edilen değerler arasındaki farkların karelerinin ortalamasını alır. Matematiksel gösterimi

Eşitlik 5.3 ifade edilmiştir.

$$\text{MSE} = \frac{1}{n} \sum_i (t_i - x_i)^2 \quad (5.3)$$

Burada t_i gerçek değerleri, x_i model tarafından tahmin edilen değerleri, n ise örnek sayısını ifade etmektedir.

5.6 Optimizasyon Algoritmaları

Optimizasyon algoritmaları, bir makinenin deneyimleri aracılığıyla öğrenebilmesinin temelini oluşturur. Bu algoritmalar, gradyanları hesaplar ve kayıp fonksiyonunu en aza indirmeye çalışırlar [119].


Sinir ağlarında bir problemin çözümü milyonlarca parametre içerir. Bu nedenle mükemmel bir parametre setinin belirlenmesi olanaksızdır. Optimizasyon algoritmalarının kullanılmasının temel sebebi ya da gerekliliği, çözüm için optimal parametrelerin belirlenmesidir. Kademeli iniş (Gradient descent), kaybı azaltmak amacıyla ağırlık çekirdekler ve ağırlıklar gibi öğrenilebilir parametrelerini yinelemeli olarak değiştiren popüler bir optimizasyon yaklaşımıdır. Öğrenilebilir parametreler için gradyan, kayıp fonksiyonunun kısmi türevidir [120]. Eşitlik 5.4'te tek bir parametrenin güncelleme adımı gösterilmiştir.

$$w := w - \alpha * \frac{\partial L}{\partial w} \quad (5.4)$$

Burada w her bir öğrenilebilir parametreyi, α öğrenme hızını, ve L kayıp fonksiyonunu ifade etmektedir.

Şekil 5.4'te örnek bir $L(w) = (w - 3)^2 + 2 * \sin(3w)$ kayıp fonksiyonunun minimum değere yakınsaması, $w = -2$ ile başlanmış ve öğrenme hızı 0.05 alınarak iteratif olarak gösterilmiştir.

Tek bir parametrenin güncellemesi için, bütün eğitim verilerinden kayıp fonksiyonunun hesaplanması hem oldukça zaman harcanmasına hemde alan karmaşıklığına neden olmaktadır. Bu sorunun çözümü için stokastik gradyan inişi (Stochastic gradient descent/SGD) [121] tarafından önerilmiştir. SGD'nin uygulanması sırasında, her bir eğitim iterasyonunda veri setinden rastgele bir örnek seçilir, bu örneğin gradyanı hesaplanır ve model parametreleri (ağırlıklar) bu gradyan doğrultusunda güncellenir. Bu süreç, belirli bir kriter karşılanana kadar



Şekil 5.4 Gradyan iniş ile optimizasyon

(örneğin, belirli bir doğruluk seviyesine ulaşılan kadar veya belirli bir iterasyon sayısına ulaşılan kadar) tekrar edilir [105]. SGD, her adımda bir örnek üzerinden gradyan hesapladığı için, her iterasyon çok daha hızlı tamamlanır, bu da özellikle büyük veri kümeleri üzerinde çalışırken algoritmanın çok daha hızlı sonuçlar üretmesini sağlar [122]. Algoritma, büyük ve karmaşık veri setleri üzerinde etkili çalışabilmekte ve genellikle iyi sonuçlar vermektedir [109]. Çalışmanın çok sınıflı olması nedeniyle derin öğrenme ile sınıflandırmada SGD optimizasyon algoritması kullanılmıştır.

5.6.1 Stotastik Gradyan İniş Algoritması ile Kullanılan Hiperparametreler

5.6.1.1 Çapraz Entropi Kaybı

Özellikle sınıflandırma problemlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur. İki olasılık dağılımı arasındaki farkı ölçer (Genellikle gerçek etiketlerin ve model tahminlerinin olasılık dağılımları). Bu kayıp fonksiyonu, modelin sınıflandırma doğruluğunu maksimize etmek için özellikle faydalıdır çünkü yanlış tahminler üzerinde daha yüksek ceza uygular. Bu, modelin doğru sınıfları tahmin etme olasılığını artırır ve sınıflandırma görevlerinde sıkça tercih edilir [109]

5.6.1.2 Öğrenme Hızı

Eşitlik 5.4'de olduğu gibi α ile gösterilmektedir. Stokastik Gradyan İniş'in en önemli parametrelerinden biridir. Bu değer, her gradyan adımı parametrelerin

ne kadar güncelleneceğini belirler. Çok düşük bir öğrenme hızı, algoritmanın çok yavaş öğrenmesine ve hızlı bir öğrenme hızı ise algoritmanın optimum çözümü aşırı sıçrayarak bulamamasına neden olabilir [105].

5.6.1.3 Öğrenme Hızı Azalımı

Öğrenme hızının zamanla azaltılması işlemidir. Bu, algoritmanın başlangıçta büyük adımlar atmasına ve zamanla adımlarını küçülterek minimum bir değere daha hassas bir şekilde yaklaşmasına olanak tanır. Bu parametrenin kullanımı, algoritmanın hızlı başlayıp yavaşlamasını ve böylece optimuma stabil bir şekilde yaklaşmasını sağlar [123]. Momentum, modelin ağırlıklarını güncellerken önceki adımlardaki güncellemelerin bir kısmını dikkate alarak yapılan bir iyileştirme yöntemidir. Bu parametre, modelin mevcut gradyanlara dayanarak değil, aynı zamanda önceki gradyanların birikimini de kullanarak ağırlıklarını güncellemesini sağlamaktadır.

5.6.1.4 Yığın Boyutu

Yığın boyutunun belirlenmesi, modelin performansı ve eğitim süresi açısından kritik öneme sahiptir. Küçük bir yığın boyutu, modelin parametrelerinin daha sık güncellenmesine neden olur ve bu da daha hızlı öğrenme sağlayabilir, ancak hesaplama yükünü artırır. Öte yandan, büyük bir yığın boyutu, daha az güncelleme ile eğitim sürecini hızlandırabilir, ancak modelin öğrenme süreci yavaşlayabilir [124].

5.6.1.5 Epok Sayısı

Epok sayısı, bir eğitim veri setinin, model tarafından kaç kez işlendiğini gösterir. Her epokta modelin ağırlıkları tekrar hesaplanarak güncellenir.

5.7 Çekirdek Nokta Konvolüsyon (KPConv)

KPConv (Kernel Point Convolution), nokta bulutu verileri üzerinde derin öğrenme işlemleri yapmak için geliştirilen özel bir konvolüsyon türüdür. Bu yöntem, 3D nokta bulutları üzerinde daha etkili ve verimli bir şekilde işlem yapabilmek amacıyla tasarlanmıştır. KPConv'un temel prensibi, klasik 2D konvolüsyonlardan farklı olarak, nokta bulutları üzerinde doğrudan çalışarak, her bir noktanın çevresindeki noktalarla ilişkisini modellemektir. KPConv, nokta bulutu verilerinin düzensiz ve dağınık yapısını dikkate alarak, her bir nokta ve onun komşuları arasındaki ilişkileri daha doğru bir şekilde öğrenir. Bu da, nokta bulutu verileri

üzerinde daha hassas ve doğru sonuçlar elde edilmesini sağlar. KPConv, özellikle büyük ve karmaşık 3D veri kümeleri üzerinde başarılı performans göstermektedir.

x_i ve f_i sırasıyla girdi noktalar ve noktalara karşılık gelen öznitelikler olup KPConv'un [19] nokta evrişimi Eşitlik 5.5'deki gibidir.

$$(F * g)(x) = \sum_{x_i \in N_x} g(x_i - x) f_i \quad (5.5)$$

Yoğunluk değişikliklerine karşı dayanıklılığı sağlamak için yarıçap komşuluklarını öneren [125] yaklaşım KPConv' da da uygulanmakta olup N_x , bu arama yarıçapı içerisinde kalan noktaları temsil etmektedir. Ek olarak, [126]' de en yakın komşuluk ve arama yarıçapı ile türetilen 3B öznitelikler karşılaştırıldığında arama yarıçapının daha etkili bir ifade yeteneğini sağladığı gözlemlenmiştir. Bu sebeple, çekirdek fonksiyonu g 'nin küresel bir alanda olması prensibine dayalı bir gösterime dayanmaktadır. KPConv'un özelliği çekirdek fonksiyon g 'nin tanımından kaynaklanmaktadır. g, x merkezli komşuların konum bilgilerini girdi olarak alır ve $y_i = x_i - x$ olarak ifade edilmektedir. Komşuluk ilişkileri r yarıçapında ifade edilmek üzere 3B bir küresel girdi sunmaktadır.

$\tilde{x}_k$ küre içindeki noktaları, W_k ise girdi ve çıktı boyutları arasındaki öznitelik haritaları olmak üzere; çekirdek fonksiyonu g Eşitlik 5.6 deki gibi ifade edilmektedir.

$$g(y_i) = \sum_{k < K} h(y_i, \tilde{x}_k) W_k \quad (5.6)$$

k evrişimin kayma bölgelerini, h ise $\tilde{x}_k$ ve y_i arasındaki korelasyonu göstermektedir. Bu kısımda bilinear enterpolasyon [127] kullanılarak doğrusal korelasyon işlemi uygulanmaktadır:

$$h(y_i, \tilde{x}_k) = \max \left(0, 1 - \frac{\|y_i - \tilde{x}_k\|}{\sigma} \right) \quad (5.7)$$

σ etki mesafesini göstermekte olup girdi verinin yoğunluğuna göre seçilmektedir. Gaussian korelasyonuyla kıyaslandığı zaman doğrusal korelasyon daha basit bir temsil sağlamaktadır. Basit gösterim sayesinde optimizasyon aşamasında çekirdek deformasyonlarının öğrenilmesini kolaylaştırmaktadır.

KPConv' un kodlayıcı kısmı olan KP-CNN (Kernel Point Convolutional Neural

6

VERİLERİN HAZIRLANMASI

6.1 Çalışma Alanı

Bu tez çalışması kapsamında altyapı ve bileşenlerine ait sınıflandırma işlemi 2 ayrı çalışma bölgesinden elde edilen 3 boyutlu nokta bulutları kullanılarak gerçekleştirilmiştir.

6.1.1 Çalışma Alanı 1


Bu çalışma kapsamında, Yıldız Teknik Üniversitesi (YTÜ) Davutpaşa Kampüsü içerisinde yer alan İnşaat Fakültesi Hidrolik Laboratuvarı'nın güney cephesi ilk çalışma bölgesi seçilmiştir. Seçilen bina cephe yüzeyi, altyapı bileşenlerinin yanı sıra farklı türde pek çok obje içermektedir. Şekil 6.1'de çalışma alanına ilişkin görsel gösterilmektedir.

Sınıflandırma işleminde kullanılacak olan veri seti Leica RCT360 yersel lazer tarayıcı kullanılarak elde edilmiştir. Toplamda 15 oturum ile gerçekleştirilen tarama işlemi 5 adet yer kontrol noktası kullanılarak birleştirilmiştir. Birleştirme işlemi sonucunda elde edilen nokta bulutunun konum hatası yaklaşık ± 1.5 cm'dir. Elde edilen 3 boyutlu nokta bulutu verisinin boyutunun büyük olması nedeniyle, işlem kolaylığı sağlanması için 3 boyutlu nokta bulutu Cloud Compare (CC) [130] yazılımı kullanılarak 1 cm örnekleme aralığı ile seyrekleştirilmiştir. CSF



Şekil 6.1 Yıldız Teknik Üniversitesi Davutpaşa Kampüsü İnşaat Fakültesi Hidrolik Laboratuvarı

(Cloth Simulation Filter) algoritması kullanılarak zemin 3 boyutlu nokta bulutundan çıkarılmıştır. Elde edilen 3 boyutlu nokta bulutunun yoğunluğu yaklaşık 25000 nokta/m^2 ve 10317915 adet noktadan oluşmaktadır. Oluşturulan tarama verisi Şekil 6.2’de gösterilmiştir.




Şekil 6.2 Yersel lazer tarayıcı ile elde edilen nokta bulutu

6.1.2 Çalışma Alanı 2


Bu çalışma kapsamında seçilen ikinci çalışma alanı kullanıma açık olarak [51] tarafından paylaşılan 122.516 batı boyları, 53.140 kuzey enleminde bulunan Britanya Kolumbiyası’nda yer alan Quesnel şehri yakınlarındaki içme suyu hattında

(Şekil 6.3) gerçekleştirilmiş insansız hava aracı ile çekilen görüntüler kullanılarak üretilmiştir.



Şekil 6.3 Britanya Kolumbiyası içme suyu hattına ilişkin oluşturulan 3 boyutlu nokta bulutu.

Elde edilen 3 boyutlu nokta bulutu verisinin boyutunun yüksek olması nedeniyle ilk çalışma alanında olduğu gibi 1 cm örnekleme aralığı ile seyrekleştirilmiştir. Elde edilen 3 boyutlu nokta bulutunun yoğunluğu yaklaşık 15000 nokta/m^2 ve 7725503 adet noktadan oluşmaktadır. Oluşturulan 3 boyutlu nokta bulutu verisi Şekil 6.4'te gösterilmiştir.




Şekil 6.4 Britanya Kolumbiyası içme suyu hattına ilişkin oluşturulan 3 boyutlu nokta bulutu.

6.2 Sınıflandırma için Verilerin Hazırlanması

Bu bölümde sınıflandırma işleminin gerçekleştirilmesi için her iki çalışma bölgesinden elde edilen verilerin etiketlenmesi, özellik çıkarımı (Makine öğrenmesi için), eğitim ve test verilerinin oluşturulması konularına değinilecektir. Ayrıca MÖ ve DÖ için kullanılan her bir yöntem için tanımlanan parametrelere ilişkin bilgi verilecektir.

6.2.1 YTÜ Hidrolik Laboratuvarı Verilerinin Etiketlenmesi

Öncelikle veri setlerinin sınıflandırma işlemine uygun hale getirilmesi gerekmektedir. Bu bağlamda sınıflandırma işleminde kullanılacak olan sınıflar belirlenmiştir. Cephe yüzeyinde yer alan objelerden oluşan 9 adet sınıf oluşturulmuş ve etiketleme işlemi CC yazılımı kullanılarak manuel olarak gerçekleştirilmiştir. Oluşturulan sınıflara ilişkin örnek görsellere Şekil 6.5'te yer verilmiştir.



Şekil 6.5 3 boyutlu nokta bulutundan oluşturulan sınıflar (YTÜ Hidrolik Laboratuvarı)


Tablo 6.1’de etiketleme işlemi sonucu oluşan her bir sınıfa ilişkin nokta sayıları ve veri seti içindeki dağılım oranları gösterilmektedir.

Tablo 6.1 3 boyutlu nokta bulutundan oluşturulan sınıflar ve dağılımları

Sınıf	Nokta Sayısı	Sınıf Dağılımı (%)	Sınıf Numarası
Büyük Boru (B.B)	1279288	12.40	0
Kaplama	3493246	33.86	1
Dirsek	891444	8.64	2
Küçük Boru (K.B)	82471	0.80	3
Güç Kaynağı	1298825	12.59	4
Duvar	2697755	26.15	5
Demir	173855	1.68	6
Pencere	83470	0.81	7
Kapı	317561	3.08	8

6.2.2 Britanya Kolumbiyası İçmesuyu Hattı Verilerinin Etiketlenmesi

İlk çalışma bölgesinde olduğu gibi sınıflandırması gerçekleştirilecek olan objelere yönelik etiketleme işlemi CC yazılımı kullanılarak manuel olarak gerçekleştirilmiştir. Toplamda 11 sınıf oluşturulmuş olup buna ilişkin görsel Şekil 6.6’da sunulmuştur.



Şekil 6.6 3 boyutlu nokta bulutundan oluşturulan sınıflar (Britanya Kolumbiyası İçme Suyu Hattı)

Tablo 6.2’de etiketleme sonrasında oluşan her bir sınıfa ait nokta sayısı, veri seti içerisindeki dağılımı ve sınıf numaraları verilmiştir.

Tablo 6.2 3 boyutlu nokta bulutundan oluşturulan sınıflar ve dağılımları

Sınıf	Nokta Sayısı	Sınıf Dağılımı (%)	Sınıf Numarası
Zemin	4490666	58.13	0
Su borusu	1100769	14.25	1
Dirsek	90148	1.17	2
Bağlantı elemanları	105583	1.37	3
Merdiven	81850	1.06	4
Çit	308799	4.00	5
İskele	513461	6.65	6
Destek kolonları	239777	3.10	7
Te	92597	1.20	8
Diğer	208387	2.70	9
Düşey Yüzey	493466	6.39	10

6.2.3 Özelliklerin Çıkarılması

Etiketleme işlemi tamamlanmış olan 3 boyutlu nokta bulutu verileri, makine öğrenimi algoritmalarının sınıflandırma yapabilmesi için oldukça önemlidir. Bu süreçte, her bir noktanın özelliklerinin doğru bir şekilde belirlenmesi gerekir. Makine öğrenimi algoritmaları, bu etiketlenmiş veriler üzerinden eğitilerek, yeni ve bilinmeyen veriler üzerinde doğru sınıflandırma yapabilme yeteneği kazanır. Eğitim aşamasında kullanılan sınıflandırma özellikleri, algoritmanın veri seti içindeki çeşitli nesne ve yapıları ayırt etmesini sağlar. Bu özellikler genellikle geometrik, yoğunluk ve renk gibi nokta özelliklerini içerir.

Komşu noktaların mekansal konumlarından elde edilen bilgiler, 3 boyutlu yapı tensörünün özdeğerlerinin hesaplanması için temel teşkil etmektedir [131]. Hesaplanan bu özdeğerler, yerel 3 boyutlu şekil özelliklerinin belirlenmesinde kullanılır. Elde edilen bu şekil özellikleri, 3 boyutlu yapıların sezgisel olarak tanımlanmasına imkan tanır ve bu yapıların sınıflandırılmasında kritik bir rol oynar. Bunlara ek olarak, açısal özellikler, yükseklik ve düzlem karakteristikleri, momentler, eğim ve dikey profiller gibi çeşitli faktörler, yapıların daha detaylı bir biçimde tanımlanmasını sağlar [132–135].


Bu çalışma kapsamında sınıflandırma işleminin eğitimi için kullanılmak üzere yüksek ve renk değerlerine ek olarak CC yazılımı içerisinde yer alan geometrik özellikler farklı küresel komşuluk yarıçaplarına ($r=0.02m$, $r=0.10m$, $r=0.30m$, $r=0.50m$ ve $r=1m$) göre hesaplanmıştır. Hesaplanan özellikler Şekil 6.7’de listelenmiştir. Komşuluk yarıçapları seçilirken cephe üzerinde bulunan obje boyutları, objeler arası mesafe ve 3 boyutlu nokta bulutunun yoğunluğu göz önünde bulundurulmuştur. Her iki çalışma bölgesinden elde edilen 3 boyutlu nokta bulut verisi için aynı geometrik özellikler hesaplanmıştır. Bütün geometrik özelliklerin

hesaplanması ve sınıflandırmada kullanılmasındaki temel etken ise altyapı ve bileşenlerinin sınıflandırılmasında baskın olan özelliklerin belirlenmesi ve bu özelliklerin makine öğrenme sınıflandırıcısına bağlı olup olmadığının irdelenmesini sağlamaktır.


Özellik	Açıklama	Özellik	Açıklama
Z	Yükseklik	Anizotropi	$(\lambda_1 - \lambda_2)\lambda_3$
Rf	Kırmızı Renk	Doğrusallık	$(\lambda_1 - \lambda_2)\lambda_3$
Gf	Yeşil Renk	Düzlemsellik	$(\lambda_2 - \lambda_3)\lambda_1$
Bf	Mavi Renk	Yüzey Değişimi	$\lambda_3 / (\lambda_1 + \lambda_2 + \lambda_3)$
1. Özdeğer	λ_1	Küresellik	λ_3 / λ_1
2. Özdeğer	λ_2	Dikeylik	$1 - \sqrt{[0 \ 0 \ 1] \cdot \lambda_3}$
3. Özdeğer	λ_3	Öz Entropi	$-\sum_{i=1}^3 \lambda_i \ln(\lambda_i)$
Özdeğerler Toplamı	$\lambda_1 + \lambda_2 + \lambda_3$	Pürüzlülük	
PCA1	$\lambda_1 / (\lambda_1 + \lambda_2 + \lambda_3)$	Komşu Sayısı	
PCA2	$\lambda_2 / (\lambda_1 + \lambda_2 + \lambda_3)$	Ortalama Eğrilik	
Hacim Yoğunluğu		Gauss Eğriligi	
Yüzey Yoğunluğu		1. Dereceden Moment	
		Normal Değişim Oranı	
Omnivaryans	$\sqrt[3]{\prod_{i=1}^3 \lambda_i}$		

Şekil 6.7 Her bir objenin sınıflandırılması için hesaplanan özellikler

Şekil 6.8 ve Şekil 6.9’de her iki bölgeye ait veri için düzlemsellik özelliğinin farklı yarıçaplardaki etkisi görsel olarak sunulmuştur.



Şekil 6.8 Farklı yarıçaplarda düzlemselliğin etkisi (a) $r=1\text{m}$, b) $r=0.50\text{m}$, c) $r=0.30\text{m}$, d) $r=0.10\text{m}$, e) $r=0.02\text{m}$ (YTÜ Hidrolik)



Şekil 6.9 Farklı yarıçaplarda düzlemselliğin etkisi (a) $r=1\text{m}$, b) $r=0.50\text{m}$, c) $r=0.30\text{m}$, d) $r=0.10\text{m}$, e) $r=0.02\text{m}$ (Britanya Kolumbiyası)

6.2.4 Eğitim ve Test Verilerinin Oluşturulması

Tez kapsamında her iki veri seti içinde 5 farklı senaryo oluşturulmuştur. Oluşturulan senaryolar hem derin öğrenme hem de makine öğrenme için aynı şekilde kullanılmıştır. Bunlara ilişkin görseller Şekil A.1, Şekil A.2, Şekil A.3, Şekil A.4, Şekil A.5, Şekil A.6, Şekil A.7, Şekil A.8, Şekil A.9' ve Şekil A.10'de sunulmuştur.


6.2.4.1 YTÜ Hidrolik Laboratuvarı

Geometrik özellikleri hesaplanmış olan 3 boyutlu nokta bulutu verisi kullanılarak gerçekleştirilecek olan sınıflandırma işlemi için 5 farklı senaryo tasarlanmıştır. Tasarlanan her bir senaryoya göre oluşturulan eğitim ve test verilerine ilişkin sayısal veriler Tablo 6.3'te sunulmuştur. Burada amaç farklı nokta sayılarına sahip eğitim setlerinin sınıflandırma sonucuna etkisini incelemek ve bu senaryolarda uygulanan sınıflandırma algoritmalarının performansını değerlendirmektir.

Tablo 6.3 Her bir senaryoya göre oluşturulan eğitim ve test nokta sayıları(YTÜ Hidrolik Laboratuvarı)

Senaryo	Eğitim ve Test Dağılımı	Nokta sayısı
S1	Eğitim (%90) Test (%10)	9230212 1087703
S2	Eğitim (%70) Test (%30)	7281498 3036417
S3	Eğitim (%50) Test (%50)	5038567 5279348
S4	Eğitim (%30) Test (%70)	3092731 7225184
S5	Eğitim (%10) Test (%90)	1187198 9130717

Her bir senaryodaki eğitim ve veri setleri içinde sınıflara ait oransal dağılım Şekil 6.10'da gösterilmektedir. Şekil incelendiğinde verilerin homojen dağılmadığı görülmektedir. Bu çalışmada makine öğrenmesi sınıflandırıcılarının ve derin öğrenme algoritmalarının sınıflandırma performansı, homojen bir dağılım göstermeyen ve gerçek dünyayı yansıtan bir veri seti üzerinde analiz edilmiştir.




Şekil 6.10 Her bir senaryodaki eğitim ve test verileri içindeki sınıfların oransal dağılımı (YTÜ Hidrolik Laboratuvarı)

6.2.4.2 Britanya Kolumbiyası İçmesuyu Hattı

İlk çalışma alanı ile benzer şekilde 5 farklı senaryo oluşturulmuştur. Oluşturulan eğitim ve test verilerinin senaryolara göre dağılımı gösteren sayısal veriler Tablo 6.4'te verilmiştir. Ayrıca her senaryodaki eğitim ve test setleri içerisinde bulunan sınıfların oransal dağılımı Şekil 6.11'de gösterilmektedir.

Tablo 6.4 Her bir senaryoya göre oluşturulan eğitim ve test nokta sayıları (Britanya Kolumbiyası)

Senaryo	Eğitim ve Test Dağılımı	Nokta sayısı
S1	Eğitim (%90)	6934407
	Test (%10)	791096
S2	Eğitim (%70)	5336516
	Test (%30)	2388987
S3	Eğitim (%50)	3860167
	Test (%50)	3865336
S4	Eğitim (%30)	2322439
	Test (%70)	5403064
S5	Eğitim (%10)	791096
	Test (%90)	6934407



Şekil 6.11 Her bir senaryodaki eğitim ve test verileri içindeki sınıfların oransal dağılımı (Britanya Kolumbiyası)

6.2.5 Makine Öğrenmesi Sınıflandırıcılarına ait Parametrelerin Belirlenmesi

Eğitim ve test verileri oluşturulmuş nokta bulutunun sınıflandırması için 3 farklı makine öğrenme algoritması kullanılmıştır. Bu algoritmalar; RF, LightGBM ve XGBoost'tur. Sınıflandırma işlemini için kullanılacak algoritma parametreleri grid search işlemi ile belirlenmiştir. Bu parametreler Tablo 6.5, Tablo 6.6 ve Tablo 6.7'de verilmiştir.

Tablo 6.5 Aşırı gradyan artırma için grid search parametreleri

Yöntem	Ağaç Sayısı	Minimum Ağırlık	Öğrenme Hızı
XGBoost	100 ve 200	1 ve 5	0.1 ve 0.2

Tablo 6.6 Hafif gradyan artırma için grid search parametreleri

Yöntem	Ağaç Sayısı	Minimum Ağırlık	Öğrenme Hızı	Artırıcı Türü
LightGBM	100 ve 200	0.001 ve 0.002	0.1 ve 0.2	gbdt ve rf

Tablo 6.7 Rastgele orman için grid search parametreleri

Yöntem	Ağaç Sayısı	Ayrırma Kriteri
RF	100 ve 200	gini ve entropy

Her iki veri seti içinde aynı parametreler kullanılarak, grid search işlemi gerçekleştirilmiştir. Bu işlem sonucunda elde edilen parametreler, RF algoritması için ağaç sayısı: 100, ayırma kriteri: gini, XGBoost için ağaç sayısı:100, minimum ağırlık:1, öğrenme hızı:0.1, LightGBM için ağaç sayısı:100, minimum ağırlık:0.001, ve artırıcı türü:gbdt, öğrenme hızı:0.1 olarak elde edilmiştir. Bulgular kısmında verilecek sonuçlar bu parametrelerden elde edilmiştir.

6.2.6 Derin Öğrenme Yöntemlerinin ait Parametrelerin Belirlenmesi

KPConv için kullanılan parametreler Tablo 6.8 verilmiştir. Girdi yarıçapı (Input Radius), nokta bulutunda modelin konvolüsyon filtreleriyle özellik çıkarmak için dikkate aldığı yarıçap boyutunu ifade eder. Diğer bir deyişle, her bir girdi noktası etrafında öznitelik hesaplama yapılan bölgelerin maksimum mesafesini belirtir. Model, bu yarıçap içindeki noktaları kullanarak yerel özellikleri tespit eder. Yarıçapın büyüklüğü, hesaplama yükünü doğrudan etkiler. Daha küçük bir yarıçap, daha detaylı yerel özelliklerin çıkarılmasını sağlarken, daha büyük bir yarıçap, global özellikleri yakalamaya yardımcı olur. Çekirdek nokta sayısı, konvolüsyon işlemi sırasında kullanılan çekirdek (kernel) noktalarının toplam sayısını ifade etmektedir. Giriş verisi üzerinden yerel özellikleri yakalamak için kullanılan sabit veya öğrenilebilir pozisyonlardaki noktalardır. Çekirdek noktalarının sayısı, çıkartılan özelliklerin detay seviyesini belirler. İlk aşağı örnekleme çözünürlüğü, modelin girdi veri setini ilk aşamada ne kadar yoğunluğa indirgediğini gösterir. Veri setinin boyutunu azaltarak modelin daha hızlı ve verimli bir şekilde eğitilmesini sağlamak için yapılır. Aşağı örnekleme, nokta bulutu verilerindeki detayları azaltırken, önemli yapısal özellikleri korumak için tasarlanmıştır. Esnek yarıçap (Deformable radius), konvolüsyon çekirdeklerinin, eğitim süreci boyunca konumlarının dinamik olarak değişebileceği maksimum yarıçapı ifade eder. Bu yaklaşım sayesinde model, veri setindeki karmaşık veya değişken bölgelerdeki özellik farklarını öğrenmektedir.

Tablo 6.8 KPConv için kullanılan parameterler

Parametreler	Değer
Girdi Yarıçapı	15 metre
Çekirdek Nokta Sayısı	15
İlk Aşağı Örnekleme Çözünürlüğü	2 santimetre
Konvolüsyon Yarıçapı	2.5 metre
Esnek Yarıçap (Deformable Radius)	6 metre
Epok Sayısı	300
Öğrenme Hızı	0.01
Momentum	0.98
Yığın Boyutu	6

Eđitim ařamasında her bir epok sonrası đrenme hızı 0.001 ile arpılarak eđitim iřlemine devam edilmiřtir. Bu iřlem, eđitim srecinin ilerleyen ařamalarında modelin ađırlık gncellemelerinde daha hassas olmasına ve ařırı uyum durumunun nlenmesine katkı sađlamaktadır. Ayrıca eđitim verisinde veri artırma (renk, leklendirme, grlt ve aynalama) iřlemi uygulanmıřtır. Bu iřlem nokta bulutu sınıflandırma modellerinin, eđitim verilerinde dođrudan temsil edilmeyen durumlarla bařa ıkabilmesine olanak tanımaktadır. Renk iin 0.8, grlt iin 0.001, dřey ekseninde 0.95-1.05 leklendirme ve yatay ekseninde aynalama yapılmıřtır.




Bu bölümde makine öğrenmesi sınıflandırıcıları ve derin öğrenme sınıflandırıcıları ile elde edilen her iki çalışma bölgesine ait sınıflandırma sonuçları paylaşılacaktır.

7.1 YTÜ Hidrolik Laboratuvarı Verilerinin Makine Öğrenmesi Sınıflandırıcıları ile Sınıflandırılması


Beş farklı senaryo ve üç farklı makine öğrenmesi sınıflandırıcısı kullanılarak gerçekleştirilen sınıflandırma işleminin sonuçları doğruluk, kesinlik, duyarlılık ve F1-Skor sonuçlarına göre incelenmiştir. S1 senaryosuna ilişkin sınıflandırma sonuçları analiz edildiğinde RF sınıflandırıcısının 0.948, XGBoost sınıflandırıcısının 0.963, ve LightGBM sınıflandırıcısının 0.961 model doğruluğu elde ettiği görülmüştür. S2 senaryosuna ilişkin sonuçlar irdelendiğinde en yüksek model doğruluğuna 0.935 ile XGBoost sınıflandırıcısı kullanılarak ulaşıldığı, LightGBM sınıflandırıcısının 0.924, RF sınıflandırıcısının 0.894 model doğruluğu elde ettiği görülmüştür. Şekil 7.1’de her bir senaryoya ait sınıflandırıcı bazlı model doğrulukları gösterilmiştir.

S3 senaryosu incelendiğinde XGBoost sınıflandırıcısı ile 0.941 model doğruluğu elde edilirken, LightGBM ile 0.905, RF ile 0.901 model doğruluğu elde edilmiştir. S4 senaryosu sonuçlarına göre XGBoost (0.924) en yüksek sonuca ulaşırken, LightGBM (0.848) ile en düşük model doğruluğu elde edilmiştir. S5 senaryosunda ise en düşük model doğruluğu RF (0.739) ile elde edilirken, XGBoost sınıflandırıcısı ile 0.840, LightGBM sınıflandırıcısı ile 0.831 sonucuna ulaşılmıştır. Model doğrulukları incelendiğinde eğitilen veri sayısı düştükçe elde edilen model doğruluklarında azalmaların olduğu gözlenmiştir.



Şekil 7.1 Her bir senaryo için sınıflandırıcılarının elde ettiği model doğrulukları


Her yönteme ilişkin F1-Skor değerleri incelendiğinde XGBoost sınıflandırıcısının beş senaryoda da en yüksek sonucu verdiği görülmektedir. Şekil 7.2’de beş farklı senaryodan elde edilmiş F1-Skor değerleri gösterilmektedir. Model doğruluğunda olduğu gibi F1-Skor değerlerinde de eğitilen veri sayısı azaldıkça, genel olarak düşüşlerin yaşandığı görülmüştür. S1 senaryosunda en yüksek değer XGBoost ile elde edilirken, en düşük değer RF ile elde edilmiştir. S2 ve S5 senaryolarında da benzer durum gözlenmiştir. S3 ve S4 senaryolarında ise XGBoost en yüksek değere ulaşırken, LightGBM en düşük değeri elde etmiştir.



Şekil 7.2 Her bir senaryo için sınıflandırıcılarının elde ettiği F1-Skor değerleri

Her bir senaryoya ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık değerleri

görselleştirilmiş, Sonuçlar ayrıca sınıf bazındada incelenmiştir.




Şekil 7.3 S1 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.3 üç farklı makine öğrenmesi sınıflandırıcısı (RF, LightGBM, XGBoost) için S1 senaryosuna ait 9 sınıfın F1-Skor, Kesinlik (Precision) ve Duyarlılık (Recall) metriklerini göstermektedir. verilen sonuçlar altyapı ve bileşenleri özelinde incelendiğinde büyük boru sınıfında en yüksek F1-Skor değerine LightGBM (0.965) ile, en düşük değer F1-Skor değerine RF (0.953) ile ulaşılmıştır. Dirsek sınıfı incelendiğinde LightGBM (0.941) ile en yüksek sonuç elde ederken, RF (0.921) en düşük değeri elde etmiştir. Küçük boru sınıfında ise XGBoost (0.781) ile en yüksek sonuca ulaşırken, en düşük değer RF (0.694) ile alınmıştır. Diğer sınıflara ait sonuçlar incelendiğinde duvar, demir, pencere ve kapı sınıfında XGBoost üstünlük sağlarken, kaplama sınıfında LightGBM, güç kaynağı sınıfında ise RF'nun üstün olduğu görülmüştür. Her üç sınıflandırıcı ile elde edilen sonuçlara göre düşük F1-Skor değerine sahip olan küçük boru, demir ve pencere sınıflarının kesinlik ve duyarlılık değerleri incelendiğinde, küçük boru ve pencere değerlerinin yüksek kesinlik değerine sahip olduğu ancak duyarlılık değerlerinin düşük olduğu görülmüştür. Bu durum modelin pozitif olarak etiketlediği değerleri doğru tahmin ettiğini, ancak gerçekte pozitif olan birçok değeri gözardı ettiğini ya da yanlış sınıflandırdığını göstermektedir. Demir sınıfında ise yüksek duyarlılık ancak düşük kesinlik değeri elde edilmiştir. Yani model gerçek pozitif değeri kaçırmamak adına yanlış pozitiflere tolerans göstermiştir.


Şekil 7.4'te sınıflandırıcılar ile elde edilmiş sınıflandırma sonuçları verilmiştir. Şekil 7.4a'da etiketli test verisi, Şekil 7.4b'de XGBoost sınıflandırıcısı ile elde

edilen sınıflandırma görseli, Şekil 7.4c’de LightGBM ile elde edilen sınıflandırma görseli, Şekil 7.4d’de ise RF ile elde edilen sınıflandırma görseli sunulmuştur.




Şekil 7.4 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma

Şekil 7.5 üç farklı makine öğrenmesi sınıflandırıcısı (RF, LightGBM, XGBoost) için S2 senaryosuna ait 9 sınıfın F1-Skor, Kesinlik (Precision) ve Duyarlılık (Recall) metriklerini göstermektedir. S2 senaryo sonuçları altyapı ve bileşenleri açısından incelendiğinde en yüksek F1-Skor değerinin XGBoost (0.960) ile elde edildiği görülmektedir. En düşük değer ise RF (0.896) ile elde edilmiştir. Dirsek sınıfı incelendiğinde ise XGBoost (0.892) en yüksek değere ulaşırken, en düşük değer ise RF(0.794) sınıflandırıcısı ile elde edilmiştir. Küçük boru sınıfında LightGBM(0.597) ile en yüksek değer elde edilirken, en düşük değere RF (0.407) ile ulaşılmıştır. Diğer sınıflara ait sonuçlar irdelendiğinde kaplama, güç kaynağı, demir ve pencere sınıfında XGBoost üstünlüğü göze çarparken, duvar ve kapı sınıfında RF sınıflandırıcısı en yüksek değeri elde etmiştir.




Şekil 7.5 S2 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.6'da S2 senaryosuna göre etiketli test verisi(a), XGBoost ile sınıflandırma sonucu (b), LightGBM ile sınıflandırma sonucu(c) ve RF ile sınıflandırma sonucu (d) gösterilmektedir. Şekil incelendiğinde RF sınıflandırıcısının tahminlerinde boru sınıfının kimi yerlerde dirsek sınıfı olarak tahmin edildiği, güç kaynağı sınıfının da duvar olarak tahmin edildiği görülmektedir.




Şekil 7.6 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma

Şekil 7.7 üç farklı makine öğrenmesi sınıflandırıcısı (RF, LightGBM, XGBoost) için S3 senaryosuna ait 9 sınıfın F1-Skor, Kesinlik (Precision) ve Duyarlılık (Recall) metriklerini göstermektedir. S3 senaryo sonuçları altyapı ve bileşenleri açısından incelendiğinde en yüksek F1-Skor değeri büyük boru sınıfında 0.969 olarak XGBoost sınıflandırıcısı ile elde edildiği görülmektedir (Şekil 5.9). LightGBM ve RF sınıflandırıcısı bu sınıfta sırasıyla 0.915 ve 0.914 F1-Skor değerine ulaşmışlardır. Küçük boru sınıfında ise 0.715 değeri ile XGBoost en yüksek sonuca ulaşırken 0.369 ile LightGBM en düşük değeri elde etmiştir. Dirsek sınıfında en yüksek F1-Skor değerine XGBoost(0.841) ile ulaşılırken, en düşük sonuç 0.744 olarak RF sınıflandırıcısı ile alınmıştır. Diğer sınıflar incelendiğinde, kapı sınıfında RF sınıflandırıcısının üstün olduğu görülürken, kaplama,güç kaynağı, duvar, demir ve pencere sınıfında XGBoost sınıflandırıcısı en yüksek değerleri elde etmiştir.




Şekil 7.7 S3 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

S3 senaryosuna ilişkin sınıflandırma sonuçları görselleştirilerek Şekil 7.8’de sunulmuştur. Şekil incelendiğinde LightGBM ile elde edilen sonuçlarda duvar ve kaplama sınıfında karışmaların olduğu görülmektedir.




Şekil 7.8 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma

Şekil 7.9’da S4 senaryosuna ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık değerleri verilmiştir. Sonuçlar altyapı ve bileşenleri açısından irdelendiğinde büyük boru sınıfında XGBoost (0.925) sınıflandırıcısının en yüksek F1-Skor değeri elde ettiği, LightGBM(0.861) sınıflandırıcısının ise en düşük değeri elde ettiği görülmüştür. Dirsek sınıfında ise 0.829 ile en yüksek değer XGBoost sınıflandırıcısı ile elde edilirken, en düşük değere 0.761 ile RF sınıflandırıcısı ile ulaşılmıştır. Küçük boru sınıfında ait sonuçlar incelendiğinde en yüksek değere XGBoost (0.726) ile, en düşük değere ise RF (0.445) ile ulaşıldığı görülmüştür. Eğitilen veri sayısı azaldıkça, XGBoost sınıflandırıcısının, sınıflandırma sonuçlarına diğer sınıflandırıcılara göre daha iyi sonuçlar elde ettiği görülmüştür. Diğer sınıflara ait sonuçlara bakıldığında RF sınıflandırıcısı kapı sınıfında üstünlük sağlarken, XGBoost sınıflandırıcısının kalan sınıflarda diğer sınıflandırıcılara göre daha yüksek değer elde etmiştir.




Şekil 7.9 S4 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.10’da üç sınıflandırıcıdan elde edilen sınıflandırma sonuçları verilmiştir. Şekil incelendiğinde, eğitim verisi azaldıkça LightGBM sınıflandırıcısının sınıflandırma sonuçlarının kötüleştiği, karmaşıklığın arttığı görülmektedir.



Şekil 7.10 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma

Şekil 7.11’de S5 senaryosuna ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık değerleri verilmiştir. S5 senaryosuna ilişkin sonuçlar incelendiğinde büyük boru sınıfında XGBoost sınıflandırıcısının 0.668 F1-Skor değeri ile en yüksek sonucu aldığı, 0.432 değeri ile RF sınıflandırıcısının en düşük değeri aldığı görülmüştür. Dirsek sınıfında yine benzer şekilde XGBoost (0.597) sınıflandırıcısı en yüksek sonuca ulaşırken, RF (0.522) sınıflandırıcısının en düşük sonucu elde ettiği görülmüştür. Küçük boru sınıfında ise RF (0.353) en yüksek değeri elde ederken, LightGBM (0.323) sınıflandırıcısı en düşük sonucu elde etmiştir. Diğer sınıflar incelendiğinde S2, S3, ve S4 senaryolarına benzer şekilde RF sınıflandırıcısı kapı sınıfında üstünlük göstermiştir. Demir ve kaplama sınıfında LightGBM en yüksek değere ulaşırken, güç kaynağı, duvar ve pencere sınıfında XGBoost üstünlüğü göze çarpmaktadır.




Şekil 7.11 S5 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.11’de gösterilen sonuçlara bakıldığında çoğu sınıf yüksek kesinlik değerine sahipken, düşük duyarlılık değeri elde etmiştir. Model gerçek pozitiflerin çoğunu doğru tahmin etmiştir ancak, model pozitif tahmin sırasında birçok doğru olmayan pozitif tahmin yapmıştır. Bu durum eğitim seti içerisinde sınıfı temsil eden noktaların yetersiz olduğu ve sınıflandırıcıların bu nedenle sınıf ayrımında başarısız olduğunu göstermektedir.

Üç sınıflandırıcıdan elde edilen sınıflandırma sonuçları Şekil 7.12’de gösterilmektedir. Görsel incelendiğinde eğitilen veri sayısında azalma olduğunda hatalı sınıflandırmaların olduğu anlaşılmaktadır. Örneğin, XGBoost sınıflandırıcısı büyük boru sınıfında en yüksek F1-Skor değeri elde etmesine rağmen Şekil

7.12b’de dirsek sınıfı ile büyük ölçüde karışmaların olduğu görülmektedir. Şekil 7.12d’de RF sınıflandırıcısının duvar ve güç kaynağı sınıflarında hatalı sınıflandırmalar yaptığı, büyük boru sınıfının dirsek sınıfı olarak tahmin edildiği anlaşılmaktadır. Altyapılar haricinde kalan sınıflar incelendiğinde, kapı sınıfında RF üstünlüğü göze çarparken, demir ve kaplama sınıflarında LightGBM, pencere, güç kaynağı ve duvar sınıflarında XGBoost üstünlüğü görülmektedir.



Şekil 7.12 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma

7.1.1 YTU Hidrolik Laboratuvarının Sınıflandırma Sonuçlarına Etki Eden Özelliklerin Belirlenmesi

Makine öğrenimi sınıflandırıcıları hedef sınıfın veriseti içerisindeki oranından ve geometrik özelliklerden etkilenmektedir. Geometrik özellik kıyaslaması yapılırken, en iyi 30 parametre seçilerek değerlendirmeler bunun üzerinden gerçekleştirilmiştir. Her bir sınıflandırıcının 5 senaryoda kullanmış olduğu en iyi 30 özellik belirlenmiş ve görselleştirilmiştir. Şekil 7.13’de S1 senaryosuna göre sınıflandırmada kullanılan en iyi 30 özellik gösterilmektedir.

S1 senaryosuna göre özellikler incelendiğinde, 3 sınıflandırıcının, sınıflandırmada farklı yarıçaplarda 9 geometrik özellik ile Z, Rf ve Bf olmak üzere 12 özelliği ortak olarak kullandıkları anlaşılmaktadır. Aynı komşuluk yarıçapları bazında incelendiğinde ise 3.özdeğer ($r=1m$), ortalama eğrilik ($r=0.10m$), normal değişim oranı ($r=0.30m$), düzlemsellik ($r=1m$), dikeylik ($r=0.10m$ ve $r=0.30m$) ve yüzey değişimi ($r=1m$) geometrik özelliklerinin ortak olduğu görülmüştür.

Şekil 7.14’de S2 senaryosuna göre sınıflandırmada kullanılan en iyi 30 özellik görselleştirilmiştir. Sonuçlar incelendiğinde 3 sınıflandırıcının, sınıflandırmada farklı yarıçaplarda 6 geometrik özellik ile Z, Rf ve Bf olmak üzere 9 özelliği ortak olarak kullandıkları görülmüştür. Komşuluk yarıçapına göre incelendiğinde, gauss eğriliği ($r=0.10m$ ve $r=0.30m$), ortalama eğrilik ($r=0.10m$), dikeylik ($r=0.02m$, $r=0.10m$ ve $r=0.30m$) ve düzlemsellik ($r=1m$) geometrik özelliklerinin ortak olduğu anlaşılmıştır.

S3 senaryosuna ilişkin sınıflandırıcıların kullanmış olduğu en iyi 30 özellik Şekil 7.15’de sunulmuştur. Görsel incelendiğinde farklı yarıçaplarda olmak üzere 5 geometrik özellik ile Z, Rf ve Bf olmak üzere 8 özellik ortak olarak kullanılmıştır. Komşuluk yarıçaplarına göre analiz edildiğinde, gauss eğriliği ($r=0.30$ ve $r=0.50$), ortalama eğrilik ($r=0.10m$, $r=0.30m$ ve $r=0.50m$), düzlemsellik ($r=1m$), yüzey değişimi ($r=0.10m$ ve $r=1m$) ve dikeylik ($r=0.10m$, $r=0.30m$ ve $r=0.50m$) özelliklerinin ortak olduğu göze çarpmaktadır.

Şekil 7.16’de S4 senaryosunda sınıflandırıcıların kullanmış olduğu özellikler verilmiştir. Sonuçlar incelendiğinde farklı yarıçaplarda 6 geometrik özellik ile Z, Rf ve Bf olmak üzere 9 özelliğin ortak olduğu görülmektedir. Komşuluk yarıçapları özelinde bakıldığında ise gauss eğriliği ($r=0.30m$ ve $r=0.50m$), ortalama eğrilik ($r=0.10m$), omnivaryans ($r=1m$), düzlemsellik ($r=1m$), yüzey değişimi ($r=1m$) ve dikeylik ($r=0.02m$, $r=0.10m$, $r=0.30m$ ve $r=0.50m$) özellikleri ortak olarak kullanıldığı anlaşılmaktadır.

XGBoost-S1		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer		✓		✓	
	3.Özdeğer					✓
	Anizotropi		✓		✓	✓
	Gauss Eğriliği		✓	✓	✓	
	Ortalama Eğrilik		✓			
	Normal Değişim Oranı			✓		
	Omnivaryans		✓		✓	
	PCA1					✓
	PCA2		✓			✓
	Düzlemsellik		✓			✓
	Küresellik		✓	✓		
	Yüzey Değişimi		✓		✓	✓
	Dikeylik	✓	✓	✓		
	Hacim Değişimi		✓			
	Z	✓				
	Rf					
	Bf					
LightGBM-S1		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	1.Özdeğer					✓
	2.Özdeğer					✓
	3.Özdeğer					✓
	Gauss Eğriliği		✓			✓
	Ortalama Eğrilik		✓	✓	✓	✓
	Normal Değişim Oranı			✓		
	Omnivaryans					✓
	1. Derece Moment			✓	✓	✓
	Düzlemsellik		✓			✓
	Yüzey Değişimi					✓
	Dikeylik	✓	✓	✓	✓	✓
	Hacim Değişimi		✓		✓	✓
	Pürüzlülük				✓	✓
	Z	✓				
	Rf					
	Bf					
RF-S1		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer					✓
	3.Özdeğer					✓
	Anizotropi		✓	✓		✓
	Gauss Eğriliği			✓	✓	
	Ortalama Eğrilik		✓			
	Normal Değişim Oranı		✓	✓		✓
	Omnivaryans			✓	✓	
	Doğrusallık					✓
	PCA2					✓
	Düzlemsellik					✓
	Küresellik		✓	✓		✓
	Yüzey Değişimi		✓	✓		✓
	Dikeylik		✓	✓	✓	✓
	Z	✓				
	Rf					
	Gf					
	Bf					

Şekil 7.13 S1 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

XGBoost-S2		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer		✓			
	3.Özdeğer					✓
	Anizotropi		✓	✓		✓
	Gauss Eğriligi		✓	✓	✓	
	Ortalama Eğrilik		✓			
	Normal Değişim Oranı		✓		✓	✓
	Omnivaryans		✓	✓	✓	
	Doğrusallık		✓			
	PCA2		✓			✓
	Düzlemsellik		✓			✓
	Küresellik		✓			✓
	Yüzey Değişimi		✓	✓		
	Dikeylik	✓	✓	✓		
	Z	✓				
	Rf					
	Bf					
LightGBM-S2		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	1.Özdeğer			✓		✓
	2.Özdeğer					✓
	3.Özdeğer					✓
	Gauss Eğriligi			✓	✓	✓
	Ortalama Eğrilik		✓	✓	✓	✓
	Normal Değişim Oranı				✓	✓
	Komşu Sayısı		✓		✓	✓
	1. Derece Moment			✓	✓	✓
	Düzlemsellik					✓
	Dikeylik	✓	✓	✓	✓	✓
	Hacim Değişimi					
	Pürüzlülük				✓	✓
	Z	✓				
	Rf					
	Bf					
RF-S2		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer					✓
	Anizotropi		✓	✓		✓
	Gauss Eğriligi			✓	✓	
	Ortalama Eğrilik		✓	✓		
	Normal Değişim Oranı		✓	✓		✓
	Omnivaryans				✓	✓
	Doğrusallık					✓
	PCA2					✓
	Düzlemsellik					✓
	Küresellik		✓			✓
	Yüzey Değişimi		✓	✓		✓
	Dikeylik	✓	✓	✓	✓	✓
	Z	✓				
	Rf					
	Gf					
	Bf					

Şekil 7.14 S2 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

XGBoost-S3		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	3.Özdeğer				✓	✓
	Anizotropi		✓		✓	
	Gauss Eğriliği			✓	✓	
	Ortalama Eğrilik		✓	✓	✓	
	Normal Değişim Oranı			✓		
	Omnivaryans		✓	✓	✓	
	PCA2		✓			✓
	Düzlemsellik	✓	✓			✓
	Küresellik	✓				✓
	Yüzey Değişimi		✓		✓	✓
	Dikeylik	✓	✓	✓	✓	
	Z	✓				
	Rf					
	Bf					
LightGBM-S3		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	1.Özdeğer					✓
	2.Özdeğer					✓
	Gauss Eğriliği			✓	✓	
	Ortalama Eğrilik		✓	✓	✓	✓
	Omnivaryans					✓
	1. Derece Moment			✓	✓	✓
	Düzlemsellik					✓
	PCA1				✓	
	Yüzey Değişimi		✓		✓	✓
	Dikeylik	✓	✓	✓	✓	✓
	Hacim Değişimi		✓		✓	✓
	Pürüzlülük				✓	✓
	Z	✓				
	Rf					
	Bf					
RF-S3		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	3.Özdeğer					✓
	Anizotropi		✓	✓		✓
	Gauss Eğriliği			✓	✓	
	Ortalama Eğrilik		✓	✓	✓	
	Normal Değişim Oranı		✓	✓	✓	
	Omnivaryans			✓		✓
	Doğrusallık					✓
	PCA2					✓
	Düzlemsellik					✓
	Küresellik		✓	✓		✓
	Yüzey Değişimi		✓			✓
	Dikeylik		✓	✓	✓	✓
	Z	✓				
	Rf					
	Gf					
	Bf					

Şekil 7.15 S3 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

XGBoost-S4		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	3.Özdeğer				✓	✓
	Anizotropi		✓			
	Gauss Eğriliği			✓	✓	
	Ortalama Eğrilik		✓		✓	
	Normal Değişim Oranı			✓		
	Omnivaryans		✓	✓	✓	
	Doğrusallık		✓			
	PCA2		✓			✓
	Düzlemsellik		✓			✓
	Küresellik		✓			✓
	Özdeğerler Toplamı				✓	
	Yüzey Değişimi		✓		✓	✓
	Dikeylik	✓	✓	✓	✓	
	Z	✓				
	Rf					
	Bf					
LightGBM-S4		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	1.Özdeğer					✓
	2.Özdeğer					✓
	Gauss Eğriliği			✓	✓	
	Ortalama Eğrilik		✓	✓	✓	✓
	1. Derece Moment			✓	✓	✓
	Özdeğerler Toplamı					✓
	Komşu Sayısı			✓		
	Düzlemsellik					✓
	PCA1					✓
	Yüzey Değişimi					✓
	Dikeylik	✓	✓	✓	✓	✓
	Hacim Yoğunluğu		✓		✓	✓
	Pürüzlülük				✓	✓
	Z	✓				
	Rf					
	Bf					
RF-S4		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer					✓
	3.Özdeğer					✓
	Anizotropi		✓	✓		✓
	Gauss Eğriliği			✓		
	Ortalama Eğrilik		✓	✓		
	Normal Değişim Oranı		✓			✓
	Omnivaryans				✓	✓
	Doğrusallık					✓
	PCA2					✓
	Düzlemsellik					✓
	Küresellik		✓	✓		✓
	Yüzey Değişimi		✓	✓		✓
	Dikeylik	✓	✓	✓	✓	✓
	Z	✓				
	Rf					
	Gf					
	Bf					

Şekil 7.16 S4 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

XGBoost-S5		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	Anizotropi			✓		
	Gauss Eğriliği				✓	
	Ortalama Eğrilik		✓	✓	✓	
	Normal Değişim Oranı			✓		
	Omnivaryans		✓	✓	✓	✓
	Öz Entropi				✓	✓
	PCA2		✓	✓		✓
	Doğrusallık		✓			✓
	Düzlemsellik		✓			✓
	Küresellik		✓		✓	
	Yüzey Değişimi		✓		✓	✓
	Dikeylik	✓		✓	✓	
	Z	✓				
	Rf					
	Bf					
LightGBM-S5		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	1.Özdeğer					✓
	Özdeğerler Toplamı					✓
	Gauss Eğriliği			✓	✓	✓
	Ortalama Eğrilik		✓	✓	✓	✓
	Normal Değişim Oranı			✓		
	Omnivaryans					✓
	1. Derece Moment					✓
	Küresellik		✓			
	Düzlemsellik					✓
	Öz Entropi					✓
	Yüzey Değişimi		✓			
	Dikeylik	✓	✓	✓	✓	✓
	Hacim Yoğunluğu		✓		✓	✓
	Pürüzlülük		✓		✓	✓
	Z	✓				
	Rf					
	Bf					
RF-S5		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	3.Özdeğer					✓
	Anizotropi		✓	✓		✓
	Gauss Eğriliği			✓		
	Ortalama Eğrilik		✓			
	Normal Değişim Oranı		✓	✓	✓	✓
	Omnivaryans				✓	✓
	Doğrusallık					✓
	PCA2					✓
	Düzlemsellik					✓
	Küresellik		✓	✓	✓	
	Yüzey Değişimi		✓	✓		✓
	Dikeylik	✓	✓	✓	✓	✓
	Z	✓				
	Rf					
	Gf					
	Bf					

Şekil 7.17 S5 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik


Son eğitim seti olan S5 senaryosuna ilişkin özellik görseli Şekil 7.17’te verilmiştir. Komşuluk yarıçapına bakılmaksızın sınıflandırıcılar 8 geometrik özellik ile Z , R_f ve B_f olmak üzere 11 özelliği sınıflandırmada ortak kullanmışlardır. Komşuluk yarıçapına göre bakıldığında, ortalama eğrilik ($r=0.10m$), normal değişim oranı ($r=0.30m$), omnivaryans ($r=1m$), düzlemsellik ($r=1m$), küresellik ($r=0.10m$), yüzey değişimi ($r=0.10m$) ve dikeylik ($r=0.02m$, $r=0.30m$ ve $r=0.50m$) özelliklerinin ortaklığı göze çarpmaktadır.



7.2 Britanya Kolumbiyası İçmesuyu Hattı Verilerinin Makine Öğrenmesi Sınıflandırıcıları ile Sınıflandırılması

YTÜ Hidrolik veri setinde olduğu gibi beş farklı senaryo ve üç farklı makine öğrenmesi sınıflandırıcısı kullanılarak sınıflandırma işlemi gerçekleştirilmiş ve sınıflandırma sonuçları doğruluk, kesinlik, duyarlılık ve F1-Skor sonuçlarına göre incelenmiştir.

Şekil 7.18, beş farklı senaryo (S1, S2, S3, S4, S5) üzerinde üç farklı makine öğrenmesi sınıflandırıcısı (RF, LightGBM, XGBoost) için doğruluk (accuracy) değerlerini göstermektedir. S1 senaryosunda, RF 0.885, LightGBM 0.871 ve XGBoost 0.886 doğruluk değerlerine ulaşmıştır. S2 senaryosunda, RF 0.910, LightGBM 0.898 ve XGBoost 0.896 doğruluk değerlerine sahiptir. S3 senaryosunda, RF 0.781, LightGBM 0.769 ve XGBoost 0.789 doğruluk değerleri ile sonuçlanmıştır. S4 senaryosunda, RF 0.831, LightGBM 0.815 ve XGBoost 0.830 doğruluk değerlerine ulaşmıştır. Son olarak, S5 senaryosunda RF 0.738, LightGBM 0.661 ve XGBoost 0.618 doğruluk değerleri elde etmiştir. Genel olarak, RF, çoğu senaryosunda en yüksek doğruluk değerlerine sahip olup, özellikle S2 (0.910) ve S5 (0.738) veri setlerinde diğer modellerden daha üstün performans göstermiştir. LightGBM çoğunlukla daha düşük doğruluk değerleri sunarken, XGBoost bazı veri setlerinde iyi performans göstermiş olsa da, genellikle RF'nin gerisinde kalmıştır.




Şekil 7.18 Her bir senaryo için sınıflandırıcılarının elde ettiği model doğrulukları

Şekil 7.19, beş farklı senaryo (S1, S2, S3, S4, S5) üzerinde üç farklı makine öğrenmesi sınıflandırıcısı (XGBoost, LightGBM, RF) için F1-Skor değerlerini göstermektedir. S1 senaryosunda, XGBoost 0.883, LightGBM 0.868 ve RF 0.882

F1-Skor değerlerine ulaşmıştır. S2 senaryosunda, XGBoost 0.893, LightGBM 0.836 ve RF 0.907 F1-Skor değerlerine sahiptir. S3 senaryosunda, XGBoost 0.777, LightGBM 0.757 ve RF 0.763 F1-Skor değerleri ile sonuçlanmıştır. S4 senaryosunda, XGBoost 0.825, LightGBM 0.811 ve RF 0.824 F1-Skor değerlerine ulaşmıştır. Son olarak, S5 senaryosunda XGBoost 0.677, LightGBM 0.707 ve RF 0.756 F1-Skor değerleri elde etmiştir.


Genel olarak, RF çoğu senaryosunda yüksek F1-Skor değerlerine sahip olup, özellikle S2 (0.907) ve S5 (0.756) senaryolarda diğer modellerden daha üstün performans göstermiştir. LightGBM bazı senaryolarda (S1 ve S4) karşılaştırılabilir F1-Skor değerleri sunarken, genel olarak XGBoost ve RF modellerinin gerisinde kalmıştır. XGBoost ise bazı senaryolarda (S1 ve S3) yüksek F1-Skor değerleri göstermiş olsa da, genelde RF performansını altında kalmıştır.



Şekil 7.19 Her bir senaryo için sınıflandırıcılarının elde ettiği F1-Skor değerleri


Şekil 7.20 üç farklı makine öğrenmesi sınıflandırıcısı (RF, LightGBM, XGBoost) için S1 senaryosuna ait F1-Skor, Kesinlik (Precision) ve Duyarlılık (Recall) metriklerine göre değerlendirilmiş 11 farklı sınıfı göstermektedir. Sonuçlar altyapı ve bileşenleri açısından incelendiğinde, su borusu sınıfında en yüksek F1-Skor değeri XGBoost (0.945) ile elde ederken, en düşük F1-Skor değere LightGBM (0.914) ile ulaşmıştır. Dirsek sınıfı özelinde incelendiğinde, su borusu sınıfında olduğu gibi XGBoost (0.818) ile en yüksek değere sahip iken, LightGBM (0.734)'nin en düşük değere sahip olduğu görülmüştür. Te sınıfına ait sonuçlara bakıldığında RF (0.930) ile en yüksek skora ulaşırken, LightGBM(0.854) ile en düşük değeri elde etmiştir. Bağlantı elemanları açısından sonuçlar irdelendiğinde XGBoost (0.894) sınıflandırıcısının en yüksek sonucu aldığı, LightGBM (0.816)

sınıflandırıcısının en düşük değeri elde ettiği görülmüştür. Altyapı haricindeki sınıflara ait sonuçlar incelendiğinde, zemin, çit ve iskele sınıfında XGBoost üstünlüğü göze çarparken, merdiven, düşey yüzey ve taşıyıcı kolon sınıfında RF sınıflandırıcısı en yüksek sonucu elde etmiştir. Diğer sınıfında ise LightGBM sınıflandırıcısının en yüksek F1-Skor değerini elde ettiği görülmüştür. Dirsek sınıfında bütün sınıflandırıcılar yüksek kesinlik değerine sahip iken, düşük duyarlılık elde ettikleri görülmektedir. Yani model pozitif değerlerin büyük çoğunluğunu doğru tahmin ederken, gerçekte pozitif olan değerlerin bir çoğunu tespit etmekte yetersiz kalmıştır.



Şekil 7.20 S1 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.21’de sınıflandırıcılar ile elde edilmiş sınıflandırma sonuçları verilmiştir. Şekil 7.21a etiketli test verisi, Şekil 7.21b XGBoost sınıflandırıcısının elde ettiği sınıflandırma görseli, Şekil 7.21c LightGBM ile elde edilen sınıflandırma görseli ve Şekil 7.21d RF ile elde edilen sınıflandırma görselidir.




Şekil 7.21 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma

Şekil 7.22 üç farklı makine öğrenmesi sınıflandırıcısı (RF, LightGBM, XGBoost) için S2 seanryosuna ait 11 sınıfın F1-Skor, Kesinlik (Precision) ve Duyarlılık (Recall) metriklerini göstermektedir. Sonuçlar altyapı ve bileşenleri açısından incelendiğinde, su borusu sınıfında en yüksek F1-Score değeri XGBoost (0.945) ile elde ederken, en düşük F1-Score değere LightGBM (0.914) ile ulaşmıştır. Dirsek sınıfı özelinde incelendiğinde, su borusu sınıfında olduğu gibi XGBoost (0.818) ile en yüksek değere sahip iken, LightGBM (0.734)'nin en düşük değere sahip olduğu görülmüştür. Te sınıfına ait sonuçlara bakıldığında RF(0.930) ile en yüksek skora ulaşırken, LightGBM (0.854) ile en düşük değeri elde etmiştir. Bağlantı elemanları açısından sonuçlar irdelendiğinde XGBoost (0.894) sınıflandırıcısının en yüksek sonucu aldığı, LightGBM(0.816) sınıflandırıcısının en düşük değeri elde ettiği görülmüştür. Altyapı haricindeki sınıflara ait sonuçlar incelendiğinde, zemin, çit ve iskele sınıfında XGBoost üstünlüğü göze çarparken, merdiven, düşey yüzey ve taşıyıcı kolon sınıfında RF sınıflandırıcısı en yüksek sonucu elde etmiştir. Diğer sınıfında ise LightGBM sınıflandırıcısının en yüksek F1-Score değerini elde ettiği görülmüştür. Dirsek sınıfında bütün sınıflandırıcılar yüksek kesinlik değerine sahip iken, düşük duyarlılık elde ettikleri görülmektedir. Yani model pozitif değerlerin büyük çoğunluğunu doğru tahmin ederken, gerçekte pozitif olan değerlerin bir çoğunu tespit etmekte yetersiz kalmıştır.



Şekil 7.22 S2 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.23’de sınıflandırıcılar ile elde edilmiş sınıflandırma sonuçları verilmiştir. Şekil 7.23a etiketli test verisi, Şekil 7.21b XGBoost sınıflandırıcısının elde ettiği sınıflandırma görseli, Şekil 7.23c LightGBM ile elde edilen sınıflandırma görseli ve Şekil 7.23d RF ile elde edilen sınıflandırma görselidir.




Şekil 7.23 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma




Şekil 7.24 S3 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.24'te S3 senaryosuna ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık değerleri verilmiştir. Altyapı ve bileşenleri açısından sonuçlar incelendiğinde su borusu sınıfında en yüksek F1-Skor değeri XGBoost(0.731) ile elde edilirken, en düşük değer RF (0.702) sınıflandırıcısı ile elde edilmiştir. Dirsek sınıfı sonuçları irdelendiğinde RF (0.737) sınıflandırıcısı en yüksek F1-Skor değerine ulaşırken, LightGBM (0.623)'in en düşük F1-Skor değerine ulaştığı görülmektedir. Te sınıfında elde edilen en yüksek F1-Skor değeri LightGBM ile elde edilmesine rağmen her üç sınıflandırıcıda bu sınıfta oldukça düşük değer elde etmiştir. Bağlantı elemanları incelendiğinde en yüksek F1-Skor değeri XGBoost (0.744) ile elde edilirken, LightGBM (0.694) ile en düşük F1-Skor değerine ulaşılmıştır. Altyapı haricindeki diğer sınıf sonuçlarına bakıldığında, zemin, merdiven ve iskele sınıflarında RF sınıflandırıcısının üstünlüğü ön plana çıkarken, çit, düşey yüzey ve taşıyıcı kolon sınıflarında XGBoost üstünlüğü göze çarpmaktadır.

Her üç sınıflandırıcı ile elde edilen sonuçlar görselleştirilerek Şekil 7.25'de sunulmuştur. Su borusunun toprak örtülü olan kısımlarında zemin sınıfının su borusu olarak tahmin edildiği, su borusu ile direk sınıfın yer yer karışıklık gösterdiği ve gerçekte su borusu olan noktaların dirsek olarak tahmin edildiği görülmektedir.




Şekil 7.25 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma



Şekil 7.26 S4 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları


Şekil 7.26’de S4 senaryosuna ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık değerleri verilmiştir. S4 senaryo sonuçları altyapı ve bileşenleri açısından incelendiğinde, su borusu sınıfında ulaşılan en yüksek F1-Score değeri XGBoost (0.761) ile, en düşük değer ise RF (0.751) ile elde edilmiştir. Dirsek sınıfı özelinde incelendiğinde RF (0.521) en yüksek F1-Score değerini elde eder iken, XGBoost (0.445)’un en düşük değeri elde ettiği görülmüştür. Te sınıfı sonuçları irdelendiğinde F1-Score değerlerinin kıyaslanamayacak ölçüde küçük olduğu görülmüştür. Bağlantı elemanları açısından sonuçlar incelendiğinde RF (0.626) sınıflandırıcısının en yüksek F1-Score değerine ulaştığı, en düşük değerin ise LightGBM (0.559) ile elde edildiği görülmüştür.

Şekil 7.26’de verilen değerler incelendiğinde dirsek sınıfının yüksek duyarlılığa sahip olmasına rağmen, F1-Skor değerinin düşük olduğu görülmektedir. Bu durum modelin gerçek pozitif değerleri doğru şekilde tanımladığı ancak, bir çok yanlış pozitif değerde ürettiğini göstermektedir.



Şekil 7.27 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma


Her üç sınıflandırıcı ile elde edilen sonuçlar görselleştirilerek Şekil 7.27’de sunulmuştur. Sınıflandırıcıların su borusu ve dirsek sınıfında karışıklık gösterdiği, yine zemin ve su borusu sınıflarında yanlış tahminler gerçekleştirdiği görülmektedir.



Şekil 7.28 S5 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

S5 senaryosuna ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık değerleri Şekil 7.28’te verilmiştir. Sonuçlar altyapı bileşenleri açısından incelendiğinde su borusu sınıfında en yüksek F1-Skor değeri RF (0.748) sınıflandırıcı ile elde edilmiştir. Bu sınıfta alınan en düşük değere XGBoost (0.728) sınıflandırıcısı ile ulaşıldığı görülmektedir. Dirsek sınıfı açısından incelendiğinde en yüksek F1-Skor değeri RF (0.543) sınıflandırıcısı ile alınırken, en düşük değer XGBoost (0.428) ile elde edilmiştir. Te sınıfında en yüksek değer XGBoost (0.424) ile elde edilirken, en düşük değere LightGBM (0.358) ile ulaşılmıştır. Bağlantı elemanları özelinde incelendiğinde en yüksek F1-Skor değeri XGBoost (0.586) sınıflandırıcısı ile en düşük değer ise RF (0.547) sınıflandırıcı ile elde edilmiştir. Altyapı bileşenleri haricindeki sınıf sonuçları incelendiğinde, zemin, çit, iskele, taşıyıcı kolon ve diğer sınıflarında RF üstünlüğü görülürken, düşey yüzey sınıfında XGBoost ve merdiven sınıfında LightGBM üstünlüğü göze çarpmaktadır.

Her üç sınıflandırıcı ile elde edilen sonuçlar görselleştirilerek Şekil 7.29’de sunulmuştur.



Şekil 7.29 a) Etiketli test verisi; b) XGBoost ile sınıflandırma; c) LightGBM ile sınıflandırma; d) RF ile sınıflandırma

7.2.1 Britanya Kolumbiyası İçmesuyu Hattı Sınıflandırma Sonuçlarına Etki Eden Özelliklerin Belirlenmesi

YTÜ Hidrolik Laboratuvarında olduğu gibi, burada da en iyi 30 özellik dikkate alınarak, her bir senaryo için etkin olan özellikler görsel olarak sunulmuştur.

Şekil 7.30'de Britanya Kolumbiyası S1 senaryosuna ilişkin 3 farklı sınıflandırıcının sınıflandırmada kullandığı en iyi 30 özellik gösterilmektedir. Komşuluk yarıçapı dikkate alınmadan 9 geometrik özellik ile Z, Rf ve Bf özellikleri olmak üzere 12 özelliğin sınıflandırıcılar tarafından ortak kullanıldığı göze çarpmaktadır. Komşuluk yarıçapları dikkate alındığında, PCA2 ($r=1m$), hacim yoğunluğu ($r=1m$), omnivaryans ($r=1m$), düzlemsellik ($r=1m$), yüzey değişimi ($r=1m$), normal değişim oranı ($r=0.30m$ ve $r=0.50m$) ve dikeylik ($r=0.10m$, $r=0.30m$ ve $r=0.50m$) özelliklerinin ortak olarak kullanıldığı görülmektedir.

S2 senaryosunun eğitiminde 3 farklı sınıflandırıcı tarafından kullanılan en iyi 30 özellik listenmiş ve Şekil 7.31'de sunulmuştur. Sınıflandırıcıların 7 geometrik özellik ile Z, Rf ve Gf özelliklerini ortak olarak kullandıkları ve komşuluk yarıçapları dikkate alındığında komşu sayısı ($r=0.30m$), normal değişim oranı ($r=0.30m$ ve $r=0.50m$), yüzey değişimi ($r=1m$), düzlemsellik ($r=0.50m$ ve $r=1m$) ve dikeylik ($r=0.10m$, $r=0.30m$ ve $r=0.50m$) özelliklerinin ortak olduğu görülmüştür.

S3 senaryosuna ilişkin sınıflandırıcıların eğitimde kullandıkları en iyi 30 özellik Şekil 7.32'te verilmiştir. Sonuçlar incelendiğinde 10 geometrik özellik ile Z olmak üzere 11 özelliğin sınıflandırmada ortak olduğu, komşuluk yarıçapı dikkate alındığında ise özdeğerler toplamı ($r=1m$), PCA2 ($r=1m$), hacim yoğunluğu ($r=1m$), yüzey değişimi ($r=1m$), düzlemsellik ($r=0.50m$ ve $r=1m$) ve dikeylik ($r=0.10m$, $r=0.30m$ ve $r=0.50m$) özelliklerinin 3 sınıflandırıcı içinde ortak olduğu anlaşılmaktadır.

Sınıflandırıcıların eğitim için kullandıkları özellikler S4 senaryosu bazında incelendiğinde 6 geometrik özellik ile Z ve Rf olmak üzere 8 özelliğin ortak olduğu görülmektedir (Şekil 7.33). Komşuluk yarıçapı dikkate alındığında omnivaryans ($r=1m$), 2.özdeğer ($r=1m$), 3.özdeğer ($r=1m$), öz entropi ($r=1m$), komşu sayısı ($r=0.30m$ ve $r=0.50m$), yüzey değişimi ($r=1m$) ve dikeylik ($r=0.10m$, $r=0.30m$ ve $r=0.50m$) özelliklerinin 3 sınıflandırıcı içinde aynı olduğu belirlenmiştir.

Şekil 7.34'te S5 senaryosuna ilişkin sınıflandırıcıların eğitim için kullandığı en iyi özellikler verilmiştir. Şekil incelendiğinde komşuluk yarıçapı dikkate alınmadığında 9 geometrik özellik ile Z ve Rf olmak üzere 11 özelliğin ortak olduğu, komşuluk yarıçapları dikkate alındığında omnivaryans ($r=1m$),

komşu sayısı ($r=0.30m$ ve $r=0.50m$), hacim yoğunluğu ($r=1m$), öz entropi ($1m$), düzlemsellik ($1m$), küresellik ($r=1m$) ve dikeylik ($r=0.02m$, $r=0.10m$, $r=0.30m$, $r=0.50m$ ve $r=1m$), yüzey değişimi ($r=1m$), özdeğerler toplamı ($r=1m$) özelliklerinin 3 sınıflandırıcı için aynı olduğu görülmüştür.



XGBoost-S1		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer		✓	✓		
	Komşu Sayısı		✓	✓	✓	
	1. Derece Moment		✓			
	Hacim Yoğunluğu					✓
	Ortalama Eğrilik			✓		
	Normal Değişim Oranı		✓	✓	✓	
	Omnivaryans					✓
	Doğrusallık		✓			
	PCA1				✓	
	PCA2					✓
	Düzlemsellik		✓	✓	✓	✓
	Küresellik				✓	
	Yüzey Değişimi		✓			✓
	Dikeylik	✓	✓	✓	✓	
	Z	✓				
	Gf					
	Rf					
	Bf					
LightGBM-S1		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	1.Özdeğer				✓	
	Komşu Sayısı		✓	✓	✓	
	PCA1					✓
	PCA2					✓
	Özdeğerler Toplamı					✓
	Öz Entropi					✓
	Gauss Eğriliği					✓
	Ortalama Eğrilik					✓
	Normal Değişim Oranı		✓	✓	✓	
	Omnivaryans					✓
	1. Derece Moment				✓	✓
	Düzlemsellik					✓
	Küresellik					✓
	Yüzey Değişimi					✓
	Dikeylik		✓	✓	✓	✓
	Hacim Yoğunluğu					✓
	Pürüzlülük				✓	✓
	Z	✓				
	Gf					
	Rf					
	Bf					
RF-S1		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer				✓	
	3.Özdeğer				✓	
	Anizotropi				✓	✓
	Komşu Sayısı					✓
	Özdeğerler Toplamı					✓
	Normal Değişim Oranı			✓	✓	✓
	Omnivaryans					✓
	Öz Entropi					✓
	PCA2			✓	✓	✓
	Düzlemsellik			✓	✓	✓
	Küresellik				✓	✓
	Yüzey Değişimi					✓
	Yüzey Yoğunluğu					✓
	Dikeylik		✓	✓	✓	✓
	Pürüzlülük					✓
	Hacim Yoğunluğu					✓
	Z	✓				
	Rf					
	Gf					

Şekil 7.30 S1 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

XGBoost-S2		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer		✓	✓		
	3.Özdeğer			✓		
	1. Derece Moment			✓		
	Öz Entropi					✓
	Komşu Sayısı			✓	✓	
	Ortalama Eğrilik			✓		
	Normal Değişim Oranı		✓	✓	✓	
	Omnivaryans		✓	✓		✓
	PCA1				✓	
	PCA2					✓
	Düzlemsellik		✓	✓	✓	✓
	Küresellik					
	Yüzey Değişimi		✓			✓
	Dikeylik	✓	✓	✓	✓	
	Z	✓				
	Rf					
	Gf					
	Bf					
LightGBM-S2		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	1.Özdeğer					✓
	2.Özdeğer					✓
	3.Özdeğer					✓
	Gauss Eğriliği					✓
	Ortalama Eğrilik					✓
	Normal Değişim Oranı			✓	✓	
	Komşu Sayısı		✓	✓	✓	
	1. Derece Moment				✓	✓
	Düzlemsellik				✓	✓
	Dikeylik		✓	✓	✓	✓
	Yüzey Değişimi					✓
	Omnivaryans					✓
	PCA1					✓
	Özdeğerler Toplamı					✓
	Öz Entropi					✓
	Hacim Yoğunluğu					✓
	Pürüzlülük				✓	✓
	Z	✓				
	Rf					
	Gf					
	Bf					
RF-S2		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer				✓	✓
	3.Özdeğer					✓
	Özdeğerler Toplamı					✓
	Komşu Sayısı			✓		✓
	Normal Değişim Oranı			✓	✓	✓
	Doğrusallık				✓	
	Yüzey Yoğunluğu			✓		✓
	Hacim Yoğunluğu					✓
	PCA2			✓	✓	✓
	Düzlemsellik			✓	✓	✓
	Küresellik					✓
	Yüzey Değişimi			✓	✓	✓
	Dikeylik		✓	✓	✓	✓
	Z	✓				
	Rf					
	Gf					

Şekil 7.31 S2 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

XGBoost-S3		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer		✓	✓		
	Anizotropi				✓	
	Komşu Sayısı		✓	✓		
	Özdeğerler Toplamı					✓
	Doğrusallık		✓	✓		
	Normal Değişim Oranı		✓	✓	✓	
	Omnivaryans				✓	
	1.Derece Moment		✓	✓		
	PCA2			✓		✓
	Düzlemsellik		✓	✓	✓	✓
	Hacim Yoğunluğu					✓
	Yüzey Değişimi					✓
	Dikeylik	✓	✓	✓	✓	
	Z	✓				
	Rf					
	Gf					
	Bf					
LightGBM-S3		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	Özdeğerler Toplamı					✓
	Öz Entropi					✓
	Komşu Sayısı			✓	✓	✓
	Doğrusallık				✓	✓
	PCA2				✓	✓
	Gauss Eğriliği				✓	✓
	Ortalama Eğrilik				✓	✓
	Normal Değişim Oranı				✓	
	Omnivaryans					✓
	1. Derece Moment				✓	✓
	Düzlemsellik				✓	✓
	PCA1					✓
	Yüzey Değişimi					✓
	Dikeylik		✓	✓	✓	✓
	Hacim Yoğunluğu					✓
	Pürüzlülük					✓
	Z	✓				
	Rf					
	Bf					
RF-S3		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer			✓	✓	
	Anizotropi			✓	✓	✓
	Özdeğerler Toplamı					✓
	1.Derece Moment					✓
	Normal Değişim Oranı			✓		✓
	Komşu Sayısı					✓
	Doğrusallık				✓	✓
	PCA2				✓	✓
	Düzlemsellik			✓	✓	✓
	Küresellik					✓
	Yüzey Değişimi			✓	✓	✓
	Dikeylik	✓	✓	✓	✓	✓
	Hacim Yoğunluğu					✓
	Yüzey Yoğunluğu					✓
	Öz Entropi					✓
	Z	✓				

Şekil 7.32 S3 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

XGBoost-S4		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer		✓	✓	✓	✓
	Anizotropi		✓			
	3.Özdeğer			✓		✓
	Öz Entropi					✓
	Komşu Sayısı			✓	✓	
	Normal Değişim Oranı		✓	✓		
	Omnivaryans			✓		✓
	1.Derece Moment		✓		✓	
	PCA2					✓
	Düzlemsellik		✓	✓		
	Küresellik		✓			
	Özdeğerler Toplamı					✓
	Yüzey Değişimi					✓
	Dikeylik	✓	✓	✓	✓	
	Z	✓				
	Rf					
	Gf					
	Bf					
LightGBM-S4		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	1.Özdeğer				✓	✓
	2.Özdeğer					✓
	3.Özdeğer					✓
	Ortalama Eğrilik				✓	✓
	Gauss Eğriligi				✓	✓
	Omnivaryans					✓
	1. Derece Moment				✓	✓
	Özdeğerler Toplamı					✓
	Doğrusallık			✓		
	Öz Entropi					✓
	Komşu Sayısı			✓	✓	
	Düzlemsellik			✓		✓
	PCA1					✓
	Yüzey Değişimi					✓
	Dikeylik	✓	✓	✓	✓	✓
	Hacim Yoğunluğu					✓
	Pürüzlülük					✓
	Z	✓				
	Rf					
	Bf					
RF-S4		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer				✓	✓
	3.Özdeğer					✓
	Anizotropi		✓			✓
	Öz Entropi					✓
	Normal Değişim Oranı			✓		✓
	Omnivaryans					✓
	Yüzey Yoğunluğu			✓		✓
	Komşu Sayısı			✓	✓	✓
	Düzlemsellik				✓	✓
	Küresellik			✓		✓
	Hacim Yoğunluğu			✓	✓	✓
	Yüzey Değişimi			✓		✓
	Dikeylik		✓	✓	✓	✓
	Z	✓				
	Rf					
	Gf					


Şekil 7.33 S4 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

XGBoost-S5		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	2.Özdeğer		✓	✓	✓	
	3.Özdeğer			✓	✓	
	1.Özdeğer				✓	
	Ortalama Eğrilik				✓	
	Normal Değişim Oranı			✓	✓	
	Omnivaryans			✓	✓	✓
	Komşu Sayısı			✓	✓	
	Hacim Yoğunluğu					✓
	Öz Entropi					✓
	Özdeğerler Toplamı					✓
	Doğrusallık					✓
	Düzlemsellik		✓			✓
	Küresellik					✓
	Yüzey Değişimi					✓
	Dikeylik	✓	✓	✓	✓	✓
Z	✓					
Rf						
Bf						
LightGBM-S5		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	Doğrusallık					✓
	Özdeğerler Toplamı					✓
	Gauss Eğriliği			✓	✓	✓
	Ortalama Eğrilik				✓	✓
	Komşu Sayısı			✓	✓	
	Omnivaryans					✓
	1. Derece Moment			✓	✓	✓
	PCA1				✓	✓
	PCA2					✓
	Küresellik					✓
	Düzlemsellik					✓
	Öz Entropi					✓
	Yüzey Değişimi					✓
	Dikeylik	✓	✓	✓	✓	✓
	Hacim Yoğunluğu					✓
Pürüzlülük			✓		✓	
Z	✓					
Rf						
RF-S5		Komşuluk Yarıçapı				
		r=0.02m	r=0.10m	r=0.30m	r=0.50m	r=1m
Özellik	Öz Entropi					✓
	Anizotropi			✓		✓
	Komşu Sayısı			✓	✓	✓
	Özdeğerler Toplamı					✓
	Normal Değişim Oranı			✓		✓
	Omnivaryans					✓
	PCA1					✓
	PCA2					✓
	Düzlemsellik					✓
	Küresellik					✓
	Yüzey Yoğunluğu			✓	✓	✓
	Hacim Yoğunluğu			✓	✓	✓
	Yüzey Değişimi		✓	✓		✓
	Dikeylik	✓	✓	✓	✓	✓
	Z	✓				
Rf						

Şekil 7.34 S5 senaryosunda 3 farklı sınıflandırıcının kullanmış olduğu en iyi 30 özellik

7.3 YTÜ Hidrolik Laboratuvarı Verilerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması

Beş farklı senaryo ve KPConv derin öğrenme sınıflandırıcısı ile gerçekleştirilen sınıflandırma sonuçları, doğruluk, kesinlik, duyarlılık ve F1-skor değerlerine göre incelenmiştir. KPConv ile yapılan sınıflandırmada, S1 senaryosunda 0.972, S2 senaryosunda 0.989, S3 senaryosunda 0.993, S4 senaryosunda 0.989 ve S5 senaryosunda 0.990 model doğruluğu elde edilmiştir. Şekil 7.35’de her bir senaryoda KPConv ile elde edilen model doğrulukları verilmiştir. Sonuçlar incelendiğinde eğitilen veri seti azalmasına rağmen model doğruluklarında artışın olduğu gözlemlenmiştir.




Şekil 7.35 Her bir senaryonun KPConv ile elde edilmiş model doğrulukları


Her senaryoya göre F1-Skor değerleri incelendiğinde S1 senaryosunda 0.972, S2 senaryosunda 0.976, S3 senaryosunda 0.984, S4 senaryosunda 0.976 ve S5 senaryosunda 0.978 olarak elde edildiği görülmektedir (Şekil 7.36).

Her bir senaryoya ait sınıf bazlı sonuçları F1-Skor, kesinlik ve duyarlılık sonuçları görselleştirilerek Şekil 7.37, Şekil 7.39, Şekil 7.41, Şekil 7.43 ve Şekil 7.45’de sunulmuştur.

S1 senaryosuna ilişkin sonuçlar altyapı ve bileşenleri özelinde incelendiğinde en yüksek F1-Skor(0.978) ile büyük boru sınıfında, en düşük F1-Skor değerinin(0.668) ise küçük boru sınıfında elde edildiği görülmüştür. Dirsek sınıfında ise 0.959 F1-skor değerine ulaşılmıştır. Diğer sınıflara ait sonuçlara bakıldığında kapı sınıfı en yüksek F1-Skor değerine ulaşırken, demir sınıfı en düşük F1-Skor değeri elde etmiştir. Düşük F1-Skor değeri elde eden küçük boru sınıfında kesinlik ve duyarlılık değerlerinin de düşük olduğu görülmektedir. Model bu sınıfa ait noktaların doğru




Şekil 7.36 Her bir senaryonun KPConv ile elde edilmiş F1-Skor değerleri



Şekil 7.37 S1 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

tespitinde diğer sınıflara göre düşük performans göstermiştir.

Şekil 7.38’da S1 senaryosuna ait sınıflandırma görseli verilmiştir. Şekil 7.38a’da hatalı sınıflandırma yapılmış noktalar kırmızı çember içine alınarak gösterilmiştir. Şekil incelendiğinde kaplama sınıfının duvar olarak tahmin edildiği, demir sınıfının ise boruya temas eden yerlerde boru olarak tahmin edildiği görülmektedir.




Şekil 7.38 a) KPCConv ile sınıflandırma; b) Etiketli test verisi


S2 senaryosu altyapı ve bileşenleri açısından ele alındığında en yüksek F1-Skor değeri (0.990) ile küçük boru sınıfında elde edilirken, en düşük değer(0.905) ile dirsek sınıfında elde edilmiştir. Diğer sınıflara ilişkin sonuçlar incelendiğinde en yüksek değer in güç kaynağı sınıfında, en düşük değer in demir sınıfında elde edildiği görülmüştür.

Şekil 7.40’da S2 senaryosuna ait sınıflandırma görseli verilmiştir. Şekil 7.40a’da hatalı sınıflandırma yapılmış noktalar kırmızı çember içine alınarak gösterilmiştir. Şekil incelendiğinde demir sınıfının boruya temas eden yerlerde boru olarak tahmin edildiği ve boru sınıfının dirsek olarak tahmin edildiği görülmüştür.


S3 senaryosu özelinde sonuçlar altyapı ve bileşenleri açısından ele alındığında, en yüksek F1-Skor değerinin(0.990) ile büyük boru sınıfında, en düşük değer in (0.976) ile dirsek sınıfında elde edildiği görülmüştür. Diğer sınıflara ait sonuçlar incelendiğinde kapı ve güç kaynağı sınıfının en yüksek F1-Skor değeri, demir sınıfının en düşük F1-Skor değeri elde ettiği belirlenmiştir.



Şekil 7.39 S2 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları




Şekil 7.40 a) KPConv ile sınıflandırma; b) Etiketli test verisi




Şekil 7.41 S3 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.42’da S3 senaryosuna ait sınıflandırma görseli verilmiştir. Şekil 7.42a’da hatalı sınıflandırma yapılmış noktalar kırmızı çember içine alınarak gösterilmiştir. Şekil incelendiğinde demir sınıfının boruya temas eden yerlerde boru olarak tahmin edildiği ve dirsek sınıfının boru olarak tahmin edildiği görülmüştür.




Şekil 7.42 a) KPConv ile sınıflandırma; b) Etiketli test verisi




Şekil 7.43 S4 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.43’de verilen sonuçlar altapı ve bileşenleri açısından incelendiğinde küçük boru sınıfının en yüksek F1-Skor değeri(0.990), dirsek sınıfının en düşük F1-Skor değeri (0.976) elde ettiği tespit edilmiştir. Diğer sınıflara ait sonuçlar incelendiğinde güç kaynağı sınıfının en yüksek F1-Skor değerine ulaştığı, demir sınıfının ise en düşük F1-Skor değeri elde ettiği görülmüştür.



Şekil 7.44 a) KPCConv ile sınıflandırma; b) Etiketli test verisi


Şekil 7.44’da S4 senaryosuna ait sınıflandırma görseli verilmiştir. Şekil 7.44a’da hatalı sınıflandırma yapılmış noktalar kırmızı çember içine alınarak gösterilmiştir. Şekil incelendiğinde demir sınıfının boruya temas eden yerlerde boru olarak tahmin edildiği, dirsek sınıfının ise boru olarak tahmin edildiği görülmüştür.



Şekil 7.45 S5 senaryonuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

Şekil 7.45’de verilen sonuçlar altapı ve bileşenleri açısından incelendiğinde küçük boru sınıfının en yüksek F1-Skor değeri(0.989), dirsek sınıfının en düşük F1-Skor

değeri (0.974) elde ettiği belirlenmiştir. Diğer sınıflara ait sonuçlar incelendiğinde kapı sınıfının en yüksek F1-Skor değerine ulaştığı, demir sınıfının ise en düşük F1-Skor değeri elde ettiği görülmüştür.




Şekil 7.46 a) KPConv ile sınıflandırma; b) Etiketli test verisi

Şekil 7.46’da S5 senaryosuna ait sınıflandırma görseli verilmiştir. Şekil 7.46a’da hatalı sınıflandırma yapılmış noktalar kırmızı çember içine alınarak gösterilmiştir. Şekil incelendiğinde demir sınıfının boru, güç kaynağı ve kaplama olarak tahmin edildiği ve dirsek sınıfının boru olarak tahmin edildiği görülmüştür.

7.4 Britanya Kolumbiyası İçmesuyu Hattı Verilerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması


5 farklı senaryoya ilişkin sınıflandırma işlemi, doğruluk, F1-skor, kesinlik ve duyarlılık sonuçlarına göre incelenmiştir. S1 senaryosunda 0.957, S2 senaryosunda 0.967, S3 senaryosunda 0.905, S4 senaryosunda 0.976 ve S5 senaryosunda 0.968 model doğruluğu elde edilmiştir. Buna ilişkin görsel Şekil 7.47’de sunulmuştur.

KPConv ile elde edilmiş 5 farklı senaryoya ilişkin F1-Skor değerleri Şekil 7.48’da verilmiştir. Görsel incelendiğinde en yüksek F1-Skor değerinin S1 senaryosunda,




Şekil 7.47 Her bir senaryo için KPCONV ile elde edilen model doğrulukları

en düşük F1-Skor değerinin ise S3 senaryosunda elde edildiği görülmektedir.




Şekil 7.48 Her bir senaryo için KPCONV ile elde edilen model doğrulukları

Sınıf bazlı kıyaslama yapılabilmesi ve sonuçların yorumlanabilmesi açısından her bir senaryoya ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık sonuçları görselleştirilmiştir. Şekil 7.49'de S1 senaryosuna ilişkin sonuçlar verilmiştir. S1 senaryo sonuçları altyapı ve bileşenleri açısından incelendiğinde su borusunu sınıfının 0.981 ile en yüksek F1-skor değerine ulaştığı belirlenmiştir. En düşük F1-Skor değeri(0.929) ise te sınıfında elde edilmiştir. Dirsek sınıfında 0.976 F1-Skor değeri elde edilirken, bağlantı elemanları sınıfında bu değer 0.979 olduğu görülmüştür. Altyapılar dışında kalan diğer sınıf sonuçlarına bakıldığında, 0.976 F1-Skor değeri ile iskele sınıfının en yüksek değeri elde ettiği, çit sınıfının ise en düşük F1-Skor değerine(0.914) ulaştığı tespit edilmiştir.



Şekil 7.49 S1 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları


S1 senaryosuna ait sınıflandırma sonuçları görselleştirildiğinde te sınıfının su borusu sınıfı olarak hatalı sınıflandırıldığı, düşey yüzey sınıfının taşıyıcı kolon sınıfı ile karıştığı ve zemin sınıfının diğer sınıfı ile karışık gösterdiği anlaşılmıştır. Şekil 7.50a’da beyaz çember içinde hatalı sınıflandırma bölgeleri gösterilmiştir.



Şekil 7.50 a) KPCConv ile sınıflandırma; b) Etiketli test verisi


S2 senaryosuna ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık sonuçları Şekil 7.51’de verilmiştir. Altyapı ve bileşenleri açısından sonuçlar incelendiğinde, su borusu sınıfının 0.962 ile en yüksek F1-skor değerini, te sınıfının 0.902 ile en düşük F1-Skor değerini elde ettiği tespit edilmiştir. Dirsek sınıfının 0.949, bağlantı elemanları sınıfının 0.929 F1-Skor değerine ulaştığı görülmüştür. Geriye kalan sınıf sonuçlarına bakıldığında, zemin sınıfı 0.988 ile en yüksek F1-Skor değerine

ulaştığı, en düşük F1-Skor değerinin(0.884) ise diğer sınıfı ile elde edilmiş olduğu belirlenmiştir.




Şekil 7.51 S2 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

S2 senaryosunun sınıflandırma görseli Şekil 7.52’de verilmiştir. Te ve dirsek sınıfının su borusu sınıfı, düşey düzey sınıfının merdiven sınıfı olarak hatalı sınıflandırıldığı görülmektedir. Hatalı sınıflandırma yapılmış yerler Şekil 7.52a’da beyaz çember içine alınmıştır.




Şekil 7.52 a) KPCnv ile sınıflandırma; b) Etiketli test verisi

Şekil 7.53’te S3 senaryosuna ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık değerleri verilmiştir. S2 senaryosuna benzer şekilde en yüksek F1-Skor değeri(0.907) su borusu sınıfında elde edilirken, en düşük F1-Skor değeri(0.771) te sınıfında elde edildiği belirlenmiştir. Dirsek sınıfının 0.853, bağlantı elemanları sınıfı 0.892 F1-Skor değeri elde ettiği görülmüştür. Altyapılar dışında kalan sınıflarda en yüksek F1-Skor değeri zemin sınıfında elde edilirken, en düşük F1-Skor değeri merdiven sınıfında elde edilmiştir



Şekil 7.53 S3 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

S3 senaryosuna ilişkin KPConv ile elde edilen sınıflandırma görseli Şekil 7.54'te verilmiştir. Görsel incelendiğinde, iskele sınıfının taşıyıcı kolon olarak hatalı sınıflandırıldığı, te ve su borusu sınıfı ile karışıklık gösterdiği, ve diğer sınıfının zemin sınıfı olarak tahmin edildiği yerlerin olduğu belirlenmiştir. Şekil 7.54a'da hatalı sınıflandırma yapılan yerler beyaz çember ile gösterilmiştir.



Şekil 7.54 a) KPConv ile sınıflandırma; b) Etiketli test verisi


S4 senaryo sonuçları altyapı ve bileşenleri açısından incelendiğinde su borusu sınıfının 0.975 ile en yüksek, te sınıfının 0.941 ile en düşük F1-Skor değeri elde ettiği belirlenmiştir (Şekil 7.55). Bağlantı elemanları sınıfı 0.964, dirsek sınıfı ise 0.958 F1-skor değeri elde etmiştir. Geri kalan sınıf sonuçlarına bakıldığında zemin

sınıfı S3 senaryosuna benzer şekilde en yüksek F1-Skor değeri elde ederken, en düşük F1-Skor değerin çit sınıfında elde ettiği görülmüştür.



Şekil 7.55 S4 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları


S4 senaryosunda diğer 3 senaryoya benzer şekilde su borusu, dirsek ve te sınıflarında hatalı sınıflandırmaların olduğu, düşey yüzey ile zemin sınıfının karışıklık gösterdiği, iskele sınıfının çit sınıfı olarak hatalı sınıflandırıldığı görülmüştür. Şekil 7.56a’da hatalı sınıflandırma yapılmış alanlar beyaz çember içerisinde gösterilmektedir.



Şekil 7.56 a) KPCConv ile sınıflandırma; b) Etiketli test verisi


S5 senaryosuna ilişkin sınıf bazlı F1-Skor, kesinlik ve duyarlılık sonuçları altyapı ve bileşenleri açısından incelendiğinde diğer 4 senaryoya benzer şekilde su borusu sınıfı en yüksek F1-Skor değerini (0.963) elde ettiği tespit edilmiştir. En düşük F1-Skor(0.905) te sınıfında elde edilirken, dirsek sınıfı 0.934, bağlantı elemanları sınıfı 0.962 F1-Skor değerine ulaşmıştır. Altyapı dışındaki sınıflara ilişkin sonuçlar

incelendiğinde zemin sınıfının en yüksek F1-Skor değerine ulaştığı, en düşük F1-skor değerin diğer sınıfta elde edildiği görülmüştür (Şekil 7.57)



Şekil 7.57 S5 senaryosuna göre her bir sınıfın F1-Skor, kesinlik ve duyarlılık sonuçları

S5 senaryosuna ilişkin sınıflandırma görseli Şekil 7.58'da sunulmuştur. Şekil 7.58a incelendiğinde demir sınıfının kaplama ve güç kaynağı olarak hatalı sınıflandırıldığı, dirsek sınıfının boru sınıfı olarak tahmin edildiği görülmüştür, ilgili kısımlar şekil üzerinde beyaz çember içerisinde belirtilmiştir.



Şekil 7.58 a) KPCConv ile sınıflandırma; b) Etiketli test verisi

8 BULGULAR VE TARTIŞMA

Bu bölümde makine öğrenmesi sınıflandırıcıları ve derin öğrenme algoritması ile elde edilen sınıflandırma sonuçları yorumlanacaktır. Sınıflandırıcı bazlı karşılaştıma yapılacak ve ortak özelliklerin incelenmesi gerçekleştirilecektir. Daha sonra makine öğrenimi ve derin öğrenme sınıflandırma sonuçlarının karşılaştırılması gerçekleştirilecektir.

8.1 Makine Öğrenmesi Sınıflandırıcıları ile Elde Edilen Sınıflandırma Sonuçlarının Yorumlanması

Hatalı sınıflandırılan noktalara ilişkin karşılaştırma yorum yapılabilmesi için en iyi ve en kötü model doğruluğu elde eden senaryolara ait sonuçlar doğru ve yanlış sınıflandırılmış nokta şeklinde iki sınıfa indirgenmiş ve sınıflandırma görselleri oluşturulmuştur (Şekil 8.1). Şekil 8.1a'da YTU Hidrolik Laboratuvarı için en iyi sonuç elde eden S1 senaryosu ve Şekil 8.1b'de YTU Hidrolik Laboratuvarı için en kötü sonuç elde eden S5 senaryosu verilmiştir.


Şekil 8.1a' incelendiğinde hatalı sınıflandırmaların olduğu bölgelerin, sınıfların kesişim noktalarında olduğu ya da birbirine yakın objelerin olduğu görülmektedir. Bu durumun geometrik özelliklerin kesişim noktalarında doğru tahmin yapamadığı ya da sınıfı temsil eden nokta sayısının yetersiz olmasından kaynaklandığı söylenebilir. Ayrıca özellikle küçük bölgelerde çok fazla sınıf değişimi varsa, geometrik benzerlik ve sınıfsal noktalar arası yakınlık sebebiyle ya da objeyi temsil eden nokta sayısının azlığı sebebiyle MÖ sınıflandırıcıları sınıf ayırt etmede yetersiz kalabilmekte ve yanlış sınıflandırmaya sebep olabilmektedir. Bu nedenle farklı açılardan çoklu oturum yapılarak objeyi temsil eden nokta sayısının artırılması bir çözüm olabilir. Bu duruma örnek olarak Şekil 8.1b'de sağ üst köşede bulunan pencere çerçevesinin hata sınıflandırılması ve küçük boru sınıfı yakınındaki demir sınıfı ile karışması verilebilir. Yine Şekil 8.1a'da alt köşede kaplama sınıfının bir bölümünün hatalı sınıflandırılması bu duruma örnek olarak verilebilir. Yine

a)



Doğru Sınıflandırılmış Nokta
Yanlış Sınıflandırılmış Nokta

b)




Şekil 8.1 a) S1 senaryosunda en iyi sonuç veren sınıflandırıcı (XGBoost) ile doğru ve yanlış tahmin edilen noktalar; b) S5 senaryosunda en iyi sonuç veren sınıflandırıcı (XGBoost) ile doğru ve yanlış tahmin edilen noktalar


şekil incelendiğinde düzlemsel objelere ait doğru tahminlerinin fazla olduğu görülmektedir. Bu durum, doğrusallığı ve düzlemselliği stabile yakın olan bu sınıfların (duvar ve kaplama gibi) veri setinde yoğun olması nedeniyle bu sınıflara ait özelliklerin daha iyi öğrenildiği yorumu ile açıklanabilir.

Şekil 8.2’de Britanya Kolumbiyası İçmesuyu Hattı için en iyi ve en kötü model doğruluğu elde eden senaryolar doğru ve yanlış sınıfa atanan noktalar kullanılarak oluşturulmuştur. Şekil 8.2a’da en iyi model doğruluğuna sahip S1 senaryosuna ait sonuçlar, ekil8.2b’de en kötü model doğruluğuna sahip S5 senaryosu gösterilmektedir. Şekil 8.2a incelendiğinde, YTÜ sonuçlarına benzer şekilde boru-dirsek, boru-te kesişimlerinde hatalı sınıflandırmaların olduğu görülmektedir. Sınıflandırıcılar bu bölgelerdeki noktaları ayırt etmede, geometrik özelliklerin benzerliği ve nokta yakınlığı nedeniyle yetersiz kalmaktadır. Şekil 8.2b’de buna ek olarak zemin sınıfının, boruyla temas ettiği yerlerde boru olarak tahmin edildiği, sağ üst bölgede ise iskele sınıfı ile karışıklık gösterdiği karışıklık matrisi incelendiğinde görülmektedir (Şekil A.11).


Şekil 8.3 ve Şekil 8.4’te verilen özellikler incelendiğinde RF ve LightGBM için baskın özellik 5 senaryo için "Z" özelliğidir. XGBoost için bu durum senaryo bazlı değişiklik göstermiştir. S1-S3 senaryoları arasında Bf (mavi renk faktörü) baskın iken, S4’te omnivaryans ($r=1m$), S5’te ise küresellik ($r=1m$)



Şekil 8.2 a) S1 senaryosunda en iyi sonuç veren sınıflandırıcı (XGBoost) ile doğru ve yanlış tahmin edilen noktalar; b) S5 senaryosunda en iyi sonuç veren sınıflandırıcı (RF) ile doğru ve yanlış tahmin edilen noktalar



Şekil 8.3 YTÜ Hidrolik Laboratuvarı için oluşturulan S1, S2 ve S3 senaryolarının eğitiminde sınıflandırıcıların kullandığı ortak özelliklerin önem sıralaması



Şekil 8.4 YTÜ Hidrolik Laboratuvarı için oluşturulan S4 ve S5 senaryolarının eğitiminde sınıflandırıcıların kullandığı ortak özelliklerin önem sıralaması


özellikleri baskındır. 5 senaryonun sınıflandırılmasında kullanılan ortak özellikler incelendiğinde Z, Bf, ortalama eğrilik ($r=0.10m$), düzlemsellik ($r=1m$) ve dikeylik ($r=0.30m$) özelliklerinin ortak olduğu ve algoritmadan bağımsız olarak bu veri seti için bu özelliklerin eğitim için kullanılması gerektiği söylenebilir. Z ile düzlemselliğin birlikte kullanımı, duvar ve kaplama gibi sınıfların tahmininde etkili olurken, ortalama eğrilik ve Z'nin kullanımı altyapı elemanlarının tahmininde etkili olmaktadır.

Şekil 8.5 ve Şekil 8.6 'te verilen sonuçlara göre, RF ve LightGBM için baskın özellik 5 senaryo için "Z" özelliğidir. XGBoost için bu durum senaryo bazlı değişiklik göstermiştir. S1 senaryosunda normal değişim oranı ($r=0.3m$), S2'de düzlemsellik ($r=0.5m$), S3'te düzlemsellik ($r=1m$), S4'te yüzey değişimi ($r=1m$) ve S5'te ise Z özelliği baskın özelliktir.


5 senaryonun sınıflandırılmasında kullanılan ortak özellikler incelendiğinde Z, yüzey değişimi ($r=1m$) ve dikeylik ($r=0.10m$, $r=0.30m$ ve $r=0.50m$) özelliklerinin ortak olduğu ve algoritmadan bağımsız olarak bu veri seti için bu özelliklerin veri setinin eğitiminde bulunması gereken özellikler olduğu söylenilebilir.

Her iki çalışma bölgesi için sonuçlar birlikte değerlendirildiğinde Z ve dikeylik ($r=0.30$) özelliklerinin her iki veri setinden oluşturulan 5 senaryoda ortak özellik olduğu tespit edilmiştir.

Makine öğrenmesi çalışmalarında sıkça rastlanılan %90 eğitim - %10 test ve %70 eğitim - %30 test yaklaşımları açısından sonuçlar incelendiğinde, sınıflandırıcıların her iki bölge için S1 ve S2 senaryolarına ilişkin kullandıkları ortak özellikler; Z, Rf, dikeylik ($r=0.10m$ ve $r=0.30m$) ve düzlemsellik ($r=1m$) olarak tespit edilmiştir.




Şekil 8.5 Britanya Kolumbiyası İçmesuyu Hattı için oluşturulan S1, S2 ve S3 senaryolarının eğitiminde sınıflandırıcıların kullandığı ortak özelliklerin önem sıralaması



Şekil 8.6 Britanya Kolumbiyası İçmesuyu Hattı için oluşturulan S4 ve S5 senaryolarının eğitiminde sınıflandırıcıların kullandığı ortak özelliklerin önem sıralaması

8.2 Derin Öğrenme Yöntemi (KPConv) ile Elde Edilen Sınıflandırma Sonuçlarının Yorumlanması


KPConv ile hatalı sınıflandırılan noktalara ilişkin karşılaştırma yorum yapılabilmesi için en iyi ve en kötü model doğruluğu elde eden senaryolara ait sonuçlar, doğru ve yanlış sınıflandırılmış nokta şeklinde iki sınıfa indirgenmiş ve sınıflandırma görselleri oluşturulmuştur (Şekil 8.7). Şekil 8.7 incelendiğinde hatalı sınıf



Şekil 8.7 a) S3 senaryosunda KPConv ile doğru ve yanlış tahmin edilen noktalar;
b) S1 senaryosunda KPConv ile doğru ve yanlış tahmin edilen noktalar

tahminlerinin makine öğrenmesi sonuçlarında olduğu gibi sınıflar arası kesişim noktalarında olduğu görülmektedir. Şekil 8.7a'da kaplama sınıfı olması gereken sınıfın hatalı tahmin edildiği görülmektedir. Bu durum, DÖ yöntemleri ile yapılan sınıflandırmada geometrik özelliklerin renk bilgisi göre daha baskın olduğunu göstermektedir. Bu sonuç Bayrak vd. [136]'ın yapmış olduğu çalışma ile de desteklenmektedir.

Şekil 8.8 incelendiğinde hatalı sınıflandırmaların genellikle iki sınıfın kesişim bölgesinde gerçekleştiği görülmektedir. S4 senaryosunda bu karışıklık daha az




Şekil 8.8 a) S4 senaryosunda KPConv ile doğru ve yanlış tahmin edilen noktalar;
b) S3 senaryosunda KPConv ile doğru ve yanlış tahmin edilen noktalar

iken S3 senaryosunda daha fazladır. Bu durum eğitim veri setinde sınıfları temsil eden noktaların, 2 sınıf arasındaki farkı ayırt edemeyecek geometrik yakınlığa sahip olduğu ile açıklanabilir. Buna örnek olarak, zemin ile su borusunun kesişim noktası verilebilir. Su borusunun yüzeyini kaplayan toprak yapı, model tarafından su borusu olarak yanlış sınıflandırılmıştır. Yine zeminle aynı doğrultuda olan diğer katmanında yer alan tahtalarda, yer yer zemin olarak tahmin edilmiştir.


8.3 Derin Öğrenme ve Makine Öğrenmesi Sonuçlarının Karşılaştırılması

YTÜ Hidrolik Laboratuvarı senaryolarına ilişkin makine öğrenmesi ve derin öğrenme yöntemleri ile elde edilen model doğruluklarının karşılaştırılması Tablo8.9'de verilmiştir. Tablo incelendiğinde KPConv bütün senaryolarda makine öğrenmesi sınıflandırıcısına göre daha üstün performans göstermiştir.



Şekil 8.9 YTÜ veri seti için derin öğrenme ve makine öğrenmesi yöntemlerinin sınıflandırma model doğruluklarının karşılaştırılması

Tablo8.10'de Britanya Kolumbiyası İçmesuyu Hattına ilişkin sınıflandırma doğruluklarının kıyaslanması gösterilmektedir. YTÜ senaryo sonuçlarına benzer şekilde derin öğrenme yönteminin her senaryo için sınıflandırma performansının oldukça üstün olduğu görülmektedir. Özellikle düşük eğitim verisinin olduğu S5 senaryosunda derin öğrenmenin yüksek doğruluk elde etmesi, seçilen eğitim alanının, bütün veriyi kapsayacak nitelikte olması ve veri içerisindeki sınıfsal varyasyonların az olması nedeniyle açıklanabilir. Ayrıca makine öğrenmesinin geometrik özelliklere göre sınıflandırma yapması, derin öğrenmenin ise geometrik



Şekil 8.10 Britanya Kolumbiyası veri seti için derin öğrenme ve makine öğrenmesi yöntemlerinin sınıflandırma model doğruluklarının karşılaştırılması

özelliklere ek olarak semantik ilişkiyi de irdelemesi model doğruluğunu artıran bir diğer unsur olarak belirtilebilir. Yani boru sınıfı dirsek ile etkileşim halinde bulunabilir ancak bir çit sınıfı ile doğrudan bir bağlantı içinde bulunmaz. Bu sebeple makine öğrenmesinde güç kaynağı sınıfı ile duvar ya da kapı sınıfı karışıklık gösterirken, derin öğrenme ile sınıflandırmada bu duruma rastlanma olasılığı bu sınıflar bitişik olmadığı sürece oldukça düşüktür.

9 SONUÇ

Bu çalışmada, yersel lazer tarayıcı ile elde edilen bir yapı üzerindeki altyapı unsurları ve bir İHA ile elde edilen su boru hattının nokta bulutlarının sınıflandırılmasında üç farklı makine öğrenmesi ve bir derin öğrenme algoritmasının performansı incelenmiştir. Karmaşık yapılardaki altyapı nesnelerinin sınıflandırılması araştırılmış ve derin öğrenme yöntemi, makine öğrenmesi sınıflandırıcılarına göre daha üstün sonuçlar elde etmiştir. Her iki çalışma bölgesinde yer alan altyapı elemanlarından büyük boru ve su borusu sınıfının F1-Skor değerlerinin yüksek olması, arazi kullanımı ve binalar ile ağaçlar gibi unsurların nokta bulutlarından sınıflandırılması gibi birçok çalışmada kullanılan makine öğrenmesi sınıflandırıcılarının, altyapı elemanlarının sınıflandırılmasında da kullanılabilir olduğunu göstermiştir. Çalışma kapsamında kullanılan XGBoost sınıflandırıcısı genelde yüksek sonuçlar elde etse de, eğitim süresi açısından RF ve LightGBM'e kıyasla daha fazla zamana gereksinim duymaktadır. Bu nedenle, istenen sınıflandırma kalitesine dayalı olarak bir sınıflandırıcı seçmek, hesaplama maliyetlerini azaltabilir.

Eğitim setinde yer alan sınıfların homojen dağılım göstermemesi nedeniyle, elde edilen model doğrulukları yanıltıcı olabilir. Çünkü, veri seti içinde nokta sayısı az olan sınıfların model doğruluğuna etkisi az olacaktır. Bu nedenle bu tarz veri setlerinin sınıflandırılmasında doğruluk analizi gerçekleştirilirken F1-Skor değerinin göz önüne alınması daha doğru bir analiz sağlayacaktır.

Çalışmada kullanılan makine öğrenmesi sınıflandırıcıların, önemli ortak geometrik özellikler konusunda benzer çıktılarına sahip olduğu görülmüştür. Prensiplerindeki farklılıklara rağmen, bu yöntemlerin bu özellikleri etkin bir şekilde tespit etmesi, bu parametrelerin doğrudan bu sınıfları tespit edebileceğine dair bir gösterge olabilir. Sınıflandırıcıların %90 eğitim - %10 test ve %70 eğitim - %30 test yaklaşımına göre elde ettikleri ortak özellikler; Z, dikeylik ve düzlemseliktir. Bu durum iki farklı test alanı olmasına rağmen makine öğrenmesinin genelleştirme yeteneğini ön plana çıkarmaktadır. Mevcut çalışmalarda, ortak parametreler henüz

nesne bazında analiz edilmemiştir ve sunulan çalışmanın, gelecekteki araştırmalara her sınıf için geometrik özellikleri belirleme konusunda bir fikir açabileceği düşünülmektedir. Bununla birlikte, bu çalışmanın sonuçları, özellikle iki farklı test çalışması bağlamında, diğer benzer araştırma odakları ve nokta bulutu veri setleri için önemli bir öneme sahiptir. Bu sınıflandırıcıların, sınıflandırma performansları ve özellik analizleri,

- Etiketleme sürecinin zaman alıcı ve dikkat gerektiren bir süreç olması,
- Literatürde altyapı elemanlarının 3B sınıflandırılması için az sayıda veya hiç halka açık veri bulunmaması,
- Tüm sınıfların farklı bölgelerde yaygın olma olasılığının düşük olması nedeniyle, bu iki test alanı ile sınırlı kalmıştır.

Test alanlarında derin öğrenme yöntemi KPConv ile elde edilen sınıflandırma doğruluğu sonuçları, makine öğrenmesi sınıflandırıcıları ile kıyaslandığında daha iyi performans elde ettiğini göstermektedir. Bu durum, derin öğrenmenin eğitim aşamasında hem geometrik hemde semantik ilişkiyi birlikte ele almasıyla açıklanabilir. Ayrıca senaryo sonuçları incelendiğinde eğitim setindeki nokta sayıları azalma gösterdiğinde makine öğrenmesi ile elde edilen sonuçlarda (XGBoost; S1(0.963), S5(0.840) düşüş görülürken, derin öğrenme sonuçlarının (KPConv; S1(0.972), S5(0.990)) bu durumdan etkilenmediği görülmüştür.

Eğitim süresi açısından derin öğrenmenin, makine öğrenmesine kıyasla daha kısa olduğu söylenebilir. Bunun en temel nedeni, derin öğrenmenin GPU (Graphics processing unit)'yu, makine öğrenmesinin CPU (Central Process Unit)'yu kullanmasıdır. Bu açıdan bakıldığında düşük maliyetli çalışmalarda makine öğrenmesi tercih edilebileceği söylenebilir.

- [1] *The wolrd bank*. [Online]. Available: www.worldbank.org/en/topic/infrastructure/overview (visited on 03/30/2024).
- [2] K. Mirzaei, M. Arashpour, E. Asadi, H. Masoumi, Y. Bai, A. Behnood, “3d point cloud data processing with machine learning for construction and infrastructure applications: A comprehensive review,” *Advanced engineering informatics*, vol. 51, p. 101 501, 2022.
- [3] H. Son, F. Bosch , C. Kim, “As-built data acquisition and its use in production monitoring and automated layout of civil infrastructure: A survey,” *Advanced Engineering Informatics*, vol. 29, no. 2, pp. 172–183, 2015.
- [4] Q. Wang, Y. Tan, Z. Mei, “Computational methods of acquisition and processing of 3d point cloud data for construction applications,” *Archives of computational methods in engineering*, vol. 27, no. 2, pp. 479–499, 2020.
- [5] C.-H. Lin, J.-Y. Chen, P.-L. Su, C.-H. Chen, “Eigen-feature analysis of weighted covariance matrices for lidar point cloud classification,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 94, pp. 70–79, 2014.
- [6] M. E. Atik, Z. Duran, D. Z. Seker, “Machine learning-based supervised classification of point clouds using multiscale geometric features,” *ISPRS International Journal of Geo-Information*, vol. 10, no. 3, p. 187, 2021.
- [7] N. Brodu, D. Lague, “3d terrestrial lidar data classification of complex natural scenes using a multi-scale dimensionality criterion: Applications in geomorphology,” *ISPRS journal of photogrammetry and remote sensing*, vol. 68, pp. 121–134, 2012.
- [8] R. Blomley, B. Jutzi, M. Weinmann, “Classification of airborne laser scanning data using geometric multi-scale features and different neighbourhood types,” *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 3, pp. 169–176, 2016.
- [9] M. Weinmann, B. Jutzi, C. Mallet, “Geometric features and their relevance for 3d point cloud classification,” *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 4, pp. 157–164, 2017.
- [10] C. Becker, E. Rosinskaya, N. H ni, E. D’Angelo, C. Strecha, “Classification of aerial photogrammetric 3d point clouds,” *Photogrammetric Engineering & Remote Sensing*, vol. 84, no. 5, pp. 287–295, 2018.
- [11] Z. Duran, K. Ozcan, M. Atik, *Classification of photogrammetric and airborne lidar point clouds using machine learning algorithms. drones 2021*, 5,104.

- [12] E. Sevgen, S. Abdikan, "Classification of large-scale mobile laser scanning data in urban area with lightgbm," *Remote Sensing*, vol. 15, no. 15, p. 3787, 2023.
- [13] X. Shi, Y. Cheng, D. Xue, "Classification algorithm of urban point cloud data based on lightgbm," in *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, vol. 631, 2019, p. 052 041.
- [14] Y. Perez-Perez, M. Golparvar-Fard, K. El-Rayes, "Segmentation of point clouds via joint semantic and geometric features for 3d modeling of the built environment," *Automation in Construction*, vol. 125, p. 103 584, 2021.
- [15] C. P. Huynh, S. Mustapha, P. Runcie, F. Porikli, "Multi-class support vector machines for paint condition assessment on the sydney harbour bridge using hyperspectral imaging," *Struct. Monit. Maint*, vol. 2, no. 3, pp. 181–197, 2015.
- [16] M. Mansour, J. Martens, J. Blankenbach, "Hierarchical svm for semantic segmentation of 3d point clouds for infrastructure scenes," *Infrastructures*, vol. 9, no. 5, p. 83, 2024.
- [17] C. R. Qi, H. Su, K. Mo, L. J. Guibas, "Pointnet: Deep learning on point sets for 3d classification and segmentation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 652–660.
- [18] C. R. Qi, L. Yi, H. Su, L. J. Guibas, "Pointnet++: Deep hierarchical feature learning on point sets in a metric space," *Advances in neural information processing systems*, vol. 30, 2017.
- [19] H. Thomas, C. R. Qi, J.-E. Deschaud, B. Marcotegui, F. Goulette, L. J. Guibas, "Kpconv: Flexible and deformable convolution for point clouds," in *Proceedings of the IEEE/CVF international conference on computer vision*, 2019, pp. 6411–6420.
- [20] Q. Hu *et al.*, "Randla-net: Efficient semantic segmentation of large-scale point clouds," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020, pp. 11 108–11 117.
- [21] Y. Wang, Y. Sun, Z. Liu, S. E. Sarma, M. M. Bronstein, J. M. Solomon, "Dynamic graph cnn for learning on point clouds," *ACM Transactions on Graphics (tog)*, vol. 38, no. 5, pp. 1–12, 2019.
- [22] L. Wang, Y. Huang, Y. Hou, S. Zhang, J. Shan, "Graph attention convolution for point cloud semantic segmentation," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2019, pp. 10 296–10 305.
- [23] F. Poux, R. Billen, "Voxel-based 3d point cloud semantic segmentation: Unsupervised geometric and relationship featuring vs deep learning methods," *ISPRS International Journal of Geo-Information*, vol. 8, no. 5, p. 213, 2019.
- [24] W. Wu, Z. Qi, F. P. Li, "Deep convolutional networks on 3d point clouds. iee," in *CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 9613–9622.

- [25] Y. Perez-Perez, M. Golparvar-Fard, K. El-Rayes, "Scan2bim-net: Deep learning method for segmentation of point clouds for scan-to-bim," *Journal of Construction Engineering and Management*, vol. 147, no. 9, p. 04 021 107, 2021.
- [26] Z. Xu, R. Kang, H. Li, "Feature-based deep learning classification for pipeline component extraction from 3d point clouds," *Buildings*, vol. 12, no. 7, p. 968, 2022.
- [27] M. Weinmann, B. Jutzi, S. Hinz, C. Mallet, "Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 105, pp. 286–304, 2015. doi: <https://doi.org/10.1016/j.isprsjprs.2015.01.016>.
- [28] C. Mallet, F. Bretar, "Full-waveform topographic lidar: State-of-the-art," *ISPRS Journal of photogrammetry and remote sensing*, vol. 64, no. 1, pp. 1–16, 2009.
- [29] A. Habib, M. Ghanma, M. Morgan, R. Al-Ruzouq, "Photogrammetric and lidar data registration using linear features," *Photogrammetric Engineering & Remote Sensing*, vol. 71, no. 6, pp. 699–707, 2005.
- [30] K. Kraus, N. Pfeifer, "Determination of terrain models in wooded areas with airborne laser scanner data," *ISPRS Journal of Photogrammetry and remote Sensing*, vol. 53, no. 4, pp. 193–203, 1998.
- [31] M. E. Hodgson *et al.*, "An evaluation of lidar-derived elevation and terrain slope in leaf-off conditions," *Photogrammetric Engineering & Remote Sensing*, vol. 71, no. 7, pp. 817–823, 2005.
- [32] N. Mehendale, S. Neoge, "Review on lidar technology," *Available at SSRN 3604309*, 2020.
- [33] X. Li, C. Liu, Z. Wang, X. Xie, D. Li, L. Xu, "Airborne lidar: State-of-the-art of system design, technology and application," *Measurement Science and Technology*, vol. 32, no. 3, p. 032 002, 2020.
- [34] M. Verma, M. Yadav, "Registration, georeferencing and processing of multiple laser scans acquired by terrestrial laser scanner for estimating tree morphological parameters," *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 10, pp. 737–742, 2023.
- [35] A. Wallace, C. Nichol, I. Woodhouse, "Recovery of forest canopy parameters by inversion of multispectral lidar data," *Remote Sensing*, vol. 4, no. 2, pp. 509–531, 2012.
- [36] H. Guan, J. Li, S. Cao, Y. Yu, "Use of mobile lidar in road information inventory: A review," *International Journal of Image and Data Fusion*, vol. 7, no. 3, pp. 219–242, 2016.
- [37] H. Guan *et al.*, "Iterative tensor voting for pavement crack extraction using mobile laser scanning data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 3, pp. 1527–1537, 2014.
- [38] M. Dassot, T. Constant, M. Fournier, "The use of terrestrial lidar technology in forest science: Application fields, benefits and challenges," *Annals of forest science*, vol. 68, pp. 959–974, 2011.

- [39] C. Wu, Y. Yuan, Y. Tang, B. Tian, “Application of terrestrial laser scanning (tls) in the architecture, engineering and construction (aec) industry,” *Sensors*, vol. 22, no. 1, p. 265, 2021.
- [40] N. Pfeifer, C. Briese, “Laser scanning—principles and applications,” in *Geosiberia 2007-international exhibition and scientific congress*, European Association of Geoscientists & Engineers, 2007, cp–59.
- [41] X. Liang, J. Hyypä, “Automatic stem mapping by merging several terrestrial laser scans at the feature and decision levels,” *Sensors*, vol. 13, no. 2, pp. 1614–1634, 2013.
- [42] A. Ulvi, “İha fotogrametrisine genel bakış: Geleneksel topoğrafik harita yapımı tekniği ile maliyet karşılaştırması,” *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, vol. 8, no. 1, pp. 458–471, 2021.
- [43] I. Colomina, P. M. de la Tecnologia, “Towards a new paradigm for high-resolution low-cost photogrammetry and remote sensing,” in *Proceedings of the isprs xxi congress, beijing, china*, 2008, pp. 3–11.
- [44] H.-J. Przybilla *et al.*, “Bildflug mit ferngelenktem kleinflugzeug,” 1979.
- [45] S. M. Hasheminasab, T. Zhou, A. Habib, “Gnss/ins-assisted structure from motion strategies for uav-based imagery over mechanized agricultural fields,” *Remote Sensing*, vol. 12, no. 3, p. 351, 2020.
- [46] B. Erol, E. Turan, S. Erol, R. A. Kuçak, “Comparative performance analysis of precise point positioning technique in the uav- based mapping,” *Measurement*, vol. 233, p. 114 768, 2024.
- [47] M. J. Westoby, J. Brasington, N. F. Glasser, M. J. Hambrey, J. M. Reynolds, “‘structure-from-motion’ photogrammetry: A low-cost, effective tool for geoscience applications,” *Geomorphology*, vol. 179, pp. 300–314, 2012.
- [48] D. G. Lowe, “Object recognition from local scale-invariant features,” in *Proceedings of the seventh IEEE international conference on computer vision*, Ieee, vol. 2, 1999, pp. 1150–1157.
- [49] E. Turan, “Comparison of satellite positioning techniques on unmanned aerial vehicle based photogrammetry,” M.S. thesis, Fen Bilimleri Enstitüsü, 2019.
- [50] J. J. Ruiz, L. Diaz-Mas, F. Perez, A. Viguria, “Evaluating the accuracy of dem generation algorithms from uav imagery,” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 40, pp. 333–337, 2013.
- [51] N. Pilkington, *Dronedeploy nerf dataset*, 2022. [Online]. Available: %5Curl%7Bhttps://github.com/nickponline/dd-nerf-dataset%7D.
- [52] J. A. Richards, X. Jia, “Image classification methodologies,” *Remote sensing digital image analysis: An introduction*, pp. 295–332, 2006.
- [53] J. R. Jensen, K. Lulla, “Introductory digital image processing: A remote sensing perspective,” 1987.
- [54] J. A. Richards, J. A. Richards, *et al.*, *Remote sensing digital image analysis*. Springer, 2022, vol. 5.

- [55] T. Lillesand, R. W. Kiefer, J. Chipman, *Remote sensing and image interpretation*. John Wiley & Sons, 2015.
- [56] T. Blaschke, “Object based image analysis for remote sensing,” *ISPRS journal of photogrammetry and remote sensing*, vol. 65, no. 1, pp. 2–16, 2010.
- [57] G. Castilla, G. Hay, “Image objects and geographic objects,” in *Object-based image analysis: Spatial concepts for knowledge-driven remote sensing applications*, Springer, 2008, pp. 91–110.
- [58] M. Pal, “Random forest classifier for remote sensing classification,” *International journal of remote sensing*, vol. 26, no. 1, pp. 217–222, 2005.
- [59] M. Pal, P. M. Mather, “Support vector machines for classification in remote sensing,” *International journal of remote sensing*, vol. 26, no. 5, pp. 1007–1011, 2005.
- [60] Q. Guo, M. Kelly, P. Gong, D. Liu, “An object-based classification approach in mapping tree mortality using high spatial resolution imagery,” *GIScience & Remote Sensing*, vol. 44, no. 1, pp. 24–47, 2007.
- [61] A. Hernando, L. A. Arroyo, J. Velázquez, R. Tejera, “Objects-based image analysis for mapping natura 2000 habitats to improve forest management,” *Photogrammetric Engineering & Remote Sensing*, vol. 78, no. 9, pp. 991–999, 2012.
- [62] R. Mathieu, J. Aryal, A. K. Chong, “Object-based classification of ikonos imagery for mapping large-scale vegetation communities in urban areas,” *Sensors*, vol. 7, no. 11, pp. 2860–2880, 2007.
- [63] S. W. Myint, P. Gober, A. Brazel, S. Grossman-Clarke, Q. Weng, “Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery,” *Remote sensing of environment*, vol. 115, no. 5, pp. 1145–1161, 2011.
- [64] Z. Cetin, “Makine öğrenme algoritmaları kullanılarak lazer verilerinden ağaç türlerinin sınıflandırılması olanaklarının araştırılması,” Ph.D. dissertation, Yıldız Teknik Üniversitesi, 2022.
- [65] S. Narkhede, “Understanding confusion matrix,” *Towards Data Science*, vol. 180, no. 1, pp. 1–12, 2018.
- [66] C. Sammut, G. I. Webb, *Encyclopedia of machine learning*. Springer Science & Business Media, 2011.
- [67] X. Deng, Q. Liu, Y. Deng, S. Mahadevan, “An improved method to construct basic probability assignment based on the confusion matrix for classification problem,” *Information Sciences*, vol. 340, pp. 250–261, 2016.
- [68] J. M. M. Yancho, N. C. Coops, P. Tompalski, T. R. Goodbody, A. Plowright, “Fine-scale spatial and spectral clustering of uav-acquired digital aerial photogrammetric (dap) point clouds for individual tree crown detection and segmentation,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 12, no. 10, pp. 4131–4148, 2019.
- [69] C. Malhotra, V. Kotwal, S. Dalal, “Ethical framework for machine learning,” in *2018 ITU Kaleidoscope: Machine Learning for a 5G Future (ITU K)*, IEEE, 2018, pp. 1–8.

- [70] I. El Naqa, M. J. Murphy, *What is machine learning?* Springer, 2015.
- [71] J. Alzubi, A. Nayyar, A. Kumar, "Machine learning from theory to algorithms: An overview," in *Journal of physics: conference series*, IOP Publishing, vol. 1142, 2018, p. 012012.
- [72] O. Guldali, *Deep feature transfer from deep learning models into machine learning algorithms to classify covid-19 from chest x-ray images*, 2021.
- [73] A. Mishra, *Machine learning in the AWS cloud: Add intelligence to applications with Amazon Sagemaker and Amazon Rekognition*. John Wiley & Sons, 2019.
- [74] E. Alpaydin, *Introduction to machine learning*. MIT press, 2020.
- [75] S. M. Ambulgekar, P. D. Mali, "Technical review on machine learning," *International Journal of Engineering Applied Sciences and Technology*, vol. 5, no. 6, pp. 183–187,
- [76] S. Ray, "2019 international conference on machine learning, big data, cloud and parallel computing (comitcon)," IEEE, 2019, pp. 35–39.
- [77] T. Jiang, J. L. Gradus, A. J. Rosellini, "Supervised machine learning: A brief primer," *Behavior therapy*, vol. 51, no. 5, pp. 675–687, 2020.
- [78] V. Nasteski, "An overview of the supervised machine learning methods," *Horizons. b*, vol. 4, no. 51-62, p. 56, 2017.
- [79] L. Breiman, "Random forests," *Machine learning*, vol. 45, pp. 5–32, 2001.
- [80] R. Genuer, J.-M. Poggi, R. Genuer, J.-M. Poggi, *Random forests*. Springer, 2020.
- [81] C. Bentéjac, A. Csörgo, G. Martínez-Muñoz, "A comparative analysis of xgboost," *ArXiv*, vol. abs/1911.01914, 2019.
- [82] T. Chen, C. Guestrin, "Xgboost: A scalable tree boosting system," in *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785–794.
- [83] J. H. Friedman, "Greedy function approximation: A gradient boosting machine," *Annals of statistics*, pp. 1189–1232, 2001.
- [84] A. A. Ibrahim, K. M. A. Elzaridi, "Xgboost algorithm for orecasting electricity consumption of germany," *AURUM Journal of Engineering Systems and Architecture*, vol. 7, no. 1, pp. 99–108, 2023.
- [85] G. Ke *et al.*, "Lightgbm: A highly efficient gradient boosting decision tree," *Advances in neural information processing systems*, vol. 30, 2017.
- [86] A. N. Saberi, A. Belahcen, J. Sobra, T. Vaimann, "Lightgbm-based fault diagnosis of rotating machinery under changing working conditions using modified recursive feature elimination," *IEEE Access*, vol. 10, pp. 81 910–81 925, 2022.
- [87] H. U. Dike, Y. Zhou, K. K. Deveerasetty, Q. Wu, "Unsupervised learning based on artificial neural network: A review," in *2018 IEEE International Conference on Cyborg and Bionic Systems (CBS)*, IEEE, 2018, pp. 322–327.

- [88] G. Rätsch, "A brief introduction into machine learning," *Friedrich Miescher Laboratory of the Max Planck Society*, pp. 1–6, 2004.
- [89] Z. Ghahramani, "Unsupervised learning," in *Summer school on machine learning*, Springer, 2003, pp. 72–112.
- [90] K. Khan, S. U. Rehman, K. Aziz, S. Fong, S. Sarasvady, "Dbscan: Past, present and future," in *The fifth international conference on the applications of digital information and web technologies (ICADIWT 2014)*, IEEE, 2014, pp. 232–238.
- [91] M. E. Wall, A. Rechtsteiner, L. M. Rocha, "Singular value decomposition and principal component analysis," in *A practical approach to microarray data analysis*, Springer, 2003, pp. 91–109.
- [92] P. Xanthopoulos, P. M. Pardalos, T. B. Trafalis, P. Xanthopoulos, P. M. Pardalos, T. B. Trafalis, "Linear discriminant analysis," *Robust data mining*, pp. 27–33, 2013.
- [93] F. T. Liu, K. M. Ting, Z.-H. Zhou, "Isolation forest," in *2008 eighth ieee international conference on data mining*, IEEE, 2008, pp. 413–422.
- [94] K.-H. Jung, "A study on machine learning for steganalysis," in *Proceedings of the 3rd International Conference on Machine Learning and Soft Computing*, 2019, pp. 12–15.
- [95] L. P. Kaelbling, M. L. Littman, A. W. Moore, "Reinforcement learning: A survey," *Journal of artificial intelligence research*, vol. 4, pp. 237–285, 1996.
- [96] Y. LeCun, Y. Bengio, G. Hinton, "Deep learning," *nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [97] K. Bhargavi, "Deep learning architectures and tools: A comprehensive survey," *Deep Learning Applications and Intelligent Decision Making in Engineering*, pp. 55–75, 2021.
- [98] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, 2012.
- [99] P. R. Kumar, E. B. K. Manash, "Deep learning: A branch of machine learning," in *Journal of Physics: Conference Series*, IOP Publishing, vol. 1228, 2019, p. 012 045.
- [100] T. Deng, "A survey of convolutional neural networks for image classification: Models and datasets," in *2022 international conference on big data, information and computer network (BDICN)*, IEEE, 2022, pp. 746–749.
- [101] J. C. Ye, J. C. Ye, "Convolutional neural networks," *Geometry of Deep Learning: A Signal Processing Perspective*, pp. 113–134, 2022.
- [102] A. Ghosh, A. Sufian, F. Sultana, A. Chakrabarti, D. De, "Fundamental concepts of convolutional neural network," *Recent trends and advances in artificial intelligence and Internet of Things*, pp. 519–567, 2020.
- [103] J. Patterson, A. Gibson, *Deep learning: A practitioner's approach*. " O'Reilly Media, Inc.", 2017.


- [104] M. S. Badar, H. B. Mehare, J. P. Anilkumar, A. Roy, M. Maksuf Ul Haque, S. Shamsi, “Case study 1: Human emotion detection,” in *A Guide to Applied Machine Learning for Biologists*, Springer, 2023, pp. 221–242.
- [105] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [106] D. Scherer, A. Müller, S. Behnke, “Evaluation of pooling operations in convolutional architectures for object recognition,” in *International conference on artificial neural networks*, Springer, 2010, pp. 92–101.
- [107] M. M. Taye, “Theoretical understanding of convolutional neural network: Concepts, architectures, applications, future directions,” *Computation*, vol. 11, no. 3, p. 52, 2023.
- [108] R. H. Hahnloser, R. Sarpeshkar, M. A. Mahowald, R. J. Douglas, H. S. Seung, “Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit,” *nature*, vol. 405, no. 6789, pp. 947–951, 2000.
- [109] I. Goodfellow, Y. Bengio, A. Courville, *Deep learning*. MIT press, 2016.
- [110] C. Szegedy *et al.*, “Going deeper with convolutions,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1–9.
- [111] A. L. Maas, A. Y. Hannun, A. Y. Ng, *et al.*, “Rectifier nonlinearities improve neural network acoustic models,” in *Proc. icml*, Atlanta, GA, vol. 30, 2013, p. 3.
- [112] C. C. Aggarwal *et al.*, *Neural networks and deep learning*. Springer, 2018, vol. 10.
- [113] J. He, L. Li, J. Xu, C. Zheng, “Relu deep neural networks and linear finite elements,” *arXiv preprint arXiv:1807.03973*, 2018.
- [114] Z. Chen, P.-H. Ho, “Global-connected network with generalized relu activation,” *Pattern Recognition*, vol. 96, p. 106 961, 2019.
- [115] B. Xu, N. Wang, T. Chen, M. Li, “Empirical evaluation of rectified activations in convolutional network,” *arXiv preprint arXiv:1505.00853*, 2015.
- [116] K. O’shea, R. Nash, “An introduction to convolutional neural networks,” *arXiv preprint arXiv:1511.08458*, 2015.
- [117] F. Bayram, “Derin öğrenme tabanlı otomatik plaka tanıma,” *Politeknik Dergisi*, vol. 23, no. 4, pp. 955–960, 2020.
- [118] C. M. Bishop, “Pattern recognition and machine learning,” *Springer google schola*, vol. 2, pp. 1122–1128, 2006.
- [119] R. Zaheer, H. Shaziya, “A study of the optimization algorithms in deep learning,” in *2019 third international conference on inventive systems and control (ICISC)*, IEEE, 2019, pp. 536–539.
- [120] R. Yamashita, M. Nishio, R. K. G. Do, K. Togashi, “Convolutional neural networks: An overview and application in radiology,” *Insights into imaging*, vol. 9, pp. 611–629, 2018.

- [121] N. Ketkar, J. Moolayil, N. Ketkar, J. Moolayil, “Deep learning with python: Learn best practices of deep learning models with pytorch,” *Apress LP*, 2020.
- [122] L. Bottou, “Large-scale machine learning with stochastic gradient descent,” in *Proceedings of COMPSTAT’2010: 19th International Conference on Computational Statistics Paris France, August 22-27, 2010 Keynote, Invited and Contributed Papers*, Springer, 2010, pp. 177–186.
- [123] L. N. Smith, “Cyclical learning rates for training neural networks,” in *2017 IEEE winter conference on applications of computer vision (WACV)*, IEEE, 2017, pp. 464–472.
- [124] Y. Bengio, N. Léonard, A. Courville, “Estimating or propagating gradients through stochastic neurons for conditional computation,” *arXiv preprint arXiv:1308.3432*, 2013.
- [125] P. Hermosilla, T. Ritschel, P.-P. Vázquez, À. Vinacua, T. Ropinski, “Monte carlo convolution for learning on non-uniformly sampled point clouds,” *ACM Transactions on Graphics (TOG)*, vol. 37, no. 6, pp. 1–12, 2018.
- [126] H. Thomas, F. Goulette, J.-E. Deschaud, B. Marcotegui, Y. LeGall, “Semantic classification of 3d point clouds with multiscale spherical neighborhoods,” in *2018 International conference on 3D vision (3DV)*, IEEE, 2018, pp. 390–398.
- [127] J. Dai *et al.*, “Deformable convolutional networks,” in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 764–773.
- [128] T. Hackel, N. Savinov, L. Ladicky, J. D. Wegner, K. Schindler, M. Pollefeys, “Semantic3d. net: A new large-scale point cloud classification benchmark,” *arXiv preprint arXiv:1704.03847*, 2017.
- [129] K. He, X. Zhang, S. Ren, J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [130] D. Girardeau-Montaut, “Cloudcompare,” *France: EDF R&D Telecom ParisTech*, vol. 11, no. 5, 2016.
- [131] B. Jutzi, H. Gross, “Nearest neighbour classification on laser point clouds to gain object structures from buildings,” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 38, no. Part 1, pp. 4–7, 2009.
- [132] T. Hackel, J. D. Wegner, K. Schindler, “Fast semantic segmentation of 3d point clouds with strongly varying density,” *ISPRS annals of the photogrammetry, remote sensing and spatial information sciences*, vol. 3, pp. 177–184, 2016.
- [133] C. Mallet, F. Bretar, M. Roux, U. Soergel, C. Heipke, “Relevance assessment of full-waveform lidar data for urban area classification,” *ISPRS journal of photogrammetry and remote sensing*, vol. 66, no. 6, S71–S84, 2011.
- [134] D. Munoz, J. A. Bagnell, N. Vandapel, M. Hebert, “Contextual classification with functional max-margin markov networks,” in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, 2009, pp. 975–982.


- [135] K. F. West, B. N. Webb, J. R. Lersch, S. Pothier, J. M. Triscari, A. E. Iverson, “Context-driven automated target detection in 3d data,” in *Automatic Target Recognition XIV*, SPIE, vol. 5426, 2004, pp. 133–143.
- [136] O. C. Bayrak, Z. Ma, E. M. Farella, F. Remondino, M. Uzar, “Estate: A large dataset of under-represented urban objects for 3d point cloud classification,” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 48, pp. 25–32, 2024.




YTÜ Hidrolik Laboratuvarına ilişkin oluşturulan eğitim ve test görselleri Şekil A.1, Şekil A.2, Şekil A.3, Şekil A.4 ve Şekil A.5’de sunulmuştur.




Şekil A.1 S1 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)



Şekil A.2 S2 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)




Şekil A.3 S3 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)



S4


Şekil A.4 S4 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)



S5


Şekil A.5 S5 Eğitim ve Test (YTÜ Hidrolik Laboratuvarı)

Britanya Kolumbiyası içmesuyu hattına ilişkin oluşturulan eğitim ve test görselleri Şekil A.6, Şekil A.7, Şekil A.8, Şekil A.9' ve Şekil A.10'de sunulmuştur.




S1


Şekil A.6 S1 Eğitim ve Test (Britanya Kolumbiyası)




Şekil A.7 S2 Eğitim ve Test (Britanya Kolumbiyası)



Şekil A.8 S3 Eğitim ve Test (Britanya Kolumbiyası)



Şekil A.9 S4 Eğitim ve Test (Britanya Kolumbiyası)



Şekil A.10 S5 Eğitim ve Test (Britanya Kolumbiyası)

Tahmin												
Sınıf	Zemin	Su Borusu	Dirsek	Bağlantı Elemanları	Merdiven	Çit	İskele	Taşıyıcı Kolon	Te	Diğer	Düşey Yüzey	
Zemin	3288281	104128	0	249	4623	9498	611453	4897	0	159911	94559	RO
Su Borusu	61301	685663	73275	60034	1491	6264	7734	6835	1722	14093	25129	
Dirsek	0	11833	51740	434	0	0	64	0	0	0	0	
Bağlantı Elemanları	1	4444	0	67120	0	254	56	6198	0	0	180	
Merdiven	15855	73	0	0	13731	3175	769	2693	0	277	36919	
Çit	7964	2745	0	9879	778	170899	44244	16787	0	9211	5282	
İskele	8483	2217	0	1108	1846	11258	381370	11092	0	2038	21379	
Taşıyıcı Kolon	267	1272	0	24453	3	5964	3612	150041	0	0	9323	
Te	5233	44456	1448	138	197	324	1536	0	17837	91	3111	
Diğer	58250	25630	0	3669	2112	12537	2782	6114	0	25006	33931	
Düşey Yüzey	59668	6168	0	1	1711	3792	131	8547	0	2735	266781	LightGBM
Zemin	2817625	111796	0	2586	12876	17021	650934	7112	1374	586500	69775	
Su Borusu	31063	657459	102047	48020	7479	10107	0	12479	2131	49989	22767	
Dirsek	0	7943	56009	119	0	0	0	0	0	0	0	
Bağlantı Elemanları	1	4328	354	66772	4	1812	187	4720	0	75	0	
Merdiven	5781	703	0	2902	31354	11962	4177	4687	0	6312	5614	
Çit	1112	1423	453	7708	2606	183755	37216	18398	0	14040	1078	
İskele	87	9970	22163	3094	2372	53914	295547	28856	0	24788	0	
Taşıyıcı Kolon	112	1878	54	14976	60	9622	563	155141	0	24	12505	
Te	4896	41396	4385	1212	494	835	0	684	17344	695	2430	
Diğer	37600	22407	0	3683	3993	16947	4901	10516	1664	38089	30231	XGBoost
Düşey Yüzey	62790	1366	0	0	503	4409	0	5338	0	9031	266097	
Zemin	2520621	132189	0	51	26643	25518	345186	14462	846	1135222	76861	
Su Borusu	23137	680589	93787	51564	9246	8019	0	12181	1819	36007	27192	
Dirsek	0	13475	49345	1251	0	0	0	0	0	0	0	
Bağlantı Elemanları	0	4183	254	65573	16	1480	127	6602	0	18	0	
Merdiven	4362	988	0	944	16238	24859	3828	8463	0	7484	6326	
Çit	1169	1645	161	7086	1799	183958	34868	20608	0	15144	1351	
İskele	271	21037	19101	3500	3129	64500	273003	33329	0	22921	0	
Taşıyıcı Kolon	223	1751	220	12520	28	7571	487	158556	27	22	13530	
Te	3165	39937	3846	1347	1647	787	0	1	20938	1218	1485	
Diğer	32078	28569	0	1763	3598	15845	4651	14997	681	40327	27522	
Düşey Yüzey	54590	1343	0	0	280	3292	0	3578	0	11282	275169	

Şekil A.11 S5 senaryosuna ilişkin karışıklık matrisi (Biritya Kolumbiyası)

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. Y. Yilmaz, O. C. Bayrak, A. Soycan, "Evaluation of Machine Learning Algorithms for Classification of Infrastructure Elements in Complex Structures", *KSCE Journal of Civil Engineering*, 1-17. DOI:10.1007/s12205-024-2062-8

Konferans Bildirisi

1. Y. Yilmaz, A. Soycan, "Investigation of Feature Selection Methods for The Detection of Infrastructure Elements from 3d Point Clouds", in 6. *International Hasankeyf Scientific Research and Innovation Congress*, Batman, 2023, pp. 619-620.