

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

JEOfİZİK MÜHENDİSLİĞİ ANA BİLİM DALI

ÇAYELİ (RİZE) İLÇESİNDE JEOfİZİK VERİLERLE BÜTÜNLEŞİK
HEYELAN DUYARLILIĞI VE RİSK HARİTALARININ
OLUŞTURULMASI

YÜKSEK LİSANS

ZEHRA SÜRÜL

Temmuz 2026
GÜMÜŞHANE



T.C.

**GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

JEOFİZİK MÜHENDİSLİĞİ ANA BİLİM DALI

**ÇAYELİ (RİZE) İLÇESİNDE JEOFİZİK VERİLERLE BÜTÜNLEŞİK
HEYELAN DUYARLILIĞI VE RİSK HARİTALARININ
OLUŞTURULMASI**

**INTEGRATED LANDSLIDE SUSCEPTIBILITY AND RISK MAPPING
USING GEOPHYSICAL DATA IN ÇAYELİ (RİZE) DISTRICT**

YÜKSEK LİSANS

ZEHRA SÜRÜL

**Temmuz 2026
GÜMÜŞHANE**



**GÜMÜŞHANE
ÜNİVERSİTESİ**

Lisansüstü Eğitim Enstitüsü

T.C.

GÜMÜŞHANE ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

JEOFİZİK MÜHENDİSLİĞİ ANA BİLİM DALI

**ÇAYELİ (RİZE) İLÇESİNDE JEOFİZİK VERİLERLE BÜTÜNLEŞİK
HEYELAN DUYARLILIĞI VE RİSK HARİTALARININ
OLUŞTURULMASI**

**INTEGRATED LANDSLIDE SUSCEPTIBILITY AND RISK MAPPING
USING GEOPHYSICAL DATA IN ÇAYELİ (RİZE) DISTRICT**

YÜKSEK LİSANS

ZEHRA SÜRÜL

DR. ÖĞR. ÜYESİ SUNA ALTUNDAŞ

Temmuz 2026

GÜMÜŞHANE

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Yüksek Lisans Tezi olarak hazırlamış olduğum “**Çayeli (Rize) İlçesinde Jeofizik Verilerle Bütünleşik Heyelan Duyarlılığı ve Risk Haritalarının Oluşturulması**” isimli bu tezimin, tamamen kendi çalışmam olduğunu, danışmanımın sorumluluğunda hazırladığımı, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmaları kaynakçada belirttiğimi ve Gümüşhane Üniversitesi’nin lisanslı kullanıcısı olduğu intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü’nün belirlediği kıstaslara uygun olarak raporladığımı taahhüt ederim. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanmasına izin verdiğimi onaylarım.

21/05/2026

.....

Zehra SÜRÜL

TEŞEKKÜR

Bu tez çalışmasının planlanması, yürütülmesi ve tamamlanması sürecinde; engin bilgi, deneyim ve değerli yönlendirmeleriyle bana yol gösteren, akademik gelişimime büyük katkı sağlayan, her aşamada desteğini ve anlayışını esirgemeyen kıymetli danışmanım Dr. Öğr. Üyesi Suna ALTUNDAŞ'a en içten teşekkürlerimi ve şükranlarımı sunarım.

Tez çalışmam süresince bilgi ve tecrübeleriyle yol gösteren, özellikle çalışmada kullanılan haritaların hazırlanması aşamasında çok değerli katkılar sağlayan ikinci danışmanım Doç. Dr. Mehmet Akif GÜNEN'e teşekkürlerimi sunarım.

Araştırma sürecinde ihtiyaç duyulan veri ve bilgilerin sağlanmasında kolaylık gösteren Çayeli Belediyesi'ne ve kurum çalışanlarına katkılarından dolayı teşekkür ederim.

Ayrıca, lisansüstü eğitimim ve çalışma süresince bilgi, görüş ve önerileriyle bana destek olan tüm değerli hocalarıma şükranlarımı sunarım.

Son olarak yüksek lisans eğitimim ve tez çalışmam boyunca desteklerini ve güvenlerini her zaman hissettiğim aileme ve sevgili eşime teşekkür ederim.

.....

Zehra SÜRÜL
GÜMÜŞHANE – 2026

ÖZET

Bu çalışmada, Çayeli ilçesinde heyelan duyarlılığının belirlenmesi amacıyla makine öğrenmesi tabanlı bütünleşik bir analiz gerçekleştirilmiştir. Çalışmada topoğrafik, hidrolojik, jeolojik, iklimsel ve sismik/jeoteknik faktörler birlikte değerlendirilmiş; AFAD, MTA, CORINE, OpenStreetMap ve sayısal yükseklik modeli verileri kullanılmıştır. Ayrıca Çayeli Belediyesi'nden temin edilen 55 adet jeolojik-jeoteknik rapor incelenmiş ve jeofizik veriler CBS ortamında modele dahil edilmiştir.

Toplam 28 koşullayıcı faktör oluşturulmuş, VIF analizi sonucunda yüksek doğrusal bağlantıya sahip değişkenler çıkarılarak modelleme süreci 22 faktör üzerinden yürütülmüştür. Lojistik Regresyon, Rastgele Orman, XGBoost, LightGBM, SVM ve YSA dahil olmak üzere on farklı makine öğrenmesi algoritması karşılaştırılmıştır. Modeller 5 katlı çapraz doğrulama ve bağımsız test veri seti ile değerlendirilmiştir.

Son aşamada SHAP analizi uygulanarak faktörlerin model tahminlerine etkisi yorumlanmıştır. Elde edilen sonuçlar doğrultusunda heyelan duyarlılık haritaları üretilmiş ve çalışma alanındaki mevcut heyelanlarla yüksek mekânsal uyum gösterdiği belirlenmiştir. Çalışma, makine öğrenmesi ve açıklanabilir yapay zekâ yöntemlerinin heyelan duyarlılık analizlerinde etkili sonuçlar sunduğunu ortaya koymuştur.

Anahtar Kelimeler: Coğrafi bilgi sistemi, Çayeli, Heyelan duyarlılığı, Jeofizik veriler, Makine öğrenmesi, Shapley toplamsal açıklamaları.

ABSTRACT

In this study, an integrated machine learning-based analysis was conducted to determine landslide susceptibility in Çayeli district. Topographic, hydrological, geological, climatic, and seismic/geotechnical factors were jointly evaluated using data obtained from AFAD, MTA, CORINE, OpenStreetMap, and Digital Elevation Models. In addition, 55 geological-geotechnical reports obtained from the Çayeli Municipality were examined, and geophysical data were integrated into the GIS-based model.

A total of 28 conditioning factors were initially generated, and after Variance Inflation Factor (VIF) analysis, variables with high multicollinearity were removed, resulting in 22 final factors. Ten different machine learning algorithms, including Logistic Regression, Random Forest, XGBoost, LightGBM, SVM, and Artificial Neural Networks, were comparatively evaluated. The models were trained using 5-fold cross-validation and validated with an independent test dataset.

In the final stage, SHAP analysis was applied to interpret the contribution of conditioning factors to model predictions. Landslide susceptibility maps were produced and showed high spatial agreement with existing landslide occurrences in the study area. The study demonstrated that machine learning and explainable artificial intelligence approaches provide effective results for landslide susceptibility assessment.

Keywords: Geographic information system, Çayeli, Landslide susceptibility, Geophysical data, Machine learning, SHapley Additive exPlanations.

İÇİNDEKİLER

KABUL VE ONAY	Hata! Yer işareti tanımlanmamış.
BİLİMSEL ETİĞE UYGUNLUK BEYANI.....	IV
TEŞEKKÜR.....	V
ÖZET.....	VI
ABSTRACT.....	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ	X
ŞEKİLLER DİZİNİ.....	XI
SİMGELER VE KISALTMALAR DİZİNİ	XV
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Önceki Çalışmalar	4
1.3. Çalışmanın Amacı ve Kapsamı	10
1.4. Çalışmanın Önemi.....	11
1.5. Problem Tanımı.....	11
2. TEORİK TEMELLER	13
2.1. Afet Duyarlılığı ve Risk Kavramı	13
2.2. Zemin Davranışı ve Afet İlişkisi	15
2.3. Jeofizik-Jeoteknik Veriler ve CBS Tabanlı Afet Duyarlılık Modeline Entegrasyonu	16
3. ÇALIŞMA ALANINA AİT GENEL BİLGİLER.....	19
3.1. Coğrafi Konum	19
3.2. Jeoloji	20
3.3. Tektonik Yapı.....	22
3.4. Jeomorfoloji	24
3.5. İklim ve Yağış	26
3.6. Geçmiş Afetler	27
4. MATERYAL VE YÖNTEM	29
4.1. Genel Metodoloji	29
4.2. Heyelan Envanter Verisi	31
4.2.1. Heyelan Olmayan Noktaların Seçimi.....	33
4.3. Koşullu Faktörlerin Belirlenmesi ve Hazırlanması.....	36

4.3.1. Topoğrafik ve Morfometrik Faktörler.....	38
4.3.2. Hidrolojik ve Antropojenik Mesafe Faktörleri	41
4.3.3. Jeolojik ve İklimsel faktörler	42
4.3.4. Sismik ve Jeoteknik Zemin Faktörleri	43
4.4. Veri Seti Oluşturma ve Hold-Out Bölme.....	55
4.5. Varyans Enflasyon Faktörü (VIF) Analizi	56
4.6. Makine Öğrenmesi Modelleri	58
4.7. Model Değerlendirme Kriterleri	61
4.8. SHAP Açıklanabilirlik Analizi	64
5. BULGULAR	66
5.1. Veri Seti ve Örnek Noktaların Dağılımı	66
5.2. VIF Analizi Bulguları	70
5.3. Makine Öğrenmesi Modellerinin Performans Bulguları.....	71
5.3.1. Çapraz Doğrulama Performansı	71
5.3.2. Hold-out Test Performansı	73
5.3.3. ROC ve Precision–Recall Eğrilerinin Değerlendirilmesi	77
5.3.4. Karışıklık Matrisleri ve Sınıflandırma Hatalarının Değerlendirilmesi	80
5.4. SHAP Açıklanabilirlik Bulguları	82
5.5. Heyelan Duyarlılık Haritalarının Üretilmesi ve Karşılaştırılması	97
6. SONUÇLAR	114
KAYNAKÇA.....	119
ÖZGEÇMİŞ	128

TABLÖLAR DİZİNİ

Tablo 1. Heyelan duyarlılık analizinde kullanılan 28 koşullu faktör.....	37
Tablo 2. Kullanılan makine öğrenmesi modellerinin hiperparametre özeti.....	60
Tablo 3. Kullanılan model değerlendirme metrikleri.....	63
Tablo 4. VIF analizi sonucunda çıkarılan koşullayıcı faktörler	70
Tablo 5. Makine öğrenmesi modellerinin 5 katlı çapraz doğrulama performansları	72
Tablo 6. Makine öğrenmesi modellerinin hold-out test performansları	74

ŞEKİLLER DİZİNİ

Şekil 1.	Çalışma alanının yer bulduru haritası.....	20
Şekil 2.	Rize ilinin 1/100.000 ölçekli jeoloji haritası (Tüysüz vd., 2008).....	21
Şekil 3.	Anadolu plakasının tektonik haritası ve Rize civarında günümüze kadar meydana gelen bölgesel depremlerin dağılımı (Şaroğlu vd.,1992).....	23
Şekil 4.	Çalışmanın genel metodoloji akış şeması.....	31
Şekil 5.	DEM tabanlı topoğrafik arka plan üzerinde heyelan ve heyelan olmayan örnek noktaların mekânsal dağılımı	35
Şekil 6.	Uydu görüntüsü üzerinde heyelan ve heyelan olmayan örnek noktaların mekânsal dağılımı.....	36
Şekil 7.	Topoğrafik ve morfometrik koşullayıcı faktörlerin mekânsal dağılımı-I (Eğim, Bakı, Toplam Eğrisellik ve Profil Eğrisellik Katmanları).....	46
Şekil 8.	Topoğrafik ve morfometrik koşullayıcı faktörlerin mekânsal dağılımı-II. Plan Eğriselliği, Yakınsama İndeksi, Yüzey Pürüzlülüğü ve Topoğrafik Konum İndeksi Katmanlarını göstermektedir	48
Şekil 9.	Topoğrafik, hidrolojik ve antropojenik koşullayıcı faktörlerin mekânsal dağılımı, Topoğrafik Pürüzlülük İndeksi, Topoğrafik Islanma İndeksi, Akarsuya Uzaklık ve Yola Uzaklık katmanlarını göstermektedir.....	50
Şekil 10.	Jeolojik, arazi örtüsü ve iklimsel koşullayıcı faktörlerin mekânsal dağılımı. Litoloji, Arazi Örtüsü, Yıllık Yağış ve Vs30 katmanlarını göstermektedir.....	51
Şekil 11.	Birinci tabakaya ait sismik/jeoteknik zemin parametrelerinin mekânsal dağılımı-I. Tabaka Yoğunluk, 1. Tabaka Kayma Modülü G, 1. Tabaka Elastisite Modülü E ve 1. Tabaka Bulk Modülü K katmanlarını göstermektedir	52
Şekil 12.	Birinci ve ikinci tabakaya ait sismik/jeoteknik zemin parametrelerinin mekânsal dağılımı-II. Tabaka Poisson Oranı, 2. Tabaka Yoğunluk, 2. Tabaka Kayma Modülü G ve 2. Tabaka Elastisite Modülü E katmanlarını göstermektedir	53
Şekil 13.	İkinci tabakaya ve zemin dinamik özelliklerine ait sismik/jeoteknik parametrelerin mekânsal dağılımı. 2. Tabaka Bulk Modülü K, 2. Tabaka Poisson Oranı, Zemin Büyütmesi ve Zemin Hâkim Titreşim Periyodu katmanlarını göstermektedir.....	54

Şekil 14. Heyelan ve heyelan olmayan sınıflara göre koşullayıcı faktörlerin violin grafikleri	69
Şekil 15. Eğitim, çapraz doğrulama ve hold-out AUC değerlerinin model bazlı karşılaştırılması.....	75
Şekil 16. Çapraz doğrulama sürecindeki AUC değerlerinin katlar arasındaki dağılımın boxplot grafikleri	76
Şekil 17. Hold-out test setinde makine öğrenmesi modellerine ait ROC eğrileri.....	78
Şekil 18. Hold-out test setinde makine öğrenmesi modellerine ait Precision–Recall eğrileri.....	79
Şekil 19. Hold-out test setinde makine öğrenmesi modellerine ait karışıklık matrisleri	81
Şekil 20. LightGBM modeli için SHAP summary grafiği	83
Şekil 21. Ekstra Ağaçlar modeli için SHAP summary grafiği	85
Şekil 22. Gradyan Artırma modeli için SHAP summary grafiği.....	86
Şekil 23. Karar Ağacı modeli için SHAP summary grafiği.....	87
Şekil 24. KNN modeli için SHAP summary grafiği.....	88
Şekil 25. Rastgele Orman modeli için SHAP summary grafiği	89
Şekil 26. SVM modeli için SHAP summary grafiği.....	90
Şekil 27. XGBoost modeli için SHAP summary grafiği	91
Şekil 28. YSA (MLP) modeli için SHAP summary grafiği	92
Şekil 29. Lojistik Regresyon modeli için SHAP summary grafiği.....	93
Şekil 30. Rastgele Orman modelinde yıllık yağış değişkenine ait SHAP dependence grafiği. Renk skalası Topoğrafik Islanma İndeksi değerlerini göstermektedir ..	95
Şekil 31. Rastgele Orman modelinde yola uzaklık değişkenine ait SHAP dependence grafiği. Renk skalası Topoğrafik Islanma İndeksi değerlerini göstermektedir ..	96
Şekil 32. Rastgele Orman modelinde eğim değişkenine ait SHAP dependence grafiği. Renk skalası yıllık yağış değerlerini göstermektedir.....	97
Şekil 33. LightGBM modeline ait heyelan duyarlılık haritası.....	101
Şekil 34. XGBoost modeline ait heyelan duyarlılık haritası	102
Şekil 35. Rastgele Orman modeline ait heyelan duyarlılık haritası.....	103
Şekil 36. Gradyan Artırma modeline ait heyelan duyarlılık haritası	104
Şekil 37. Ekstra Ağaçlar modeline ait heyelan duyarlılık haritası.....	105
Şekil 38. YSA (MLP) modeline ait heyelan duyarlılık haritası.....	106

Şekil 39. SVM modeline ait heyelan duyarlılık haritası	107
Şekil 40. Karar Ağacı modeline ait heyelan duyarlılık haritası	108
Şekil 41. KNN modeline ait heyelan duyarlılık haritası	109
Şekil 42. Lojistik Regresyon modeline ait heyelan duyarlılık haritası	110
Şekil 43. Tüm modellerde heyelan duyarlılık sınıflarının yüzdesel alan dağılımı	111

SİMGELER VE KISALTMALAR DİZİNİ¹

Σ	: Toplam sembolü
ρ	: Yoğunluk
σ'	: Efektif Gerilme
σ	: Toplam Gerilme
τ	: Kayma Dayanımını
ϕ	: İçsel Sürtünme Açısı
$^{\circ}$	: Derece
A_0	: Zemin Büyütmesi
AFAD	: Afet ve Acil Durum Yönetimi Başkanlığı
AHP / AHS	: Analitik Hiyerarşi Prosesi / Süreci
AP	: Ortalama Kesinlik (Average Precision)
AUC	: ROC Eğrisi Altındaki Alan (Area Under the Curve)
BLUE	: En İyi Doğrusal Sapmasız Kestirici (Best Linear Unbiased Estimator)
$^{\circ}\text{C}$	: Santigrat
c	: Kohezyon
CART	: Sınıflandırma-Regresyon Ağaçları (Classification and Regression Trees)
CBS	: Coğrafi Bilgi Sistemleri
CORINE	: Coordination of Information on the Environment (Avrupa arazi örtüsü/veri sistemi)
CRS	: Koordinat Referans Sistemi (Coordinate Reference System)
CSV	: Virgülle Ayrılmış Değerler (Comma-Separated Values)
CV.	: Çapraz Doğrulama (Cross-Validation)
Cu-Zn	: Bakır-Çinko Sülfid Mineralleşmesi
ÇKKA	: Çok Kriterli Karar Analizi
DEM / SYM	: Sayısal Yükseklik Modeli (Digital Elevation Model)
DES	: Düşey Elektrik Sondaj
DSİ	: Devlet Su İşleri Genel Müdürlüğü
DSM	: Digital Surface Model (Sayısal Yüzey Modeli)
E	: Young (Elastisite) Modülü

¹ TDK Kısaltmalar Dizini

EPSG	: Avrupa Petrol Araştırma Grubu – projeksiyon kodu (European Petroleum Survey Group)
ERT	: Elektrik Öz direnç Tomografisi
FN	: Yanlış Negatif (False Negative)
FO	: Frekans Oranı
FP	: Yanlış Pozitif (False Positive)
G	: Kayma Modülü
GKKA	: Göreceli Katastrofik Kayıp Analizi
H/V	: Yatay/Düşey Spektral Oran (Nakamura Yöntemi)
IDW	: Ters Mesafe Ağırlıklı Enterpolasyon (Inverse Distance Weighting)
IPCC	: Intergovernmental Panel on Climate Change (Hükümetlerarası İklim Değişikliği Paneli)
İRAP	: İl Afet Risk Azaltma Planı
K	: Hacim (Bulk) Modülü
KB-GD	: Kuzeybatı - Güneydoğu
KD-GB	: Kuzeydoğu - Güneybatı
KML	: Keyhole Markup Language (Coğrafi veri formatı)
KNN	: K-En Yakın Komşu (K-Nearest Neighbors)
LightGBM	: Light Gradient Boosting Machine
LR	: Lojistik Regresyon
MASW	: Yüzey Dalgalarının Çok Kanallı Analizi (Multichannel Analysis of Surface Waves)
MGM	: Meteoroloji Genel Müdürlüğü
MLP	: Çok Katmanlı Algılayıcı (Multi-Layer Perceptron)
MTA	: Maden Tetkik ve Arama Genel Müdürlüğü
NaN	: Not a Number (Eksik/geçersiz veri değeri)
NDVI	: Normalize Edilmiş Fark Bitki İndeksi (Normalized Difference Vegetation Index)
NoData	: Veri bulunmayan hücre değeri
PR	: Kesinlik-Duyarlılık (Precision-Recall)
QGIS	: Quantum Geographic Information System (Açık kaynak CBS yazılımı)
ReLU	: Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
ROC	: Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
SHAP	: Shapley Toplamsal Açıklamalar (SHapley Additive exPlanations)
SHP	: Shapefile – ESRI vektör dosya biçimi

SINMAP	: Stability Index Mapping (Stabilite İndeksi Haritalama)
SPT	: Standart Penetrasyon Testi
SPT-N	: Standart Penetrasyon Testi Vuruş Sayısı
SRTM	: Sayısal yükseklik verisi sağlayan NASA görevi (Shuttle Radar Topography Mission)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
T ₀	: Zemin Hâkim Titreşim Periyodu
TBDY	: Türkiye Bina Deprem Yönetmeliği (2018)
TN	: Gerçek Negatif (True Negative)
TP	: Gerçek Pozitif (True Positive)
TPI	: Topoğrafik Konum İndeksi (Topographic Position Index)
TRI	: Topoğrafik Pürüzlülük İndeksi (Topographic Ruggedness Index)
TWI	: Topoğrafik Islanma İndeksi (Topographic Wetness Index)
u	: Boşluk Suyu Basıncı
UA	: Uzaktan Algılama
UNDRR	: United Nations Office for Disaster Risk Reduction (Birleşmiş Milletler Afet Risk Azaltma Ofisi)
UTM	: Evrensel Enine Mercator (Universal Transverse Mercator)
v	: Poisson Oranı
VIF	: Varyans Enflasyon Faktörü (Variance Inflation Factor)
vb.	: Ve benzeri
vd.	: Ve diğerleri, ve devamı
V _p	: P-Dalgası (Boyuna Dalga) Hızı
V _s	: S-Dalgası (Kayma Dalgası) Hızı
V _{s30}	: İlk 30 m için Kayma Dalgası Hızı
XGBoost	: Extreme Gradient Boosting
YSA	: Yapay Sinir Ağları
y.y.	: Yayıncı yok
Z	: Yükseklik

1. GENEL BİLGİLER

1.1. Giriş

Heyelanlar, yamaç dengesinin doğal veya insan kaynaklı süreçler sonucunda bozulmasıyla ortaya çıkan ve can-mal kayıplarına, ulaşım ve altyapı sistemlerinde hasara, tarımsal üretim alanlarında bozulmaya ve yerleşim alanlarında uzun vadeli risklere neden olabilen önemli kütle hareketleridir. Özellikle yüksek eğimli topoğrafya, yoğun yağış, zayıf litolojik birimler ve insan kaynaklı müdahalelerin bir arada bulunduğu alanlarda heyelan duyarlılığı belirgin biçimde artmaktadır (Cruden ve Varnes, 1996; Highland ve Bobrowsky, 2008). Heyelan oluşumu çoğu zaman tek bir faktörün sonucu değildir; topoğrafya, litoloji, jeolojik yapı, yüzeysel ve yeraltı suyu koşulları, yağış rejimi, arazi örtüsü, yol açma faaliyetleri, drenaj düzenindeki değişimler ve zemin mekanik özellikleri birlikte etki ederek yamaç stabilitesini kontrol etmektedir (Guzzetti vd., 1999; Sidle ve Ochiai, 2006). Bu nedenle heyelan duyarlılığının değerlendirilmesinde çok değişkenli, mekânsal ve istatistiksel olarak güçlü yaklaşımlara ihtiyaç duyulmaktadır.

Türkiye, topoğrafik ve jeolojik çeşitliliği, aktif tektonik yapısı, yoğun yağış alan bölgeleri ve hızlı arazi kullanım değişimleri nedeniyle heyelan açısından duyarlı ülkeler arasında yer almaktadır (Can vd., 2005; AFAD, 2022). Bu risk özellikle Doğu Karadeniz Bölgesi'nde daha belirgin hale gelmektedir (Gökçe vd, 2008). Bölgenin kısa mesafelerde büyük yükselti farkları göstermesi, dik yamaçların yaygınlığı, yoğun akarsu ağı, yüksek yıllık yağış miktarı, ayrışmaya yatkın jeolojik birimler ve yol/yerleşim kaynaklı yamaç müdahaleleri heyelan oluşumunu kolaylaştırmaktadır (Erener ve Düzgün, 2012; Akgün, 2012). Rize ili ve özellikle Çayeli ilçesi, Karadeniz kıyısından dağlık iç kesimlere doğru hızla yükselen topoğrafyası ve nemli iklim koşulları nedeniyle heyelan duyarlılığının ayrıntılı olarak incelenmesi gereken alanlardan biridir. Bu nedenle Çayeli ilçesi, hem doğal çevresel faktörler hem de insan faaliyetleri bakımından heyelan duyarlılık modellemesi için uygun bir çalışma alanı oluşturmaktadır (Dağ ve Bulut, 2012).

Heyelan duyarlılık haritalaması, geçmiş heyelanların mekânsal dağılımı ile heyelan oluşumunu etkileyen koşullayıcı faktörler arasındaki ilişkileri analiz ederek gelecekte heyelan gelişme olasılığı yüksek alanların belirlenmesini amaçlayan önemli bir afet risk azaltma aracıdır (Varnes, 1984; Guzzetti vd., 2005). Bu haritalar; yerleşim

planlaması, altyapı güzergâhlarının belirlenmesi, yol ve şev güvenliği, arazi kullanım kararları, erken uyarı sistemleri ve afet yönetimi süreçlerinde karar vericilere mekânsal bilgi sağlamaktadır (Fell vd., 2008). Duyarlılık haritalarının güvenilirliği ise doğrudan kullanılan heyelan envanterinin doğruluğuna, koşullayıcı faktörlerin temsil gücüne, örnekleme stratejisine, modelleme yaklaşımına ve sonuçların bağımsız verilerle test edilmesine bağlıdır (Reichenbach vd., 2018). Bu nedenle güncel çalışmalarda yalnızca duyarlılık haritası üretmek değil, aynı zamanda modelin doğrulanması, karşılaştırılması ve açıklanabilir hale getirilmesi de önemli bir gereklilik haline gelmiştir.

Geleneksel heyelan duyarlılık çalışmalarında frekans oranı, ağırlıklı doğrusal kombinasyon, analitik hiyerarşi süreci, lojistik regresyon ve istatistiksel indeks yöntemleri yaygın olarak kullanılmıştır (Ayalew ve Yamagishi, 2005; Lee ve Pradhan, 2007). Bu yöntemler belirli avantajlar sunmakla birlikte, heyelan oluşumunu kontrol eden değişkenler arasındaki doğrusal olmayan ilişkileri ve karmaşık etkileşimleri yakalamada sınırlı kalabilmektedir (Tien Bui vd., 2012). Örneğin eğim, yağış veya litoloji gibi değişkenler heyelan üzerinde tek başına etkili değildir; bu değişkenlerin etkisi çoğu zaman birlikte ortaya çıkmaktadır. Orta–yüksek eğimli bir yamaç, yüksek yağış, zayıf litoloji, yol kesisi ve yüksek topoğrafik ıslanma koşullarıyla birleştiğinde daha duyarlı hale gelebilmektedir. Bu tür eşik, etkileşim ve doğrusal olmayan ilişkilerin klasik doğrusal modellerle tam olarak temsil edilmesi güçtür (Tehrani vd., 2022).

Makine öğrenmesi algoritmaları, heyelan duyarlılık modellemesinde güçlü bir alternatif sunmaktadır. Makine öğrenmesi modelleri, çok sayıda koşullayıcı faktör arasındaki karmaşık örüntüleri öğrenebilmekte, doğrusal olmayan ilişkileri yakalayabilmekte ve farklı değişken kombinasyonlarının heyelan olasılığı üzerindeki etkisini daha esnek biçimde değerlendirebilmektedir (Merghadi vd., 2020; Sameen vd., 2020). Özellikle karar ağacı tabanlı topluluk modelleri, boosting algoritmaları, destek vektör makineleri, k-en yakın komşu ve yapay sinir ağı modelleri, heyelan duyarlılık çalışmalarında giderek daha fazla kullanılmaktadır (Arabameri vd., 2019). Bununla birlikte her algoritmanın öğrenme yapısı farklı olduğundan, tek bir modelin sonucuna dayanmak yerine farklı model ailelerinin karşılaştırmalı olarak değerlendirilmesi daha güvenilir bir yaklaşım sağlamaktadır (Goetz vd., 2015; Pham vd., 2016).

Makine öğrenmesi modellerinin en önemli avantajlarından biri yüksek tahmin performansı sunabilmeleridir; ancak bu modellerin bir bölümü “kara kutu” yapıda kabul edilmekte ve hangi değişkenleri hangi yönde kullandıkları doğrudan anlaşılamamaktadır (Al-Najjar, 2025). Bu durum özellikle afet riski ve arazi planlaması gibi uygulamalı alanlarda önemli bir sınırlılık oluşturmaktadır. Çünkü yalnızca yüksek doğruluk değeri

elde etmek yeterli olmamakta Modelin neden belirli alanları yüksek riskli olarak sınıflandırdığının da anlaşılması gerekmektedir. Bu nedenle son yıllarda açıklanabilir yapay zekâ yaklaşımları heyelan duyarlılık çalışmalarında önem kazanmıştır. Shapley Toplamsal Açıklamalar (SHAP) yöntemi, her bir değişkenin model tahminine katkısını örnek düzeyinde ve global düzeyde açıklayabilmesi nedeniyle bu alanda güçlü bir araçtır (Al-Najjar vd., 2025). SHAP analizi sayesinde modelin yalnızca hangi değişkenleri önemli gördüğü değil, bu değişkenlerin yüksek veya düşük değerlerinin heyelan olasılığını artırıcı ya da azaltıcı yönde nasıl etki ettiği de değerlendirilebilmektedir.

Bu çalışmada heyelan duyarlılığını etkileyebilecek koşullayıcı faktörler çok boyutlu bir yaklaşımla ele alınmıştır. Çalışma kapsamında topoğrafik ve morfometrik değişkenler, hidrolojik ve antropojenik mesafe faktörleri, litoloji, arazi örtüsü, yıllık yağış ve sismik/jeoteknik zemin özellikleri birlikte değerlendirilmiştir. Özellikle sismik ve jeoteknik zemin parametrelerinin modele dahil edilmesi, çalışmanın özgün yönlerinden birini oluşturmaktadır (Reichenbach vd, 2018; Tehrani vd., 2022). Kesme dalgası hızının ilk 30 metredeki ortalama hızı (V_{s30}), zemin büyütmesi, zemin hâkim titreşim periyodu ve iki tabakalı zemin profiline ait yoğunluk, kayma modülü, elastisite modülü, bulk modülü ve Poisson oranı gibi parametreler; Yamaç malzemesinin dinamik ve mekanik davranışını temsil etmektedir (Nakamura, 1989; Kramer, 2003). Bu parametrelerin heyelan duyarlılığı modellemesine dahil edilmesi, yalnızca yüzey morfolojisine dayalı yaklaşımların ötesine geçerek zemin özelliklerinin de değerlendirilmesine olanak sağlamaktadır.

Çalışmada kullanılan heyelan envanteri, Afet ve Acil Durum Yönetimi Başkanlığı (AFAD) ve Maden Tetkik ve Arama Genel Müdürlüğü (MTA) kaynaklarından temin edilmiş, QGIS ortamında ön işleme tabi tutulmuş ve Python ortamında makine öğrenmesi analizlerine aktarılmıştır. Heyelan varlığını temsil eden pozitif örnekler envanter poligonlarından üretilen centroid noktaları ile oluşturulmuştur. Heyelan duyarlılık modellerinde eğitim ve doğrulama veri setlerinin oluşturulmasında kullanılan örnekleme stratejisinin, model performansı ve tahmin gücü üzerinde önemli etkisi bulunmaktadır (Reichenbach vd., 2018). Bu çalışmada negatif örnekler, mevcut heyelan alanlarından belirli uzaklıkta, geçerli raster değerlerine sahip ve mekânsal dağılım açısından dengeli olacak şekilde kontrollü olarak seçilmiştir. Bu yaklaşım ile modelin yalnızca belirli bölgelerde kümelenmiş veya kolay ayırt edilebilir örnekler üzerinden öğrenmesinin önüne geçilmesi ve pozitif-negatif sınıfların dengeli biçimde temsil edilmesi amaçlanmıştır.

Modelleme sürecinde veri sızıntısını önlemek amacıyla eğitim ve test ayrımı dikkatli biçimde yapılmıştır. Veri seti stratified hold-out yaklaşımıyla eğitim ve bağımsız test setlerine ayrılmış; VIF tabanlı değişken seçimi yalnızca eğitim seti üzerinde uygulanmıştır. Bu yaklaşım, test verisinden model geliştirme sürecine bilgi aktarılmasını engellemiş ve bağımsız test performansının daha güvenilir biçimde değerlendirilmesini sağlamıştır (Kapoor ve Narayanan, 2023). Model performansları yalnızca doğruluk metriğiyle değil; hassasiyet, duyarlılık, F1 skoru, ROC-AUC, Precision–Recall eğrisi, Average Precision, Cohen’s Kappa ve Matthews Korelasyon Katsayısı gibi çoklu değerlendirme ölçütleriyle analiz edilmiştir. Böylece modellerin genel ayırt ediciliği, pozitif sınıf başarısı, yanlış pozitif–yanlış negatif dengesi ve genelleme kapasitesi birlikte değerlendirilmiştir (Tehrani vd., 2022; Abdelkader ve Csámer, 2025).

Bu çalışmanın temel katkısı, Çayeli ilçesi için yalnızca bir heyelan duyarlılık haritası üretmekle sınırlı değildir. Çalışma aynı zamanda farklı makine öğrenmesi algoritmalarının aynı veri seti ve aynı koşullayıcı faktörler üzerinde karşılaştırmalı performansını ortaya koymakta, en başarılı modellerin mekânsal duyarlılık desenlerini değerlendirmekte ve SHAP analizi ile model kararlarını jeomorfolojik açıdan yorumlanabilir hale getirmektedir. Böylece çalışma, hem yöntemsel hem de uygulamalı açıdan bütüncül bir heyelan duyarlılık değerlendirmesi sunmaktadır.

1.2. Önceki Çalışmalar

Afet duyarlılığı ve risk analizleri, doğa kaynaklı afetlerin oluşum mekanizmalarının anlaşılması, riskli alanların belirlenmesi ve sürdürülebilir yerleşim planlamalarının yapılabilmesi açısından önem taşımaktadır (Wang ve Sassa, 2005). Özellikle topoğrafik eğimin yüksek, jeolojik yapının karmaşık ve yoğun yağış koşullarının etkili olduğu bölgelerde afet süreçlerinin doğru değerlendirilmesi için jeoloji, jeofizik ve Coğrafi Bilgi Sistemleri (CBS) tabanlı çalışmaların birlikte ele alınması gerekmektedir (Yılmaz ve Keskin, 2009; Reichenbach vd., 2018). Jeolojik özellikler; litoloji, ayrışma durumu, tektonik yapı ve zemin özellikleri açısından afet oluşumunu doğrudan etkilerken, jeofizik yöntemler zeminin fiziksel ve dinamik davranışının belirlenmesine olanak sağlamaktadır (Segoni vd., 2020). Sismik yöntemlerden elde edilen hız değerleri, dinamik elastik özellikler ve mikrotremor verileri özellikle yerel zemin davranışının, zemin büyütmesinin ve mühendislik özelliklerinin ortaya konulmasında önemli katkılar sunmaktadır (Molnar vd., 2018). CBS teknolojileri ise farklı veri türlerinin aynı ortamda değerlendirilmesini sağlayarak

mekânsal analizlerin gerçekleştirilmesine ve afet duyarlılık haritalarının oluşturulmasına imkân vermektedir (Wang ve Sassa, 2005; Reichenbach vd., 2018). Son yıllarda gerçekleştirilen çalışmalarda jeolojik, jeofizik ve CBS tabanlı verilerin birlikte kullanılmasıyla daha gerçekçi ve güvenilir afet modellerinin geliştirildiği görülmektedir (Reichenbach vd., 2018; Tehrani vd., 2022). Bu kapsamda konu ile ilgili ulusal ve uluslararası ölçekte gerçekleştirilmiş çalışmalar incelenmiş olup, aşağıda literatür özetleri verilmektedir.

Demirkesen (2011), Coğrafi Bilgi Sistemleri (CBS) ve sayısal arazi analiz yöntemleri kullanılarak Hatay ilindeki doğal afet risklerini değerlendirilmiştir. Çalışma alanı, tektonik ve sismik açıdan aktif olması ile kıyı su baskını ve taşkın riski taşıması nedeniyle seçilmiştir. Analizlerde SRTM tabanlı sayısal yükseklik modeli, drenaj ağları, yapısal-jeolojik veriler ve lineamentler kullanılarak 3B arazi modeli oluşturulmuş ve afet duyarlılık değerlendirmesi yapılmıştır. Elde edilen sonuçlar, kıyı taşkınları, nehir taşkınları ve deprem açısından riskli alanların belirlenmesinde CBS tabanlı yaklaşımın etkili olduğunu ortaya koymuştur.

Mutlu (2012) tarafından, Eskişehir kent merkezinde yapılan bu çalışmada, deprem riskinin değerlendirilmesi amacıyla Coğrafi Bilgi Sistemleri (CBS) ve sismik yöntemler kullanılmıştır. 23 farklı noktada yapılan sismik kırılma ve mikrotremör ölçümleriyle zemin özellikleri belirlenmiş, kayma dalga hızı, zemin büyütmesi ve hakim periyot gibi parametreler hesaplanmıştır. Elde edilen veriler CBS ortamında haritalanarak bölgenin zemin özellikleri ortaya konmuş ve sonuçların kentsel planlama ile deprem risk yönetiminde önemli olduğu vurgulanmıştır.

Şahin (2012)'nin, Trabzon ilinde gerçekleştirdiği tez çalışmasında, heyelan duyarlılık haritası üretimi amacıyla Coğrafi Bilgi Sistemleri (CBS) ortamında Çok Kriterli Karar Analizi (ÇKKA), lojistik regresyon ve frekans oranı yöntemleri kullanılmıştır. Analizlerde litoloji, eğim, arazi örtüsü, bakı, topoğrafik ıslaklık indeksi, drenaj yoğunluğu ve yola uzaklık gibi faktörler değerlendirilmiştir. Elde edilen sonuçlara göre ÇKKA yönteminin diğer yöntemlere kıyasla daha yüksek doğruluk sağladığı belirlenmiş ve çalışma alanı için en güvenilir sonuçların bu yöntemle elde edildiği ortaya konmuştur.

Pektezel (2015) tarafından, Gelibolu Yarımadası'nda gerçekleştirilen çalışmada, heyelan duyarlılığının belirlenmesi amacıyla Coğrafi Bilgi Sistemleri (CBS) tabanlı Analitik Hiyerarşi Süreci (AHS) yöntemi kullanılmıştır. Analizlerde litoloji, eğim, bakı, yağış, arazi kullanımı, akarsuya ve fay hatlarına uzaklık gibi çok sayıda parametre değerlendirilerek duyarlılık haritası oluşturulmuştur. Elde edilen sonuçlara göre çalışma

alanının önemli bir kısmının orta düzeyde heyelan potansiyeline sahip olduğu, belirli alanların ise yüksek ve çok yüksek duyarlılık gösterdiği belirlenmiştir. Ayrıca heyelanların özellikle eğimin ve yağışın yüksek olduğu, belirli litolojik birimlerde yoğunlaştığı tespit edilmiştir. Çalışma, elde edilen haritanın arazi kullanımı, yerleşim planlaması ve risk azaltma çalışmalarında önemli bir rehber niteliği taşıdığını ortaya koymaktadır.

Akıncı vd. (2015), Artvin (Merkez) yerleşim alanında heyelan duyarlılığının belirlenmesi amacıyla Analitik Hiyerarşi Prosesi (AHP) yöntemi kullanılmıştır. Analizlerde litoloji, yükseklik, eğim, bakı ve akarsuya yakınlık gibi faktörler dikkate alınarak duyarlılık haritası oluşturulmuştur. Elde edilen sonuçlara göre çalışma alanının önemli bir bölümünün yüksek ve çok yüksek heyelan duyarlılığına sahip olduğu belirlenmiştir. Ayrıca duyarlılık haritası, yerleşim alanları ve imar planı ile karşılaştırılarak özellikle bazı mahalle ve köylerde yapılaşmanın büyük ölçüde yüksek riskli alanlarda bulunduğu ortaya konmuştur. Bu durum, planlama ve afet yönetimi açısından gerekli önlemlerin alınmasının önemini göstermektedir.

Coşkunlu vd. (2014), Ladik ilçesinde yaptıkları çalışmada, jeolojik, jeofizik ve jeoteknik veriler CBS ortamında değerlendirilmiştir. Çalışma alanı, Kuzey Anadolu Fay Zonu üzerinde yer alması nedeniyle seçilmiştir. İlçede yapı envanteri oluşturulmuş, mikrotremor ölçümleri ile frekans, periyot ve büyütme haritaları hazırlanmıştır. Ayrıca sondaj ve jeofizik çalışmalarla zemin özellikleri belirlenmiş ve elde edilen veriler mikrobölgeleme çalışmalarında kullanılmıştır.

Keleş (2018) tarafından, Rize ili Güneysu havzasında yapılan çalışmada, sıg heyelan duyarlılığı Coğrafi Bilgi Sistemleri (CBS) tabanlı SINMAP modeli kullanılarak analiz edilmiştir. Jeolojik, jeomorfolojik ve hidrolojik veriler ile arazi ve laboratuvar çalışmaları birleştirilmiş, heyelan envanteri ile model kalibrasyonu yapılmıştır. Farklı infiltrasyon senaryolarına göre oluşturulan analizler sonucunda modelin yüksek doğrulukla (%97,2) heyelan duyarlılığını belirlediği ortaya konmuştur.

Özşahin ve Eroğlu (2019), Erzincan ilinde gerçekleştirilen çalışmada, yerel zemin koşullarının deprem duyarlılığı üzerindeki etkisinin belirlenmesi amaçlanmıştır. Coğrafi Bilgi Sistemleri (CBS) teknikleri kullanılarak frekans oranı yöntemi ile analizler yapılmış ve kentsel alanın deprem duyarlılık dağılımı değerlendirilmiştir. Çalışmada yerel zemin özelliklerinin deprem etkisini artırdığı ve bazı mahallelerin yüksek deprem duyarlılığına sahip olduğu belirlenmiştir. Elde edilen sonuçlar, Erzincan kentinin genel olarak yüksek deprem riski taşıdığını ortaya koymuş ve yeni yapılaşmalarda zemin koşullarının dikkate alınmasının zorunlu olduğunu göstermiştir.

Şengün vd. (2019), Elazığ ili Sivrice ilçesi Kürk Çayı Havzasının heyelan duyarlılık analizlerinin yapılması ve riskli alanları belirlemiştir. Çalışma alanı, geçmişte sık sık heyelanların meydana geldiği ve özellikle ulaşım ağlarını etkileyen Kalaba Köyü yolu çevresini kapsamaktadır. Analizlerde Google Earth görüntüleri, saha gözlemleri ve ArcGIS 10.5 programı kullanılmış; Coğrafi Bilgi Sistemleri (CBS) tabanlı Analitik Hiyerarşi Yöntemi (AHP) ve Ağırlıklı Çakıştırma yöntemi uygulanmıştır. Elde edilen sonuçlar doğrultusunda, litolojik yapı ve tektonik aktivitenin etkisiyle bazı bölgelerin yüksek heyelan riski taşıdığı belirlenmiş ve riskli alanlara yönelik öneriler geliştirilmiştir.

Kahya (2019) tarafından, Rize il merkezi ve yakın çevresinde gerçekleştirilen bu çalışmada, heyelan duyarlılık analizinin yapılması amacıyla Coğrafi Bilgi Sistemleri (CBS) ve Uzaktan Algılama (UA) teknikleri kullanılmıştır. Arazi çalışmaları ve uydu görüntülerinden elde edilen verilerle heyelan envanteri oluşturulmuş ve lojistik regresyon yöntemi ile duyarlılık haritası üretilmiştir. Analiz sonucunda alan çok az duyarlıdan çok yüksek duyarlıya kadar beş sınıfa ayrılmış, bölgenin büyük kısmının orta ve yüksek duyarlılıkta olduğu belirlenmiştir. Elde edilen sonuçlar, üretilen haritanın heyelan risk değerlendirmesinde kullanılabilir olduğunu göstermiştir.

Öncü (2021), Bursa ilinde deprem, heyelan, sel, orman yangını ve çığ tehlikeleri Coğrafi Bilgi Sistemleri (CBS) kullanılarak bütünleşik olarak analiz edilmiştir. Her bir tehlike için oluşturulan veriler çakıştırılarak bütünleşik doğal tehlike haritası üretilmiştir. Sonuçlar, yüksek riskli alanların özellikle Uludağ çevresi ile Bursa ve İnegöl ovalarında yoğunlaştığını göstermiştir.

Aydınoğlu ve Altürk (2021) yaptıkları çalışmada Rize ili Taşlıdere Havzası'nda sığ heyelanlara yönelik duyarlılık analizinin yapılması ve model performanslarının karşılaştırılması amaçlanmıştır. Çalışmada Coğrafi Bilgi Sistemleri (CBS) ortamında üretilen arazi kullanımı, litoloji, eğim, bakı, drenaj yoğunluğu, yol mesafesi gibi 15 farklı parametre girdi olarak kullanılmıştır. Heyelan duyarlılık haritaları Frekans Oranı (FO), Lojistik Regresyon (LR) ve Yapay Sinir Ağları (YSA) yöntemleri ile üretilmiş ve modellerin başarımı ROC eğrisi (AUC) ile değerlendirilmiştir. Elde edilen sonuçlara göre YSA en yüksek doğruluğu sağlarken, LR yöntemi de yüksek performans göstererek güvenilir bir alternatif olarak belirlenmiştir.

Ocak ve Bahadır (2022), Ladik Gölü Havzası'nda gerçekleştirdikleri çalışmada, deprem duyarlılık sınıflarının belirlenmesi amacıyla Coğrafi Bilgi Sistemleri ve Analitik Hiyerarşi Prosesi yöntemleri kullanılmıştır. Analizlerde eğim, litoloji, fay hatlarına uzaklık, maksimum yer ivmesi, yeryüzü şekilleri ve zemin özellikleri olmak üzere altı

coğrafi faktör dikkate alınmış ve bu faktörler AHP ile ağırlıklandırılarak CBS ortamında ağırlıklı çakıştırma analizi uygulanmıştır. Elde edilen sonuçlara göre çalışma alanı düşük, orta, yüksek ve çok yüksek olmak üzere dört deprem duyarlılık sınıfına ayrılmış; özellikle belirli alanların yüksek ve çok yüksek duyarlılığa sahip olduğu belirlenerek bölgenin önemli bir deprem riski potansiyeli taşıdığı ortaya konmuştur.

Demirel ve Hastaoğlu (2022) tarafından, Sivas'ın Koyulhisar ilçesinde gerçekleştirilen bu çalışmada, heyelan duyarlılığının belirlenmesi ve üretilen haritaların doğruluğunun değerlendirilmesi amacıyla Coğrafi Bilgi Sistemleri (CBS) tabanlı Analitik Hiyerarşi (AHP) yöntemi kullanılmıştır. Analizlerde eğim, litoloji, bakı, yükseklik, faylara uzaklık, topografik nemlilik indeksi, bitki örtüsü indeksi (NDVI), eğrisellik ve akarsuya bağlı çeşitli indeksler gibi çok sayıda parametre dikkate alınarak duyarlılık haritası oluşturulmuştur. Elde edilen sonuçlar, mevcut heyelan verileri ile karşılaştırılmış ve ROC eğrisi kullanılarak doğruluk analizi yapılmıştır. Analiz sonucunda elde edilen 0,73'lük eğri altı alan değeri, modelin orta düzeyde doğruluk sağladığını göstermiştir.

Çellek vd. (2015), heyelan duyarlılık analizlerinde Analitik Hiyerarşi Süreci (AHP) yönteminin kullanımına yönelik literatür değerlendirmesi yapılmış ve Sinop ve çevresi için heyelan duyarlılık haritası üretilmiştir. Analizlerde bakı, litoloji, arazi kullanımı, eğim, yükseklik, yamaç eğriselliği, anayola ve akarsuya uzaklık gibi heyelan oluşumunu etkileyen çok sayıda faktör dikkate alınmıştır. Bu faktörler CBS ortamında ağırlıklandırılarak grid haritalara dönüştürülmüş ve duyarlılık sınıfları oluşturulmuştur. Elde edilen sonuçlara göre çalışma alanının büyük bir kısmı orta ve yüksek derecede heyelan duyarlılığı gösterirken, düşük ve çok düşük duyarlılığa sahip alanların oranı daha az kalmıştır. Çalışma, AHP yönteminin heyelan duyarlılık analizlerinde yüksek performans sağlayan etkili bir yöntem olduğunu ortaya koymuştur.

Demir vd. (2022) tarafından, Van ili Erciş ilçesinde gerçekleştirilen bu çalışmada, çoklu tehlike analizi ile afet riski yüksek alanların belirlenmesi ve kentsel dirençliliğin artırılmasına yönelik öneriler geliştirilmesi amaçlanmıştır. Çalışmada, farklı afet türlerine ait veriler değerlendirilmiş, çok kriterli karar verme yöntemi kullanılarak analizler Coğrafi Bilgi Sistemleri (CBS) ortamında gerçekleştirilmiştir. Elde edilen sonuçlara göre ilçenin özellikle kuzey ve kuzeydoğu kesimleri ile Zilan Çayı çevresi ve Van Gölü kıyıları yüksek afet riski taşımaktadır. Çalışma, bu alanlarda risk azaltma önlemlerinin alınması, halkın bilinçlendirilmesi ve mekânsal planlama süreçlerinde bu risklerin dikkate alınmasının kentsel dirençliliğin artırılması açısından önemli olduğunu ortaya koymaktadır.

Güneş ve Kömüşçü (2025), Erzincan-Sivas karayolu ve çevresindeki heyelan duyarlılığının belirlenmesi amacıyla Coğrafi Bilgi Sistemleri (CBS) tabanlı Analitik Hiyerarşi Süreci (AHS) yöntemi kullanılmıştır. Analizlerde eğim, bakı, yükseklik, litoloji, fay hatlarına mesafe, akarsuya mesafe, anayola mesafe, yağış ve bitki yoğunluğu (NDVI) gibi faktörler dikkate alınarak AHS ile ağırlıklandırılmış ve CBS ortamında değerlendirilmiştir. Elde edilen sonuçlara göre çalışma alanında belirli kesimlerin yüksek ve çok yüksek heyelan duyarlılığına sahip olduğu, özellikle karayolu çevresinde riskin arttığı belirlenmiştir. Ayrıca, karayolundan uzaklaştıkça duyarlılığın azaldığı ortaya konmuş ve yüksek riskli alanlarda erken uyarı sistemlerinin kurulmasının gerekliliği vurgulanmıştır.

Taş vd. (2024) tarafından, Trabzon'un Of ilçesinde gerçekleştirilen bu çalışmada, heyelan riskinin belirlenmesi amacıyla Coğrafi Bilgi Sistemleri (CBS) tabanlı Analitik Hiyerarşi Süreci (AHS) yöntemi kullanılmıştır. Çalışmada, eğim, yükselti ve yüksek yağış gibi doğal faktörlerin etkisi altında bulunan alan için farklı ulusal ve uluslararası veri kaynaklarından elde edilen veriler değerlendirilerek heyelan risk haritası oluşturulmuştur. Analiz sonuçlarına göre çalışma alanının belirli bir kısmının riskli ve çok riskli, bir bölümünün orta, büyük bir kısmının ise düşük ve çok düşük risk sınıfında yer aldığı belirlenmiştir. Elde edilen bulgular, bölgenin heyelan potansiyelinin yüksek olduğunu ortaya koymakta ve afet yönetimi açısından gerekli önlemlerin alınması gerektiğini göstermektedir.

Partigöç ve Dinçer (2024), kentsel alanlarda afet risklerinin mekânsal olarak ortaya konulması amaçlanmıştır. Coğrafi Bilgi Sistemleri (CBS) araçları ve Ağırlıklı Çakıştırma yöntemi kullanılarak, doğal ve yapılı çevreye ait çeşitli faktörler değerlendirilmiştir. Analizler sonucunda ilin kuzeybatı kesiminin daha düşük riskli, merkez ve güney kesimlerinin ise daha yüksek afet riskine sahip olduğu belirlenmiştir. Elde edilen bulguların İl Afet Risk Azaltma Planı (İRAP) ve afet müdahale planlarıyla uyumlu olduğu görülmüş, çalışma sonuçlarının risk yönetimi ve mekânsal planlama açısından önemli bir girdi sunduğu ortaya konmuştur. mevcut tez çalışması, afet duyarlılığının değerlendirilmesinde farklı makine öğrenmesi algoritmalarını karşılaştırarak ve topografik, hidrolojik, jeolojik, iklimsel, sismik ve jeoteknik değişkenleri bütünleşik biçimde kullanarak literatürdeki bu eksikliğin giderilmesine katkı sağlamayı amaçlamaktadır.

Yıldız vd. (2024) tarafından, Bu çalışmada, geomekansal verilerin Coğrafi Bilgi Sistemleri (CBS) tabanlı yöntemlerle değerlendirilerek saha karakterizasyon çalışmalarında kullanımı ele alınmıştır. Çalışma kapsamında jeoteknik ve jeofizik

veriler birlikte değerlendirilmiş, zemin ve kaya birimlerinin fiziksel ve mekanik özelliklerinin derinliğe bağlı değişimi analiz edilmiştir. Elektrik rezistivite, sismik kırılma ve korozyon gibi farklı veri türleri kullanılarak zemin özellikleri görselleştirilmiş ve olası risk alanları belirlenmiştir. Elde edilen sonuçlar, geomekansal veri modelleme yaklaşımının heyelan analizi, zemin dayanımı değerlendirmesi ve mühendislik tasarım süreçlerinde etkili bir yöntem olduğunu ortaya koymuştur. mevcut tez çalışması jeofizik ve jeoteknik verileri yalnızca saha karakterizasyonu amacıyla değil, heyelan duyarlılığının modellenmesinde diğer çevresel ve topoğrafik faktörlerle bütünleşik olarak kullanmakta; farklı makine öğrenmesi algoritmalarını karşılaştırmakta ve SHAP analizi ile model sonuçlarının yorumlanabilirliğini artırmaktadır.

1.3. Çalışmanın Amacı ve Kapsamı

Bu tez çalışmasının amacı; Rize ili Çayeli ilçesinde çok kaynaklı çevresel, topoğrafik, hidrolojik, jeolojik, iklimsel ve sismik/jeoteknik verileri kullanarak makine öğrenmesi tabanlı heyelan duyarlılık modelleri geliştirmek; bu modelleri çapraz doğrulama ve bağımsız hold-out test seti ile değerlendirmek; model performanslarını karşılaştırmak; SHAP yöntemiyle değişken katkılarını açıklamak ve çalışma alanı için beş sınıflı heyelan duyarlılık haritaları üretmektir. Elde edilen sonuçların, Çayeli ilçesinde heyelan açısından öncelikli alanların belirlenmesine, arazi kullanım planlamasına, altyapı projelerinin risk açısından değerlendirilmesine ve afet risk azaltma çalışmalarına katkı sağlaması beklenmektedir.

Literatürde afet duyarlılık çalışmalarında genellikle eğim, litoloji, arazi kullanımı ve fay hatlarına uzaklık gibi klasik CBS tabanlı parametrelerin kullanıldığı görülmektedir. Son yıllarda ise yerel zemin davranışını daha doğru temsil edebilmek amacıyla jeofizik ve jeoteknik verilerin bu modellere entegre edilmesine yönelik çalışmalar artış göstermiştir. Özellikle Vs hızları, dinamik elastik parametreler ve mikrotremor verilerinin deprem davranışının belirlenmesinde önemli parametreler olduğu birçok araştırmada ortaya konulmuştur (Akin ve Sayil, 2025). Bu parametrelerin CBS tabanlı heyelan duyarlılık analizlerinde birlikte ve bütüncül şekilde kullanıldığı çalışmaların sayısı sınırlıdır. Bu çalışma, klasik CBS parametreleri ile jeofizik ve jeoteknik verileri bütünleşik biçimde değerlendirerek literatürdeki bu eksikliğe katkı sağlamayı amaçlamaktadır. Bu yönüyle çalışma; yerel zemin koşullarını doğrudan dikkate alan, daha gerçekçi ve güvenilir afet duyarlılık modellerinin geliştirilmesine katkı sunacak niteliktedir.

1.4. Çalışmanın Önemi

Doğu Karadeniz Bölgesi, topoğrafik eğimin yüksek olması, yoğun yağış rejimi, karmaşık jeolojik yapı ve aktif tektonik özellikleri nedeniyle Türkiye'nin doğal afetler açısından en hassas alanlarından biri olarak değerlendirilmektedir (Gökçe vd., 2008). Özellikle kıyı kuşağında yer alan yerleşim alanlarında heyelan, kaya düşmesi, sel, taşkın ve deprem kaynaklı zemin problemleri sıkça görülmekte; bu durum can ve mal kayıplarının yanında ciddi ekonomik ve çevresel sorunlara neden olmaktadır (Karsli vd., 2009; Çömert vd., 2025). Bu afetlerin oluşumunda yalnızca yüzeysel morfolojik koşullar değil, aynı zamanda zeminin jeoteknik ve jeofizik özellikleri de belirleyici rol oynamaktadır (Karsli ve Yalcin., 2009). Bu nedenle afet duyarlılık çalışmalarında yalnızca coğrafi bilgi sistemleri (CBS) tabanlı yüzey parametrelerinin kullanılması çoğu zaman yeterli olmamakta; zeminin dinamik davranışını ortaya koyan jeofizik verilerin de değerlendirilmesi gerekmektedir (Karsli ve Yalcin., 2009)

Çayeli ilçesi, Doğu Karadeniz kıyı kuşağında yer almakta olup yoğun yağış, dik topoğrafya ve yerleşim baskısı nedeniyle afet riski yüksek alanlardan biridir. İlçede özellikle heyelan, sel-taşkın ve zemin kaynaklı mühendislik problemleri yaygın olarak gözlenmektedir. Ayrıca bölgenin tektonik olarak aktif zonlara yakın konumu, deprem etkilerinin zemin koşullarına bağlı olarak büyüyebilme potansiyelini artırmaktadır. Bu bağlamda çalışma alanında gerçekleştirilecek jeofizik tabanlı afet duyarlılık analizleri, hem yerleşim güvenliği hem de sürdürülebilir arazi kullanım planlaması açısından önem taşımaktadır.

Bu tez çalışmasında, sismik yöntemlerden elde edilen hız parametreleri, bu verilere bağlı olarak hesaplanan dinamik elastik parametreler, mikrotremor ölçümleri ve sondaj verileri birlikte değerlendirilerek zemin özelliklerine dayalı bütünlüklü afet duyarlılık ve risk haritalarının oluşturulması amaçlanmaktadır. Böylece klasik CBS tabanlı yaklaşımların ötesine geçilerek, zeminin dinamik davranışını dikkate alan daha gerçekçi ve mühendislik temelli bir model ortaya konulacaktır.

1.5. Problem Tanımı

Çayeli ilçesinde yoğun yağış, eğimli topoğrafya ve karmaşık jeolojik yapı nedeniyle afet riski oldukça yüksektir. Özellikle kontrolsüz yapılaşma ve uygun olmayan zemin koşullarında gerçekleştirilen mühendislik uygulamaları, doğal afetlerin etkisini artırmaktadır. Bölgede meydana gelen heyelan, taşkın ve zemin oturmaları, mevcut yerleşim alanları açısından önemli riskler oluşturmaktadır. Bununla birlikte, mevcut afet duyarlılık çalışmalarının büyük bölümü yüzeysel morfolojik parametrelere

dayalı olup zeminin dinamik davranışını yeterince temsil etmemektedir. Deprem sırasında zeminin göstereceği büyütme etkisi, zemin rijitliği, kayma direnci ve elastik özellikler gibi parametreler çoğu çalışmada dikkate alınmamaktadır. Bu durum, özellikle yerel zemin etkilerinin belirlenmesinde önemli belirsizliklere neden olmaktadır.

Bu tez kapsamında çözülmesi hedeflenen temel problem; Çayeli ilçesinde farklı jeofizik ve jeoteknik veri setlerinin birlikte kullanılmasıyla zeminin mühendislik davranışını daha doğru temsil eden bütünleşik bir afet duyarlılık modelinin oluşturulmasıdır. Böylece klasik CBS tabanlı modellerin sınırlılıklarının azaltılması ve daha güvenilir risk değerlendirmelerinin yapılması amaçlanmaktadır.

2. TEORİK TEMELLER

2.1. Afet Duyarlılığı ve Risk Kavramı

Afetler; doğal, teknolojik veya insan kaynaklı süreçler sonucunda meydana gelen, toplumların sosyal, ekonomik ve fiziksel yapıları üzerinde ciddi kayıplara neden olan olaylar olarak tanımlanmaktadır. Günümüzde afet yönetimi anlayışı yalnızca afet sonrası müdahaleyi değil, afet öncesi risk azaltma çalışmalarını da kapsayan bütünlüklü bir yaklaşım haline gelmiştir (UNDRR, 2015; AFAD, 2014). Bu nedenle afetlerin oluşum mekanizmalarının, etkileyen faktörlerin ve risk bileşenlerinin doğru şekilde değerlendirilmesi önem taşımaktadır. Afet riskinin belirlenmesinde temel olarak tehlike, maruziyet ve zarar görebilirlik kavramları birlikte ele alınmaktadır (UNDRR, 2015).

Afet duyarlılığı; belirli bir alanda doğal veya insan kaynaklı afetlerin meydana gelme olasılığına karşı ortamın gösterdiği hassasiyet düzeyini ifade etmektedir. Duyarlılık analizleri, afetlerin oluşumunu etkileyen fiziksel, çevresel ve mühendislik parametrelerinin değerlendirilmesiyle gerçekleştirilmektedir. Özellikle deprem, heyelan ve sıvılaşma gibi zemin koşullarına bağlı afetlerde; litoloji, topoğrafya, yeraltı suyu, jeolojik yapı ve zemin özellikleri önemli rol oynamaktadır. Bu nedenle afet duyarlılık çalışmalarında CBS, uzaktan algılama, jeofizik ve jeoteknik verilerin birlikte kullanılması yaygınlaşmıştır (Aleotti ve Chowdhury, 1999).

Afet riski ise genel olarak; belirli bir tehlikenin meydana gelme olasılığı ile bu tehlikeye maruz kalan unsurların zarar görebilirlik düzeylerinin birleşimi sonucu ortaya çıkan olası kayıplar olarak tanımlanmaktadır (UNDRR,2017). Risk kavramı yalnızca afetin oluşma ihtimalini değil, aynı zamanda insanların, yapıların, altyapının ve çevresel unsurların bu olaydan ne ölçüde etkilenebileceğini de kapsamaktadır (UNDRR, 2015). Bu bağlamda afet riskinin değerlendirilmesinde temel bileşenler olan tehlike, maruziyet ve zarar görebilirlik kavramları büyük önem taşımaktadır (UNDRR, 2015; AFAD, 2014).

Tehlike (Hazard): Tehlike; can, mal, çevre ve ekonomik kayıplara neden olabilecek doğal veya insan kaynaklı olayların meydana gelme potansiyeli olarak tanımlanmaktadır (UNISDR, 2009). Deprem, heyelan, taşkın, volkanizma ve tsunami gibi doğal olaylar afet tehlikeleri arasında yer almaktadır. Ancak bir olayın afet olarak değerlendirilebilmesi için yalnızca tehlikenin varlığı yeterli değildir; aynı zamanda bu tehlikeye maruz kalan unsurların bulunması gerekmektedir (UNDRR, 2015). Zemin

temelli afet çalışmalarında tehlike kavramı çoğunlukla deprem hareketleri, sıvılaşma potansiyeli, heyelan oluşumu ve zemin büyütmesi gibi süreçlerle ilişkilidir. Özellikle aktif fay hatlarına yakınlık, litolojik özellikler, topoğrafik eğim ve yerel zemin koşulları tehlikenin düzeyini doğrudan etkileyen faktörlerdir. Bu nedenle afet duyarlılık analizlerinde tehlike parametrelerinin doğru belirlenmesi, risk değerlendirmesinin en önemli aşamalarından birini oluşturmaktadır.

Maruziyet (Exposure): Bu kavram; insanların, yapıların, altyapının, ekonomik faaliyetlerin veya çevresel unsurların tehlike etkisine açık durumda bulunmasını ifade etmektedir (Cardona, 2003). Başka bir ifadeyle maruziyet, afet tehlikesinin etkileyebileceği nüfus, yapı stoku ve fiziksel unsurların mekânsal dağılımını kapsamaktadır. Bir bölgede tehlike düzeyi yüksek olsa bile, eğer bölgede yerleşim veya ekonomik faaliyet bulunmuyorsa afet riski düşük olabilmektedir. Buna karşılık yoğun nüfuslu ve plansız yapılaşmanın bulunduğu alanlarda maruziyet düzeyi artmakta ve afetlerin etkileri daha yıkıcı hale gelmektedir. Özellikle hızlı kentleşme süreçleri, düzensiz yapılaşma ve yanlış arazi kullanımı maruziyetin artmasına neden olan temel faktörler arasında yer almaktadır (UNDRR, 2015).

CBS tabanlı afet çalışmalarında nüfus yoğunluğu, yerleşim alanları, ulaşım ağları ve kritik altyapılar maruziyet analizlerinde yaygın olarak kullanılan parametrelerdir (Wang ve Sassa, 2005; UNDRR, 2015). Böylece afetlerden etkilenebilecek unsurların mekânsal dağılımı belirlenebilmekte ve risk yönetimi çalışmalarına katkı sağlanmaktadır (UNISDR, 2009).

Zarar Görebilirlik (Vulnerability): Bir toplumun, yapının veya sistemin tehlike karşısında zarar görmeye yatkınlık düzeyi ‘Zarar görebilirlik’ olarak tanımlanmaktadır (Birkmann, 2013). Bu kavram fiziksel, sosyal, ekonomik ve çevresel bileşenleri içermektedir. Özellikle mühendislik açısından değerlendirildiğinde zemin özellikleri, yapı kalitesi, yapılaşma türü ve altyapı durumu zarar görebilirliği belirleyen temel unsurlar arasında yer almaktadır. Deprem sırasında gevşek zeminler, yüksek yeraltı su seviyesi, düşük taşıma gücü ve yüksek zemin büyütmesi gibi özellikler zarar görebilirliği artırmaktadır. Bu nedenle jeofizik ve jeoteknik çalışmalarla elde edilen sismik hızlar, dinamik elastik parametreler ve mikrotremor verileri, zeminlerin zarar görebilirlik düzeylerinin belirlenmesinde önemli rol oynamaktadır. Afet riskinin azaltılabilmesi için yalnızca tehlikenin belirlenmesi yeterli olmayıp, aynı zamanda maruziyet ve zarar görebilirlik düzeylerinin de azaltılması gerekmektedir. Bu nedenle günümüzde afet yönetiminde bütünlük risk analizleri ön plana çıkmakta ve CBS tabanlı çok kriterli değerlendirme yöntemleri yaygın olarak kullanılmaktadır.

2.2. Zemin Davranışı ve Afet İlişkisi

Zemin davranışı, özellikle deprem gibi dinamik kuvvetler altında zeminin gösterdiği fiziksel ve mekanik tepkiyi ifade etmektedir. Deprem dalgalarının yeryüzüne ulaşmasıyla birlikte zemin tabakalarının litolojik özellikleri, yoğunlukları, suya doygunluk durumları ve elastik parametreleri doğrultusunda farklı tepkiler vermesi, yerel zemin koşullarının afet şiddetini doğrudan etkilemesine neden olmaktadır. Bu nedenle zemin davranışı, afet mühendisliği ve deprem tehlike analizlerinde kritik bir bileşen olarak değerlendirilmektedir (Kramer, 2003).

Zemin Büyütmesi: Zemin büyütmesi, deprem dalgalarının zayıf veya yumuşak zemin tabakalarından geçerken genliklerinin artmasıdır. Bu durum, özellikle düşük kayma dalgası hızına (V_s) sahip gevşek alüvyal zeminlerde daha belirgin şekilde ortaya çıkmaktadır. Ana kaya seviyesinden yüzeye doğru ilerleyen sismik dalgalar, zemin tabakalarının dinamik özelliklerine bağlı olarak enerji birikimi yaşamakta ve yer yüzeyinde daha büyük yer hareketlerine neden olabilmektedir.

$$V_s = \sqrt{\frac{G}{\rho}} \quad (1)$$

Burada kayma dalgası hızı (V_s), zeminin kayma modülü (G) ve yoğunluğu (ρ) ile ilişkilidir. Düşük V_s değerleri genellikle yüksek zemin büyütme potansiyeline işaret etmektedir. Bu durum, yapıların maruz kalacağı deprem yüklerini artırarak hasar riskini yükseltmektedir. Literatürde zemin büyütmesinin özellikle mikrotremor çalışmaları ve spektral oran yöntemleri ile etkin şekilde belirlendiği görülmektedir (Nakamura, 1989; Bard, 1999).

Sıvılaşma: Sıvılaşma, suya doygun, gevşek ve granüler zeminlerin deprem etkisi altında ani dayanım kaybına uğrayarak sıvı gibi davranması olayıdır. Bu durum, boşluk suyu basıncının artması ve efektif gerilmenin azalması sonucu meydana gelmektedir. Sıvılaşma, özellikle kumlu ve siltli zeminlerde, yeraltı su seviyesinin yüksek olduğu bölgelerde önemli bir mühendislik problemi oluşturmaktadır.

$$\sigma' = \sigma - u \quad (2)$$

Burada efektif gerilme (σ'), toplam gerilme (σ) ile boşluk suyu basıncı (u) arasındaki fark olarak tanımlanmaktadır. Deprem sırasında boşluk suyu basıncının artması, efektif gerilmenin sıfıra yaklaşmasına ve zeminin taşıma kapasitesini

kaybetmesine neden olmaktadır. Bu durum yapılar için oturma, devrilme ve yan yatma gibi ciddi hasarlara yol açabilmektedir (NASEM, 2021).

Kayma Direnci: Kayma direnci, zeminin kayma deformasyonuna karşı gösterdiği dayanımı ifade etmektedir ve zemin stabilitesinin temel belirleyicilerinden biridir. Mohr-Coulomb kırılma kriterine göre kayma direnci, kohezyon (c) ve içsel sürtünme açısı (ϕ) ile tanımlanmaktadır.

$$\tau = c + \sigma' \tan \phi \quad (3)$$

Burada τ kayma dayanımını, σ' efektif gerilmeyi, c kohezyonu ve ϕ içsel sürtünme açısını ifade etmektedir. Kayma direncinin düşük olduğu zeminlerde deprem etkisiyle birlikte stabilite kaybı meydana gelmekte ve özellikle eğimli arazilerde heyelan riski artmaktadır. Bu nedenle kayma direnci parametreleri, zemin temelli afet duyarlılık çalışmalarında kritik bir rol oynamaktadır.

Genel olarak değerlendirildiğinde, zemin büyütmesi, sıvılaşma ve kayma direnci gibi parametreler, zeminin deprem davranışını doğrudan etkileyen temel mekanizmalar olup, afet riskinin belirlenmesinde kritik öneme sahiptir. Bu parametrelerin jeofizik, jeoteknik ve CBS tabanlı analizlerle birlikte değerlendirilmesi, daha güvenilir afet duyarlılık modellerinin oluşturulmasına olanak sağlamaktadır.

2.3. Jeofizik-Jeoteknik Veriler ve CBS Tabanlı Afet Duyarlılık Modeline Entegrasyonu

Bu çalışmada jeofizik ve jeoteknik veriler, Çayeli ilçesinde gerçekleştirilen toplam 55 adet jeolojik ve jeoteknik çalışmaya ait verilerden elde edilmiştir. Bu çalışmalar kapsamında sismik kırılma, MASW (Multichannel Analysis of Surface Waves) ve mikrotremor ölçümlerinden elde edilen jeofizik parametreler değerlendirilmiş ve çalışma alanının heyelan duyarlılığının modellenmesinde kullanılmıştır. Bu yöntemler, yeraltı zemin özelliklerinin doğrudan gözlenemediği durumlarda zeminin fiziksel, mekanik ve dinamik davranışını ortaya koymak için kullanılan temel jeofizik tekniklerdir. Özellikle deprem kaynaklı yer hareketinin zemin tarafından nasıl değiştirildiğinin anlaşılmasında kritik rol oynamaktadır (Kramer, 2003). Elde edilen veriler yalnızca zemin özelliklerinin tanımlanmasında değil, aynı zamanda CBS tabanlı afet duyarlılık modeline doğrudan sayısal girdi parametrelerinin üretilmesinde kullanılmaktadır.

Sismik kırılma ve MASW yöntemleri, zeminin sismik dalgalara verdiği tepkiyi ortaya koyarak P-dalgası (V_p) ve S-dalgası (V_s) hızlarının belirlenmesini sağlamaktadır. Özellikle S-dalgası hızı, zeminin rijitliğini ve deprem etkisi altındaki davranışını temsil eden en temel parametrelerden biridir. Kayma dalgası hızı (V_s) değerleri kullanılarak zeminin dinamik özellikleri doğrudan sayısallaştırılabilmektedir. Bu sismik verilerden hareketle zeminin mekanik davranışını tanımlayan dinamik elastik parametreler hesaplanmaktadır. Kayma modülü (G), Young modülü (E), hacim modülü (K) ve Poisson oranı (ν) bu kapsamda elde edilen temel parametrelerdir. Kayma modülü, zeminin rijitliğini doğrudan ifade etmekte ve V_s ile yoğunluk ilişkisi üzerinden tanımlanmaktadır. Young ve hacim modülleri ise zeminin deformasyon davranışını ve hacimsel tepkisini temsil etmektedir. Bu parametreler özellikle deprem yükleri altında zeminin ne kadar deformasyona uğrayacağını ve ne düzeyde dayanım göstereceğini ortaya koyması açısından afet duyarlılık analizlerinde kritik öneme sahiptir.

Mikrotremor yöntemi ise zeminin doğal titreşim özelliklerinin belirlenmesinde kullanılmaktadır. H/V spektral oran yaklaşımı ile zeminin hakim periyot (T_0) ve büyütme özellikleri elde edilmektedir. Nakamura Method yaklaşımı, özellikle yerel zemin etkilerinin belirlenmesinde yaygın olarak kullanılan bir yöntemdir. Hakim periyot değerleri yapı-zemin rezonans riskini ortaya koyarken, büyütme katsayıları deprem dalgalarının yer yüzeyinde ne ölçüde şiddetlendiğini göstermektedir.

Jeoteknik açıdan sondaj verileri, bu çalışmada yalnızca zeminin litolojik özelliklerinin belirlenmesi amacıyla kullanılmaktadır. Sondaj loglarından elde edilen veriler ile çalışma alanındaki zemin tabakalaşması, litolojik birimlerin düşey ve yatay sürekliliği, ayrışma derecesi ve litolojik geçişler ortaya konulmaktadır. Özellikle heterojen alüvyal ortamlarda farklı litolojik birimlerin değişken dağılımı, zemin davranışını doğrudan etkilediğinden sondaj verileri, jeofizik yöntemlerden elde edilen dolaylı zemin parametrelerinin doğrulanmasında kritik bir kontrol verisi olarak değerlendirilmektedir. Güncel çalışmalar, jeofizik yöntemler ile sondaj loglarının birlikte kullanılmasının zemin-yapı modellemesinde daha güvenilir sonuçlar verdiğini ve yeraltı litolojik sınırların daha doğru tanımlanmasını sağladığını göstermektedir (Ertekin ve Ulugergerli, 2022; Akingboye ve Bery, 2023). Bu bütünsel yaklaşım, zemin modelinin jeolojik açıdan tutarlı hale getirilmesine ve mühendislik değerlendirmelerinin doğruluk seviyesinin artırılmasına katkı sağlamaktadır.


Elde edilen tüm jeofizik ve jeoteknik veriler CBS ortamına aktarılmakta ve mekânsal analizlere uygun hale getirilmektedir. Noktasal ölçüm verileri uygun enterpolasyon yöntemleri kullanılarak sürekli yüzeylere dönüştürülmekte ve V_s

dağılımı, dinamik elastik parametreler, hakim periyot ve zemin büyütme gibi tematik haritalar oluşturulmaktadır. Bu katmanlar, eğim, jeoloji, arazi kullanımı ve fay hatlarına uzaklık gibi klasik CBS parametreleri ile birlikte değerlendirilerek çok kriterli analiz yöntemleri ile afet duyarlılık modeli oluşturulmaktadır. Bu süreçte parametrelerin ağırlıklandırılması literatür bilgisi ve uzman görüşlerine dayalı olarak yapılmakta ve her bir değişkenin afet oluşumu üzerindeki etkisi sayısal olarak modellenmektedir.

3. ÇALIŞMA ALANINA AİT GENEL BİLGİLER

3.1. Coğrafi Konum


Çalışma alanı olarak seçilen Çayeli ilçesi, Türkiye'nin Karadeniz Bölgesi'nde yer alan Rize iline bağlıdır ve yaklaşık 40°22' – 40°34' kuzey enlemi ile 40°36' – 41°09' doğu boylamları arasında konumlanmaktadır (Şekil 1). İlçe; kuzeyde Karadeniz kıyısına dayanmakta, güneyinde Kavrun ve İkizdere geçitleriyle Rize merkeze, doğusunda Ardeşen ve batısında Rize merkez ilçesiyle sınır oluşturmaktadır. Yaklaşık 550 km² yüzey alanına sahip ilçe, karakteristik bir Karadeniz topoğrafyasına; kıyı şeridinden hızla yükselen dağlık iç bölgelere, derin vadilere ve çok sayıda dere koluna sahiptir. İlçe genelinde deniz seviyesinden sarp yamaçlarla yükselen arazi, yer yer 3.000 m'yi aşan zirvelere ulaşmaktadır. Bu yükselti farkının kısa yatay mesafelerde gerçekleşmesi; hem yüksek eğim değerleri hem de güçlü akarsu erozyon dinamiğiyle karakterize edilen bir jeomorfik ortam yaratmaktadır. İlçe merkezinin yaklaşık 5 m rakımda deniz kıyısına konumlanmasına karşın 10 km iç kesimlerde 2.000 m'yi aşan yükseltiler gözlemlenmektedir (T.C. Rize Valiliği, 2022).



Şekil 1. Çalışma alanının yer bulduru haritası

3.2. Jeoloji

Çayeli (Rize) ilçesi, Doğu Karadeniz Bölgesi'nin jeolojik olarak en karmaşık alanlarından biri olan Doğu Pontid Tektonik Birliği içerisinde yer almaktadır. Bu birlik, Alp-Himalaya orojenik kuşağının bir parçası olup, Neo-Tetis okyanusunun kapanmasına bağlı olarak gelişen volkanik, sedimanter ve metamorfik kayaç topluluklarından oluşmaktadır (Bozkurt, 2001; MTA, 2011). Bölgenin temel jeolojik yapısını Üst Kretase–Paleosen yaşlı volkanik kayaçlar oluşturmaktadır. Bu birimler çoğunlukla andezit, bazalt, dasit, tuf ve piroklastik kayaçlardan meydana gelmekte olup, yoğun volkanik aktivite sonucu oluşmuşlardır. Söz konusu volkanik birimler, yer yer hidrotermal alterasyona uğramış ve bu süreç sonucunda kayaçların mineralojik ve fiziksel özelliklerinde önemli değişimler meydana gelmiştir (MTA, 2011).



Şekil 2. Rize ilinin 1/100.000 ölçekli jeoloji haritası (Tüysüz vd., 2008).


Volkanik birimlere ek olarak bölgede volkano-sedimanter istifler de yaygın olarak gözlenmektedir. Bu birimler genellikle kumtaşı, şeyl ve kiltası gibi kırıntılı tortul kayalardan oluşmakta olup, tabakalı ve zayıf dayanımlı yapıları nedeniyle mühendislik jeolojisi açısından önemli zayıflık zonları oluşturmaktadır. Özellikle kil ve şeyl seviyeleri, suya doymun hale geldiklerinde kayma dayanımlarının önemli ölçüde azalmasına neden olmaktadır (Gökçeoğlu ve Sezer, 2012). Çayeli çevresinde metamorfik kayalar da geniş alanlarda yüzeylemektedir. Şist, gnays ve amfibolit türü kayalar, bölgenin yüksek derecede tektonik deformasyona uğramış eski temelini oluşturmaktadır. Bu birimler genellikle foliasyonlu yapıda olup, ayrışma süreçlerine bağlı olarak yüzeyde zayıf mühendislik özellikleri sergileyebilmektedir. Bölgedeki önemli jeolojik unsurlardan biri de intrüzif kayalardır. Granitik ve diyoritik sokulumlar, özellikle derin seviyelerde gözlenmekte olup, çevre kayalarla olan dokanak zonlarında kontakt metamorfizma etkileri görülmektedir. Bu durum, kaya kütlesi dayanımında lokal değişimlere neden olmaktadır (Şekil 2).

Çayeli ve çevresinde kayaçların önemli bir kısmı yoğun tektonik deformasyon ve hidrotermal alterasyon süreçlerine maruz kalmıştır. Bu süreçler sonucunda kayaçların büyük bölümü yüzeyde ileri derecede ayrılmış ve zemin-kaya geçiş zonları oldukça geniş alanlara yayılmıştır. Bu durum, özellikle mühendislik jeolojisi açısından zemin heterojenliğini artırmakta ve zayıf zemin koşullarının oluşmasına neden olmaktadır. Ayrıca Çayeli-Madenköy çevresinde Üst Kretase yaşlı volkanik kayaçlar içerisinde gelişmiş masif sülfür (Cu-Zn) cevherleşmeleri bulunmaktadır. Bu cevherleşmeler, bölgedeki hidrotermal sistemlerin ve volkanik aktivitenin önemli bir göstergesi olup, jeolojik evrimin madenleşme süreçleri ile birlikte değerlendirildiğini göstermektedir (Altun, 1977).

Sonuç olarak Çayeli ilçesi, litolojik çeşitliliğin yüksek olduğu, tektonik olarak yoğun deformasyon geçirmiş ve hidrotermal alterasyonun yaygın olduğu karmaşık bir jeolojik yapıya sahiptir. Bu durum, bölgenin hem doğal afet duyarlılığı hem de mühendislik jeolojisi açısından yüksek risk potansiyeline sahip olmasına neden olmaktadır.

3.3. Tektonik Yapı

Çayeli (Rize) ilçesi, Türkiye'nin en aktif tektonik kuşaklarından biri olan Doğu Pontid Tektonik Birliği içerisinde yer almaktadır. Bu birlik, Alp-Himalaya orojenik kuşağının bir parçası olup, Neo-Tetis okyanusunun kapanmasına bağlı olarak gelişen çarpışma, dalma-batma ve çökme süreçleri sonucunda şekillenmiştir (Bozkurt, 2001; Okay ve Şahintürk, 1997). Bu tektonik evrim (Şekil 3), bölgedeki kayaçların yoğun deformasyona uğramasına, karmaşık yapısal ilişkilerin gelişmesine ve çok sayıda kırık sisteminin oluşmasına neden olmuştur. Doğu Karadeniz Bölgesi genelinde olduğu gibi Çayeli çevresinde de tektonik yapı, başlıca KD-GB (kuzeydoğu-güneybatı) ve KB-GD (kuzeybatı-güneydoğu) doğrultulu fay ve kırık sistemleri tarafından kontrol edilmektedir. Bu yapısal doğrultular, hem bölgesel ölçekli deformasyonun hem de yerel ölçekli jeomorfolojik şekillenmenin temel belirleyicilerindendir. Özellikle vadi sistemlerinin yönelmesi, akarsu ağlarının gelişimi ve yamaç eğimlerinin dağılımı büyük ölçüde bu yapısal kontrol ile ilişkilidir (MTA, 2011).



Şekil 3. Anadolu plakasının tektonik haritası ve Rize civarında günümüze kadar meydana gelen bölgesel depremlerin dağılımı (Şaroğlu vd.,1992).

Bölgedeki tektonik yapı, farklı yaş ve kökene sahip kayaç birimlerinin yoğun kıvrımınma, kırılınma ve bindirme süreçlerine maruz kalması sonucu oldukça karmaşık bir karakter kazanmıştır. Bu deformasyonlar sonucunda kaya kütlelerinde süreksizlik yoğunluğu artmış, eklem (joint) sistemleri gelişmiş ve kaya kütlelerinin bloklu bir yapı kazanmasına neden olmuştur. Bu durum, özellikle mühendislik jeolojisi açısından kaya kütle dayanımını olumsuz etkileyen önemli bir faktördür. Çayeli ve çevresi, günümüzde aktif tektonik hareketlerin doğrudan etkisi altında olmamakla birlikte, Doğu Anadolu Fayı ve Kuzey Anadolu Fay Sistemi gibi büyük ölçekli aktif fay zonlarının bölgesel gerilme alanlarından dolayı olarak etkilenmektedir. Bu durum, bölgede düşük–orta şiddetli sismik aktivitenin zaman zaman gözlenmesine neden olmaktadır (AFAD, 2023).

Tektonik yapı aynı zamanda zemin davranışı üzerinde de önemli etkilere sahiptir. Kırıklı ve çatlaklı kaya birimlerinin yaygın olması, sismik dalgaların yayılım hızında heterojenliğe neden olmakta ve yerel zemin büyütmesi etkisini artırabilmektedir. Ayrıca fay zonlarına yakın alanlarda zemin zayıflaması, geçirgenlik artışı ve suya doygunluk gibi mühendislik açısından kritik problemler ortaya çıkabilmektedir. Bununla birlikte, tektonik deformasyonun uzun jeolojik zaman ölçeğinde oluşturduğu yapısal zayıflık

zonları, bölgedeki heyelan duyarlılığının artmasında da önemli rol oynamaktadır. Özellikle süreksizlik düzlemlerinin yamaç eğimleri ile uyumlu olduğu alanlarda kütle hareketleri daha sık gözlenmektedir. Sonuç olarak Çayeli ilçesi, yoğun tektonik deformasyona uğramış, kırıklı ve fay kontrollü bir jeolojik yapıya sahip olup, bu yapı hem zemin özelliklerini hem de doğal afet duyarlılığını doğrudan etkilemektedir.

3.4. Jeomorfoloji

Çayeli (Rize) ilçesi, Doğu Karadeniz Bölgesi'nin karakteristik topoğrafik özelliklerini yansıtan genç ve dinamik bir jeomorfolojik yapıya sahiptir. Bölgenin mevcut morfolojisi; tektonik hareketler, litolojik özellikler, flüvyal süreçler ve yoğun yağış rejiminin birlikte etkisiyle şekillenmiştir. Doğu Karadeniz Bölgesi, Türkiye'nin topoğrafik enerjisi en yüksek alanlarından biri olup, kıyıya paralel uzanan dağ sıraları nedeniyle kısa mesafelerde büyük yükselti farkları göstermektedir (Emre vd., 2018). Çayeli ilçesinde de kıyı kesiminden itibaren topoğrafya hızla yükselmekte ve iç kesimlerde 2000 m'nin üzerine ulaşan dağlık alanlar gelişmektedir. İlçenin kuzey kesiminde dar bir kıyı kuşağı yer almakta, güney kesimlerde ise oldukça eğimli yamaçlar hâkim olmaktadır. Doğu Karadeniz Bölgesi'nde eğim değerlerinin yüksek olması yüzey akışını hızlandırmakta ve aşınım süreçlerini önemli ölçüde artırmaktadır (Dağ ve Bulut, 2012). Çayeli'nde topoğrafik eğimin fazla olması, yüzeysel akışın kısa sürede yoğunlaşmasına ve akarsu aşındırmasının etkili olmasına neden olmaktadır.

Bölgedeki akarsular kısa boylu, yüksek eğimli ve hızlı akış karakterine sahiptir. Doğu Karadeniz Havzası'ndaki akarsu sistemleri genç jeomorfolojik özellik göstermekte ve yüksek aşındırma gücüne sahip bulunmaktadır (DSİ, 2021). Çayeli çevresindeki akarsular zaman içerisinde dar ve derin vadiler oluşturarak topoğrafyanın şekillenmesinde önemli rol oynamıştır. Vadilerin büyük kısmı "V" profilli olup, flüvyal aşındırmanın aktif olarak devam ettiğini göstermektedir. Bölgenin jeomorfolojik gelişiminde kütle hareketleri önemli yer tutmaktadır. Doğu Karadeniz Bölgesi, Türkiye'de heyelan olaylarının en sık görüldüğü alanlardan biridir (AFAD, 2023). Çayeli ilçesinde yüksek eğim, yoğun yağış ve ayrılmış kayaç yapısının birlikte bulunması heyelan oluşumunu kolaylaştırmaktadır. Özellikle ayrılmış volkanik kayaçlar, kil içeriği yüksek seviyeler ve süreksizlik düzlemleri boyunca gelişen zayıf zonlar heyelanların yoğunlaştığı alanları oluşturmaktadır.

Heyelan duyarlılığını belirleyen temel faktörler eğim, litoloji, drenaj yoğunluğu ve yağış olarak ifade edilmektedir (Gökçeoğlu ve Ercanoğlu, 2001). Çayeli'nde de topoğrafik eğimin yüksek olduğu ve yüzeysel ayrışmanın yoğun geliştiği alanlarda

heyelan olayları sık gözlenmektedir. Özellikle uzun süreli yağış sonrasında zeminin suya doymuş hale gelmesi, kayma direncini azaltarak yamaç stabilitesinin bozulmasına neden olmaktadır. Çayeli çevresinde yamaçlar üzerinde yaygın şekilde kolüvyal örtü gelişmiştir. Bu örtü genellikle ayrılmış kaya parçaları, bloklu malzeme, kil ve silt boyutundaki ince taneli zeminlerden oluşmaktadır. Kolüvyal birimler topoğrafik koşullara bağlı olarak farklı kalınlıklarda bulunmakta olup, yağışlı dönemlerde su içeriğinin artması sonucu stabilitesini kaybedebilmektedir. Bu durum bölgede yüzeysel kaymaların sık görülmesine neden olmaktadır. Akarsu vadileri boyunca ise alüvyal birikimler gelişmiştir. Dere yatakları ve kıyı kesimlerinde gözlenen bu alüvyal alanlar gevşek yapılı, yüksek boşluk oranına sahip ve suya doymuş zeminlerden oluşmaktadır. Bu tür zeminler mühendislik özellikleri açısından problemli olup taşkın ve oturma açısından risk taşımaktadır. Ani yağışlar sonrasında dere yataklarında hızlı debi artışları meydana gelmekte ve bu durum taşkın riskini artırmaktadır (DSİ, 2021). Çayeli'nin kıyı kesimlerinde denizel süreçlerin etkisiyle sınırlı düzlük alanlar gelişmiştir. Ancak kıyı kuşağının dar olması nedeniyle yerleşim alanlarının büyük bölümü eğimli topoğrafya üzerinde kurulmuştur. Yol yapımı, kontrolsüz kazılar, şev kesimleri ve plansız yapılaşma gibi antropojenik müdahaleler doğal yamaç dengesini bozarak heyelan riskini artırmaktadır. Son yıllarda Doğu Karadeniz Bölgesi'nde meydana gelen birçok heyelan olayında insan kaynaklı topoğrafya değişimlerinin etkili olduğu belirtilmektedir (AFAD, 2023).

İklim değişikliğine bağlı olarak kısa süreli ve yüksek şiddetli yağışların artması da bölgedeki jeomorfolojik süreçleri hızlandırmaktadır. Özellikle ani yağışlar sonrası gelişen yoğun yüzey akışı, hem erozyon süreçlerini artırmakta hem de yamaç stabilitesini olumsuz yönde etkilemektedir. Bu durum Çayeli'nin doğal afet duyarlılığı açısından oldukça hassas bir jeomorfolojik yapıya sahip olduğunu göstermektedir. Sonuç olarak, Çayeli ilçesi: yüksek topoğrafik eğim, yoğun yağış rejimi, aktif flüvyal süreçler, ayrılmış kayaç yapısı ve tektonik kontrolün birlikte etkisi altında gelişmiş karmaşık bir jeomorfolojik yapıya sahiptir. Bu özellikler bölgeyi heyelan, taşkın ve erozyon gibi doğal afetler açısından yüksek duyarlılığa sahip bir alan haline getirmektedir. Bu nedenle jeomorfolojik özelliklerin jeofizik ve jeoteknik verilerle birlikte değerlendirilmesi, afet duyarlılık analizlerinin doğruluğu açısından büyük önem taşımaktadır.

3.5. İklim ve Yağış

Çayeli (Rize) ilçesi, Doğu Karadeniz kıyı kuşağında yer alması nedeniyle tipik Karadeniz ikliminin etkisi altındadır. Bölge genelinde yıl boyunca nemli ve yağışlı bir iklim hâkim olup, sıcaklık farkları kıyı kesimlerinde oldukça düşüktür. Karadeniz'in denizel etkisi sayesinde yazlar serin, kışlar ise ılıman geçmektedir (MGM, 2023). Doğu Karadeniz Bölgesi, Türkiye'nin yıllık yağış miktarı bakımından en yüksek değerlere sahip alanlarından biridir. Özellikle Rize ve çevresi, nemli hava kütlelerinin kıyıya paralel uzanan Doğu Karadeniz Dağları boyunca yükselmesi sonucu oluşan orografik yağışların etkisi altında kalmaktadır. Bu durum yıl boyunca düzenli ve yüksek miktarda yağış oluşmasına neden olmaktadır (MGM, 2023). Çayeli ilçesinde yıllık ortalama yağış miktarı 2000 mm'nin üzerinde olup, bazı yüksek kesimlerde bu değer daha da artmaktadır.

Yağış rejimi incelendiğinde, yağışların yılın tüm aylarına dağıldığı görülmektedir. Bununla birlikte sonbahar aylarında yağış miktarlarında belirgin artış gözlenmektedir. Özellikle Eylül, Ekim ve Kasım aylarında kısa süreli fakat yüksek şiddetli yağış olayları sık meydana gelmektedir. Bu tür yağışlar yüzey akışını artırmakta ve ani taşkın ile heyelan olaylarını tetiklemektedir (AFAD, 2023). Bölgedeki yüksek bağıl nem oranı, yıl boyunca bulutluluğun fazla olmasına neden olmaktadır. Nem oranının yüksek olması, kayaçların ayrışma süreçlerini hızlandırmakta ve zeminlerin sürekli nemli kalmasına yol açmaktadır. Bu durum özellikle ayrışmış volkanik kayaçlar ve kil içeriği yüksek zeminlerde mühendislik özelliklerinin olumsuz yönde değişmesine neden olmaktadır.

Çayeli'nde sıcaklık değerleri kıyı kesimlerinde genel olarak ılıman karakter göstermektedir. Ortalama yıllık sıcaklık yaklaşık 14–15 °C civarındadır (MGM, 2023). Kış aylarında sıcaklık nadiren 0 °C'nin altına düşerken, yaz aylarında aşırı yüksek sıcaklıklar görülmemektedir. İç kesimlere ve yüksek kotlara çıkıldıkça sıcaklık değerleri düşmekte ve kış aylarında kar yağışı etkili olmaktadır. İlçede görülen yoğun yağışlar, yüzeysel akışın artmasına ve drenaj sistemlerinin kısa sürede yüksek debilere ulaşmasına neden olmaktadır. Özellikle kısa süreli şiddetli yağışlar sonucunda dere yataklarında ani su yükselmeleri meydana gelmekte ve taşkın riski oluşmaktadır. Doğu Karadeniz Havzası'nda meydana gelen taşkınların büyük bölümü yoğun yağış olayları ile ilişkilendirilmektedir (DSİ, 2021).

Yüksek yağış miktarı aynı zamanda bölgedeki heyelan oluşumunda en önemli tetikleyici faktörlerden biridir. Uzun süreli yağış sonrasında zeminlerin suya doygun hale gelmesi, gözenek suyu basıncını artırarak kayma dayanımını azaltmaktadır. Bu durum özellikle yüksek eğimli ve ayrışmış zeminlerde heyelan oluşumunu

kolaylaştırmaktadır (Gökçeoğlu ve Ercanoğlu, 2001). Son yıllarda iklim değişikliğine bağlı olarak ekstrem yağış olaylarının sıklığında artış gözlemlendiği belirtilmektedir. Özellikle kısa sürede yüksek miktarda yağış bırakan meteorolojik olaylar, Doğu Karadeniz Bölgesi'nde taşkın ve heyelan afetlerinin daha sık meydana gelmesine neden olmaktadır (IPCC, 2021). Bu durum, Çayeli ilçesinin doğal afet duyarlılığı açısından daha hassas hale gelmesine yol açmaktadır. Sonuç olarak, Çayeli ilçesi yıl boyunca yüksek yağış alan, nem oranı fazla ve orografik yağışların etkili olduğu tipik Doğu Karadeniz iklim özelliklerini taşımaktadır. Yoğun yağış rejimi, topoğrafik eğim ve ayrılmış jeolojik yapı ile birlikte değerlendirildiğinde, bölgenin heyelan ve taşkın gibi hidro-meteorolojik afetlere karşı oldukça duyarlı olduğu görülmektedir.

3.6. Geçmiş Afetler

Çayeli (Rize) ilçesi, bulunduğu coğrafi konum, topoğrafik özellikler, jeolojik yapı ve iklim koşulları nedeniyle doğal afetlerin sık görüldüğü bir bölge içerisinde yer almaktadır. Özellikle heyelan, taşkın, kaya düşmesi ve sel olayları ilçede geçmişten günümüze kadar önemli can ve mal kayıplarına neden olmuştur. Doğu Karadeniz Bölgesi, Türkiye'de heyelan afetlerinin en yoğun gözlemlendiği alanlardan biri olarak tanımlanmakta olup, Rize ili bu afetlerin en sık yaşandığı iller arasında yer almaktadır (AFAD, 2023).

Bölgedeki afetlerin oluşumunda en önemli faktörlerden biri topoğrafik yapıdır. Kıyıdan kısa mesafede hızla yükselen eğimli yamaçlar, yoğun yağış rejimi ile birleştiğinde yamaç stabilitesinin bozulmasına neden olmaktadır. Özellikle ayrılmış volkanik kayalar, kil içeriği yüksek zeminler ve tektonik kırık zonları boyunca gelişen zayıf seviyeler, heyelan oluşumunu kolaylaştırmaktadır (Gökçeoğlu ve Ercanoğlu, 2001). Çayeli ve çevresinde meydana gelen afetlerin büyük kısmını heyelan olayları oluşturmaktadır. Bölgede özellikle uzun süreli ve yüksek şiddetli yağışların ardından yüzeysel ve derin oturmalı heyelanlar gelişmektedir. AFAD (2023) verilerine göre Doğu Karadeniz Bölgesi'nde meydana gelen heyelanların önemli bir bölümü Rize ili ve çevresinde yoğunlaşmaktadır. Çayeli ilçesinde de birçok yerleşim alanı heyelan riski altında bulunmaktadır.

Bölgedeki en önemli afet türlerinden biri de taşkın ve sel olaylarıdır. Çayeli'nde kısa boylu ve yüksek eğimli akarsuların bulunması, yoğun yağış sonrasında yüzey akışının kısa sürede dere yataklarına ulaşmasına neden olmaktadır. Bu durum dere debilerinde ani yükselmelere yol açarak taşkın oluşumunu tetiklemektedir. Özellikle yaz sonu ve sonbahar dönemlerinde meydana gelen kısa süreli fakat yüksek şiddetli

yağışlar, ani sel ve taşkın olaylarının en önemli nedenidir (DSİ, 2021). Doğu Karadeniz Bölgesi'nde son yıllarda meydana gelen aşırı yağış olayları sonucunda çok sayıda taşkın ve heyelan afeti yaşanmıştır. Özellikle 2021 yılında Rize ve çevresinde meydana gelen yoğun yağışlar sonucunda çok sayıda heyelan oluşmuş, yollar kapanmış ve ciddi altyapı hasarları meydana gelmiştir. Bu olaylarda birçok yerleşim alanı etkilenmiş ve önemli ekonomik kayıplar oluşmuştur (AFAD, 2021).

Çayeli ilçesinde görülen diğer doğal afetlerden biri kaya düşmeleridir. Özellikle dik yamaçların bulunduğu alanlarda fiziksel ayrışma süreçleri sonucu kaya blokları yamaç boyunca hareket ederek ulaşım yolları ve yerleşim alanları açısından risk oluşturmaktadır. Yol yarmaları, kontrolsüz şev kesimleri ve doğal süreksizlik sistemleri kaya düşmesi riskini artırmaktadır.

İnsan faaliyetleri de afet oluşum süreçlerini önemli ölçüde etkilemektedir. Yol yapımı, şev kazıları, dere yataklarının daraltılması, plansız yapılaşma ve kontrolsüz dolgu uygulamaları doğal topoğrafik dengeyi bozarak afet duyarlılığını artırmaktadır. Özellikle Karadeniz Sahil Yolu ve bağlantı yolları kapsamında yapılan kazı çalışmaları sonrasında birçok bölgede yamaç instabilitesinin geliştiği rapor edilmiştir. Son yıllarda kısa sürede yüksek miktarda yağış bırakan sistemlerin artış göstermesi, özellikle heyelan ve taşkın afetlerinin daha sık meydana gelmesine neden olmaktadır (IPCC, 2021). Bu durum Çayeli ilçesinin hidro-meteorolojik afetler açısından yüksek riskli bir alan olduğunu göstermektedir.

Geçmiş afet kayıtları değerlendirildiğinde, Çayeli ilçesinin özellikle heyelan ve taşkın açısından yüksek duyarlılığa sahip olduğu görülmektedir. Bu nedenle bölgedeki afet risklerinin azaltılabilmesi için jeolojik, jeomorfolojik, hidrolojik ve jeofizik verilerin birlikte değerlendirilmesi büyük önem taşımaktadır. Özellikle zemin özelliklerinin belirlenmesi, yerel zemin davranışlarının ortaya konulması ve afet duyarlılık haritalarının hazırlanması, sürdürülebilir yerleşim planlaması açısından kritik öneme sahiptir.

4. MATERİYAL VE YÖNTEM

4.1. Genel Metodoloji

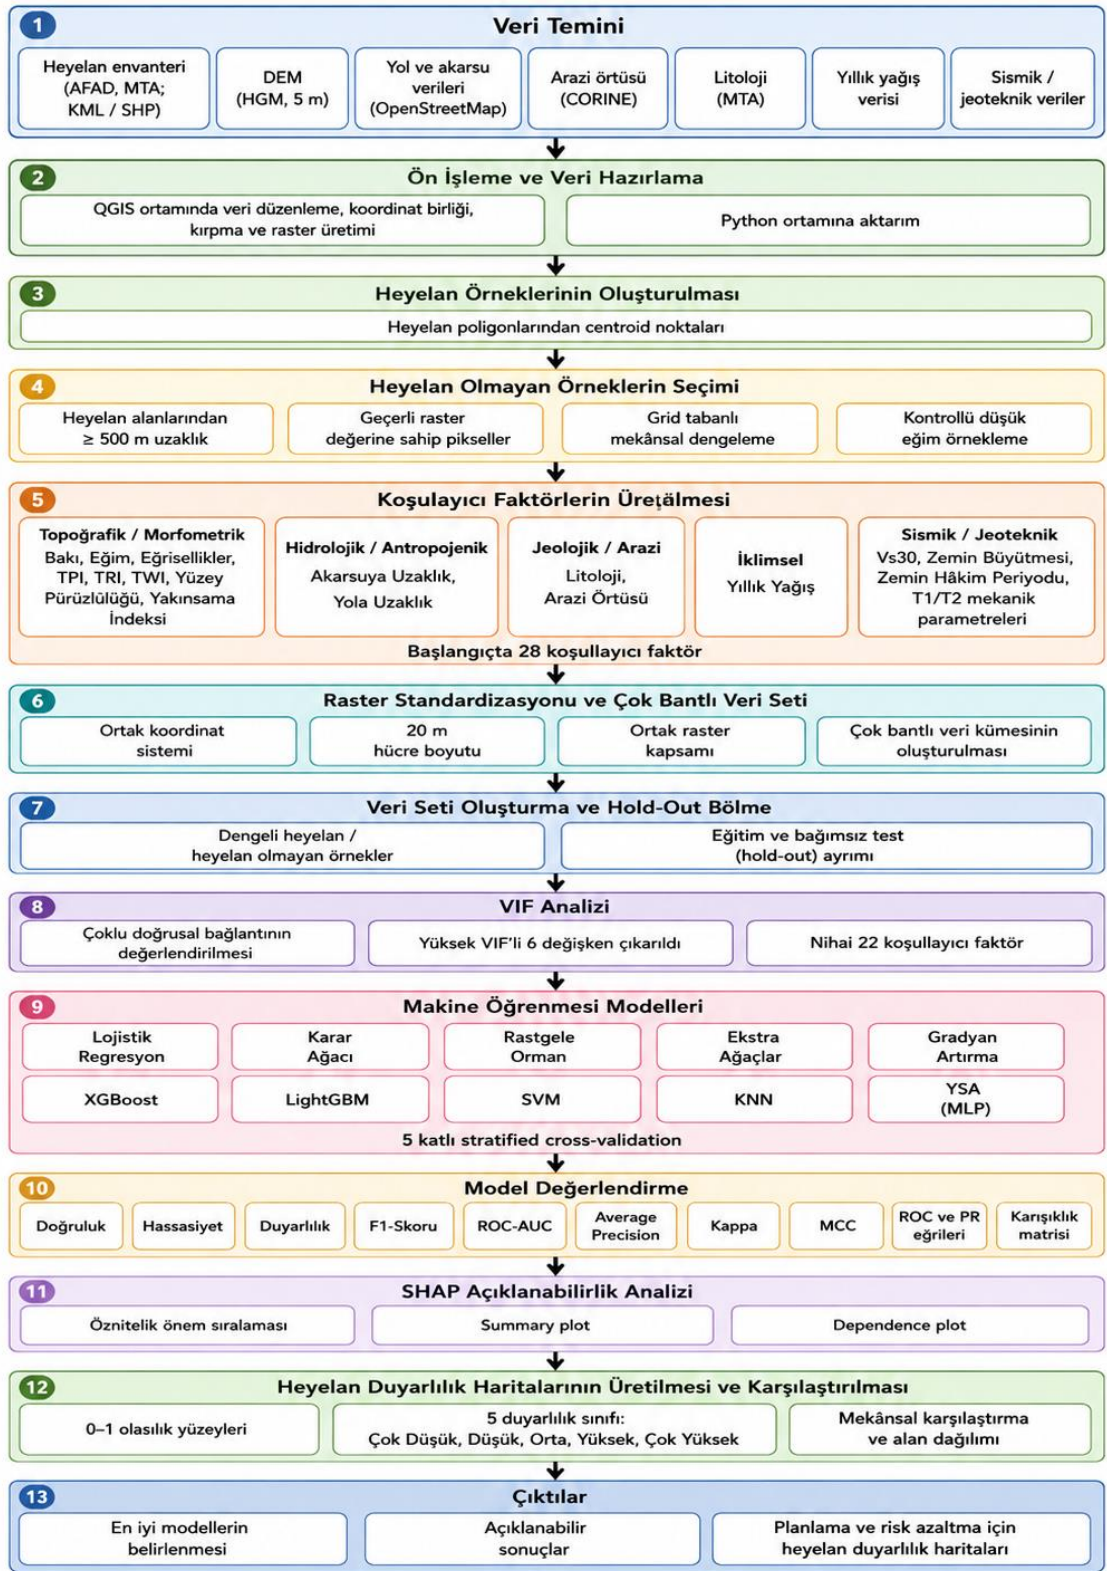
Bu çalışmada heyelan duyarlılığının belirlenmesi amacıyla çok aşamalı ve bütünselik bir metodolojik süreç izlenmiştir. Çalışmanın genel akış şeması Şekil 4'te sunulmuştur. İlk aşamada heyelan envanteri, sayısal yükseklik modeli, yol ve akarsu verileri, arazi örtüsü, litoloji, yıllık yağış ve sismik/jeoteknik veriler farklı kurumsal ve açık veri kaynaklarından temin edilmiştir. Heyelan envanteri AFAD ve MTA'dan KML/SHP formatlarında sağlanmış; DEM verisi Harita Genel Müdürlüğü kaynaklı 5 m çözünürlüklü veri setinden elde edilmiş; yol ve akarsu verileri OpenStreetMap tabanlı olarak kullanılmıştır. Arazi örtüsü CORINE, litoloji ise MTA verileriyle temsil edilmiştir. Bu veri kaynakları, heyelan oluşumunu etkileyebilecek topoğrafik, hidrolojik, antropojenik, jeolojik, iklimsel ve zemin koşullarını birlikte değerlendirebilmek amacıyla modele dahil edilmiştir.

Veri temini sonrasında tüm mekânsal veriler QGIS ortamında ön işleme tabi tutulmuştur. Bu aşamada veri formatlarının düzenlenmesi, koordinat sistemlerinin eşleştirilmesi, çalışma alanına göre kırpma işlemleri ve raster üretimi gerçekleştirilmiştir. Daha sonra hazırlanan raster ve vektör veri katmanları Python ortamına aktarılmıştır. Heyelan sınıfını temsil eden örnekler, heyelan envanteri poligonlarından üretilen centroid noktaları aracılığıyla oluşturulmuştur. Heyelan olmayan örneklerin seçiminde ise mevcut heyelan alanlarından en az 500 m uzaklıkta bulunma, tüm koşullayıcı raster katmanlarında geçerli piksel değerine sahip olma, grid tabanlı mekânsal dengeleme ve kontrollü düşük eğim örnekleme kriterleri birlikte uygulanmıştır. Böylece negatif örneklerin çalışma alanında rastgele ve kontrolsüz biçimde seçilmesi önlenmiş, modelin yalnızca kolay ayrılabilir alanları öğrenme eğilimi sınırlandırılmıştır. Bir sonraki aşamada heyelan duyarlılığını etkileyebilecek koşullayıcı faktörler üretilmiştir. Bu faktörler topoğrafik/morfometrik, hidrolojik/antropojenik, jeolojik/arazi, iklimsel ve sismik/jeoteknik olmak üzere beş ana grupta ele alınmıştır. DEM tabanlı olarak bakı, eğim, eğrisellikler, TPI, TRI, TWI, yüzey pürüzlülüğü ve yakınsama indeksi gibi morfometrik değişkenler üretilmiştir. Akarsuya uzaklık ve yola uzaklık hidrolojik ve antropojenik etkileri temsil etmek için kullanılmıştır. Litoloji ve arazi örtüsü jeolojik ve yüzey koşullarını, yıllık yağış iklimsel etkiyi, Vs_{30} , zemin büyütmesi, zemin hâkim periyodu ve T1/T2 mekanik parametreleri ise sismik/jeoteknik

zemin koşullarını temsil etmiştir. Başlangıçta toplam 28 koşullayıcı faktör oluşturulmuştur. Tüm koşullayıcı faktörler ortak koordinat sistemi, ortak raster kapsamı ve 20 m hücre boyutu altında standartlaştırılarak çok bantlı raster veri seti haline getirilmiştir. Bu işlem, farklı kaynaklardan elde edilen verilerin aynı mekânsal çözünürlük ve aynı piksel yapısı üzerinden karşılaştırılabilir hale getirilmesini sağlamıştır.

Ardından heyelan ve heyelan olmayan örneklerden dengeli bir veri seti oluşturulmuş ve veri seti eğitim ile bağımsız hold-out test alt kümelerine ayrılmıştır. Modelleme öncesinde çoklu doğrusal bağlantının kontrolü amacıyla Varyans Enflasyon Faktörü (VIF) analizi uygulanmış, yüksek VIF değerine sahip 6 değişken çıkarılmış ve nihai modelleme süreci 22 koşullayıcı faktör üzerinden yürütülmüştür. Modelleme aşamasında Lojistik Regresyon, Karar Ağacı, Rastgele Orman, Ekstra Ağaçlar, Gradyan Artırma, XGBoost, LightGBM, SVM, KNN ve YSA (MLP) olmak üzere on farklı makine öğrenmesi algoritması karşılaştırmalı olarak değerlendirilmiştir. Modeller 5 katlı stratified cross-validation yaklaşımıyla eğitilmiş ve bağımsız hold-out test seti üzerinde doğrulanmıştır. Model performansları doğruluk, hassasiyet, duyarlılık, F1 skoru, ROC-AUC, Average Precision, Cohen's Kappa, Matthews Korelasyon Katsayısı, ROC ve Precision–Recall eğrileri ile karışıklık matrisi kullanılarak çok yönlü biçimde değerlendirilmiştir. Böylece modellerin yalnızca genel doğruluk düzeyi değil, aynı zamanda heyelan sınıfını yakalama kapasitesi, yanlış pozitif–yanlış negatif dengesi ve bağımsız veri üzerindeki genelleme başarısı da incelenmiştir.

Son aşamada model kararlarının yorumlanabilirliğini artırmak için SHAP açıklanabilirlik analizi uygulanmıştır. SHAP analizi ile koşullayıcı faktörlerin model tahminlerine katkısı, önem sıralaması, summary plot ve dependence plot grafikleri aracılığıyla değerlendirilmiştir. Daha sonra her model için 0–1 aralığında heyelan olasılık yüzeyleri üretilmiş ve bu yüzeyler çok düşük, düşük, orta, yüksek ve çok yüksek olmak üzere beş duyarlılık sınıfına ayrılarak heyelan duyarlılık haritaları oluşturulmuştur. Üretilen haritalar hem mevcut heyelan envanteriyle mekânsal uyum hem de duyarlılık sınıflarının alan dağılımı açısından karşılaştırılmıştır. Böylece çalışma sonucunda en başarılı modeller belirlenmiş, model kararları açıklanabilir hale getirilmiş ve planlama ile risk azaltma süreçlerinde kullanılabilecek heyelan duyarlılık haritaları elde edilmiştir.



Şekil 4. Çalışmanın genel metodoloji akış şeması

4.2. Heyelan Envanter Verisi

Bu çalışmada heyelan envanter verisi, çalışma alanında geçmişte meydana gelmiş heyelanların mekânsal dağılımını temsil eden temel referans veri seti olarak kullanılmıştır. Heyelan duyarlılık modellemesinde envanter verisinin doğruluğu,

konumsal tutarlılığı ve çalışma alanını temsil etme gücü model performansını doğrudan etkilediğinden, veri hazırlama süreci yalnızca ham verinin modele aktarılması şeklinde değerlendirilmemiş; aksine, çok aşamalı bir mekânsal ön işleme süreci uygulanmıştır. Bu kapsamda heyelanlara ait konumsal veriler, AFAD ve MTA kaynaklarından KML ve SHP formatlarında temin edilmiştir. Farklı kurumlardan ve farklı veri formatlarından elde edilen bu envanterler, çalışma alanındaki heyelan olaylarının daha bütüncül biçimde temsil edilebilmesi amacıyla birlikte değerlendirilmiştir.

İlk aşamada AFAD ve MTA'dan sağlanan KML ve SHP formatındaki heyelan verileri QGIS ortamına aktarılmıştır. KML formatındaki veriler öncelikle vektör veri formatına dönüştürülmüş, ardından SHP formatındaki diğer heyelan katmanlarıyla birlikte aynı proje ortamında değerlendirilmiştir. Bu aşamada veri setlerinin koordinat referans sistemleri kontrol edilmiş, farklı projeksiyonlarda bulunan katmanlar ortak bir koordinat sistemine dönüştürülmüştür. Çalışmada kullanılan raster veri setleri ve nokta koordinatları ile uyumlu olacak şekilde heyelan envanteri metrik tabanlı bir projeksiyon sisteminde düzenlenmiştir.

QGIS ortamında ikinci aşama olarak geometri kontrolü yapılmıştır. Heyelan poligonları ve noktasal kayıtlar olası topolojik hatalar, yinelenen geometriler, eksik veya bozuk geometri yapıları ve çalışma alanı dışında kalan kayıtlar açısından incelenmiştir. Farklı kaynaklardan gelen verilerde aynı heyelan alanının birden fazla kez temsil edilmesi olasılığı bulunduğundan, örtüşen veya tekrar eden kayıtlar görsel ve mekânsal olarak kontrol edilmiştir. Gerekli durumlarda katmanlar birleştirilmiş, geometri onarımları yapılmış ve çalışma alanı sınırları dışında kalan ya da raster veri setleriyle çakışmayan kayıtlar analiz dışında bırakılmıştır. Böylece modelleme sürecinde kullanılacak envanterin hem konumsal hem de tematik açıdan daha tutarlı hale getirilmesi amaçlanmıştır.

Heyelan duyarlılık modellemesinde kullanılan makine öğrenmesi algoritmaları, her bir örnek nokta için raster katmanlardan öznitelik değerlerinin çıkarılmasını gerektirdiğinden, poligon tabanlı envanter verilerinden temsil edici noktasal örnekler üretilmiştir. Bu amaçla QGIS ortamında heyelan poligonlarının merkez noktaları/centroidleri hesaplanmış ve bu centroidler heyelan varlığını temsil eden pozitif örnekler olarak kullanılmıştır. Centroid yaklaşımı, her bir heyelan alanından tekil ve konumsal olarak temsil edici bir örnek elde edilmesini sağladığı için özellikle piksel tabanlı öznitelik çıkarımı ve sınıflandırma algoritmalarına veri hazırlanmasında yaygın biçimde tercih edilmektedir. Ancak bu işlem sırasında centroidlerin poligon dışında kalmaması, raster kapsamı içinde yer alması ve NoData alanlarına denk gelmemesi

ayrıca kontrol edilmiştir. QGIS’te düzenlenen ve centroidleri oluşturulan heyelan envanteri daha sonra tablo formatında dışa aktarılmıştır. Bu kapsamda her bir heyelan örneğine ait X ve Y koordinatları CSV formatında kaydedilmiş ve Python ortamında analiz edilecek şekilde hazırlanmıştır. Python ortamına aktarılan heyelan envanteri, raster verilerle birlikte yeniden kontrol edilmiştir. İlk olarak centroid koordinatları raster grid sistemindeki satır ve sütun konumlarına dönüştürülmüş, ardından her bir noktaya karşılık gelen raster piksel değerleri çıkarılmıştır. Raster sınırları dışında kalan, eksik veri içeren veya herhangi bir bantta NaN/NoData değerine denk gelen heyelan örnekleri analiz dışı bırakılmıştır. Bu işlem, modelin eksik ya da hatalı öznitelik değerleriyle eğitilmesini önlemek ve tüm modellerde aynı temiz veri setinin kullanılmasını sağlamak amacıyla uygulanmıştır. Sonuç olarak yalnızca tüm raster bantlarında geçerli öznitelik değerine sahip olan heyelan noktaları pozitif sınıf örnekleri olarak veri setine dahil edilmiştir. Buna ek olarak, poligon biçimindeki heyelan envanteri yalnızca nokta üretimi için değil, aynı zamanda sonuç haritalarının görsel ve mekânsal doğrulaması için de kullanılmıştır.


4.2.1. Heyelan Olmayan Noktaların Seçimi

Heyelan duyarlılık modellemesinde pozitif sınıfı temsil eden heyelan noktalarının yanı sıra, modelin sınıflandırma öğrenebilmesi için heyelan olmayan alanları temsil eden negatif örneklerin de dikkatli biçimde seçilmesi gerekmektedir. Bu çalışmada heyelan olmayan noktalar rastgele fakat kontrollü bir örnekleme stratejisiyle belirlenmiştir. Amaç, modelin yalnızca belirli kolay topoğrafik ayrımlara, özellikle de eğim değişkenine aşırı bağımlı biçimde öğrenmesini önlemek ve çalışma alanının farklı morfolojik koşullarını temsil eden dengeli bir negatif örnek seti oluşturmaktır.


Bu amaçla öncelikle bilinen heyelan centroid noktaları raster grid sistemine dönüştürülmüş ve bu noktalar üzerinde bir heyelan maskesi oluşturulmuştur. Ardından, bilinen heyelan alanlarına çok yakın piksellerin yanlışlıkla “heyelan olmayan” sınıfına dahil edilmesini önlemek için heyelan noktaları etrafında 500 m tampon mesafe uygulanmıştır. Bu tampon alan içerisinde kalan pikseller negatif örnek havuzundan çıkarılmıştır. Böylece seçilen heyelan olmayan noktaların, mevcut envanterde tanımlı heyelanlardan belirli bir güvenli uzaklıkta yer alması sağlanmıştır. Bu işlem, özellikle envanter belirsizliği, poligon/centroid konum hataları ve heyelan çevresindeki geçiş zonlarının yanlış sınıflandırılması riskini azaltmak amacıyla uygulanmıştır. Negatif örneklerin mekânsal olarak belirli alanlarda kümelenmesini önlemek için aday pikseller üzerinde grid tabanlı örnekleme uygulanmıştır.

Çalışma alanı 500 m×500 m boyutlu hücrelere ayrılmış ve her bir grid hücresinden en fazla iki adet heyelan olmayan aday nokta seçilmesine izin verilmiştir. Bu yaklaşım, geniş ve homojen alanlardan aşırı sayıda örnek alınmasını engellemiş, buna karşılık negatif örneklerin çalışma alanına daha dengeli biçimde dağılmasını sağlamıştır. Böylece modelin belirli bir bölgesel/topografik kümeye aşırı uyum göstermesi azaltılmış ve çalışma alanının farklı çevresel koşulları negatif sınıf içerisinde daha dengeli biçimde temsil edilmiştir. Ek olarak, düşük eğimli alanların modelde kontrollü biçimde temsil edilmesi için 0–5° eğim aralığında yer alan aday pikseller ayrı bir havuz olarak değerlendirilmiştir. Bu adımın temel gerekçesi, modelin heyelan olmayan sınıfı yalnızca yüksek eğim dışındaki çok belirgin alanlar üzerinden öğrenmesini ya da eğim değişkenine dayalı basit bir ayırım geliştirmesini sınırlamaktır. Bu nedenle düşük eğimli adaylar ana negatif örnek havuzundan ayrılmış, grid örnekleme bu havuz için de ayrıca uygulanmış ve nihai heyelan olmayan örneklerin belirli bir bölümü bu düşük eğimli havuzdan seçilmiştir. Toplam non-heyelan örnek sayısı heyelan örnek sayısına eşit olacak şekilde ayarlanmıştır.

Yeterli aday bulunması durumunda, negatif örneklerin yaklaşık %50'sinin kontrollü düşük eğim havuzundan seçilmesi hedeflenmiştir. Bu işlem, toplam sınıf dengesini bozmadan düşük eğimli alanların model eğitiminde temsil edilmesini sağlamıştır. Son aşamada ana havuzdan ve düşük eğim havuzundan seçilen noktalar birleştirilmiş, karıştırılmış ve her bir pikselin satır/sütun konumu coğrafi koordinata dönüştürülmüştür. Böylece heyelan olmayan noktalar, modelleme veri setinde label = 0, heyelan noktaları ise label = 1 olarak tanımlanmıştır. Nihai veri setinde heyelan ve heyelan olmayan örneklerin sayısı dengeli tutulmuş, böylece makine öğrenmesi algoritmalarının sınıf dengesizliğinden etkilenmesi azaltılmıştır. Model eğitiminde kullanılan heyelan ve heyelan olmayan noktaların mekânsal dağılımı ayrıca görsel olarak kontrol edilmiştir. Bu kapsamda noktalar ilk olarak DEM tabanlı topoğrafik arka plan üzerinde gösterilmiş ve negatif örneklerin çalışma alanına dengeli biçimde dağılıp dağılmadığı değerlendirilmiştir. Daha sonra aynı noktalar uydu görüntüsü üzerinde yeniden görselleştirilmiş ve arazi bağlamı içerisinde kontrol edilmiştir. Bu görselleştirmelerde heyelan noktaları ve heyelan olmayan noktalar farklı sembollerle temsil edilmiş; böylece örnekleme stratejisinin hem topoğrafik hem de gerçek arazi örtüsü bağlamındaki dağılımı incelenebilmiştir. Model eğitiminde kullanılan heyelan ve heyelan olmayan noktaların DEM tabanlı gösterimi Şekil 5 ve uydu görüntüsü üzerindeki gösterimi ise Şekil 6'da sunulmuştur.



Şekil 5. DEM tabanlı topoğrafik arka plan üzerinde heyelan ve heyelan olmayan örnek noktaların mekânsal dağılımı



Şekil 6. Uydu görüntüsü üzerinde heyelan ve heyelan olmayan örnek noktaların mekânsal dağılımı

4.3. Koşullu Faktörlerin Belirlenmesi ve Hazırlanması

Heyelan duyarlılık modellemesinde kullanılan koşullayıcı faktörler (Tablo 1), çalışma alanında heyelan oluşumunu kontrol eden topoğrafik, morfometrik, hidrolojik, jeolojik, arazi örtüsü, iklimsel ve sismik/jeoteknik özellikleri temsil edecek şekilde belirlenmiştir. Heyelanlar; eğim, litoloji, drenaj koşulları, yüzey şekli, yağış, arazi örtüsü, insan müdahalesi ve zemin özelliklerinin birlikte etkilediği çok faktörlü kütle hareketleridir. Bu nedenle çalışmada tek bir değişken grubuna dayalı bir modelleme yaklaşımı yerine, farklı veri kaynaklarından elde edilen çok boyutlu koşullayıcı

faktörler birlikte değerlendirilmiştir. Veri hazırlama sürecinde çalışma alanına ait sayısal yükseklik modeli (SYM/DEM), tüm koşullayıcı faktörlerin üretilmesi ve ortak raster geometriye dönüştürülmesi için temel referans veri olarak kullanılmıştır. Çalışmada kullanılan DEM verisi, Harita Genel Müdürlüğü'nden temin edilen 5 m mekânsal çözünürlüklü yükseklik verisinden elde edilmiştir.

Çalışmada kullanılan nihai koşullayıcı faktörler; topoğrafik ve morfometrik faktörler, hidrolojik ve antropojenik mesafe faktörleri, Jeolojik ve İklimsel faktörler ve sismik/jeoteknik zemin faktörleri olmak üzere 4 ana grupta değerlendirilmiştir. Bunlar Tablo 1’de sunulmuştur.

Tablo 1. Heyelan duyarlılık analizinde kullanılan 28 koşullu faktör

Ana kriter grubu	Alt kriter	Metinde kullanılacak gerçek isim
Topoğrafik ve morfometrik faktörler	Eğim	Eğim (°)
	Bakı	Bakı (°)
	Toplam eğrisellik	Toplam Eğrisellik (m^{-1})
	Profil eğriselliği	Profil Eğriselliği (m^{-1})
	Plan eğriselliği	Plan Eğriselliği (m^{-1})
	Yakınsama indeksi	Yakınsama İndeksi
	Yüzey pürüzlülüğü	Yüzey Pürüzlülüğü
	Topoğrafik konum indeksi	Topoğrafik Konum İndeksi (TPI)
	Topoğrafik ıslanma indeksi	Topoğrafik Islanma İndeksi (TWI)
	Topoğrafik pürüzlülük indeksi	Topoğrafik Pürüzlülük İndeksi (TRI)
Hidrolojik ve antropojenik mesafe faktörleri	Akarsuya uzaklık	Akarsuya Uzaklık (m)
	Yola uzaklık	Yola Uzaklık (m)
Jeolojik ve İklimsel faktörleri	Litoloji	Litoloji
	Arazi örtüsü / arazi kullanımı	Arazi Örtüsü
	Yıllık yağış	Yıllık Yağış (mm)
Sismik ve jeoteknik zemin faktörleri	İlk 30 m’deki kayma dalgası hızı ortalaması	V_{s30} (m/s)
	1. tabaka yoğunluğu	1. tabaka yoğunluk (g/cm^3)
	1. tabaka kayma modülü	1. tabaka kayma modülü
	1. tabaka elastisite modülü	1. tabaka elastisite modülü
	1. tabaka bulk modülü	1. tabaka bulk modülü
	1. tabaka poisson oranı	1. tabaka poisson oranı
	2. tabaka yoğunluğu	2. tabaka yoğunluk (g/cm^3)
	2. tabaka kayma modülü	2. tabaka kayma modülü
	2. tabaka elastisite modülü	2. tabaka elastisite modülü
	2. tabaka bulk modülü	2. tabaka bulk modülü
	2. tabaka poisson oranı	2. tabaka poisson oranı
	Zemin büyütmesi	Zemin Büyütme Faktörü (A_0)
	Zemin hâkim titreşim periyodu	Zemin Hâkim Titreşim Periyodu T_0 (s)

Yüksek çözünürlüklü DEM verisi, çalışma alanındaki topoğrafik ayrıntıları temsil etme açısından önemli bir avantaj sağlamakla birlikte, çok sayıda morfometrik değişkenin üretilmesi, sismik ve çevresel raster katmanlarla birlikte çok bantlı veri seti oluşturulması ve makine öğrenmesi modellerinde piksel tabanlı tahmin haritalarının üretilmesi süreçlerinde yüksek işlem yükü ve veri hacmi oluşturmaktadır. Bu nedenle, hem topoğrafik temsil gücünü korumak hem de hesaplama süresini, bellek gereksinimini ve dosya boyutunu yönetilebilir düzeyde tutmak amacıyla 5 m çözünürlüklü DEM verisi 20 m mekânsal çözünürlüğe yeniden örneklenmiştir. Yeniden örnekleme işlemi sonrasında 20 m çözünürlüklü DEM, çalışma alanındaki tüm raster tabanlı analizler için ana referans katman olarak kabul edilmiştir.

DEM'in hücre boyutu, koordinat referans sistemi ve raster boyutu diğer koşullayıcı faktörlerin hizalanmasında esas alınmıştır. Çalışma alanı sınırı vektör formatında içe aktarılmış, DEM ile aynı koordinat sistemine dönüştürülmüş ve raster maske haline getirilmiştir. Böylece tüm koşullayıcı faktörler aynı koordinat sistemi, aynı hücre boyutu ve aynı mekânsal kapsam içerisinde hazırlanmıştır. Sürekli değişkenler DEM gridine yeniden örneklenirken bilinear yeniden örnekleme yaklaşımı kullanılmıştır.

4.3.1. Topoğrafik ve Morfometrik Faktörler

Topoğrafik ve morfometrik faktörler, heyelan duyarlılığını etkileyen en temel değişken grubunu oluşturmaktadır. Yamaç eğimi, bakı, yüzey eğriselliği, topoğrafik konum, pürüzlülük ve potansiyel yüzeysel su birikimi gibi faktörler; yerçekimi etkisini, yüzeysel akışı, infiltrasyonu, malzeme birikimini ve yamaç stabilitesini doğrudan etkileyebilir. Bu çalışmada DEM'den Eğim, Bakı, Toplam Eğrisellik, Profil Eğriselliği, Plan Eğriselliği, Yakınsama İndeksi, Yüzey Pürüzlülüğü, Topoğrafik Konum İndeksi, Topoğrafik Islanma İndeksi ve Topoğrafik Pürüzlülük İndeksi üretilmiştir.

Eğim, yamaç yüzeyinin yatay düzleme göre diklik derecesini ifade eder. Heyelan oluşumunda en önemli faktörlerden biridir; çünkü eğim arttıkça yerçekiminin yamaç aşağı bileşeni artar ve kayma potansiyeli yükselir. Ancak eğim–heyelan ilişkisi her zaman doğrusal değildir. (Reichenbach vd., 2018). Çok düşük eğimli alanlarda kayma potansiyeli sınırlı olabilirken, çok dik yamaçlarda malzeme birikimi daha az olabilir. Bu nedenle eğim, diğer jeolojik ve çevresel değişkenlerle birlikte değerlendirilmiştir. Eğim, DEM'in x ve y yönündeki yükseklik gradyanlarından hesaplanmıştır.

$$Eğim_{rad} = \tan^{-1} \left(\sqrt{\left(\frac{\partial z}{\partial x}\right)^2 + \left(\frac{\partial z}{\partial y}\right)^2} \right), Eğim_{deg} = Eğim_{rad} \times \frac{180}{\pi} \quad (4)$$

Burada z yükseklik değerini, $\partial z/\partial x$ ve $\partial z/\partial y$ ise DEM'in x ve y yönündeki gradyanlarını ifade etmektedir.

Bakı, yamaç yüzeyinin baktığı yönü ifade eder. Bakı; güneşlenme süresi, buharlaşma, nemlilik, bitki örtüsü gelişimi, kar erime hızı ve ayrışma süreçleri üzerinde etkili olabilir. Bu nedenle heyelan duyarlılık modellemesinde dolaylı fakat önemli bir topoğrafik faktör olarak değerlendirilmiştir. Çalışmada bakı $0-360^\circ$ aralığında hesaplanmış, eğimin 0.1° 'den düşük olduğu neredeyse düz alanlarda bakı değeri -1 olarak atanmıştır.

$$Bakı = \tan^{-1} \left(-\frac{\partial z}{\partial x}, \frac{\partial z}{\partial y} \right), Bakı = \begin{cases} Bakı + 360 & Bakı < 0 \\ Bakı, & Bakı \geq 0 \end{cases} \quad (5)$$

Kartografik görselleştirme aşamasında bakı değerleri düz, kuzey, kuzeydoğu, doğu, güneydoğu, güney, güneybatı, batı ve kuzeybatı sınıflarına ayrılmıştır.

Eğrisellik değişkenleri, yamaç yüzeyinin içbükey, dışbükey veya düz karakterini tanımlar. Eğrisellik, yüzeysel akışın hızlanması, yavaşlaması, belirli alanlarda toplanması veya yüzey boyunca dağılması üzerinde etkilidir. Bu çalışmada üç eğrisellik değişkeni kullanılmıştır: Profil Eğriselliği, Plan Eğriselliği ve Toplam Eğrisellik. Profil eğriselliği akış yönündeki eğriliği, plan eğriselliği ise kontur çizgilerine paralel yöndeki eğriliği ve akışın yanal yakınsama/dağılma eğilimini temsil eder. Toplam eğrisellik ise bu iki bileşenin birlikte değerlendirilmesiyle elde edilen genel yüzey eğriliği göstergesidir.

$$\begin{aligned} \text{Profil Eğriselliği} &= -\frac{g_{xx}g_x^2 + 2g_{xy}g_xg_y + g_{yy}g_y^2}{(g_x^2 + g_y^2)(1 + g_x^2 + g_y^2)} \\ \text{Plan eğriselliği} &= -\frac{g_{xx}g_y^2 - 2g_{xy}g_xg_y + g_{yy}g_x^2}{(g_x^2 + g_y^2)(1 + g_x^2 + g_y^2)} \\ \text{Toplam eğrisellik} &= \frac{\text{Profil eğriselliği} + \text{plan eğriselliği}}{2} \end{aligned} \quad (6)$$

Burada, g_x ve g_y DEM'in x ve y yönündeki birinci türevlerini; g_{xx} , g_{yy} ve g_{xy} ise ikinci türevleri ifade etmektedir.

Yakınsama İndeksi, yüzeysel akışın belirli alanlarda toplanma veya dağılma eğilimini temsil eden morfolojik bir göstergedir. Akışın yakınsadığı alanlarda su birikimi, infiltrasyon ve boşluk suyu basıncı artışı görülebilir. Bu durum özellikle zayıf litolojik birimlerde yamaç stabilitesini azaltabilir. Çalışmada yakınsama indeksi, 3×3 hareketli pencere içinde merkez hücrenin bakı değeri ile komşu hücrelerin bakı değerleri arasındaki açısal farklılıklar dikkate alınarak hesaplanmıştır.

$$CI = \frac{1}{N} \sum_{i=1}^n \Delta\theta_i - 90, \Delta\theta_i = \min(|\theta_i - \theta_c|, 360 - |\theta_i - \theta_c|) \quad (7)$$

Burada CI yakınsama indeksini, θ_c merkez hücrenin bakı değerini, θ_i komşu hücrelerin bakı değerini ve n geçerli komşu hücre sayısını ifade etmektedir.

Yüzey Pürüzlülüğü, kısa mesafede yükseklik değerlerindeki değişkenliği gösterir. Yüksek yüzey pürüzlülüğü; parçalanmış topoğrafya, litolojik dayanım farklılıkları, eski kütle hareketleri, erozyon süreçleri veya morfolojik düzensizliklerle ilişkili olabilir. Bu çalışmada yüzey pürüzlülüğü, 3×3 hareketli pencere içerisindeki yükseklik değerlerinin standart sapması olarak hesaplanmıştır.

$$\text{Yüzey pürüzlülüğü} = \sqrt{\frac{1}{n} \sum_{i=1}^n (z_i - \bar{z})^2} \quad (8)$$

Burada z_i pencere içindeki hücre yüksekliklerini, $\bar{z}$ ise bu hücrelerin ortalama yüksekliğini ifade etmektedir.

Topoğrafik Konum İndeksi, bir hücrenin çevresindeki hücrelere göre göreceli yükseklik konumunu ifade eder. Pozitif değerler sırt, omuz veya yüksek konumlu topoğrafik birimleri; negatif değerler ise vadi, çukur veya düşük konumlu alanları temsil edebilir. Bu nedenle yamaç üzerindeki morfolojik pozisyonun tanımlanmasında önemlidir.

$$TPI = Z_0 - \bar{z}_{komşuluk} \quad (9)$$

Burada Z_0 merkez hücre yüksekliğini, $\bar{z}_{komşuluk}$ ise komşu hücrelerin ortalama yüksekliğini göstermektedir.

Topoğrafik İslanma İndeksi, topoğrafyanın potansiyel nem birikimi ve yüzeysel su tutma eğilimini temsil eder. Klasik yaklaşımda özgül katkı alanı ile eğim açısının tanjantı arasındaki ilişkiye dayanır.

$$TWI = \ln\left(\frac{A_s}{\tan\beta}\right) \quad (10)$$

Burada β eğim açısını göstermektedir.

Topoğrafik Pürüzlülük İndeksi, merkez hücre ile komşu hücreler arasındaki yükseklik farklarının toplamına dayalı olarak hesaplanmıştır. Bu değişken, arazinin kısa mesafedeki engebelilik derecesini ifade eder.

$$TRI = \sum_{i=1}^n |z_i - z_0| \quad (11)$$

Burada z_i komşu hücre yüksekliklerini, z_0 ise merkez hücre yüksekliğini ifade etmektedir.

4.3.2. Hidrolojik ve Antropojenik Mesafe Faktörleri

Hidrolojik ve antropojenik etkileri temsil etmek amacıyla Akarsuya Uzaklık ve Yola Uzaklık değişkenleri oluşturulmuştur. Akarsular, yamaç topuğunu aşındırarak destek kaybına neden olabilir, yüzeysel ve yeraltı suyu koşullarını değiştirebilir ve özellikle vadi yamaçlarında stabiliteyi azaltabilir. Bu nedenle akarsuya yakınlık, heyelan duyarlılığı açısından önemli bir koşullayıcı faktör olarak değerlendirilmiştir. Akarsu ağı vektör formatında içe aktarılmış, DEM ile aynı koordinat sistemine dönüştürülmüş ve çalışma alanı sınıрыyla kırılmıştır. Daha sonra akarsu geometrileri raster biçimine getirilmiş ve her hücrenin en yakın akarsu hücresine olan mesafesi hesaplanmıştır. Uzaklık hesabı Öklid mesafesine dayanmaktadır. Akarsuya uzaklık değerleri 0–100 m, 100–500 m, 500–1000 m ve >1000 m sınıflarına ayrılmıştır. Bu değişken modelleme aşamasında Akarsuya Uzaklık adıyla kullanılmıştır. Benzer işlem yol verisi için de uygulanmıştır. Yol ağı, antropojenik müdahalenin önemli göstergelerinden biridir. Yol açma, kazı-dolgu işlemleri, şev kesimleri ve drenaj koşullarındaki değişiklikler yamaç stabilitesini bozabilir. Bu nedenle yol ağı DEM gridine raster biçimine getirilmiş, her hücrenin en yakın yola olan mesafesi hesaplanmış ve 0–100 m, 100–500 m, 500–1000 m ve >1000 m sınıfları oluşturulmuştur. Bu çalışmada hidrolojik ve antropojenik mesafe faktörlerinin oluşturulmasında kullanılan

akarsu ağı ve yol ağı verileri, OpenStreetMap tabanlı vektör veri kaynaklarından elde edilmiş ve çalışma alanı sınırına göre düzenlenmiştir.

4.3.3. Jeolojik ve İklimsel faktörler

Litoloji, heyelan duyarlılığını kontrol eden temel jeolojik faktörlerden biridir. Kayaç türü, ayrışma derecesi, süreksizlik yapısı, geçirgenlik, kil içeriği ve dayanım özellikleri yamaç stabilitesini doğrudan etkileyebilir. (Reichenbach vd., 2018). Bu çalışmada litoloji verisi vektör formatında içe aktarılmış, DEM koordinat sistemine dönüştürülmüş ve çalışma alanı sınırıyla kırılmıştır. Daha sonra litolojik birimler, shapefile içerisindeki açıklama alanına göre sayısal sınıflara dönüştürülmüş ve DEM gridine uygun raster formatında hazırlanmıştır. Bu değişken modelleme aşamasında Litoloji adıyla kullanılmıştır. Arazi Örtüsü, yüzeyin bitki örtüsü, su kütlesi, yerleşim, otçul alan, tarım alanı, seyrek bitki örtüsü veya diğer arazi kullanım sınıflarını temsil etmektedir. Arazi örtüsü kök tutunması, yüzeysel akış, infiltrasyon, erozyon, geçirimsizlik ve insan etkisi gibi süreçler aracılığıyla heyelan duyarlılığını etkileyebilir. Çalışmada arazi örtüsü rasteri yeniden sınıflandırılmış ve DEM gridine uyumlu hale getirilmiştir. Nihai sınıflar; ağaç örtüsü, su kütleleri, yerleşim, otçul alan, tarım alanı, seyrek bitki örtüsü ve diğer sınıflardan oluşmuştur. Bu değişken modelde Arazi Örtüsü adıyla kullanılmıştır. Arazi örtüsü verisi CORINE Land Cover veri setinden elde edilmiş, litoloji verisi ise Maden Tetkik ve Arama Genel Müdürlüğü'nden (MTA) temin edilen jeoloji/litoloji haritalarından üretilmiştir.

Yıllık Yağış, heyelanların hazırlayıcı ve tetikleyici süreçleri açısından önemli bir iklimsel değişkendir. (Çömert vd., 2025; Reichenbach vd., 2018). Yağışın artması; infiltrasyonu, toprak nemini ve boşluk suyu basıncını artırabilir. Bu durum efektif gerilmeyi azaltarak kayma direncinin düşmesine neden olabilir. Yıllık yağış verisi, yaklaşık 1 km mekânsal çözünürlüğe sahip WorldClim 2.1 tabanlı aylık toplam yağış rasterlerinden elde edilmiştir. Çalışma kapsamında ilgili döneme ait aylık yağış rasterleri kullanılarak yıllık toplam yağış değerleri hesaplanmış ve çok yıllık ortalama yağış rasteri üretilmiştir. Elde edilen yağış rasteri daha sonra çalışma alanı sınırına göre kırılmış, 20 m çözünürlüklü DEM tabanlı referans raster geometrisine bilinear yeniden örnekleme yöntemiyle uyumlandırılmış.

4.3.4. Sismik ve Jeoteknik Zemin Faktörleri

Bu çalışmada klasik topoğrafik, hidrolojik ve jeolojik faktörlere ek olarak sismik ve jeoteknik zemin özellikleri de koşullayıcı faktörler arasına dahil edilmiştir. Bu yaklaşım, heyelan duyarlılığının yalnızca yüzey morfolojisi veya litoloji ile değil, aynı zamanda zemin profilinin yoğunluk, rijitlik, deformasyon ve dinamik davranış özellikleriyle de ilişkili olabileceği varsayımına dayanmaktadır.

Sismik ve jeoteknik veriler, Çayeli Belediyesi tarafından sağlanan 55 adet jeolojik ve jeoteknik rapordan temin edilmiştir. Söz konusu raporlarda yer alan sismik kırılma, MASW ve mikrotremor ölçümleri ile zemin özelliklerine ilişkin jeoteknik parametreler, ölçüm noktalarının X-Y koordinatlarıyla birlikte değerlendirilmiştir. Noktasal veriler CBS ortamına aktarılmış ve ilgili parametrelerin çalışma alanı içerisindeki mekânsal dağılımlarının modellenmesinde kullanılmıştır.. Bu verilerde zemin profili iki tabaka halinde ele alınmıştır. Bu nedenle modelde kullanılan 1. tabaka parametreleri yüzeye yakın ilk zemin tabakasının, 2. tabaka parametreleri ise altta yer alan ikinci zemin tabakasının özelliklerini temsil etmektedir. Sismik parametreler arasında V_{s30} , 1. tabaka yoğunluk, 1. tabaka kayma modülü, 1. tabaka elastisite modülü, 1. tabaka bulk modülü, 1. tabaka poisson oranı, 2. tabaka yoğunluk, 2. tabaka kayma modülü, 2. tabaka elastisite modülü, 2. tabaka bulk modülü, 2. tabaka poisson oranı, zemin büyütmesi ve zemin hâkim titreşim periyodu yer almaktadır.

Noktasal sismik/jeoteknik verilerin raster modelleme veri setine dahil edilebilmesi için Ters Mesafe Ağırlıklı Enterpolasyon (Inverse Distance Weighting, IDW) yöntemi kullanılmıştır. IDW yöntemi, tahmin edilecek bir hücre değerini çevresindeki ölçüm noktalarının uzaklığına bağlı ağırlıklı ortalaması ile hesaplar.

$$\hat{Z}(x_0) = \frac{\sum_{i=1}^n w_i Z(x_i)}{\sum_{i=1}^n w_i} w_i = \frac{1}{d_i^p} \quad (12)$$

Burada $\hat{Z}(x_0)$ tahmin edilen raster hücre değerini, $Z(x_i)$ i. ölçüm noktasındaki gözlenen değeri, d_i ölçüm noktası ile tahmin edilen hücre arasındaki mesafeyi, w_i uzaklığa bağlı ağırlığı ve p güç parametresini ifade etmektedir. Bu çalışmada IDW güç parametresi $p = 3$, komşu nokta sayısı ise $k = 20$ olarak kullanılmıştır. Böylece tahmin edilen raster hücre değerlerinde yakın ölçüm noktalarının etkisi uzak noktalara göre daha yüksek tutulmuştur.

V_{s30} , yüzeyden itibaren ilk 30 metredeki ortalama kayma dalgası hızını temsil etmektedir. Düşük V_{s30} değerleri genellikle daha yumuşak, gevşek veya düşük rijitlikli


zemin koşullarına; yüksek V_{s30} değerleri ise daha rijit zemin veya kaya koşullarına işaret eder. Bu nedenle V_{s30} , hem yerel zemin sınıfı hem de yamaç malzemesinin dinamik davranışı açısından önemli bir değişken olarak modele dahil edilmiştir.

1. tabaka yoğunluk, yüzeye yakın ilk zemin tabakasının birim hacimdeki kütlesini temsil eder. Yoğunluk, yamaç malzemesinin ağırlığı ve gerilme koşulları üzerinde etkili olabilir. 1. tabaka Kayma Modülü G , zeminin kayma deformasyonuna karşı direncini; 1. tabaka Elastisite Modülü E , elastik deformasyon davranışını; 1. tabaka Bulk Modülü K , hacimsel sıkışabilirlik özelliğini; 1. tabaka Poisson Oranı ise eksenel deformasyon ile yanal deformasyon arasındaki ilişkiyi ifade etmektedir. Bu değişkenler yüzeye yakın zemin tabakasının rijitlik ve deformasyon davranışını temsil etmektedir. 2. tabaka yoğunluk, yüzeye yakın tabakanın altında yer alan ikinci zemin tabakasının yoğunluk özelliğini temsil etmektedir. Benzer şekilde 2. tabaka kayma modülü, 2. tabaka elastisite modülü, 2. tabaka bulk modülü ve 2. tabaka poisson oranı ikinci tabakanın mekanik ve dinamik davranışını tanımlamak için kullanılmıştır. İkinci tabaka parametrelerinin ayrıca modele dahil edilmesi, heyelan duyarlılığının yalnızca yüzeysel zemin özellikleriyle değil, daha derindeki zemin/kaya birimlerinin rijitlik ve deformasyon özellikleriyle de ilişkili olabileceği varsayımına dayanmaktadır.

Zemin Büyütmesi, yerel zemin koşullarının sismik dalga genliklerini artırma potansiyelini temsil eder. Yüksek zemin büyütmesi değerlerine sahip alanlarda dinamik yükler altında yamaç stabilitesi daha olumsuz etkilenebilir. Zemin Hâkim Titreşim Periyodu T_0 (s) ise zemin profilinin dinamik davranış karakterini ve titreşim özelliklerini yansıtır. Bu iki değişken, özellikle sismik etki altında heyelan duyarlılığı artabilecek alanların belirlenmesinde tamamlayıcı bilgi sağlamaktadır. Tüm koşullayıcı faktörler üretildikten sonra ortak koordinat sistemi, ortak hücre boyutu ve ortak raster kapsamı altında çok bantlı raster veri seti halinde birleştirilmiştir.

Nihai modelleme sürecinde kullanılan faktörler; Bakı, Yakınsama İndeksi, Arazi Örtüsü, Litoloji, Plan Eğriselliği, Yıllık Yağış, Profil Eğriselliği, Yola Uzaklık, 1. tabaka bulk modülü k , 1. tabaka elastisite modülü, 1. tabaka kayma modülü, 1. tabaka poisson oranı, 1. tabaka yoğunluk, 2. tabaka bulk modülü, 2. tabaka elastisite modülü, 2. tabaka kayma modülü, 2. tabaka poisson oranı, 2. tabaka yoğunluk, V_{s30} , Zemin Büyütmesi, Zemin Hâkim Titreşim Periyodu, Eğim, Akarsuya Uzaklık, Yüzey Pürüzlülüğü, Toplam Eğrisellik, Topoğrafik Konum İndeksi, Topoğrafik Pürüzlülük İndeksi ve Topoğrafik Islanma İndeksi değişkenlerinden oluşmuştur. Bu koşullayıcı faktörlerin çalışma alanındaki mekânsal dağılımlarını göstermek ve veri hazırlama sürecinin görsel kontrolünü sağlamak amacıyla kartografik haritalar üretilmiştir.


Şekil 7’de Çalışma alanına ait topoğrafik ve morfometrik koşullayıcı faktörlerin mekânsal dağılımları gösterilmiştir. Haritalar, çalışma alanındaki topoğrafik ve yüzey morfolojisine ilişkin değişkenlerin mekânsal değişimini ortaya koymaktadır. Faktörlerin alansal dağılımlarındaki farklılıklar, çalışma alanının topoğrafik özelliklerinin heterojen yapısını yansıtmaktadır.



Şekil 7. Topoğrafik ve morfometrik koşullayıcı faktörlerin mekânsal dağılımı-I (Eğim, Bakı, Toplam Eğrisellik ve Profil Eğrisellik Katmanları)





Görselleştirme aşamasında faktörler, okunabilirliği artırmak amacıyla tematik gruplar halinde düzenlenmiş ve her biri dört alt panelden oluşan toplam yedi harita kompozisyonu halinde sunulmuştur. Sürekli değişkenlerde uç değerlerin renk skalasını baskılamasını önlemek ve haritalardaki mekânsal desenleri daha okunabilir hale

getirmek amacıyla görselleştirme aralığı çoğunlukla alt ve üst yüzdelik dilim değerlerine göre sınırlandırılmıştır. Bu kapsamda sürekli raster katmanlarda renk dağılımı genel olarak 2. ve 98. persentil aralığı dikkate alınarak oluşturulmuştur.




Şekil 8. Topoğrafik ve morfometrik koşullayıcı faktörlerin mekânsal dağılımı-II. Plan Eğriselliği, Yakınsama İndeksi, Yüzey Pürüzlülüğü ve Topoğrafik Konum İndeksi Katmanlarını göstermektedir


Bu nedenle haritalardaki lejant deęerleri her deęiřkenin kendi veri daęılımına gre farklılık gsterebilir; lejantlar mutlak minimum–maksimum deęerlerden ziyade grselleřtirme iin optimize edilmiř deęer aralıklarını temsil etmektedir. Kategorik deęiřkenlerde ise litoloji, arazi rts, bakı ve mesafe sınıfları gibi sınıflandırılmıř katmanlar kendi sınıf etiketleri ve kategorik lejant yapılarıyla gsterilmiřtir. Bylece hem srekli hem de kategorik kořullayıcı faktrler, kendi veri yapısına uygun renk skalası ve lejant dzeniyle sunulmuřtur. Kořullayıcı faktrlere ait kartografik gsterimler řekil 7–20 arasında verilmiřtir.




Şekil 9. Topoğrafik, hidrolojik ve antropojenik koşullayıcı faktörlerin mekânsal dağılımı, Topoğrafik Pürüzlülük İndeksi, Topoğrafik Islanma İndeksi, Akarsuya Uzaklık ve Yola Uzaklık katmanlarını göstermektedir




Şekil 10. Jeolojik, arazi örtüsü ve iklimsel koşullayıcı faktörlerin mekânsal dağılımı. Litoloji, Arazi Örtüsü, Yıllık Yağış ve Vs₃₀ katmanlarını göstermektedir



Şekil 11. Birinci tabakaya ait sismik/jeoteknik zemin parametrelerinin mekânsal dağılımı-I. Tabaka Yoğunluk, 1. Tabaka Kayma Modülü G, 1. Tabaka Elastisite Modülü E ve 1. Tabaka Bulk Modülü K katmanlarını göstermektedir



Şekil 12. Birinci ve ikinci tabakaya ait sismik/jeoteknik zemin parametrelerinin mekânsal dağılımı-II. Tabaka Poisson Oranı, 2. Tabaka Yoğunluk, 2. Tabaka Kayma Modülü G ve 2. Tabaka Elastisite Modülü E katmanlarını göstermektedir



Şekil 13. İkinci tabakaya ve zemin dinamik özelliklerine ait sismik/jeoteknik parametrelerin mekânsal dağılımı. 2. Tabaka Bulk Modülü K, 2. Tabaka Poisson Oranı, Zemin Büyütmesi ve Zemin Hâkim Titreşim Periyodu katmanlarını göstermektedir

4.4. Veri Seti Oluşturma ve Hold-Out Bölme

Koşullayıcı faktörlerin hazırlanması ve heyelan/heyelan olmayan örnek noktaların belirlenmesinden sonra, makine öğrenmesi modellerinde kullanılacak nihai veri matrisi oluşturulmuştur. Bu aşamada her bir örnek nokta, çok bantlı raster veri setindeki karşılık gelen piksel değerleriyle temsil edilmiştir. Başka bir ifadeyle, her satır bir örnek noktayı; her sütun ise heyelan duyarlılığını etkileyebilecek bir koşullayıcı faktörü temsil edecek şekilde yapılandırılmıştır. Böylece nokta tabanlı heyelan envanteri ve raster tabanlı çevresel faktörler, makine öğrenmesi algoritmaları tarafından işlenebilecek sayısal bir öznitelik matrisine dönüştürülmüştür. Oluşturulan veri seti hem CSV hem de Excel formatında kaydedilmiştir. CSV dosyasında tüm koşullayıcı faktörlerin ham bant adları ve sınıf etiketi korunurken, Excel çıktısında değişken adları makale standardına uygun şekilde düzenlenmiştir. Nihai veri seti oluşturulduktan sonra modelleme sürecinde kullanılmak üzere eğitim ve bağımsız test alt kümelerine ayrılmıştır. Bu işlem için hold-out bölme yaklaşımı kullanılmıştır.

Hold-out yöntemi, veri setinin bir bölümünün model eğitimi için, geri kalan bağımsız bölümünün ise model performansını değerlendirmek için ayrılmasına dayanır. Bu çalışmada veri setinin %70'i eğitim, %30'u ise hold-out test seti olarak ayrılmıştır. Eğitim ve test kümeleri oluşturulurken sınıf dağılımının korunması amacıyla stratified sampling yaklaşımı uygulanmıştır. Böylece hem eğitim setinde hem de hold-out test setinde heyelan ve heyelan olmayan örneklerin oranı, nihai veri setindeki genel sınıf dağılımıyla uyumlu kalmıştır. Bu işlem, özellikle dengeli performans değerlendirmesi için önemlidir; çünkü rastgele bölme sonucunda test setinde bir sınıfın orantısız biçimde fazla veya az temsil edilmesi, model performans metriklerinin güvenilirliğini azaltabilir. Hold-out test seti, model geliştirme aşamasında kullanılmamış ve yalnızca eğitilen modellerin bağımsız performansını değerlendirmek amacıyla saklanmıştır. Böylece modellerin eğitim verisine ne ölçüde uyum sağladığı ile daha önce görmediği bağımsız veriler üzerindeki genelleme kapasitesi ayrı ayrı değerlendirilebilmiştir. Bu yaklaşım, özellikle heyelan duyarlılık modellemesinde aşırı öğrenme riskini azaltmak ve modelin gerçek mekânsal tahmin performansına daha yakın bir değerlendirme sağlamak açısından önemlidir.

Veri sızıntısını önlemek amacıyla sonraki aşamalarda uygulanan öznitelik seçimi ve ölçekleme işlemleri de yalnızca eğitim verisi temel alınarak gerçekleştirilmiştir. VIF tabanlı öznitelik seçimi, eğitim seti üzerinde uygulanmış; seçilen değişkenler daha sonra aynı indeks yapısıyla hold-out test setine aktarılmıştır. Benzer şekilde ölçekleme gerektiren Lojistik Regresyon, SVM, KNN ve YSA modelleri için StandardScaler

yalnızca eğitim setine fit edilmiş, ardından aynı dönüşüm test setine uygulanmıştır. Böylece test setinden eğitim sürecine bilgi taşınması engellenmiş ve hold-out performans değerlendirmesinin bağımsızlığı korunmuştur. Sonuç olarak, bu aşamada heyelan ve heyelan olmayan örneklerden oluşan dengeli, eksiksiz ve mekânsal olarak kontrol edilmiş bir veri seti oluşturulmuş; veri seti daha sonra stratified hold-out yaklaşımı ile eğitim ve bağımsız test alt kümelerine ayrılmıştır. Bu yapı, makine öğrenmesi modellerinin hem eğitim sürecinde karşılaştırılmasına hem de bağımsız test seti üzerinde nesnel biçimde değerlendirilmesine olanak sağlamıştır.

4.5. Varyans Enflasyon Faktörü (VIF) Analizi

Makine öğrenmesi tabanlı heyelan duyarlılık modellemesinde çok sayıda koşullayıcı faktör birlikte kullanıldığında, bazı değişkenler arasında yüksek düzeyde doğrusal ilişki bulunabilir. Özellikle DEM'den türetilen eğim, eğrisellik, yüzey pürüzlülüğü, topoğrafik konum indeksi ve topoğrafik pürüzlülük indeksi gibi morfometrik değişkenler aynı temel yükseklik verisinden üretildikleri için birbirleriyle belirli düzeyde ilişkili olabilir. Benzer şekilde 1. ve 2. tabaka sismik/jeoteknik parametreleri arasında da fiziksel olarak ilişkili değişkenler bulunabilir. Bu durum, model girdileri arasında çoklu doğrusal bağlantı sorununa neden olabilir.

Bu çalışmada koşullayıcı faktörler arasındaki çoklu doğrusal bağlantıyı değerlendirmek amacıyla Varyans Enflasyon Faktörü (Variance Inflation Factor, VIF) analizi uygulanmıştır. VIF, bir bağımsız değişkenin diğer bağımsız değişkenler tarafından ne ölçüde açıklanabildiğini gösteren istatistiksel bir ölçüttür. Bir değişkenin VIF değeri yükseldikçe, o değişkenin veri setindeki diğer değişkenlerle doğrusal ilişkisinin arttığı kabul edilir. VIF değeri genel olarak aşağıdaki formülle ifade edilir:

$$VIF_i = \frac{1}{1-R_i^2} \quad (13)$$

Burada VIF_i , i. değişkene ait varyans enflasyon faktörünü; R_i^2 ise i. değişkenin diğer bağımsız değişkenler kullanılarak regresyona sokulması sonucunda elde edilen determinasyon katsayısını ifade etmektedir. R_i^2 değeri 1'e yaklaştıkça ilgili değişkenin diğer değişkenler tarafından büyük ölçüde açıklandığı anlaşılır ve buna bağlı olarak VIF değeri yükselir. Örneğin $R_i^2 = 0$ olduğunda değişken diğer değişkenlerle doğrusal olarak ilişkili değildir ve VIF değeri 1 olur. Buna karşılık R_i^2 değeri 1'e yaklaştıkça VIF değeri teorik olarak sonsuza yaklaşır. Bu çalışmada VIF analizi, veri sızıntısını önlemek

amacıyla yalnızca eğitim veri seti üzerinde uygulanmıştır. Hold-out test seti, VIF hesaplamasına dahil edilmemiştir. Bunun nedeni, test verisinden elde edilen herhangi bir bilginin değişken seçim sürecine yansımaları engellemek ve bağımsız test performansının tarafsız biçimde değerlendirilebilmesini sağlamaktır. İş akışında akışında öncelikle veri seti stratified hold-out yaklaşımıyla eğitim ve test setlerine ayrılmış, daha sonra VIF tabanlı öznelik seçimi yalnızca eğitim verisi üzerinde gerçekleştirilmiştir. Seçilen değişken indeksleri daha sonra aynı sırayla hem eğitim hem de hold-out test setine uygulanmıştır. Böylece eğitim ve test setleri aynı değişken uzayında temsil edilmiş, ancak değişken seçim kararı yalnızca eğitim verisinden türetilmiştir.

VIF analizi iteratif bir eleme yaklaşımıyla gerçekleştirilmiştir. İlk aşamada eğitim veri setindeki tüm koşullayıcı faktörler için VIF değerleri hesaplanmıştır. Daha sonra en yüksek VIF değerine sahip değişken belirlenmiş ve bu değer önceden tanımlanan eşik değerin üzerinde ise ilgili değişken veri setinden çıkarılmıştır. Değişken çıkarıldıktan sonra kalan değişkenler için VIF değerleri yeniden hesaplanmış ve aynı işlem tekrarlanmıştır. Bu döngü, tüm değişkenlerin VIF değerleri belirlenen eşik değerin altında kalana kadar sürdürülmüştür. Bu çalışmada VIF eşik değeri 1000 olarak belirlenmiştir. Literatürde VIF için 5 veya 10 gibi daha düşük eşikler sıklıkla kullanılsa da, bu çalışmada eşik değerin daha yüksek tutulmasının temel nedeni, heyelan duyarlılık modellemesinde kullanılan koşullayıcı faktörlerin önemli bir bölümünün fiziksel olarak ilişkili olması ve çok düşük VIF eşiklerinin jeomorfolojik açıdan anlamlı değişkenleri gereğinden fazla dışlayabilme riskidir. Özellikle DEM türevleri ve sismik/jeoteknik parametreler arasında belirli düzeyde korelasyon beklenen bir durumdur. Bu nedenle VIF analizi, değişken setini agresif biçimde daraltmak için değil, aşırı düzeyde doğrusal bağımlılık gösteren ve model yorumlanabilirliğini bozabilecek değişkenleri kontrol etmek amacıyla uygulanmıştır. Burada özellikle vurgulanması gereken nokta, VIF analizinin tüm model türleri için aynı amaca hizmet etmediğidir. Lojistik regresyon gibi doğrusal modellerde yüksek çoklu doğrusal bağlantı katsayı tahminlerinin kararlılığını bozabilir ve değişken etkilerinin yorumlanmasını güçleştirebilir.

Ağaç tabanlı modeller ise doğrusal bağlantıdan doğrusal modellere kıyasla daha az etkilenebilir. Bununla birlikte, bu çalışmada farklı algoritmaların aynı öznelik seti üzerinde karşılaştırılması hedeflendiğinden, VIF analizi tüm modeller için ortak ve tutarlı bir ön işleme adımı olarak uygulanmıştır. Bu yaklaşım, özellikle model karşılaştırmalarının adil biçimde yapılmasına ve SHAP tabanlı değişken önem yorumlarının daha tutarlı değerlendirilmesine katkı sağlamıştır.

4.6. Makine Öğrenmesi Modelleri

Bu çalışmada heyelan duyarlılığını tahmin etmek amacıyla farklı öğrenme prensiplerine sahip on makine öğrenmesi algoritması kullanılmıştır. Model seçimi yapılırken yalnızca tek bir algoritma ailesine bağlı kalınmamış; doğrusal modeller, karar ağacı tabanlı modeller, topluluk öğrenme yöntemleri, boosting algoritmaları, mesafe/marjin tabanlı yöntemler ve yapay sinir ağı modeli birlikte değerlendirilmiştir. Bu yaklaşımın temel amacı, çalışma alanındaki heyelan–koşullayıcı faktör ilişkilerinin doğrusal, doğrusal olmayan, eşik temelli veya karmaşık etkileşimli yapıda olup olmadığını karşılaştırmalı olarak ortaya koymaktır.

Çalışmada kullanılan modeller; Lojistik Regresyon, Karar Ağacı, Rastgele Orman, Ekstra Ağaçlar, Gradyan Artırma, XGBoost, LightGBM, Destek Vektör Makinesi, K-En Yakın Komşu ve Çok Katmanlı Algılayıcı Yapay Sinir Ağı modellerinden oluşmuştur. Bu modeller, VIF analizi sonrasında seçilen koşullayıcı faktörler kullanılarak eğitilmiş ve her model aynı eğitim/test bölünmesi üzerinde değerlendirilmiştir. On farklı makine öğrenmesi algoritması karşılaştırmalı olarak değerlendirilmiştir.

Lojistik Regresyon, ikili sınıflandırma problemlerinde yaygın kullanılan doğrusal bir modeldir. Bu model, bağımsız değişkenlerin doğrusal kombinasyonunu lojistik fonksiyon aracılığıyla 0–1 aralığında bir olasılık değerine dönüştürür. Bu çalışmada Lojistik Regresyon, diğer daha karmaşık modeller için karşılaştırmalı bir temel model olarak kullanılmıştır.

Karar Ağacı, veriyi ardışık karar kurallarıyla alt gruplara ayıran, yorumlanabilirliği yüksek bir sınıflandırma yöntemidir. Karar ağacı modelleri, değişkenler arasındaki doğrusal olmayan ilişkileri ve eşik etkilerini yakalayabilir. Heyelan duyarlılık çalışmalarında eğim, litoloji veya akarsuya uzaklık gibi değişkenlerin belirli eşik değerleri üzerinden risk oluşturabilmesi nedeniyle karar ağacı yaklaşımı önemli bir karşılaştırma modeli olarak değerlendirilmiştir. Bu çalışmada karar ağacı modeli max_depth=6 ve min_samples_leaf=5 parametreleriyle sınırlandırılmıştır. Böylece ağacın aşırı derinleşmesi ve eğitim verisine aşırı uyum göstermesi kontrol altına alınmıştır.

Rastgele Orman, çok sayıda karar ağacının bir araya getirilmesiyle oluşturulan topluluk öğrenme yöntemidir. Her ağaç, veri setinin farklı örneklem ve değişken alt kümeleri üzerinde eğitilir. Nihai tahmin ise ağaçların ortak kararına dayanır. Bu yapı, tek karar ağacına kıyasla varyansı azaltır ve genelleme performansını artırabilir. Heyelan duyarlılık modellemesinde Rastgele Orman, değişkenler arası karmaşık ve

doğrusal olmayan ilişkileri yakalayabilmesi nedeniyle güçlü bir model olarak kabul edilmektedir. Bu çalışmada Rastgele Orman modeli $n_estimators=200$, $max_depth=10$, $min_samples_leaf=3$ ve $max_features="sqrt"$ parametreleriyle uygulanmıştır.

Ekstra Ağaçlar, Rastgele Orman'a benzer şekilde çok sayıda karar ağacından oluşan bir topluluk öğrenme yöntemidir. Ancak Ekstra Ağaçlar modelinde bölünme noktaları daha rastgele biçimde seçilir. Bu ek rastgelelik, model varyansını azaltabilir ve bazı veri setlerinde daha iyi genelleme sağlayabilir. Bu çalışmada Ekstra Ağaçlar modeli, Rastgele Orman ile benzer parametre yapısında değerlendirilmiş; $n_estimators=200$, $max_depth=10$, $min_samples_leaf=3$ ve $max_features="sqrt"$ değerleri kullanılmıştır.

Gradyan Artırma, zayıf öğrencilerin ardışık biçimde eğitildiği bir boosting yöntemidir. Her yeni ağaç, önceki ağaçların hatalarını azaltmaya odaklanır. Bu nedenle Gradyan Artırma, karmaşık doğrusal olmayan örüntüleri öğrenmede etkili olabilir. Ancak boosting yöntemleri uygun kontrol edilmediğinde aşırı öğrenmeye yatkın olabilir. Bu çalışmada modelin kontrollü öğrenmesi için $n_estimators=100$, $max_depth=4$, $learning_rate=0.05$ ve $subsample=0.8$ parametreleri kullanılmıştır.

XGBoost, gradyan artırma karar ağaçlarının düzenlenmiş ve yüksek performanslı bir uygulamasıdır. XGBoost, düzenleme terimleri, alt örnekleme, değişken alt örnekleme ve optimize edilmiş kayıp fonksiyonu sayesinde tabular veri problemlerinde güçlü sonuçlar verebilen bir algoritmadır. Bu çalışmada XGBoost modeli $n_estimators=200$, $max_depth=4$, $learning_rate=0.05$, $subsample=0.8$, $colsample_bytree=0.8$, $reg_alpha=0.1$ ve $reg_lambda=1.0$ parametreleriyle uygulanmıştır. Bu parametre yapısı, modelin karmaşık ilişkileri öğrenmesini sağlarken aşırı öğrenme riskini azaltmayı amaçlamaktadır.

LightGBM, gradyan artırma ailesinde yer alan, özellikle büyük veri setlerinde hızlı ve etkili çalışabilen bir boosting algoritmasıdır. LightGBM, yaprak odaklı ağaç büyütme stratejisiyle karmaşık örüntüleri etkili biçimde öğrenebilir. Bu çalışmada LightGBM modeli $n_estimators=200$, $max_depth=5$, $num_leaves=20$, $learning_rate=0.05$, $subsample=0.8$, $min_child_samples=20$, $reg_alpha=0.1$ ve $reg_lambda=1.0$ parametreleriyle uygulanmıştır.

Destek Vektör Makinesi (SVM), sınıflar arasında en uygun ayırım hiperdüzlemini bulmayı amaçlayan güçlü bir sınıflandırma yöntemidir. Doğrusal olmayan ilişkilerin modellenebilmesi için bu çalışmada radyal tabanlı fonksiyon çekirdeği kullanılmıştır. RBF çekirdeği, koşullayıcı faktörler ile heyelan varlığı arasındaki karmaşık doğrusal olmayan ilişkileri modelleyebilir. SVM modeli $kernel="rbf"$, $C=1.0$ ve $probability=True$

parametreleriyle uygulanmıştır. Olasılık çıktısı etkinleştirildiği için model, yalnızca sınıf tahmini değil, heyelan olasılığı da üretebilmiştir.

K-En Yakın Komşu (KNN), tahmin edilecek örneğin en yakın komşularının sınıf bilgisine göre karar veren mesafe tabanlı bir yöntemdir. Bu model, benzer çevresel/topoğrafik koşullara sahip örneklerin benzer heyelan duyarlılığı gösterebileceği varsayımına dayanır. Ancak KNN mesafe tabanlı bir yöntem olduğu için değişken ölçeklerinden doğrudan etkilenir. Bu nedenle KNN modeli, standartlaştırılmış veri üzerinde uygulanmıştır. Bu çalışmada komşu sayısı $n_neighbors=10$ olarak belirlenmiştir.

Tablo 2. Kullanılan makine öğrenmesi modellerinin hiperparametre özeti

Model	Model ailesi	Temel parametreler
Lojistik Regresyon	Doğrusal model	$max_iter=1000$, $C=1.0$
Karar Ağacı	Ağaç tabanlı model	$max_depth=6$, $min_samples_leaf=5$
Rastgele Orman	Bagging/topluluk modeli	$n_estimators=200$, $max_depth=10$, $min_samples_leaf=3$, $max_features="sqrt"$
Ekstra Ağaçlar	Rastgeleleştirilmiş topluluk modeli	$n_estimators=200$, $max_depth=10$, $min_samples_leaf=3$, $max_features="sqrt"$
Gradyan Artırma	Boosting modeli	$n_estimators=100$, $max_depth=4$, $learning_rate=0.05$, $subsample=0.8$
XGBoost	Düzenleştirilmiş boosting modeli	$n_estimators=200$, $max_depth=4$, $learning_rate=0.05$, $subsample=0.8$, $colsample_bytree=0.8$, $reg_alpha=0.1$, $reg_lambda=1.0$
LightGBM	Hızlı boosting modeli	$n_estimators=200$, $max_depth=5$, $num_leaves=20$, $learning_rate=0.05$, $subsample=0.8$, $min_child_samples=20$, $reg_alpha=0.1$, $reg_lambda=1.0$
SVM	Marjın tabanlı model	$kernel="rbf"$, $C=1.0$, $probability=True$
KNN	Mesafe tabanlı model	$n_neighbors=10$
YSA (MLP)	Yapay sinir ağı	$hidden_layer_sizes=(128,64,32)$, $max_iter=1000$, $alpha=0.01$

Çok Katmanlı Algılayıcı Yapay Sinir Ağı (YSA/MLP), girdi değişkenleri ile hedef sınıf arasındaki karmaşık ve doğrusal olmayan ilişkileri öğrenebilen yapay sinir ağı tabanlı bir modeldir. Bu çalışmada MLP modeli üç gizli katmandan oluşacak şekilde yapılandırılmıştır. Gizli katman yapısı (128, 64, 32) olarak tanımlanmış, maksimum iterasyon sayısı 1000, düzenleştirme parametresi ise $alpha=0.01$ olarak belirlenmiştir.

Bu yapı, modelin karmaşık ilişkileri öğrenmesini sağlarken düzenlileştirme yoluyla aşırı öğrenme riskini azaltmayı amaçlamaktadır. Tüm modellerin hiperparametre kümeleri Tablo 2’ de özetlenmektedir.

4.7. Model Değerlendirme Kriterleri

Makine öğrenmesi modellerinin performansı, yalnızca tek bir başarı ölçütüne dayalı olarak değil, farklı yönleri değerlendiren çoklu metrikler kullanılarak analiz edilmiştir. Heyelan duyarlılık modellemesinde amaç, yalnızca genel doğru sınıflandırma oranını artırmak değil, aynı zamanda gerçek heyelan noktalarının doğru şekilde tanımlanmasını, heyelan olmayan alanların yanlış pozitif olarak sınıflandırılmasının azaltılmasını ve modellerin bağımsız test verisi üzerindeki genelleme kapasitesinin değerlendirilmesini sağlamaktır. Bu nedenle çalışmada doğruluk, hassasiyet/kesinlik, sınıf duyarlılığı, F1 skoru, ROC-AUC, Precision–Recall eğrisi, Average Precision, Cohen’s Kappa ve Matthews Korelasyon Katsayısı gibi farklı değerlendirme ölçütleri birlikte kullanılmıştır.

Model değerlendirme süreci iki aşamalı olarak yürütülmüştür. İlk aşamada modeller, eğitim veri seti üzerinde 5 katlı stratified cross-validation yaklaşımıyla değerlendirilmiştir. Bu aşamada her model için doğruluk, hassasiyet, duyarlılık, F1 skoru ve ROC-AUC metriklerinin ortalama ve standart sapma değerleri hesaplanmıştır. İkinci aşamada ise modeller tüm eğitim setiyle yeniden eğitilmiş ve daha önce model geliştirme sürecinde kullanılmayan bağımsız hold-out test seti üzerinde değerlendirilmiştir. Hold-out test setinde doğruluk, hassasiyet, duyarlılık, F1 skoru, ROC-AUC, Cohen’s Kappa ve Matthews Korelasyon Katsayısı hesaplanmıştır. Böylece modellerin hem çapraz doğrulama kararlılığı hem de bağımsız veri üzerindeki genelleme başarısı birlikte değerlendirilmiştir.

Model performans metriklerinin hesaplanmasında karışıklık matrisi temel alınmıştır. İkili sınıflandırma yapısında heyelan sınıfı pozitif sınıf, heyelan olmayan sınıf ise negatif sınıf olarak değerlendirilmiştir. Buna göre gerçek pozitif değerler, doğru şekilde heyelan olarak sınıflandırılan heyelan örneklerini; gerçek negatif değerler, doğru şekilde heyelan olmayan olarak sınıflandırılan negatif örnekleri; yanlış pozitif değerler, heyelan olmadığı halde heyelan olarak tahmin edilen örnekleri; yanlış negatif değerler ise gerçekte heyelan olduğu halde model tarafından heyelan olmayan olarak tahmin edilen örnekleri ifade etmektedir. TP = Gerçekte heyelan olan ve model tarafından heyelan olarak tahmin edilen örnek sayısı, TN = Gerçekte heyelan olmayan ve model tarafından heyelan olmayan olarak tahmin edilen örnek sayısı, FP = Gerçekte heyelan

olmayan ancak model tarafından heyelan olarak tahmin edilen örnek sayısı, FN = Gerçekte heyelan olan ancak model tarafından heyelan olmayan olarak tahmin edilen örnek sayısını ifade etmektedir. Doğruluk (Accuracy), modelin tüm örnekler içerisindeki doğru tahmin oranını göstermektedir. Heyelan ve heyelan olmayan sınıfların dengeli olduğu veri setlerinde genel performans hakkında hızlı bir fikir verir. Ancak tek başına kullanıldığında modelin pozitif sınıfı ne ölçüde yakaladığını göstermekte yetersiz kalabilir. Bu nedenle doğruluk metriği diğer metriklerle birlikte yorumlanmıştır. Hassasiyet / Kesinlik (Precision), modelin heyelan olarak tahmin ettiği örneklerin ne kadarının gerçekten heyelan olduğunu gösterir. Bu metrik, yanlış pozitif tahminleri değerlendirmek açısından önemlidir.

Heyelan duyarlılık haritalarında gereğinden fazla alanın yüksek riskli olarak sınıflandırılması istenmeyen bir durum olabileceğinden, precision değeri modelin pozitif tahminlerinin güvenilirliğini değerlendirmek için kullanılmıştır. Duyarlılık (Recall / Sensitivity), gerçek heyelan örneklerinin ne kadarının model tarafından doğru şekilde yakalandığını göstermektedir. Heyelan duyarlılık çalışmalarında bu metrik özellikle önemlidir; çünkü gerçek heyelan alanlarının model tarafından atlanması, duyarlılık haritasının güvenilirliğini azaltabilir. Bu nedenle recall değeri, modellerin heyelan sınıfını yakalama kapasitesinin değerlendirilmesinde temel ölçütlerden biri olarak kullanılmıştır. F1 skoru, precision ve recall değerlerinin harmonik ortalamasıdır. Bu metrik, modelin hem yanlış pozitifleri hem de yanlış negatifleri dikkate alarak dengeli bir performans gösterip göstermediğini değerlendirmek için kullanılmıştır. Özellikle precision ve recall arasında belirgin fark bulunan durumlarda F1 skoru, model başarısının daha dengeli yorumlanmasına katkı sağlar. ROC eğrisi ve ROC-AUC, modellerin farklı eşik değerlerinde pozitif ve negatif sınıfları ayırma kapasitesini değerlendirmek için kullanılmıştır. ROC eğrisi, doğru pozitif oranı ile yanlış pozitif oranı arasındaki ilişkiyi gösterir. Bu çalışmada ROC-AUC, modellerin genel ayırt edici performansını karşılaştırmak için temel metriklerden biri olarak değerlendirilmiştir. AUC değerinin 0.5'e yakın olması rastgele sınıflandırmaya yakın performansı, 1'e yaklaşması ise daha güçlü ayırt edici performansı göstermektedir.

Bu çalışmada ROC-AUC değerleri hem 5 katlı çapraz doğrulama aşamasında hem de bağımsız hold-out test setinde hesaplanmıştır. Ayrıca eğitim AUC, çapraz doğrulama AUC ve hold-out AUC değerleri birlikte karşılaştırılmıştır. Eğitim AUC değeri ile çapraz doğrulama veya hold-out AUC değeri arasındaki fark, modelin aşırı öğrenme eğilimini değerlendirmek için kullanılmıştır. CV_AUC_Gap ile eğitim AUC değeri ile çapraz doğrulama AUC ortalaması arasındaki fark olarak hesaplanmıştır. Precision–

Recall eğrisi, özellikle pozitif sınıf performansını değerlendirmek için kullanılmıştır. ROC eğrisi genel ayırt ediciliği gösterirken, Precision–Recall eğrisi modelin heyelan sınıfına yönelik tahminlerinin kalitesini daha doğrudan yansıtır. Bu çalışmada her model için Precision–Recall eğrisi çizilmiş ve Average Precision değeri hesaplanmıştır. Average Precision, farklı recall seviyelerinde elde edilen precision değerlerinin özet bir ölçüsüdür. Cohen’s Kappa katsayısı, model tahminleri ile gerçek sınıflar arasındaki uyumu, rastlantısal uyumu da dikkate alarak değerlendiren bir metriktir. Bu nedenle yalnızca doğruluk oranına kıyasla daha dengeli bir değerlendirme sağlar. Kappa değerinin 1’e yaklaşması güçlü uyumu, 0’a yakın olması rastlantısal uyuma yakın performansı göstermektedir.

Tablo 3. Kullanılan model değerlendirme metrikleri

Değerlendirme kriteri	Formül	Amaç	Yorum
Doğruluk (Accuracy)	$\frac{TP + TN}{TP + TN + FP + FN}$	Tüm örnekler içinde doğru sınıflandırılan örneklerin oranını gösterir.	Genel sınıflandırma başarısını özetler; ancak tek başına pozitif sınıf başarısını göstermekte yetersiz kalabilir.
Hassasiyet / Kesinlik (Precision)	$\frac{TP}{TP + FP}$	Modelin heyelan olarak tahmin ettiği örneklerin ne kadarının gerçekten heyelan olduğunu gösterir.	Yanlış pozitif tahminleri değerlendirmek için önemlidir.
Duyarlılık (Recall / Sensitivity)	$\frac{TP}{TP + FN}$	Gerçek heyelan örneklerinin model tarafından ne kadarının doğru yakalandığını gösterir.	Heyelan alanlarının atlanmamasını değerlendirmek için kritik bir metriktir.
F1 skoru	$2 \times \frac{Precision \times Recall}{Precision + Recall}$	Precision ve recall değerlerinin harmonik ortalamasını verir.	Pozitif sınıf performansını dengeli biçimde özetler.
Özgüllük (Specificity)	$\frac{TN}{TN + FP}$	Gerçek heyelan olmayan örneklerin ne kadarının doğru sınıflandırıldığını gösterir.	Heyelan olmayan alanların yanlışlıkla riskli sınıfa atanmasını değerlendirmeye yardımcı olur.
ROC-AUC	$\int_0^1 TPR(FPR)d(FPR)$	Modelin farklı eşik değerlerinde sınıfları ayırt etme gücünü değerlendirir.	Eşik değerinden bağımsız genel ayırt edici performansı gösterir.
Average Precision (AP)	$\sum_n (R_n - R_{n-1})P_n$	Precision–Recall eğrisi altında pozitif sınıf odaklı performansı özetler.	Heyelan sınıfına yönelik tahmin kalitesini değerlendirmeye katkı sağlar.

Tablo 3. (Devamı)

Değerlendirme kriteri	Formül	Amaç	Yorum
Cohen's Kappa	$\frac{P_0 - P_e}{1 - P_e}$	Gözlenen sınıflandırma uyumunu rastlantısal uyuma göre düzeltir.	Doğruluğun ötesinde model–gerçek sınıf uyumunu gösterir.
Matthews Korelasyon Katsayısı (MCC)	$\frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$	Karışıklık matrisinin tüm bileşenlerini birlikte değerlendirir.	Dengeli ve güçlü bir ikili sınıflandırma ölçütüdür.
CV AUC farkı	$CV_{AUCGap} = AUC_{train} - AUC_{CV}$	Eğitim AUC değeri ile çapraz doğrulama AUC değeri arasındaki farkı gösterir.	Aşırı öğrenme eğilimini değerlendirmek için kullanılır.

Matthews Korelasyon Katsayısı (MCC), ikili sınıflandırma problemlerinde tüm karışıklık matrisi bileşenlerini aynı anda dikkate alan güçlü bir performans ölçütüdür. MCC değeri -1 ile +1 arasında değişir. +1 mükemmel sınıflandırmayı, 0 rastgele sınıflandırmaya yakın performansı, -1 ise tamamen ters sınıflandırmayı ifade eder. Bu çalışmada MCC, modellerin dengeli sınıflandırma kapasitesini değerlendirmek için kullanılmıştır.

4.8. SHAP Açıklanabilirlik Analizi

Makine öğrenmesi modelleri, heyelan duyarlılığını etkileyen koşullayıcı faktörler arasındaki doğrusal olmayan ve karmaşık ilişkileri başarılı biçimde öğrenebilmekle birlikte, özellikle ağaç tabanlı topluluk modelleri, boosting algoritmaları, destek vektör makineleri ve yapay sinir ağları gibi yöntemlerde model kararlarının doğrudan yorumlanması zorlaşabilmektedir. Bu nedenle çalışmada yalnızca model performans metrikleri değerlendirilmemiş, aynı zamanda modellerin hangi değişkenlere ne ölçüde önem verdiğini ve bu değişkenlerin heyelan olasılığı üzerindeki yönlü etkilerini açıklamak amacıyla SHAP (SHapley Additive exPlanations) analizi uygulanmıştır.

SHAP analizi, oyun teorisindeki Shapley değerlerine dayanan model açıklanabilirlik yaklaşımıdır. Bu yöntem, her bir değişkenin tekil bir tahmin üzerindeki katkısını hesaplayarak model çıktısını değişken bazında ayrıştırır. Başka bir ifadeyle, her örnek için modelin ürettiği heyelan olasılığı, başlangıç/beklenen model çıktısı ile koşullayıcı faktörlerin pozitif veya negatif katkılarının toplamı olarak açıklanır. Bu sayede yalnızca genel değişken önem sıralaması değil, aynı zamanda her değişkenin belirli örneklerde heyelan olasılığını artırıcı veya azaltıcı yönde nasıl davrandığı da değerlendirilebilir. SHAP yaklaşımının temel katkı yapısı aşağıdaki gibi ifade edilebilir:

$$f(x) = \phi_0 + \sum_{i=1}^p \phi_j \quad (14)$$

Burada $f(x)$ modelin ilgili örnek için ürettiği tahmin değerini, ϕ_0 modelin beklenen/bazal tahmin değerini, p değişken sayısını ve ϕ_j ise j . değişkenin tahmine katkısını ifade etmektedir. Pozitif SHAP değerleri ilgili değişkenin model tahminini heyelan sınıfı yönünde artırdığını, negatif SHAP değerleri ise tahmini heyelan olmayan sınıf yönünde azalttığını gösterir. Bir değişkene ait Shapley değeri genel olarak aşağıdaki şekilde tanımlanabilir:

$$\phi_j = \sum_{S \subseteq F, \{j\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} \left[f_{S \cup \{j\}}(X_{S \cup \{j\}}) - f_S(X_S) \right] \quad (15)$$

Burada F tüm değişkenler kümesini, S j . değişkeni içermeyen değişken alt kümesini, $|S|$ alt kümedeki değişken sayısını, $|F|$ toplam değişken sayısını, $f_{S \cup \{j\}}$ j . değişkenin dahil edildiği model çıktısını ve f_S j . değişkenin dahil edilmediği model çıktısını ifade etmektedir. Bu formül, ilgili değişkenin tüm olası değişken kombinasyonları içerisindeki ortalama marjinal katkısını hesaplamaktadır. SHAP hesaplamalarında işlem yükünü yönetilebilir düzeyde tutmak için örnekleme yaklaşımı uygulanmıştır. Bu kapsamda Ağaç tabanlı modellerde en fazla 500 örnek, Lojistik Regresyon modelinde en fazla 500 örnek, KernelExplainer kullanılan modellerde ise en fazla 80 örnek üzerinden SHAP değerleri hesaplanmıştır.

5. BULGULAR

5.1. Veri Seti ve Örnek Noktaların Dağılımı

Çalışmada makine öğrenmesi modellerinin eğitimi ve değerlendirilmesi için heyelan ve heyelan olmayan örneklerden oluşan dengeli bir veri seti oluşturulmuştur. Heyelan sınıfını temsil eden örnekler, AFAD ve MTA kaynaklı heyelan envanterinden elde edilen centroid noktalarından üretilmiş; heyelan olmayan sınıfı temsil eden örnekler ise bilinen heyelan alanlarından en az 500 m uzaklıkta yer alan, tüm koşullayıcı faktörlerde geçerli raster değerine sahip pikseller arasından seçilmiştir. Heyelan olmayan noktaların seçiminde tampon mesafe, grid tabanlı mekânsal dengeleme ve kontrollü düşük eğim örnekleme yaklaşımı birlikte uygulanmıştır. Böylece negatif örneklerin çalışma alanında belirli bölgelerde kümelenmesi önlenmiş ve modelin yalnızca kolay topoğrafik ayrımlara dayalı öğrenme yapması sınırlandırılmıştır.

Heyelan ve heyelan olmayan sınıfların koşullayıcı faktörlere göre dağılımları violin grafikleri ile Şekil 21’de incelenmiştir. Violin grafikler, her bir değişkenin iki sınıf içerisindeki dağılım genişliğini, yoğunlaşma aralıklarını ve merkezi eğilimini karşılaştırmalı olarak göstermektedir. Grafiklerde genel olarak bazı değişkenlerde iki sınıf arasında belirgin dağılım farklılıkları izlenirken, bazı değişkenlerde dağılımların kısmen örtüştüğü görülmektedir. Bu durum, heyelan oluşumunun tek bir faktörle açıklanamayacağını, bunun yerine topoğrafik, hidrolojik, litolojik, iklimsel ve sismik/jeoteknik faktörlerin birlikte değerlendirilmesi gerektiğini desteklemektedir. Özellikle Eğim, Yüzey Pürüzlülüğü, Topoğrafik Pürüzlülük İndeksi, Yıllık Yağış, Yola Uzaklık, V_{s30} , Zemin Büyütme Faktörü, Zemin Hâkim Periyodu ve bazı sismik/jeoteknik tabaka parametrelerinde heyelan ve heyelan olmayan sınıflar arasında görsel olarak ayrılan dağılımlar dikkati çekmektedir. Heyelan örneklerinin eğim değerlerinin genel olarak daha yüksek aralıklarda yoğunlaştığı, buna karşılık heyelan olmayan örneklerde düşük eğimli alanların daha belirgin temsil edildiği görülmektedir. Bu bulgu, yamaç eğiminin heyelan duyarlılığı üzerindeki temel kontrol edici rolüyle uyumludur. Bununla birlikte heyelan olmayan örneklerde de yüksek eğimli alanların bulunması, eğimin tek başına ayırt edici olmadığını ve diğer koşullayıcı faktörlerle birlikte değerlendirilmesi gerektiğini göstermektedir.


Hidrolojik ve antropojenik faktörler açısından bakıldığında, Yola Uzaklık değişkeninde heyelan örneklerinin daha dar ve daha düşük mesafe sınıflarında

yoğunlaşma eğiliminde olduğu görülmektedir. Bu durum, yol açma, şev kesimi, drenaj değişimi ve kazı-dolgu etkilerinin yamaç stabilitesi üzerinde rol oynayabileceğini düşündürmektedir. Akarsuya Uzaklık değişkeninde ise sınıflar arasında daha karmaşık ve kısmen örtüşen bir dağılım izlenmektedir. Bu durum, akarsu etkisinin çalışma alanında yalnızca mesafe ile değil, aynı zamanda vadi morfolojisi, eğim, litoloji ve drenaj yoğunluğu gibi diğer faktörlerle birlikte şekillendiğini göstermektedir. Topoğrafik nem ve morfometrik göstergeler incelendiğinde, Topoğrafik Islanma İndeksi değerlerinin heyelan olmayan sınıfta daha geniş ve daha yüksek değer aralığında dağıldığı, heyelan sınıfında ise daha dar bir aralıkta yoğunlaştığı görülmektedir. Bu durum, negatif örneklerin kontrollü düşük eğim alanlarından da seçilmiş olmasıyla ilişkili olabilir; çünkü düşük eğimli alanlarda TWI değerleri daha yüksek hesaplanabilmektedir. Buna karşılık Yüzey Pürüzlülüğü ve Topoğrafik Pürüzlülük İndeksi değerlerinin heyelan sınıfında daha yüksek aralıklarda yoğunlaşması, heyelanların daha parçalanmış, engebeli ve morfolojik olarak düzensiz yamaç koşullarıyla ilişkili olabileceğini göstermektedir.

Sismik ve jeoteknik zemin parametreleri açısından, heyelan sınıfında V_{s30} değerlerinin nispeten daha düşük, Zemin Büyütme Faktörü ve Zemin Hâkim Periyodu değerlerinin ise daha yüksek aralıklarda yoğunlaşma eğiliminde olduğu görülmektedir. Bu bulgu, daha düşük rijitlikli veya daha yüksek dinamik büyütme potansiyeline sahip zemin koşullarının heyelan duyarlılığıyla ilişkili olabileceğini düşündürmektedir. Ayrıca 1. ve 2. tabakaya ait yoğunluk, kayma modülü, elastisite modülü, bulk modülü ve Poisson oranı gibi parametrelerde sınıflar arasında tam bir ayrışma olmasa da dağılım merkezleri ve yoğunlaşma bölgeleri bakımından farklılıklar bulunmaktadır. Bu durum, zemin profilinin yalnızca yüzeysel değil, tabakalı mekanik özellikleriyle birlikte değerlendirilmesinin model açısından anlamlı bilgi sağlayabileceğini göstermektedir. Litoloji, arazi örtüsü ve bakı gibi kategorik veya sınıfsal değişkenlerde violin grafiklerin yorumu daha dikkatli yapılmalıdır; çünkü bu değişkenler sürekli ölçekte değil, sınıf kodları üzerinden temsil edilmektedir. Buna rağmen bu grafikler, belirli litolojik veya arazi örtüsü sınıflarının heyelan ve heyelan olmayan örneklerde farklı yoğunluklarda temsil edilebildiğini göstermektedir. Bu tür kategorik değişkenlerin model içerisindeki gerçek katkısı, daha sonra SHAP açıklanabilirlik analizi ile daha ayrıntılı olarak değerlendirilmiştir.

Genel olarak violin grafikleri, bazı koşullayıcı faktörlerin heyelan ve heyelan olmayan sınıflar arasında belirgin dağılım farkları sunduğunu, buna karşın birçok değişkende sınıflar arasında önemli ölçüde örtüşme bulunduğunu göstermektedir. Bu

örtüşme, heyelan duyarlılığının karmaşık ve çok değişkenli bir süreç olduğunu desteklemektedir. Dolayısıyla tek değişkenli eşik yaklaşımları yerine, değişkenler arası doğrusal olmayan ilişkileri ve etkileşimleri öğrenebilen makine öğrenmesi modellerinin kullanılması bu çalışma için uygun bir yaklaşım olarak değerlendirilmiştir.



Şekil 14. Heyelan ve heyelan olmayan sınıflara göre koşullayıcı faktörlerin violin grafikleri

5.2. VIF Analizi Bulguları

Modelleme öncesinde koşullayıcı faktörler arasındaki çoklu doğrusal bağlantı düzeyi VIF analizi ile değerlendirilmiştir. VIF analizi yalnızca eğitim veri seti üzerinde uygulanmış, hold-out test seti bu sürece dahil edilmemiştir. Böylece test verisinden değişken seçim sürecine bilgi aktarılması engellenmiş ve bağımsız test setinin tarafsızlığı korunmuştur. Analizde başlangıçta toplam 28 koşullayıcı faktör değerlendirilmiştir. VIF eşik değeri 1000 olarak belirlenmiş ve bu eşik değerin üzerinde kalan değişkenler iteratif olarak veri setinden çıkarılmıştır. VIF analizi sonucunda 6 değişken eşik değerin üzerinde bulunmuştur. En yüksek VIF değeri Plan Eğriselliği değişkeninde saptanmıştır. Bu değişkenin VIF değerinin çok yüksek olması, diğer morfometrik eğrisellik değişkenleriyle ileri düzeyde doğrusal ilişki gösterdiğini düşündürmektedir. Benzer şekilde bazı sismik/jeoteknik değişkenlerde de yüksek VIF değerleri elde edilmiştir. Özellikle 1. ve 2. tabakaya ait yoğunluk, elastisite ve Poisson oranı gibi parametrelerin kendi aralarında fiziksel ve matematiksel olarak ilişkili olması, bu değişkenlerde yüksek çoklu doğrusal bağlantının ortaya çıkmasına neden olmuş olabilir. Bu nedenle eşik değerin üzerinde kalan değişkenler modelleme veri setinden çıkarılmıştır (Tablo 4).

Tablo 4. VIF analizi sonucunda çıkarılan koşullayıcı faktörler

Çıkarılan değişken	VIF değeri
Plan Eğriselliği	6.0048×10^{14}
2. Tabaka Yoğunluk	14769.83
1. Tabaka Elastisite Modülü E	8075.33
1. Tabaka Yoğunluk	4334
Zemin Büyütme Faktörü	2073.25
1. Tabaka Poisson Oranı	1495.87

VIF analizi sonrasında kalan 22 koşullayıcı faktör, makine öğrenmesi modellerinin eğitiminde ortak öznitelik seti olarak kullanılmıştır. Böylece tüm algoritmalar aynı değişken uzayı üzerinde karşılaştırılmış ve model performanslarının farklı öznitelik setlerinden etkilenmesi önlenmiştir.

5.3. Makine Öğrenmesi Modellerinin Performans Bulguları

5.3.1. Çapraz Doğrulama Performansı

VIF analizi sonrasında seçilen 22 koşullayıcı faktör kullanılarak on farklı makine öğrenmesi modeli eğitilmiş ve ilk aşamada 5 katlı stratified cross-validation yaklaşımıyla değerlendirilmiştir. Çapraz doğrulama sürecinde her model için doğruluk, hassasiyet, duyarlılık, F1 skoru ve ROC-AUC değerlerinin ortalama ve standart sapmaları hesaplanmıştır. Ayrıca eğitim AUC değeri ile çapraz doğrulama AUC değeri arasındaki fark CV AUC Gap olarak değerlendirilmiştir. Bu değer, modellerin eğitim verisine aşırı uyum gösterip göstermediğini yorumlamak amacıyla kullanılmıştır. Çapraz doğrulama sonuçlarına göre modeller genel olarak yüksek ayırt edici performans göstermiştir. En yüksek ortalama CV AUC değeri Rastgele Orman modelinde elde edilmiştir ($CV\ AUC = 0.9651 \pm 0.0123$). Bu modeli çok yakın performansla XGBoost ($CV\ AUC = 0.9650 \pm 0.0156$) ve LightGBM ($CV\ AUC = 0.9624 \pm 0.0166$) izlemiştir. Bu bulgu, topluluk öğrenme ve boosting tabanlı modellerin heyelan ve heyelan olmayan örnekleri ayırt etmede güçlü performans sergilediğini göstermektedir.

Doğruluk açısından da en yüksek değer Rastgele Orman modelinde gözlenmiştir (0.9123 ± 0.0245). Bunu LightGBM (0.9079 ± 0.0290) ve XGBoost (0.9064 ± 0.0313) takip etmiştir. F1 skoru bakımından da benzer bir sıralama izlenmiş; Rastgele Orman modeli en yüksek F1 skoruna ulaşmıştır (0.9150 ± 0.0242). Bu sonuç, Rastgele Orman modelinin yalnızca genel sınıflandırma başarısı açısından değil, hassasiyet ve duyarlılık dengesini temsil eden F1 skoru açısından da güçlü bir performans sunduğunu göstermektedir. Duyarlılık değerleri incelendiğinde, Rastgele Orman modeli gerçek heyelan örneklerini yakalama açısından en yüksek performansı göstermiştir (0.9463 ± 0.0308). Bunu Ekstra Ağaçlar (0.9433 ± 0.0359) ve XGBoost (0.9374 ± 0.0319) izlemiştir. Heyelan duyarlılık çalışmalarında gerçek heyelan alanlarının model tarafından atlanmaması kritik olduğundan, yüksek duyarlılık değerleri özellikle önemlidir. Buna karşılık hassasiyet değerlerinde LightGBM modeli en yüksek ortalama değeri göstermiştir (0.8896 ± 0.0331). Bu durum, LightGBM modelinin heyelan olarak tahmin ettiği örneklerin doğruluğu açısından güçlü bir performans sergilediğini düşündürmektedir. CV AUC Gap değerleri açısından değerlendirildiğinde, Lojistik Regresyon modelinde en düşük fark elde edilmiştir (0.0197). Ancak bu modelin genel AUC performansı topluluk modellerine göre daha düşük kalmıştır ($CV\ AUC = 0.9119 \pm 0.0336$). KNN ve SVM modellerinde de CV AUC Gap değerleri düşük bulunmuştur; bu durum bu modellerin eğitim ve doğrulama performansları arasında daha sınırlı fark

olduğunu göstermektedir. Buna karşın Karar Ağacı modelinde CV AUC Gap değeri daha yüksek bulunmuştur (0.0762). Bu sonuç, tekil karar ağacı modelinin eğitim verisine daha fazla uyum gösterme eğiliminde olabileceğini düşündürmektedir. YSA (MLP) modelinde de CV AUC Gap değeri 0.0545 olarak hesaplanmış ve bu değer diğer birçok modele göre daha yüksek bulunmuştur.

Tablo 5. Makine öğrenmesi modellerinin 5 katlı çapraz doğrulama performansları

Model	CV Doğruluk	CV Hassasiyet	CV Duyarlılık	CV F1	CV AUC	Eğitim AUC	CV AUC Gap
Rastgele Orman	0.9123 ± 0.0245	0.8860 ± 0.0253	0.9463 ± 0.0308	0.9150 ± 0.0242	0.9651 ± 0.0123	0.999	0.0339
XGBoost	0.9064 ± 0.0313	0.8832 ± 0.0366	0.9374 ± 0.0319	0.9091 ± 0.0302	0.9650 ± 0.0156	10.000	0.035
LightGBM	0.9079 ± 0.0290	0.8896 ± 0.0331	0.9315 ± 0.0261	0.9099 ± 0.0281	0.9624 ± 0.0166	10.000	0.0376
Gradyan Artırma	0.8886 ± 0.0146	0.8643 ± 0.0225	0.9225 ± 0.0258	0.8920 ± 0.0145	0.9574 ± 0.0144	0.9998	0.0424
Ekstra Ağaçlar	0.9019 ± 0.0280	0.8716 ± 0.0311	0.9433 ± 0.0359	0.9056 ± 0.0271	0.9554 ± 0.0164	0.9956	0.0402
YSA (MLP)	0.8915 ± 0.0343	0.8860 ± 0.0362	0.8987 ± 0.0417	0.8920 ± 0.0348	0.9455 ± 0.0278	10.000	0.0545
SVM	0.8885 ± 0.0323	0.8717 ± 0.0185	0.9105 ± 0.0627	0.8897 ± 0.0354	0.9513 ± 0.0239	0.9776	0.0263
Karar Ağacı	0.8544 ± 0.0166	0.8429 ± 0.0222	0.8720 ± 0.0362	0.8565 ± 0.0177	0.8967 ± 0.0197	0.9729	0.0762
KNN	0.8574 ± 0.0293	0.8263 ± 0.0270	0.9047 ± 0.0386	0.8634 ± 0.0292	0.9315 ± 0.0244	0.9564	0.0249
Lojistik Regresyon	0.8455 ± 0.0380	0.8312 ± 0.0288	0.8659 ± 0.0649	0.8473 ± 0.0413	0.9119 ± 0.0336	0.9316	0.0197

Genel olarak çapraz doğrulama bulguları, topluluk tabanlı ağaç modellerinin ve boosting algoritmalarının çalışma alanındaki heyelan duyarlılığını modellemede daha başarılı olduğunu göstermektedir. Özellikle Rastgele Orman, XGBoost ve LightGBM modelleri hem yüksek CV AUC hem de yüksek doğruluk ve F1 skorlarıyla öne çıkmıştır. Tekil Karar Ağacı ve Lojistik Regresyon modelleri ise diğer modellere kıyasla daha düşük ayırt edici performans göstermiştir. Bu durum, heyelan duyarlılığının doğrusal veya basit eşik tabanlı ilişkilerden ziyade, koşullayıcı faktörler

arasındaki doğrusal olmayan ve etkileşimli örüntülerle daha iyi temsil edildiğini düşündürmektedir. Bununla birlikte, yalnızca çapraz doğrulama sonuçlarına dayanarak nihai model seçimi yapılmamıştır. Modellerin bağımsız genelleme başarısını değerlendirmek amacıyla hold-out test seti sonuçları ayrıca incelenmiştir. Bu nedenle nihai performans yorumunda CV sonuçları, hold-out test metrikleri ve AUC–F1 dengesi birlikte değerlendirilmiştir.

5.3.2. Hold-out Test Performansı

Çapraz doğrulama analizinden sonra modeller, eğitim sürecinde kullanılmayan bağımsız hold-out test seti üzerinde değerlendirilmiştir. Bu aşama, modellerin daha önce görmediği örnekler üzerindeki genelleme başarısını ortaya koyması açısından önemlidir. Hold-out test setinde doğruluk, hassasiyet, duyarlılık, F1 skoru, ROC-AUC, Cohen’s Kappa ve Matthews Korelasyon Katsayısı (MCC) değerleri hesaplanmıştır. Hold-out test sonuçlarına göre en yüksek ROC-AUC değeri Rastgele Orman modelinde elde edilmiştir (AUC = 0.9637). Bu modeli çok yakın performansla XGBoost (AUC = 0.9613) ve LightGBM (AUC = 0.9611) takip etmiştir. Bu üç modelin AUC değerlerinin birbirine oldukça yakın olması, ağaç tabanlı topluluk ve boosting yöntemlerinin heyelan–heyelan olmayan sınıfları ayırt etmede güçlü ve kararlı performans gösterdiğini ortaya koymaktadır.

Bununla birlikte, yalnızca AUC değeri dikkate alındığında Rastgele Orman modeli ilk sırada yer alırken, çoklu performans metrikleri birlikte değerlendirildiğinde LightGBM modeli daha dengeli bir sonuç üretmiştir. LightGBM modeli hold-out test setinde en yüksek doğruluk (0.8962), en yüksek F1 skoru (0.9020), en yüksek Cohen’s Kappa (0.7923) ve en yüksek MCC (0.7972) değerlerine ulaşmıştır. Bu durum, LightGBM modelinin yalnızca ayırt edici performans açısından değil, aynı zamanda sınıflandırma dengesini temsil eden ölçütler açısından da oldukça başarılı olduğunu göstermektedir.

XGBoost modeli de LightGBM’e çok yakın sonuçlar üretmiştir. XGBoost’un doğruluk değeri 0.8927, F1 skoru 0.8990, AUC değeri 0.9613, Kappa değeri 0.7854 ve MCC değeri 0.7909 olarak hesaplanmıştır. Bu bulgu, XGBoost modelinin de bağımsız test verisi üzerinde yüksek genelleme kapasitesine sahip olduğunu göstermektedir. Duyarlılık açısından en yüksek değer KNN modelinde elde edilmiştir (0.9586). Ancak KNN modelinin hassasiyet değeri daha düşük kalmıştır (0.7765). Bu durum, KNN modelinin gerçek heyelan örneklerini yakalama eğiliminin yüksek olduğunu, ancak daha fazla heyelan olmayan alanı yanlış pozitif olarak heyelan sınıfına atayabildiğini

göstermektedir. Buna karşılık LightGBM ve XGBoost modelleri hem yüksek duyarlılık hem de daha yüksek hassasiyet değerleriyle daha dengeli bir sınıflandırma performansı sunmuştur. Lojistik Regresyon modeli hold-out test setinde en düşük AUC değerine sahip model olmuştur (AUC = 0.8950). Buna rağmen model tamamen başarısız bir performans göstermemiş, ancak doğrusal yapısı nedeniyle karmaşık ve doğrusal olmayan heyelan–koşullayıcı faktör ilişkilerini ağaç tabanlı topluluk modelleri kadar etkili yakalayamamıştır. Karar Ağacı modeli de tekil ağaç yapısı nedeniyle topluluk modellerine göre daha düşük AUC ve sınıflandırma başarısı göstermiştir.


Tablo 6. Makine öğrenmesi modellerinin hold-out test performansları

Model	Doğruluk	Hassasiyet	Duyarlılık	F1skoru	AUC	Kappa	MCC
Rastgele Orman	0.8824	0.8405	0.9448	0.8896	0.9637	0.7646	0.7706
XGBoost	0.8927	0.8519	0.9517	0.899	0.9613	0.7854	0.7909
LightGBM	0.8962	0.8571	0.9517	0.902	0.9611	0.7923	0.7972
Gradyan Artırma	0.8824	0.8405	0.9448	0.8896	0.9567	0.7646	0.7706
Ekstra Ağaçlar	0.8824	0.8405	0.9448	0.8896	0.9436	0.7646	0.7706
YSA (MLP)	0.8754	0.8562	0.9034	0.8792	0.9375	0.7508	0.752
SVM	0.8581	0.8467	0.8759	0.861	0.9362	0.7162	0.7167
Karar Ağacı	0.8685	0.8452	0.9034	0.8733	0.9211	0.737	0.7387
KNN	0.8408	0.7765	0.9586	0.858	0.9125	0.6814	0.7011
Lojistik Regresyon	0.8339	0.8089	0.8759	0.8411	0.895	0.6677	0.67

Çapraz doğrulama ve hold-out test sonuçları birlikte değerlendirildiğinde, Rastgele Orman, XGBoost ve LightGBM modellerinin en başarılı model grubu olduğu görülmektedir. Rastgele Orman modeli hem çapraz doğrulama hem de hold-out test setinde en yüksek AUC değerlerini üretmiş, bu nedenle ayırt edici performans açısından en güçlü model olarak öne çıkmıştır. LightGBM ise hold-out test setinde en yüksek doğruluk, F1, Kappa ve MCC değerlerine ulaşarak dengeli sınıflandırma performansı açısından en başarılı model olmuştur. Özellikle Rastgele Orman modelinde çapraz doğrulama AUC değeri 0.9651, hold-out AUC değeri ise 0.9637 olarak hesaplanmıştır. Bu iki değer birbirine çok yakın olması, modelin eğitim verisindeki performansını bağımsız test setine büyük ölçüde taşıyabildiğini ve aşırı öğrenme eğiliminin sınırlı olduğunu göstermektedir. Benzer şekilde XGBoost ve LightGBM modellerinde de çapraz doğrulama ve hold-out AUC değerleri arasında belirgin bir düşüş gözlenmemiştir. Bu durum, bu modellerin genellenebilirlik açısından güvenilir

olduğunu desteklemektedir. Genel olarak hold-out test bulguları, heyelan duyarlılığı modellemesinde doğrusal veya tekil ağaç yapısındaki modeller yerine, çoklu ağaç yapısı ve boosting stratejisi kullanan modellerin daha başarılı olduğunu göstermektedir. Bu sonuç, heyelan oluşumunun çoklu koşullayıcı faktörlerin doğrusal olmayan ve etkileşimli etkileriyle şekillendiğini desteklemektedir.

Çapraz doğrulama ve hold-out test metriklerine ek olarak, modellerin genelleme performansını ve olası aşırı öğrenme eğilimini görsel olarak değerlendirmek amacıyla eğitim, çapraz doğrulama ve hold-out AUC değerleri birlikte incelenmiştir. Bu amaçla ilk olarak her model için eğitim AUC, çapraz doğrulama AUC ve hold-out AUC değerleri karşılaştırılmıştır. Bu karşılaştırma, modellerin eğitim veri setinde elde ettikleri ayırt edici performansı bağımsız test setine ne ölçüde taşıyabildiklerini göstermektedir. Eğitim, çapraz doğrulama ve hold-out AUC değerlerinin model bazlı karşılaştırılması Şekil 23'te verilmiştir.




Şekil 15. Eğitim, çapraz doğrulama ve hold-out AUC değerlerinin model bazlı karşılaştırılması

Şekil 15 incelendiğinde, Rastgele Orman, XGBoost ve LightGBM modellerinde çapraz doğrulama AUC değerleri ile hold-out AUC değerlerinin birbirine oldukça yakın olduğu görülmektedir. Rastgele Orman modelinde CV AUC değeri 0.9651 iken hold-out AUC değeri 0.9637 olarak elde edilmiştir. Benzer şekilde XGBoost modelinde CV

AUC 0.9650 ve hold-out AUC 0.9613; LightGBM modelinde ise CV AUC 0.9624 ve hold-out AUC 0.9611 olarak hesaplanmıştır. Bu sonuçlar, bu üç modelin eğitim verisinde öğrendiği örüntüleri bağımsız test setine başarılı biçimde genelleyebildiğini göstermektedir. Bununla birlikte bazı modellerde eğitim AUC değerlerinin oldukça yüksek olduğu, hatta bazı modellerde 1.00'a yaklaştığı görülmektedir. Ancak bu modellerde hold-out AUC değerlerinin belirgin biçimde düşmemesi, özellikle topluluk tabanlı modellerde aşırı öğrenme etkisinin sınırlı kaldığını düşündürmektedir. Buna karşılık Karar Ağacı, KNN ve Lojistik Regresyon modellerinde hem CV hem de hold-out AUC değerleri daha düşük düzeyde kalmış, bu modellerin heyelan ve heyelan olmayan sınıfları ayırt etmede topluluk modellerine kıyasla daha sınırlı performans gösterdiği anlaşılmıştır.

İkinci olarak, çapraz doğrulama sürecindeki AUC değerlerinin katlar arasındaki dağılımı boxplot grafikleriyle Şekil 23'te değerlendirilmiştir. Bu grafiklerde kutular 5 katlı çapraz doğrulamada elde edilen AUC değerlerinin dağılımını, kırmızı elmas işareti ise ilgili modelin bağımsız hold-out test setindeki AUC değerini göstermektedir.



Şekil 16. Çapraz doğrulama sürecindeki AUC değerlerinin katlar arasındaki dağılımın boxplot grafikleri

Şekil 16'ya göre Rastgele Orman, XGBoost, LightGBM ve Gradyan Artırma modellerinde CV AUC dağılımları dar bir aralıkta yoğunlaşmış ve hold-out AUC değerleri bu dağılımlarla uyumlu konumlanmıştır. Bu durum, söz konusu modellerin farklı çapraz doğrulama katlarında kararlı performans sergilediğini ve bağımsız test


setinde de benzer başarı düzeyini koruduğunu göstermektedir. Özellikle Rastgele Orman ve XGBoost modellerinde hold-out AUC değerlerinin CV dağılımına oldukça yakın olması, bu modellerin genellenebilirlik açısından güçlü olduğunu desteklemektedir. Genel olarak bu iki grafik birlikte değerlendirildiğinde, Rastgele Orman, XGBoost ve LightGBM modellerinin hem yüksek ayırt edici performans hem de kararlı genelleme kapasitesi açısından öne çıktığı görülmektedir. Rastgele Orman modeli en yüksek hold-out AUC değerine ulaşırken, LightGBM modeli hold-out test setinde en yüksek doğruluk, F1 skoru, Kappa ve MCC değerlerini üretmiştir. Bu nedenle model seçimi yalnızca AUC değerine göre değil, AUC–F1 dengesi, bağımsız test başarısı ve çapraz doğrulama kararlılığı birlikte dikkate alınarak değerlendirilmiştir.

5.3.3. ROC ve Precision–Recall Eğrilerinin Değerlendirilmesi

Makine öğrenmesi modellerinin hold-out test setindeki ayırt edici performanslarını daha ayrıntılı değerlendirmek amacıyla ROC ve Precision–Recall eğrileri incelenmiştir. ROC eğrileri, modellerin farklı eşik değerlerinde doğru pozitif oranı ile yanlış pozitif oranı arasındaki dengeyi ortaya koyarken; Precision–Recall eğrileri özellikle pozitif sınıf olan heyelan örneklerinin tahmin başarısını daha ayrıntılı biçimde göstermektedir. Bu nedenle her iki eğri birlikte değerlendirilerek modellerin yalnızca genel ayırt ediciliği değil, aynı zamanda heyelan sınıfına yönelik tahmin kalitesi de yorumlanmıştır. Şekil 25’te hold-out test seti için elde edilen ROC eğrileri sunulmuştur. ROC eğrileri incelendiğinde, tüm modellerin rasgele sınıflandırmayı temsil eden diyagonal referans çizgisinin belirgin biçimde üzerinde yer aldığı görülmektedir. Bu durum, tüm modellerin heyelan ve heyelan olmayan örnekleri rastgele tahminden daha başarılı biçimde ayırt edebildiğini göstermektedir. Bununla birlikte eğrilerin sol üst köşeye yaklaşma derecesi modellere göre farklılık göstermektedir. ROC eğrilerine göre en yüksek AUC değeri Rastgele Orman modelinde elde edilmiştir (AUC = 0.9637). Bu modeli çok yakın değerlerle XGBoost (AUC = 0.9613) ve LightGBM (AUC = 0.9611) izlemiştir. Ayrıca Gradyan Artırma modelinin de yüksek bir performans sergilediği görülmektedir (AUC = 0.9567). Bu sonuçlar, özellikle ağaç tabanlı topluluk ve boosting modellerinin farklı eşik değerlerinde yüksek doğru pozitif oranı üretirken yanlış pozitif oranını görece düşük tutabildiğini göstermektedir.


Ekstra Ağaçlar (AUC = 0.9436), YSA (MLP) (AUC = 0.9375) ve SVM (AUC = 0.9362) modelleri de güçlü performans göstermiştir; ancak bunların ROC eğrileri en başarılı üç model kadar sol üst köşeye yaklaşmamıştır. Karar Ağacı (AUC = 0.9211)

ve KNN (AUC = 0.9125) modellerinin performansları kabul edilebilir düzeyde olmakla birlikte, ayırt edici güçlerinin topluluk temelli modellere göre daha sınırlı olduğu görülmektedir. En düşük ROC-AUC değeri ise Lojistik Regresyon modelinde elde edilmiştir (AUC = 0.8950). Bu bulgu, doğrusal yapıya sahip modellerin heyelan oluşumunu etkileyen karmaşık ve doğrusal olmayan ilişkileri daha sınırlı temsil edebildiğini düşündürmektedir.



Şekil 17. Hold-out test setinde makine öğrenmesi modellerine ait ROC eğrileri

Şekil 17’de hold-out test seti için elde edilen Precision–Recall eğrileri verilmiştir. Precision–Recall eğrileri, özellikle pozitif sınıf olan heyelan örneklerinin tahmin başarısını değerlendirmek açısından önemlidir. ROC eğrileri genel ayırt ediciliği ortaya koyarken, Precision–Recall eğrileri modelin recall arttıkça precision değerini ne ölçüde koruyabildiğini göstermektedir. Bu nedenle Precision–Recall eğrileri, heyelan sınıfına yönelik daha hassas bir performans değerlendirmesi sunmaktadır.



Şekil 18. Hold-out test setinde makine öğrenmesi modellerine ait Precision–Recall eğrileri


Şekil 18 incelendiğinde, Rastgele Orman, XGBoost, LightGBM ve Gradyan Artırma modellerinin eğrilerinin genel olarak üst bölgede seyrettiği görülmektedir. Average Precision (AP) değerleri dikkate alındığında en yüksek değer Rastgele Orman modelinde elde edilmiştir (AP = 0.9581). Bunu XGBoost (AP = 0.9551) ve LightGBM (AP = 0.9512) modelleri izlemektedir. Gradyan Artırma modelinin de yüksek AP değeriyle dikkat çektiği görülmektedir (AP = 0.9430). Bu sonuçlar, söz konusu modellerin recall arttıkça precision düzeyini daha iyi koruyabildiğini ve heyelan sınıfının tahmininde daha dengeli performans gösterdiğini ortaya koymaktadır. Ekstra Ağaçlar modelinin AP değeri 0.9320, SVM modelinin AP değeri 0.9070 ve YSA (MLP) modelinin AP değeri ise 0.9021 olarak hesaplanmıştır. Bu modeller de pozitif sınıfın tahmininde iyi performans göstermiş olmakla birlikte, üst düzey topluluk modellerine göre bir miktar daha düşük sonuç vermiştir. Karar Ağacı (AP = 0.8798) ve KNN (AP = 0.8696) modelleri daha sınırlı başarı sergilerken, en düşük AP değeri Lojistik Regresyon modelinde elde edilmiştir (AP = 0.8648). Bu bulgu, Lojistik Regresyon modelinin hem ROC analizi hem de Precision–Recall analizi açısından diğer modellerin

gerisinde kaldığını desteklemektedir. Precision–Recall eğrileri aynı zamanda modellerin yüksek recall düzeylerinde precision değerini ne ölçüde koruyabildiğini de göstermektedir. Bu açıdan bakıldığında Rastgele Orman, XGBoost ve LightGBM modelleri, recall yükseldikçe precision değerinde daha sınırlı düşüş göstermiş ve daha kararlı bir yapı ortaya koymuştur. Bu durum, gerçek heyelan örneklerini yakalama başarısı artarken yanlış pozitif tahminlerin nispeten kontrol altında tutulabildiğini göstermektedir.

Genel olarak Şekil 26, pozitif sınıf performansı açısından da Rastgele Orman, XGBoost ve LightGBM modellerinin öne çıktığını ortaya koymaktadır. ROC ve Precision–Recall eğrileri birlikte değerlendirildiğinde, bu üç modelin hem genel ayırt edicilik hem de heyelan sınıfına yönelik tahmin kalitesi bakımından en güçlü modeller olduğu anlaşılmaktadır. Özellikle Rastgele Orman modeli hem en yüksek ROC-AUC hem de en yüksek AP değerini üretmiş; buna karşılık LightGBM modeli önceki bölümde gösterildiği üzere doğruluk, F1 skoru, Kappa ve MCC açısından daha dengeli sonuçlar vermiştir. Bu nedenle nihai model değerlendirmesinde yalnızca tek bir metrik değil, ROC-AUC, AP, F1 skoru ve bağımsız test performansı birlikte dikkate alınmıştır.

5.3.4. Karışıklık Matrisleri ve Sınıflandırma Hatalarının Değerlendirilmesi

Makine öğrenmesi modellerinin hold-out test setindeki sınıflandırma davranışlarını daha ayrıntılı incelemek amacıyla karışıklık matrisleri değerlendirilmiştir. Karışıklık matrisleri, her modelin heyelan ve heyelan olmayan örnekleri ne ölçüde doğru sınıflandırabildiğini ve hangi tür hatalara daha yatkın olduğunu göstermektedir. Bu analiz, yalnızca genel performans ölçütlerine değil, aynı zamanda yanlış pozitif ve yanlış negatif hataların dağılımına da odaklanılması açısından önemlidir. Özellikle heyelan duyarlılık çalışmalarında yanlış negatif sonuçlar, yani gerçek heyelan örneklerinin model tarafından heyelan olmayan sınıfa atanması, riskli alanların gözden kaçmasına neden olabileceği için kritik öneme sahiptir. Şekil 26’da her modele ait hold-out test karışıklık matrisleri sunulmuştur. Genel olarak tüm modellerin hem heyelan hem de heyelan olmayan örnekleri yüksek oranda doğru sınıflandırabildiği görülmektedir. Bununla birlikte, modellerin hata örüntüleri incelendiğinde bazı önemli farklılıklar ortaya çıkmaktadır.



Şekil 19. Hold-out test setinde makine öğrenmesi modellerine ait karışıklık matrisleri

Rastgele Orman modelinde 118 heyelan olmayan örnek doğru biçimde heyelan olmayan olarak, 137 heyelan örneği ise doğru biçimde heyelan olarak sınıflandırılmıştır. Bu modele ait yanlış pozitif ve yanlış negatif sayıları sırasıyla 26 ve 8'dir. Bu sonuç, Rastgele Orman modelinin yanlış negatif hata sayısını düşük tutarken yüksek sayıda gerçek heyelan örneğini doğru yakalayabildiğini göstermektedir. Aynı hata dağılımının Ekstra Ağaçlar ve Gradyan Artırma modellerinde de gözlemlendiği görülmektedir. Bu üç modelde 118 doğru negatif, 137 doğru pozitif, 26 yanlış pozitif ve 8 yanlış negatif değerleri elde edilmiştir. Bu durum, bu modellerin özellikle heyelan sınıfını tanıma açısından benzer bir performans sergilediğini göstermektedir.

XGBoost modeli, 120 heyelan olmayan örneği doğru şekilde sınıflandırırken 138 heyelan örneğini de doğru olarak tespit etmiştir. Modelin yanlış pozitif sayısı 24, yanlış negatif sayısı ise yalnızca 7'dir. Bu sonuç, XGBoost modelinin hem pozitif sınıfı güçlü biçimde yakaladığını hem de yanlış pozitifleri görece düşük düzeyde tuttuğunu göstermektedir. LightGBM modeli ise 121 doğru negatif ve 138 doğru pozitif ile en dengeli sınıflandırma örüntülerinden birini sergilemiştir. Bu modelde yanlış pozitif sayısı 23, yanlış negatif sayısı ise 7 olarak hesaplanmıştır. Dolayısıyla LightGBM modeli, yanlış alarm oranını sınırlı tutarken yüksek sayıda gerçek heyelan örneğini de doğru biçimde tanımlamıştır. Bu bulgu, önceki bölümde LightGBM için elde edilen yüksek doğruluk, F1 skoru, Kappa ve MCC değerleriyle uyumludur.

YSA (MLP) modeli 122 doğru negatif ve 131 doğru pozitif örnek üretmiştir. Modelin yanlış pozitif sayısı 22 olup bu değer tüm modeller arasında en düşük değerlerden biridir. Ancak yanlış negatif sayısı 14'tür. Bu durum, YSA modelinin heyelan olmayan alanları heyelan olarak işaretleme eğilimini daha düşük tuttuğunu, ancak bazı gerçek heyelan örneklerini kaçırabildiğini göstermektedir. Benzer şekilde

Karar Ağacı modeli 120 doğru negatif ve 131 doğru pozitif örnek sınıflandırmış; 24 yanlış pozitif ve 14 yanlış negatif hata üretmiştir. Karar Ağacı modelinin tekil yapısı nedeniyle topluluk tabanlı modellere göre daha sınırlı bir performans sergilediği anlaşılmaktadır.


SVM modelinde 121 doğru negatif ve 127 doğru pozitif sınıflandırma elde edilmiştir. Buna karşılık yanlış pozitif sayısı 23 ve yanlış negatif sayısı 18'dir. Bu sonuç, SVM modelinin heyelan olmayan örnekleri ayırt etmede görece başarılı olduğunu, ancak gerçek heyelan örneklerini kaçırma eğiliminin daha yüksek olabildiğini düşündürmektedir. Lojistik Regresyon modeli ise 114 doğru negatif ve 127 doğru pozitif üretmiş; 30 yanlış pozitif ve 18 yanlış negatif hata yapmıştır. Bu modelde hem yanlış pozitif hem de yanlış negatif hata sayısının nispeten daha yüksek olması, doğrusal model yapısının karmaşık heyelan örüntülerini yakalamada sınırlı kaldığını desteklemektedir.

KNN modeli dikkat çekici bir hata örüntüsü göstermektedir. Model 139 heyelan örneğini doğru sınıflandırarak en yüksek doğru pozitif sayılarından birine ulaşmıştır. Ayrıca yanlış negatif sayısı yalnızca 6'dır ve bu yönüyle gerçek heyelanları yakalama kapasitesi oldukça yüksektir. Ancak buna karşılık yalnızca 104 heyelan olmayan örnek doğru şekilde sınıflandırılmış, 40 heyelan olmayan örnek yanlışlıkla heyelan olarak tahmin edilmiştir. Yani KNN modelinin yanlış pozitif sayısı diğer tüm modellere kıyasla belirgin biçimde yüksektir. Bu nedenle KNN modeli duyarlılık açısından avantaj sağlamakla birlikte, yanlış alarm üretme eğilimi nedeniyle daha düşük bir sınıflandırma dengesi sergilemektedir.

5.4. SHAP Açıklanabilirlik Bulguları


Makine öğrenmesi modellerinin tahmin süreçlerinde hangi koşullayıcı faktörlere daha fazla önem verdiğini değerlendirmek amacıyla SHAP açıklanabilirlik analizi uygulanmıştır. SHAP summary grafikleri, her bir değişkenin model çıktısına katkısını hem önem sırası hem de etkinin yönü bakımından göstermektedir. Grafiklerde x ekseninde SHAP değerini, renkler ise ilgili değişkenin düşük veya yüksek değerlerini temsil etmektedir. Pozitif SHAP değerleri ilgili değişkenin heyelan olasılığını artırıcı yönde katkı verdiğini, negatif SHAP değerleri ise model çıktısını heyelan olmayan sınıf yönünde etkilediğini göstermektedir. Bu nedenle SHAP grafikleri, yalnızca değişken önemini değil, aynı zamanda değişken değerlerinin model tahmini üzerindeki yönlü etkisini de yorumlamaya olanak sağlamaktadır.

SHAP sonuçları genel olarak değerlendirildiğinde, modellerin büyük bölümünde Yıllık Yağış, Yola Uzaklık, Topoğrafik Islanma İndeksi (TWI), Akarsuya Uzaklık, Eğim, Zemin Hâkim Periyodu, V_{s30} , Topoğrafik Konum İndeksi (TPI), Yüzey Pürüzlülüğü, Topoğrafik Pürüzlülük İndeksi (TRI) ve bazı tabakalı sismik/jeoteknik parametrelerin öne çıktığı görülmektedir. Bu bulgu, heyelan duyarlılığının yalnızca topoğrafik faktörlerle değil, aynı zamanda hidrolojik, antropojenik, iklimsel ve zemin dinamiğiyle ilişkili değişkenlerin birlikte etkisiyle şekillendiğini göstermektedir.



Şekil 20. LightGBM modeli için SHAP summary grafiği


Şekil 20’de sunulan LightGBM modeli için elde edilen SHAP summary grafiğinde en etkili değişkenlerin Topoğrafik Islanma İndeksi (TWI), Yıllık Yağış, Yola Uzaklık, Akarsuya Uzaklık, Zemin Hâkim Periyodu, T1 Kayma Modülü, T2 Poisson Oranı, V_{S30} , TPI ve Eğim olduğu görülmektedir. Özellikle TWI ve Yıllık Yağış değişkenlerinin geniş SHAP dağılımı göstermesi, modelin hidrolojik ve iklimsel koşulları heyelan duyarlılığı açısından güçlü ayırt edici faktörler olarak kullandığını göstermektedir. Yola uzaklık ve akarsuya uzaklık değişkenlerinin de üst sıralarda yer alması, drenaj ağına ve yol kaynaklı antropojenik müdahalelere yakınlığın model kararlarında önemli rol oynadığını ortaya koymaktadır. LightGBM modelinin hold-out test setinde en yüksek doğruluk, F1 skoru, Kappa ve MCC değerlerine ulaşması dikkate alındığında, SHAP sonuçları bu modelin hem güçlü performans hem de jeomorfolojik olarak anlamlı değişken kullanımı sergilediğini desteklemektedir.



Şekil 21. Ekstra Ağaçlar modeli için SHAP summary grafiği

Şekil 21’de sunulan Ekstra Ağaçlar modelinde en önemli değişkenlerin başında Yola Uzaklık, Yıllık Yağış, Akarsuya Uzaklık, Eğim, TWI, Yüzey Pürüzlülüğü, TRI, Yakınsama İndeksi, TPI ve Arazi Örtüsü gelmektedir. Bu modelde özellikle yola uzaklık değişkeninin ilk sırada yer alması, insan kaynaklı şev kesimi, yol açma ve drenaj değişikliklerinin heyelan duyarlılığı üzerindeki etkisinin model tarafından güçlü biçimde yakalandığını düşündürmektedir. Yıllık yağış ve akarsuya uzaklık değişkenlerinin üst sıralarda yer alması ise hidrolojik koşulların model kararlarında


belirgin rol oynadığını göstermektedir. Ekstra Ağaçlar modelinde topoğrafik ve hidrolojik değişkenlerin birlikte öne çıkması, heyelan oluşumunun çok faktörlü doğasıyla uyumludur.



Şekil 22. Gradyan Artırma modeli için SHAP summary grafiği


Şekil 22’de sunulan Gradyan Artırma modelinde Yıllık Yağış, Eğim, Yola Uzaklık, TWI, Akarsuya Uzaklık, Zemin Hâkim Periyodu, Vs₃₀, TPI, T2 Poisson Oranı ve Yüzey Pürüzlülüğü en önemli değişkenler olarak öne çıkmaktadır. Yıllık yağışın ilk

sırada yer alması, yağışın çalışma alanında heyelan duyarlılığı açısından güçlü bir hazırlayıcı veya tetikleyici faktör olarak model tarafından değerlendirildiğini göstermektedir. Eğim değişkeninin ikinci sırada yer alması ise yamaç stabilitesinde topoğrafik eğimin temel rolünü desteklemektedir. Bu modelde yola uzaklık, TWI ve akarsuya uzaklık değişkenlerinin de üst sıralarda bulunması, Gradyan Artırma modelinin topoğrafik, hidrolojik ve antropojenik etkileri birlikte kullandığını göstermektedir.




Şekil 23. Karar Ağacı modeli için SHAP summary grafiği

Şekil 23’de sunulan Karar Ağacı modelinde en etkili değişkenlerin TWI, Yıllık Yağış, Yola Uzaklık, Akarsuya Uzaklık, T2 Elastisite Modülü, T1 Hacimsel Modül, Zemin Hâkim Periyodu ve V_{s30} olduğu görülmektedir. Bununla birlikte Karar Ağacı modelinde birçok değişkenin SHAP değerlerinin sıfıra yakın yoğunlaştığı izlenmektedir. Bu durum, tekil karar ağacı yapısının sınırlı sayıda değişken ve eşik üzerinden karar verme eğiliminde olduğunu göstermektedir. Dolayısıyla Karar Ağacı modeli bazı değişkenleri güçlü biçimde kullanırken, diğer değişkenlerin modele katkısı sınırlı kalmıştır. Bu bulgu, Karar Ağacı modelinin topluluk modellerine kıyasla daha düşük performans göstermesiyle uyumludur.



Şekil 24. KNN modeli için SHAP summary grafiği


Şekil 24’de sunulan KNN modelinde Yola Uzaklık, Yıllık Yağış, TWI, Akarsuya Uzaklık, Eğim, Arazi Örtüsü, Yüzey Pürüzlülüğü, TPI ve TRI değişkenleri öne çıkmaktadır. KNN’nin mesafe tabanlı bir algoritma olması nedeniyle, benzer çevresel koşullara sahip örneklerin sınıflandırma sürecinde etkili olduğu anlaşılmaktadır. Bu modelde özellikle yola uzaklık ve yağışın üst sıralarda yer alması, KNN’nin heyelan örneklerini hidrolojik ve antropojenik benzerlikler üzerinden ayırabildiğini düşündürmektedir. Ancak önceki performans sonuçlarında KNN’nin yanlış pozitif sayısının yüksek olduğu görülmüştür. SHAP sonuçları bu durumu destekler nitelikte, modelin bazı değişkenlerde geniş ve dağınık katkı örüntüleri ürettiğini göstermektedir.



Şekil 25. Rastgele Orman modeli için SHAP summary grafiği


Şekil 25’de sunulan Rastgele Orman modelinde Yıllık Yağış, Yola Uzaklık, Eğim, TWI, Akarsuya Uzaklık, Zemin Hâkim Periyodu, Yüzey Pürüzlülüğü, TRI, Vs₃₀

ve T1 Kayma Modülü en önemli değişkenler olarak belirlenmiştir. Bu modelin en yüksek hold-out AUC değerini üretmesi dikkate alındığında, SHAP sonuçları modelin heyelan duyarlılığını açıklayan jeomorfolojik ve çevresel faktörleri güçlü biçimde kullandığını göstermektedir. Özellikle yağış, eğim ve TWI gibi hidro-topografik değişkenlerin üst sıralarda bulunması, su içeriği ve yamaç dikliğinin heyelan olasılığı üzerindeki belirleyici etkisini desteklemektedir. Yola uzaklık ve akarsuya uzaklık değişkenleri ise hem antropojenik hem de doğal drenaj etkilerinin model kararlarında önemli olduğunu ortaya koymaktadır.




Şekil 26. SVM modeli için SHAP summary grafiği

Şekil 26’da sunulan SVM modelinde en etkili değişkenler Yıllık Yağış, Yola Uzaklık, TWI, T1 Kayma Modülü, Akarsuya Uzaklık, TPI, TRI, Eğim, T1 Hacimsel Modül ve Toplam Eğrisellik olarak sıralanmaktadır. SVM modelinin SHAP dağılımında yağış ve yola uzaklık gibi değişkenlerin belirgin genişlik göstermesi, bu değişkenlerin model karar sınırının oluşumunda önemli rol oynadığını göstermektedir. Ancak SVM’nin hold-out performansı, en başarılı topluluk modellerine göre daha düşük kalmıştır. Bu durum, SVM’nin önemli değişkenleri yakalayabilmesine rağmen, çok değişkenli ve doğrusal olmayan heyelan örüntülerini ağaç tabanlı topluluk modelleri kadar esnek temsil edemediğini düşündürmektedir.




Şekil 27. XGBoost modeli için SHAP summary grafiği

Şekil 27’de sunulan XGBoost modelinde Yıllık Yağış, Yola Uzaklık, TWI, Akarsuya Uzaklık, Zemin Hâkim Periyodu, Eğim, T1 Kayma Modülü, T2 Poisson Oranı, TPI ve Vs₃₀ en etkili değişkenler arasında yer almaktadır. Bu sıralama, XGBoost modelinin hem hidrolojik/iklimsel faktörleri hem de topoğrafik ve sismik/jeoteknik değişkenleri birlikte kullandığını göstermektedir. Yıllık yağış ve TWI değişkenlerinin üst sıralarda bulunması, nemlenme ve suya bağlı yamaç stabilitesi süreçlerinin modelde güçlü biçimde temsil edildiğini ortaya koymaktadır. XGBoost’un hold-out test setindeki yüksek AUC ve F1 skoru dikkate alındığında, SHAP sonuçları bu modelin yüksek performansını jeomorfolojik olarak anlamlı değişken kombinasyonları üzerinden sağladığını göstermektedir.



Şekil 28. YSA (MLP) modeli için SHAP summary grafiği

Şekil 28’de sunulan YSA (MLP) modelinde Yıllık Yağış, TWI, Yola Uzaklık, T1 Kayma Modülü, Yüzey Pürüzlülüğü, TRI, Akarsuya Uzaklık, Vs₃₀, T1 Hacimsel Modül ve Profil Eğriselliği değişkenleri öne çıkmaktadır. Bu modelde SHAP değerlerinin birçok değişken için sıfır etrafında daha dar yoğunlaştığı, ancak bazı değişkenlerde belirgin uç katkılar bulunduğu görülmektedir. Bu durum, MLP modelinin belirli örneklerde bazı değişkenlere yüksek katkı atayabildiğini, ancak genel olarak topluluk modellerine göre daha dağınık ve daha az kararlı bir açıklanabilirlik örüntüsü sunduğunu düşündürmektedir. MLP’nin performansının topluluk modellerinin gerisinde kalması da bu yorumla uyumludur.



Şekil 29. Lojistik Regresyon modeli için SHAP summary grafiği


Şekil 29’da sunulan Lojistik Regresyon modelinde TWI, Eğim, Yola Uzaklık, Yıllık Yağış, Yüzey Pürüzlülüğü, V_{s30} , TRI, Toplam Eğrisellik, T1 Kayma Modülü ve Akarsuya Uzaklık değişkenleri öne çıkmaktadır. Ancak Lojistik Regresyon modelinde bazı değişkenlerin SHAP değerlerinin geniş aralıklara yayılması, modelin doğrusal katsayı yapısından kaynaklanan daha keskin katkı örüntülerine işaret etmektedir. Lojistik Regresyon, değişkenlerin doğrusal katkılarına dayandığından, heyelan duyarlılığını etkileyen karmaşık eşik ve etkileşim süreçlerini sınırlı temsil edebilmiştir. Bu nedenle performans metrikleri de topluluk modellerine kıyasla daha düşük kalmıştır. Bununla birlikte SHAP sonuçları, doğrusal modelde dahi TWI, eğim, yol uzaklığı ve yağış gibi temel değişkenlerin önemli olduğunu göstermektedir.

Genel olarak tüm SHAP summary grafikleri birlikte değerlendirildiğinde, farklı algoritmaların bazı değişkenleri ortak biçimde önemli bulduğu görülmektedir. Özellikle Yıllık Yağış, Yola Uzaklık, Topoğrafik Islanma İndeksi, Akarsuya Uzaklık ve Eğim değişkenleri çok sayıda modelde ilk sıralarda yer almıştır. Bu bulgu, çalışma alanındaki heyelan duyarlılığının hidrolojik koşullar, antropojenik etkiler ve topoğrafik yapı tarafından birlikte kontrol edildiğini göstermektedir. Ayrıca V_{s30} , Zemin Hâkim Periyodu, T1 Kayma Modülü, T2 Poisson Oranı ve diğer tabakalı zemin parametrelerinin bazı modellerde üst sıralarda yer alması, sismik/jeoteknik zemin özelliklerinin de model tahminlerine katkı sağladığını göstermektedir. SHAP sonuçları, yüksek performanslı modellerin yalnızca istatistiksel olarak başarılı olmadığını, aynı zamanda jeomorfolojik olarak anlamlı değişken örüntüleri kullandığını ortaya koymaktadır. Özellikle Rastgele Orman, XGBoost ve LightGBM modellerinde yağış, eğim, TWI, yol uzaklığı ve akarsuya uzaklık gibi değişkenlerin tutarlı biçimde öne çıkması, bu modellerin heyelan oluşumunu etkileyen temel çevresel süreçleri daha iyi yakalayabildiğini göstermektedir. Buna karşılık Lojistik Regresyon ve tekil Karar Ağacı gibi modellerde değişken katkılarının daha sınırlı veya daha keskin eşiklere bağlı olduğu, bu nedenle genel performansın topluluk modellerine kıyasla daha düşük kaldığı anlaşılmaktadır.

Bu bulgular, heyelan duyarlılık modellemesinde açıklanabilirlik analizlerinin yalnızca model kararlarını yorumlamak için değil, aynı zamanda modelin jeolojik ve jeomorfolojik süreçlerle uyumunu değerlendirmek için de önemli olduğunu göstermektedir. SHAP analizine göre model tahminleri, çalışma alanındaki yağış, yamaç eğimi, hidrolojik birikim, yol etkisi, drenaj yakınlığı ve zemin dinamik özellikleriyle tutarlı bir karar yapısı üretmiştir.


Rastgele Orman modeli hold-out test setinde en yüksek AUC değerini verdiği için, bu modelde öne çıkan değişkenlerin etkisini daha ayrıntılı değerlendirmek amacıyla SHAP dependence grafikleri incelenmiştir. Bu grafiklerde x eksenini ilgili değişkenin gerçek değerini, y eksenini ise bu değişkenin model tahminine SHAP katkısını göstermektedir. Pozitif SHAP değerleri heyelan olasılığını artırıcı, negatif SHAP değerleri ise heyelan olasılığını azaltıcı katkıyı ifade etmektedir.

Şekil 30’da sunulan yıllık yağış değişkenine ait SHAP dependence grafiği, yağışın model tahminine doğrusal olmayan ancak genel olarak artan yönde katkı verdiğini göstermektedir. Düşük yağış değerlerinde SHAP katkıları çoğunlukla negatif olup bu alanlar model tarafından daha düşük heyelan duyarlılığıyla ilişkilendirilmiştir. Yağış değeri arttıkça SHAP katkılarının pozitifliğe geçtiği ve özellikle yaklaşık 130–155 mm aralığında yıllık yağışın heyelan olasılığını artırıcı yönde güçlü katkı sağladığı görülmektedir. Renk skalasında Topoğrafik Islanma İndeksi’nin kullanılması, yağış etkisinin topoğrafik nem birikimiyle birlikte değişebildiğini göstermektedir. Bu durum, yağış ve topoğrafik nemlenmenin birlikte heyelan duyarlılığı üzerinde etkili olduğunu desteklemektedir.



Şekil 30. Rastgele Orman modelinde yıllık yağış değişkenine ait SHAP dependence grafiği. Renk skalası Topoğrafik Islanma İndeksi değerlerini göstermektedir


Şekil 31’de sunulan yola uzaklık değişkenine ait SHAP dependence grafiği, modelin yol yakınlığını önemli bir antropojenik etki olarak değerlendirdiğini göstermektedir. Grafikte düşük yola uzaklık sınıflarında SHAP değerleri pozitif veya pozitive yakınen, daha yüksek uzaklık sınıflarında SHAP değerleri belirgin şekilde negatife dönmektedir. Bu bulgu, yollara yakın alanların model tarafından daha yüksek heyelan duyarlılığıyla ilişkilendirildiğini; yollardan uzaklaştıkça heyelan olasılığına katkının azaldığını göstermektedir. Bu sonuç, yol açma, şev kesimi, drenaj düzeninin bozulması ve kazı-dolgu etkilerinin yamaç stabilitesi üzerindeki olası etkileriyle uyumludur.



Şekil 31. Rastgele Orman modelinde yola uzaklık değişkenine ait SHAP dependence grafiği. Renk skalası Topoğrafik Islanma İndeksi değerlerini göstermektedir

Şekil 32’de sunulan eğim değişkenine ait SHAP dependence grafiği, eğimin heyelan tahminine eşik benzeri ve doğrusal olmayan bir katkı sunduğunu göstermektedir. Çok düşük eğimli alanlarda SHAP değerleri belirgin şekilde negatiftir; bu durum modelin düşük eğimli bölgeleri heyelan olasılığını azaltıcı yönde değerlendirdiğini göstermektedir. Yaklaşık 8–10° eğimden sonra SHAP değerlerinin pozitive geçtiği ve özellikle 10–40° aralığında eğimin heyelan olasılığını artırıcı yönde katkı sağladığı görülmektedir. Çok yüksek eğim değerlerinde katkının yeniden azalması, modelin eğim etkisini sınırsız artan doğrusal bir ilişki olarak değil, belirli bir aralıkta maksimum etki gösteren jeomorfolojik bir eşik ilişkisi olarak öğrendiğini

düşündürmektedir. Renk skalasında yıllık yağışın gösterilmesi, eğim etkisinin yağış koşullarıyla birlikte güçlenebileceğini ortaya koymaktadır.



Şekil 32. Rastgele Orman modelinde eğim değişkenine ait SHAP dependence grafiği. Renk skalası yıllık yağış değerlerini göstermektedir

5.5. Heyelan Duyarlılık Haritalarının Üretilmesi ve Karşılaştırılması

Makine öğrenmesi modellerinin sayısal performansları değerlendirildikten sonra, her model için çalışma alanı genelinde piksel tabanlı heyelan duyarlılık haritaları üretilmiştir. Bu aşamada VIF analizi sonrasında seçilen koşullayıcı faktörler tüm çalışma alanı boyunca modellere girdi olarak verilmiş ve her piksel için heyelan sınıfına ait olasılık değeri hesaplanmıştır. Elde edilen olasılık değerleri 0–1 aralığında sürekli duyarlılık yüzeyleri olarak üretilmiş, daha sonra bu değerler beş sınıfa ayrılarak Çok Düşük, Düşük, Orta, Yüksek ve Çok Yüksek duyarlılık sınıfları şeklinde haritalandırılmıştır.

Duyarlılık sınıfları haritalarda yeşilden kırmızıya doğru artan risk düzeyini temsil edecek şekilde gösterilmiştir. Buna göre koyu yeşil alanlar çok düşük, açık yeşil alanlar düşük, sarı alanlar orta, turuncu alanlar yüksek, kırmızı alanlar ise çok yüksek heyelan duyarlılığını göstermektedir. Ayrıca mevcut heyelan envanteri siyah poligon sınırları ile haritalar üzerine bindirilmiş ve modellerin yüksek duyarlılık alanları ile mevcut heyelan envanteri arasındaki mekânsal uyum görsel olarak değerlendirilmiştir. Üretilen duyarlılık haritaları Şekil 33-42’de sunulmuştur.

Haritalar genel olarak değerlendirildiğinde, mevcut heyelan envanterinin önemli bir bölümünün yüksek ve çok yüksek duyarlılık sınıfları içerisinde veya bu sınıfların yakın çevresinde yer aldığı görülmektedir. Bu durum, modellerin eğitimde kullandığı koşullayıcı faktörler ile mevcut heyelan dağılımı arasında anlamlı mekânsal ilişkiler kurabildiğini göstermektedir. Özellikle çalışma alanının kuzey, kuzeybatı ve orta kesimlerinde kırmızı ve turuncu sınıfların geniş alanlar kapladığı; güney ve güneydoğu kesimlerde ise modelden modele değişmekle birlikte daha düşük duyarlılık sınıflarının arttığı izlenmektedir. Bu mekânsal örüntü, önceki SHAP analizlerinde öne çıkan yağış, eğim, TWI, yola uzaklık, akarsuya uzaklık ve zemin dinamik parametrelerinin birlikte etkisiyle uyumlu görünmektedir.

Rastgele Orman, LightGBM ve XGBoost modellerine ait haritalar, performans sonuçlarıyla uyumlu biçimde daha dengeli ve mekânsal olarak tutarlı duyarlılık örüntüleri üretmiştir. Bu modellerde yüksek ve çok yüksek duyarlılık alanları özellikle mevcut heyelan envanterinin yoğunlaştığı bölgelerle belirgin biçimde örtüşmektedir. Aynı zamanda düşük duyarlılık alanları da çalışma alanında daha seçici ve düzenli biçimde ayrılmıştır. Bu durum, söz konusu modellerin hem yüksek ayırt edici performans göstermesi hem de çalışma alanı genelinde jeomorfolojik açıdan anlamlı duyarlılık yüzeyleri üretmesi bakımından önemlidir.

LightGBM haritasında çok yüksek duyarlılık sınıfının mevcut heyelan envanteriyle güçlü bir mekânsal uyum gösterdiği, buna karşın düşük duyarlılık sınıflarının daha belirgin biçimde ayrıldığı görülmektedir. Bu durum, LightGBM modelinin hold-out test setinde en yüksek doğruluk, F1 skoru, Kappa ve MCC değerlerini üretmesiyle uyumludur. Model, çok yüksek duyarlılık alanlarını özellikle heyelan envanterinin yoğunlaştığı kuzeybatı, kuzey ve orta kesimlerde toplarken, daha stabil görünen alanları düşük duyarlılık sınıflarında bırakmıştır.

XGBoost modeli de LightGBM'e oldukça benzer bir mekânsal örüntü üretmiştir. Çok yüksek duyarlılık sınıfı, özellikle mevcut heyelan poligonlarının yoğun olduğu kuzey ve orta kesimlerde belirgindir. XGBoost haritasında yüksek ve çok yüksek duyarlılık sınıflarının süreklilik gösteren yamaç kuşakları boyunca dağıldığı, düşük duyarlılık alanlarının ise daha çok çalışma alanının güney ve bazı doğu kesimlerinde yoğunlaştığı görülmektedir. Bu bulgu, XGBoost modelinin yüksek AUC ve F1 performansı ile uyumludur.

Rastgele Orman modeli, hold-out test setinde en yüksek AUC değerine sahip model olarak öne çıkmıştı. Harita incelendiğinde, modelin özellikle mevcut heyelan envanterinin yoğunlaştığı alanlarda yüksek ve çok yüksek duyarlılık sınıfları ürettiği

görülmektedir. Rastgele Orman haritası, LightGBM ve XGBoost ile genel olarak benzer bir duyarlılık paterni sunmakla birlikte bazı bölgelerde orta ve yüksek duyarlılık sınıflarının daha geçişli dağıldığı izlenmektedir. Bu durum, Rastgele Orman modelinin çok sayıda karar ağacının ortalamasına dayalı daha yumuşak bir olasılık yüzeyi üretmesiyle ilişkili olabilir.

Gradyan Artırma ve Ekstra Ağaçlar modelleri de genel olarak mevcut heyelan envanteriyle uyumlu duyarlılık alanları üretmiştir. Gradyan Artırma haritasında yüksek ve çok yüksek duyarlılık sınıflarının daha geniş ve yer yer daha baskın biçimde dağıldığı görülmektedir. Ekstra Ağaçlar modelinde ise kuzey ve orta kesimlerde yüksek duyarlılık alanları belirgin olmakla birlikte, bazı bölgelerde orta duyarlılık sınıfının daha geniş geçiş alanları oluşturduğu izlenmektedir. Her iki modelin de performans metriklerinde güçlü sonuçlar üretmesi, harita çıktılarındaki genel mekânsal uyumla desteklenmektedir.

Karar Ağacı modeline ait duyarlılık haritası, diğer topluluk modellerinden daha keskin ve bloklu bir sınıflandırma yapısı göstermektedir. Bu modelde bazı alanlar geniş homojen sınıflar halinde ayrılmıştır. Bu durum tekil karar ağacı yapısının sınırlı sayıda eşik değeri üzerinden karar vermesiyle ilişkilidir. Karar Ağacı haritasında mevcut heyelan envanterinin bir kısmı yüksek duyarlılık alanlarıyla örtüşmekle birlikte, haritanın genel mekânsal deseni topluluk modellerine göre daha kaba ve daha az geçişli görünmektedir. Bu bulgu, Karar Ağacı modelinin performans metriklerinin topluluk modellerinden daha düşük kalmasıyla uyumludur.


Lojistik Regresyon modelinde çok yüksek duyarlılık sınıfının geniş alanlara yayıldığı ve bazı bölgelerde daha yaygın bir kırmızı/turuncu desen olduğu görülmektedir. Bu durum, doğrusal model yapısının karmaşık topoğrafik, hidrolojik ve jeoteknik etkileşimleri yeterince esnek biçimde ayıramamasıyla ilişkili olabilir. Lojistik Regresyon, mevcut heyelan envanterinin önemli bir bölümünü yüksek duyarlılık alanları içerisinde yakalamakla birlikte, haritada yüksek duyarlılık sınıfının daha yaygın görünmesi yanlış pozitif alanların artabileceğini düşündürmektedir. Bu yorum, modelin hold-out test setinde en düşük AUC değerlerinden birini üretmesiyle de uyumludur.

KNN modeline ait harita, yüksek ve çok yüksek duyarlılık sınıflarının daha yaygın ve yer yer parçalı biçimde dağıldığını göstermektedir. Önceki karışıklık matrisi bulgularında KNN modelinin yanlış negatif sayısını düşük tuttuğu, ancak yanlış pozitif sayısının yüksek olduğu görülmüştü. Harita çıktısı da bu bulguyla uyumludur; model geniş alanları yüksek duyarlılık sınıfına atama eğilimindedir. Bu nedenle KNN modeli

gerçek heyelanları yakalama açısından duyarlı olmakla birlikte, yüksek riskli alanları fazla genişletme eğilimi gösterebilir.


Genel olarak heyelan duyarlılık haritaları, sayısal performans sonuçları ve SHAP açıklanabilirlik bulgularıyla birlikte değerlendirildiğinde, LightGBM, XGBoost ve Rastgele Orman modellerinin hem istatistiksel performans hem de mekânsal tutarlılık açısından en güçlü modeller olduğunu göstermektedir. Bu modellerde yüksek ve çok yüksek duyarlılık sınıfları mevcut heyelan envanteriyle daha anlamlı örtüşmekte, düşük duyarlılık alanları ise çalışma alanının daha stabil görünen kesimlerinde yoğunlaşmaktadır. Buna karşılık Lojistik Regresyon, KNN ve tekil Karar Ağacı modellerinde duyarlılık sınıflarının ya daha yaygın ya da daha bloklu dağıldığı görülmektedir. Bu durum, heyelan duyarlılık haritalarının yalnızca AUC veya doğruluk değerleriyle değil, aynı zamanda mekânsal desen, sınıf sürekliliği ve mevcut heyelan envanteriyle uyum açısından da değerlendirilmesi gerektiğini göstermektedir.

**Heyelan Duyarlılık Haritası
LightGBM**




Şekil 33. LightGBM modeline ait heyelan duyarlılık haritası

Heyelan Duyarlılık Haritası XGBoost




Şekil 34. XGBoost modeline ait heyelan duyarlılık haritası

**Heyelan Duyarlılık Haritası
Rastgele Orman**




Şekil 35. Rastgele Orman modeline ait heyelan duyarlılık haritası

Heyelan Duyarlılık Haritası Gradyan Artırma




Şekil 36. Gradyan Artırma modeline ait heyelan duyarlılık haritası

**Heyelan Duyarlılık Haritası
Ekstra Ağaçlar**




Şekil 37. Ekstra Ağaçlar modeline ait heyelan duyarlılık haritası

Heyelan Duyarlılık Haritası YSA (MLP)




Şekil 38. YSA (MLP) modeline ait heyelan duyarlılık haritası

Heyelan Duyarlılık Haritası SVM




Şekil 39. SVM modeline ait heyelan duyarlılık haritası

Heyelan Duyarlılık Haritası SVM




Şekil 40. Karar Ağacı modeline ait heyelan duyarlılık haritası

**Heyelan Duyarlılık Haritası
KNN**




Şekil 41. KNN modeline ait heyelan duyarlılık haritası

Heyelan Duyarlılık Haritası
Lojistik Regresyon



Şekil 42. Lojistik Regresyon modeline ait heyelan duyarlılık haritası

Heyelan duyarlılık haritalarının mekânsal yorumunu desteklemek amacıyla, her model için Çok Düşük, Düşük, Orta, Yüksek ve Çok Yüksek duyarlılık sınıflarının çalışma alanı içerisindeki yüzdesel alan dağılımları hesaplanmıştır. Bu analiz, modellerin yalnızca heyelan envanteriyle görsel uyumunu değil, aynı zamanda çalışma alanını hangi duyarlılık sınıflarına ne ölçüde ayırdığını değerlendirmek açısından önemlidir. Alan dağılımı sonuçları, modellerin tahmin davranışları arasındaki farkları daha açık biçimde ortaya koymuştur. Şekil 43'te tüm modeller için duyarlılık sınıflarının yüzdesel alan dağılımı yığılmış çubuk grafik olarak sunulmuştur. Grafik genel olarak değerlendirildiğinde, modeller arasında yüksek ve çok yüksek duyarlılık sınıflarına ayrılan alan oranlarının belirgin biçimde farklılaştığı görülmektedir. Bu farklılık, her algoritmanın koşullayıcı faktörler arasındaki ilişkileri farklı biçimde öğrenmesinden ve duyarlılık olasılıklarını farklı dağıtmasından kaynaklanmaktadır.



Şekil 43. Tüm modellerde heyelan duyarlılık sınıflarının yüzdesel alan dağılımı

Alan dağılımı açısından Rastgele Orman, LightGBM ve XGBoost modelleri daha dengeli bir sınıflandırma yapısı göstermektedir. Bu modellerde çalışma alanının önemli bir bölümü düşük ve çok düşük duyarlılık sınıflarında temsil edilirken, yüksek ve çok yüksek duyarlılık sınıfları daha seçici biçimde belirli alanlarda yoğunlaşmıştır. Bu durum, önceki performans analizlerinde elde edilen yüksek AUC, F1, Kappa ve MCC değerleriyle uyumludur. Özellikle LightGBM ve XGBoost modellerinde düşük duyarlılık sınıflarının geniş yer kaplaması, buna karşılık yüksek ve çok yüksek sınıfların

mevcut heyelan envanteriyle ilişkili zonlarda yoğunlaşması, bu modellerin mekânsal açıdan daha ayırt edici bir duyarlılık yüzeyi ürettiğini düşündürmektedir. Rastgele Orman modelinde çok düşük ve düşük duyarlılık sınıflarının birlikte önemli bir alan kapladığı, buna karşılık yüksek ve çok yüksek duyarlılık sınıflarının daha sınırlı ve seçici biçimde dağıldığı görülmektedir. Bu yapı, modelin yüksek AUC değerine rağmen çalışma alanını aşırı geniş riskli alanlar olarak sınıflandırmadığını göstermektedir. Bu nedenle Rastgele Orman modeli, ayırt edici performans ile mekânsal seçicilik arasında dengeli bir yapı sunmaktadır. LightGBM modelinde de çok düşük ve düşük duyarlılık sınıfları belirgin bir alan kaplamaktadır. Bununla birlikte orta, yüksek ve çok yüksek sınıflar da çalışma alanında anlamlı bir dağılım göstermektedir.

LightGBM'nin hold-out test setinde en yüksek doğruluk, F1 skoru, Kappa ve MCC değerlerini üretmiş olması dikkate alındığında, bu alan dağılımı modelin hem sınıf bazında dengeli hem de mekânsal olarak tutarlı bir sonuç verdiğini desteklemektedir. XGBoost modelinde duyarlılık sınıflarının dağılımı LightGBM ve Rastgele Orman'a benzer şekilde dengeli görünmektedir. Çok düşük ve düşük duyarlılık alanları geniş bir bölümü temsil ederken, yüksek ve çok yüksek duyarlılık sınıfları belirli bölgelerde yoğunlaşmaktadır. Bu durum, XGBoost modelinin yüksek AUC ve F1 performansı ile birlikte, çalışma alanında aşırı yaygın risk tahmini üretmeden heyelan duyarlılığı yüksek alanları ayırt edebildiğini göstermektedir. Buna karşılık KNN, Lojistik Regresyon, Gradyan Artırma ve Ekstra Ağaçlar modellerinde yüksek ve çok yüksek duyarlılık sınıflarına ayrılan alan oranlarının daha fazla olduğu görülmektedir. Özellikle KNN modelinde yüksek ve çok yüksek duyarlılık sınıflarının geniş alan kaplaması, önceki karışıklık matrisi bulgularıyla uyumludur.

KNN modeli hold-out test setinde en yüksek duyarlılık değerlerinden birini üretmiş, ancak yanlış pozitif sayısı da yüksek bulunmuştur. Bu nedenle KNN'nin geniş alanları yüksek duyarlılık sınıfına ataması, gerçek heyelanları kaçırmama eğiliminin bir sonucu olarak değerlendirilebilir; ancak bu durum potansiyel olarak daha fazla yanlış alarm üretme riskini de beraberinde getirmektedir. Lojistik Regresyon modelinde de yüksek ve çok yüksek duyarlılık sınıflarının çalışma alanında görece geniş yer kapladığı görülmektedir. Bu durum, doğrusal model yapısının karmaşık topoğrafik, hidrolojik ve jeoteknik etkileşimleri yeterince esnek biçimde ayıramamasıyla ilişkili olabilir. Lojistik Regresyon modeli belirli duyarlılık zonlarını yakalayabilmekle birlikte, yüksek duyarlılık alanlarını daha geniş biçimde yayma eğilimindedir. Bu bulgu, modelin hold-out test setinde diğer modellere göre daha düşük AUC, Kappa ve MCC değerleri üretmesiyle uyumludur. Karar Ağacı modelinde ise çok düşük duyarlılık sınıfının geniş

alan kapladığı, buna karşılık çok yüksek duyarlılık sınıfının da belirli bölgelerde keskin biçimde ayrıldığı görülmektedir. Bu yapı, tekil karar ağacı modelinin sınırlı sayıda eşik değerine dayalı karar üretmesiyle ilişkilidir. Harita yorumlarında da görüldüğü üzere Karar Ağacı modeli daha bloklu ve keskin sınıf geçişleri üretmiştir. Alan dağılımı grafiği de bu davranışı desteklemektedir. Genel olarak alan dağılımı sonuçları, modellerin yalnızca performans metrikleriyle değil, mekânsal sınıf dağılımlarıyla da karşılaştırılması gerektiğini göstermektedir.

Yüksek ve çok yüksek duyarlılık sınıflarının çok geniş alanlara yayılması, modelin gerçek heyelanları yakalama olasılığını artırabilir; ancak bu durum yanlış pozitif alanların artması ve planlama açısından gereğinden geniş risk zonları tanımlanması anlamına da gelebilir. Buna karşılık yüksek duyarlılık sınıflarının çok dar tutulması, bazı gerçek heyelan alanlarının gözden kaçmasına neden olabilir. Bu nedenle ideal model, mevcut heyelan envanteriyle uyumlu yüksek duyarlılık alanları üretirken, çalışma alanının tamamını aşırı riskli olarak sınıflandırmayan dengeli bir alan dağılımı sunmalıdır. Bu açıdan değerlendirildiğinde, LightGBM, XGBoost ve Rastgele Orman modelleri hem sayısal performans metrikleri hem karışıklık matrisi sonuçları hem SHAP açıklanabilirlik bulguları hem de duyarlılık sınıfı alan dağılımları bakımından en tutarlı modeller olarak öne çıkmaktadır. Bu modeller, yüksek ve çok yüksek duyarlılık sınıflarını mevcut heyelan envanteriyle ilişkili alanlarda yoğunlaştırırken, düşük duyarlılık sınıflarını çalışma alanının daha stabil görünen kesimlerinde daha belirgin biçimde ayırabilmiştir. Bu nedenle nihai heyelan duyarlılık değerlendirmesinde bu üç modelin çıktıları daha güvenilir ve mekânsal olarak daha yorumlanabilir sonuçlar üretmiştir.

6. SONUÇLAR

Bu çalışmada Rize ili Çayeli ilçesi için topoğrafik, hidrolojik, antropojenik, jeolojik, iklimsel ve sismik/jeoteknik koşullayıcı faktörler kullanılarak makine öğrenmesi tabanlı kapsamlı bir heyelan duyarlılık modellemesi gerçekleştirilmiştir. Çalışmanın temel amacı, yalnızca yüksek doğrulukta bir sınıflandırma modeli geliştirmek değil, aynı zamanda farklı makine öğrenmesi algoritmalarının heyelan duyarlılığı üretme kapasitesini karşılaştırmak, model kararlarını açıklanabilir hale getirmek ve çalışma alanı için mekânsal olarak yorumlanabilir heyelan duyarlılık haritaları üretmektir. Bu kapsamda Lojistik Regresyon, Karar Ağacı, Rastgele Orman, Ekstra Ağaçlar, Gradyan Artırma, XGBoost, LightGBM, SVM, KNN ve YSA (MLP) olmak üzere on farklı makine öğrenmesi algoritması karşılaştırmalı olarak değerlendirilmiştir.

Çalışmada öncelikle AFAD ve MTA kaynaklı heyelan envanter verileri kullanılarak pozitif sınıfı temsil eden heyelan noktaları oluşturulmuş, buna karşılık heyelan olmayan alanlar kontrollü negatif örnekleme yaklaşımıyla belirlenmiştir. Heyelan olmayan noktaların seçiminde mevcut heyelanlardan en az 500 m uzaklık, geçerli raster değerlerine sahip olma, grid tabanlı mekânsal dengeleme ve düşük eğimli alanların kontrollü temsili birlikte dikkate alınmıştır. Bu yaklaşım, modelin yalnızca kolay topoğrafik ayrımlara veya belirli bölgesel kümelenmelere dayalı öğrenmesini sınırlandırmış ve daha dengeli bir eğitim veri seti oluşturulmasına katkı sağlamıştır. Nihai veri setinde heyelan ve heyelan olmayan sınıfların dengeli biçimde temsil edilmesi, model performanslarının daha güvenilir karşılaştırılmasına olanak tanımıştır.

Koşullayıcı faktörlerin hazırlanması aşamasında çalışma alanına ait 5 m çözünürlüklü DEM verisi temel alınmış, işlem yükü ve veri hacmi dikkate alınarak 20 m mekânsal çözünürlüğe yeniden örneklenmiştir. DEM'den eğim, bakı, eğrisellik bileşenleri, topoğrafik konum indeksi, topoğrafik pürüzlülük indeksi, topoğrafik ıslanma indeksi ve yüzey pürüzlülüğü gibi morfometrik değişkenler üretilmiştir. Buna ek olarak akarsuya uzaklık, yola uzaklık, litoloji, arazi örtüsü, yıllık yağış, Vs₃₀, zemin büyütmesi, zemin hâkim titreşim periyodu ve iki tabakalı sismik/jeoteknik zemin parametreleri modelleme sürecine dahil edilmiştir. Böylece klasik heyelan duyarlılık çalışmalarında yaygın kullanılan topoğrafik ve jeolojik faktörlere ek olarak, zemin dinamiği ve tabakalı mekanik özellikleri temsil eden değişkenler de çalışma kapsamında değerlendirilmiştir.

Bu yönüyle çalışma, heyelan duyarlılık modellemesine sismik ve jeoteknik zemin parametrelerinin entegre edilmesi bakımından özgün bir katkı sunmaktadır.

Modelleme öncesinde koşullayıcı faktörler arasındaki çoklu doğrusal bağlantı VIF analizi ile değerlendirilmiştir. Başlangıçta 28 koşullayıcı faktör kullanılmış; VIF analizi sonucunda Plan Eğriselliği, 2. Tabaka Yoğunluk, 1. Tabaka Elastisite Modülü, 1. Tabaka Yoğunluk, Zemin Büyütme Faktörü ve 1. Tabaka Poisson Oranı değişkenleri yüksek çoklu doğrusal bağlantı nedeniyle modelleme veri setinden çıkarılmıştır. Böylece nihai modelleme süreci 22 koşullayıcı faktör üzerinden yürütülmüştür. VIF analizinin yalnızca eğitim veri seti üzerinde uygulanması ve hold-out test setinin bu sürece dahil edilmemesi, veri sızıntısını önlemiş ve bağımsız test performansının tarafsız biçimde değerlendirilmesini sağlamıştır.

Model performansları hem 5 katlı stratified cross-validation hem de bağımsız hold-out test seti üzerinden değerlendirilmiştir. Çapraz doğrulama sonuçlarına göre en yüksek ortalama AUC değeri Rastgele Orman modelinde elde edilmiştir. Rastgele Orman modelinin CV AUC değeri 0.9651 ± 0.0123 olup, bu modeli XGBoost ve LightGBM çok yakın değerlerle izlemiştir. Hold-out test setinde de en yüksek AUC değeri Rastgele Orman modelinde hesaplanmış ve bu değer 0.9637 olarak bulunmuştur. XGBoost 0.9613 ve LightGBM 0.9611 AUC değerleriyle Rastgele Orman modeline çok yakın performans göstermiştir. Bu sonuçlar, ağaç tabanlı topluluk ve boosting modellerinin çalışma alanındaki heyelan ve heyelan olmayan örnekleri yüksek ayırt edicilikle sınıflandırabildiğini göstermektedir.

Bununla birlikte model performansı yalnızca AUC değerine göre değerlendirilmemiştir. Hold-out test sonuçlarında LightGBM modeli en yüksek doğruluk, F1 skoru, Cohen's Kappa ve Matthews Korelasyon Katsayısı değerlerine ulaşarak dengeli sınıflandırma performansı açısından öne çıkmıştır. LightGBM için doğruluk 0.8962, F1 skoru 0.9020, Kappa 0.7923 ve MCC 0.7972 olarak elde edilmiştir. Bu durum, Rastgele Orman modelinin ayırt edici performans açısından en güçlü model olduğunu; LightGBM modelinin ise sınıflandırma dengesi, yanlış pozitif–yanlış negatif dengesi ve genel uyum açısından oldukça başarılı olduğunu göstermektedir. XGBoost modeli de bu iki modele çok yakın sonuçlar üretmiş ve hem AUC hem de F1 skoru bakımından güçlü bir alternatif olarak değerlendirilmiştir.

Karışıklık matrisleri modellerin hata örüntülerini daha ayrıntılı biçimde ortaya koymuştur. Rastgele Orman, XGBoost ve LightGBM modelleri gerçek heyelan örneklerini yüksek oranda doğru sınıflandırmış ve yanlış negatif hata sayılarını düşük düzeyde tutmuştur. LightGBM ve XGBoost modellerinde yalnızca 7 heyelan örneğinin

yanlış negatif olarak sınıflandırılması, bu modellerin gerçek heyelan alanlarını yakalama açısından güçlü performans sunduğunu göstermektedir. KNN modeli ise en yüksek duyarlılık değerlerinden birini üretmiş olmasına rağmen, yanlış pozitif sayısının yüksek olması nedeniyle geniş alanları riskli sınıfa atama eğilimi göstermiştir. Lojistik Regresyon ve tekil Karar Ağacı modelleri ise genel olarak daha sınırlı performans üretmiş, bu durum heyelan duyarlılığının doğrusal veya basit eşik tabanlı ilişkilerle yeterince açıklanamayacağını göstermiştir.

SHAP açıklanabilirlik analizleri, modellerin hangi değişkenleri karar sürecinde daha güçlü kullandığını ve bu değişkenlerin heyelan tahminine hangi yönde katkı verdiğini ortaya koymuştur. Tüm modeller birlikte değerlendirildiğinde Yıllık Yağış, Yola Uzaklık, Topoğrafik Islanma İndeksi, Akarsuya Uzaklık ve Eğim değişkenlerinin çok sayıda modelde en önemli faktörler arasında yer aldığı görülmüştür. Bu sonuç, çalışma alanındaki heyelan duyarlılığının hidrolojik koşullar, topoğrafik yapı, antropojenik müdahale ve yağış rejimi tarafından birlikte kontrol edildiğini göstermektedir. Ayrıca V_{s30} , Zemin Hâkim Periyodu, T1 Kayma Modülü, T2 Poisson Oranı ve diğer sismik/jeoteknik zemin parametrelerinin bazı modellerde üst sıralarda yer alması, zemin dinamik özelliklerinin de heyelan duyarlılığı modellemesine anlamlı katkı sağlayabildiğini ortaya koymuştur.

Rastgele Orman modeli en yüksek hold-out AUC değerini verdiği için bu model özelinde SHAP dependence grafikleri ayrıntılı olarak değerlendirilmiştir. Yıllık yağış değişkeninde düşük yağış değerlerinin heyelan olasılığını azaltıcı yönde, yüksek yağış değerlerinin ise artırıcı yönde katkı verdiği belirlenmiştir. Yola uzaklık değişkeninde yollara yakın alanların heyelan olasılığını artırıcı katkı sunduğu, yollardan uzaklaştıkça bu katkının negatife döndüğü görülmüştür. Bu sonuç, yol açma, şev kesimi, kazı-dolgu uygulamaları ve drenaj düzenindeki değişimlerin yamaç stabilitesi üzerindeki etkisiyle uyumludur. Eğim değişkeninde ise çok düşük eğimli alanlarda SHAP katkılarının negatif olduğu, yaklaşık $8-10^\circ$ sonrasında pozitifte geçtiği ve $10-40^\circ$ aralığında heyelan olasılığını artırıcı etki gösterdiği izlenmiştir. Bu bulgular, modelin eğim, yağış ve yol etkisini basit doğrusal ilişkiler şeklinde değil, eşik ve etkileşim içeren doğrusal olmayan örüntüler halinde öğrendiğini göstermektedir.

Üretilen heyelan duyarlılık haritaları, sayısal performans sonuçlarıyla genel olarak uyumlu mekânsal örüntüler ortaya koymuştur. Mevcut heyelan envanterinin önemli bir bölümünün yüksek ve çok yüksek duyarlılık sınıfları içerisinde veya bu sınıfların yakın çevresinde yer aldığı görülmüştür. Özellikle kuzey, kuzeybatı ve orta kesimlerde yüksek duyarlılık alanlarının yoğunlaşması, çalışma alanının topoğrafik, hidrolojik ve iklimsel

koşullarıyla uyumludur. Rastgele Orman, LightGBM ve XGBoost modelleri hem mevcut heyelan envanteriyle uyumlu yüksek duyarlılık zonları üretmiş hem de düşük duyarlılık alanlarını daha seçici biçimde ayırabilmiştir. Buna karşılık KNN ve Lojistik Regresyon modellerinde yüksek duyarlılık sınıflarının daha geniş alanlara yayıldığı, Karar Ağacı modelinde ise sınıf geçişlerinin daha bloklu ve keskin olduğu görülmüştür.

Duyarlılık sınıflarının alan dağılımı da modeller arasındaki tahmin davranışını desteklemiştir. Yüksek ve çok yüksek duyarlılık sınıflarının çok geniş alanlara yayılması, modelin gerçek heyelanları kaçırmama eğilimini artırabilir; ancak bu durum yanlış pozitif alanların artması ve planlama açısından gereğinden geniş risk zonları tanımlanması anlamına da gelebilir. Buna karşılık yüksek duyarlılık alanlarının çok dar tutulması, bazı gerçek heyelan alanlarının gözden kaçmasına neden olabilir. Bu nedenle ideal modelin, mevcut heyelan envanteriyle uyumlu yüksek duyarlılık alanları üretirken, çalışma alanının tamamını aşırı riskli olarak sınıflandırmayan dengeli bir mekânsal yapı sunması beklenir. Bu açıdan Rastgele Orman, LightGBM ve XGBoost modelleri en tutarlı sonuçları üretmiştir.

Sonuç olarak bu çalışma, Çayeli ilçesi için makine öğrenmesi tabanlı, çok faktörlü ve açıklanabilir bir heyelan duyarlılık modelleme yaklaşımı sunmuştur. Bulgular, heyelan duyarlılığının tek bir koşullayıcı faktörle açıklanamayacağını; yağış, eğim, topoğrafik nemlenme, yol etkisi, drenaj yakınlığı, yüzey pürüzlülüğü ve zemin dinamik özelliklerinin birlikte değerlendirilmesi gerektiğini göstermiştir. Rastgele Orman modeli en yüksek ayırt edici performansı sağlarken, LightGBM modeli dengeli sınıflandırma ölçütleri açısından en güçlü sonuçları üretmiş, XGBoost ise her iki açıdan da yüksek ve kararlı performans göstermiştir. Bu nedenle nihai değerlendirmede bu üç modelin heyelan duyarlılık haritaları, çalışma alanında risk azaltma, arazi kullanım planlaması, altyapı projelerinin önceliklendirilmesi ve ayrıntılı saha incelemeleri için güvenilir karar destek çıktıları olarak değerlendirilebilir.

Bununla birlikte çalışmanın bazı sınırlılıkları bulunmaktadır. Heyelan envanteri geçmiş olaylara dayalıdır ve envanterin eksiksizliği model performansını doğrudan etkileyebilir. Heyelan olmayan noktalar kontrollü örnekleme ile seçilmiş olsa da, envanterde yer almayan potansiyel eski veya küçük ölçekli heyelan alanlarının negatif sınıfa dahil edilmiş olma olasılığı tamamen dışlanamaz. Ayrıca sismik/jeoteknik zemin parametreleri noktasal ölçümlerden IDW enterpolasyonu ile raster yüzeylere dönüştürülmüştür; bu nedenle bu katmanların doğruluğu ölçüm noktalarının yoğunluğu ve mekânsal dağılımına bağlıdır. Gelecekte daha ayrıntılı saha gözlemleri, güncel heyelan envanterleri, zaman serisi yağış verileri, yüksek çözünürlüklü jeoteknik

ölçümler ve farklı mekânsal doğrulama yaklaşımlarının kullanılması, model sonuçlarının daha da güçlendirilmesine katkı sağlayacaktır.

Genel olarak, bu çalışma makine öğrenmesi modellerinin yalnızca yüksek performanslı tahmin araçları olarak değil, aynı zamanda SHAP gibi açıklanabilirlik yöntemleriyle birlikte kullanıldığında jeomorfolojik süreçleri yorumlamaya katkı sağlayan analitik araçlar olarak değerlendirilebileceğini göstermiştir. Çayeli ilçesi özelinde üretilen heyelan duyarlılık haritaları, yüksek riskli alanların belirlenmesi, izleme çalışmalarının yönlendirilmesi, yerleşim ve altyapı planlamasında öncelikli bölgelerin tanımlanması ve afet risk azaltma stratejilerinin geliştirilmesi açısından uygulanabilir nitelikte sonuçlar sunmaktadır.

KAYNAKÇA

- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD). (2014). *Açıklamalı afet yönetimi terimleri sözlüğü*. T.C. Başbakanlık Afet ve Acil Durum Yönetimi Başkanlığı (12.06.2026)
- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD). (2021). *Rize ve çevresi aşırı yağış ve heyelan olayları değerlendirme raporu*. (12.06.2026)
- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD). (2023a). *Türkiye deprem tehlike haritası ve sismotektonik değerlendirmeler*. (15.06.2026)
- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD). (2023b). *Türkiye heyelan duyarlılık ve afet risk analizleri raporu*. (15.06.2026)
- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD). (2023c). *Türkiye afet risk azaltma ve heyelan değerlendirme raporları*. (19.06.2026)
- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD). (2023d). *Türkiye heyelan ve taşkın afet istatistikleri raporu*. (19.06.2026)
- Abdelkader, M. M., ve Csámer, Á. (2025). Heyelan duyarlılık haritalaması için makine öğrenimi modellerinin karşılaştırmalı değerlendirmesi: doğrulama ve doğruluk üzerine odaklanma. *Natural Hazards*, 121, 10299–10321. <https://doi.org/10.1007/s11069-025-07197-0>
- Akgün, A. (2012). A Lojistik regresyon, çok kriterli karar verme ve olasılık oranı yöntemleriyle üretilen heyelan duyarlılık haritalarının karşılaştırılması: Türkiye, İzmir’de bir vaka çalışması. *Heyelanlar*, 9(1), 93–106. <https://doi.org/10.1007/s10346-011-0283-7>
- Akın, O., ve Sayıl, N. (2025). Aktif ve pasif kaynak yüzey dalga yöntemlerine dayalı zemin kayma gerilimi kullanılarak heyelan riski taşıyan alanlarda toprak karakterizasyonu. *Pure and Applied Geophysics*, 182(4), 1579–1600. <https://doi.org/10.1007/s00024-025-03696-0>
- Akıncı, H., Kılıçoğlu, C., ve Dogan, S. (2020). Türkiye'nin Artvin İli Kıyı Bölgelerinde Rastgele Orman Algoritması Tabanlı Heyelan Duyarlılık Haritalaması. *ISPRS International Journal of Geo-Information*, 9(9), 553. <https://doi.org/10.3390/ijgi9090553>
- Akıncı, H., Yavuz Özalp, A., ve Temuçin Kılıçer, S. (2015). Coğrafi Bilgi Sistemleri ve AHP Yöntemi Kullanılarak Planlı Alanlarda Heyelan Duyarlılığının

- Değerlendirilmesi: Artvin Örneği. *Doğal Afetler ve Çevre Dergisi*, 1(1-2), 40-53.
<https://doi.org/10.21324/dacd.20952>
- Akingboye, A. S., ve Bery, A. A. (2022). Granitik bir ortamda toprak-kaya arayüzünün haritalanması için birleştirilmiş ERT ve sondaj kayıtları. *Geofizika*, 39(2), 321–337. <https://doi.org/10.15233/gfz.2022.39.17>
- Aleotti, P., Chowdhury, R. (1999). Heyelan tehlikesi değerlendirmesi: özet inceleme ve yeni bakış açıları. *Bull Eng Geol Env* 58, 21–44
<https://doi.org/10.1007/s100640050066>
- Al-Najjar, H., Kalantar, B., Pradhan, B., Beydoun, G. ve Ueda, N. (2025). Heyelan Duyarlılık Modelleri için SHapley Katkısız Açıklamaları (SHAP): Açıklanabilir Yapay Zekaya Işık Tutmak, *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, XG-2025, 81–85, <https://doi.org/10.5194/isprs-annals-XG-2025-81-2025>,
- Altun, Y. (1977). Çayeli-Madenköy bakır-çinko (Cu–Zn) yatağının jeolojisi ve cevherleşmeye ilişkin sorunlar. *Maden Tetkik ve Arama Bülteni*, 89, 10–23.
- Arabameri, A., Pradhan, B., Rezaei, K. (2019). Sayısal risk faktörü iki değişkenli modeli ve doğrusal çok değişkenli regresyon ve güçlendirilmiş regresyon ağacı algoritmalarıyla birleştirilmiş modeli kullanılarak GIS tabanlı heyelan duyarlılık haritalaması. *J. Mt. Sci.* 16, 595–618. <https://doi.org/10.1007/s11629-018-5168-y>
- Ayalew, L., ve Yamagishi, H. (2005). Japonya'nın orta kesimindeki Kakuda-Yahiko Dağları'nda heyelan duyarlılık haritalaması için CBS tabanlı lojistik regresyonun uygulanması. *Geomorphology*, 65(1–2), 15–31.
<https://doi.org/10.1016/j.geomorph.2004.06.010>
- Aydinoğlu, A. Ç., ve Altürk, G. (2021). Heyelan duyarlılık haritalarının istatistik ve makine öğrenmesi teknikleri kullanılarak üretilmesi: Taşlıdere Havzası örneği (Rize). *Coğrafya Dergisi*, 43, 159–176. <https://doi.org/10.26650/JGEOG2021-814561>
- Bard, P. Y. (1999). Mikrotremor ölçümleri: Saha etkisi tahmininde bir araç mı? Konferans: Yüzey Jeolojisinin Sismik Hareket Üzerindeki Etkileri Üzerine İkinci Uluslararası Sempozyum *Geology on Seismic Motion*, 1251–1279. Balkema.
- Birkmann, J. (2013). *Doğal tehlikelere karşı kırılganlığın ölçülmesi: Afetlere dirençli toplumlara doğru*. United Nations University Press.
- Borcherdt, R. D. (1994). Tasarım için sahaya bağlı tepki spektrumlarının tahminleri (Yöntem ve gerekçelendirme). *Earthquake Spectra*, 10(4), 617–653.
<https://doi.org/10.1193/1.1585791>

- Bozkurt, E. (2001). Türkiye'nin neotektoniği: Bir sentez. *Geodinamica Acta*, 14(1–3), 3–30. <https://doi.org/10.1080/09853111.2001.11432432>
- Can, T., Nefeslioğlu, H. A., Gökçeoğlu, C., Sönmez, H., ve Duman, T. Y. (2005). Ağır yağışlarla tetiklenen sığ toprak akımlarının üç havzada lojistik regresyon analizleri ile duyarlılık değerlendirmeleri. *Geomorphology*, 72(1–4), 250–271. <https://doi.org/10.1016/j.geomorph.2005.05.011>
- Cardona, O. D. (2003). Kırılabilirlik ve risk kavramlarının bütüncül bir perspektiften yeniden düşünülmesi: Etkili risk yönetimi için gerekli bir değerlendirme ve eleştiri. In J. Birkmann (Ed.), *Measuring vulnerability to natural hazards* (ss. 37–51). UN University Press.
- Ceylan Demirel, Ş., ve Hastaoğlu, K. Ö. (2022). CBS Tabanlı AHP Yöntemi Kullanılarak Oluşturulan Sivas Koyulhisar Heyelan Duyarlılık Haritalarının Güvenilirliğinin Araştırılması. *Afet ve Risk Dergisi*, 5(2), 715-730. <https://doi.org/10.35341/afet.1071728>
- Cruden, D. M., ve Varnes, D. J. (1996). Heyelan türleri ve süreçleri. In A. K. Turner ve R. L. Schuster (Eds.), *Heyelanlar: Araştırma ve önleme* (Transportation Research Board Özel Rapor No. 247, ss. 36–75). National Academy Press.
- Çellek, S., Bulut, F., ve Ersoy, H. (2015). AHP Yöntemi'nin Heyelan Duyarlılık Haritalarının Üretilmesinde Kullanımı ve Uygulaması (Sinop ve Yakın Çevresi). *Jeoloji Mühendisliği Dergisi*, 39(2), 59-90. <https://doi.org/10.24232/jeoloji-muhendisligi-dergisi.295366>
- Çömert, R., Tanyaş, H., Lombardo, L., ve Görüm, T. (2025). Türkiye'nin doğu Karadeniz bölgesinde yağmur kaynaklı heyelanların ve çevresel özelliklerinin açık bir olay envanteri veritabanı. *Engineering Geology*, 355, 108258. <https://doi.org/10.1016/j.enggeo.2025.108258>
- Dağ, S., ve Bulut, F. (2012). Coğrafi bilgi sistemleri tabanlı heyelan duyarlılık haritalarının hazırlanmasına bir örnek: Çayeli (Rize, KD Türkiye). *Jeoloji Mühendisliği Dergisi*, 36(1), 35–62.
- Demir, A., Kemeç, S., ve İlke, E. F. (2022). Afet riski değerlendirmelerinde çoklu tehlike analizi: Erciş, Van örneği. *Resilience*, 6(1), 15–38. <https://doi.org/10.32569/resilience.1013912>
- Demirkesen, S. (2011). Safety training in construction (Tez No. 656471) [Yüksek lisans tezi, Illinois Institute Of Technology]. Ulusal Tez Merkezi.
- National Academies of Sciences, Engineering, and Medicine. (2021). State of the Art and Practice in the Assessment of Earthquake-Induced Soil Liquefaction and Its

- Consequences. Washington, DC: The National Academies Press.
<https://doi.org/10.17226/23474>.
- DSİ (Devlet Su İşleri Genel Müdürlüğü). (2021). Doğu Karadeniz havzası hidrolojik ve taşkın değerlendirme raporu. DSİ Genel Müdürlüğü.
- Emre, Ö., Duman, TY, Özalp, S. (2018). Türkiye'nin aktif fay veritabanı. Deprem Mühendisliği Bülteni 16, 3229–3275 <https://doi.org/10.1007/s10518-016-0041-2>
- Erener, A., ve Düzgün, H. S. B. (2012). Landslide susceptibility assessment: What are the effects of mapping unit and mapping method? *Environmental Earth Sciences*, 66(3), 859–877.
- Ersan, A., Beker, Y., Coşkunlu, E., Doğramacı, E., Çalışkan, K., Tekin, E., ve Koparmal, E. (2014). *Ladik (Samsun) ilçesinde mikrotremor ölçümleri* [Bildiri]. TMMOB Jeoloji Mühendisleri Odası.
- Ertekin, C., ve Uluggerli, E. U. (2022). Türkiye'deki Yukarı Sakarya Nehri Havzası'nın kuzey kesiminde askıda akiferlerin jeoelektrik araştırılması *Journal of Groundwater Science and Engineering*, 10(4), 335–352.
<http://dx.doi.org/10.19637/j.cnki.2305-7068.2022.04.003>
- Fell, R., Corominas, J., Bonnard, C., Cascini, L., Leroi, E., ve Savage, W. Z. (2008). Arazi Kullanım Planlaması için Heyelan Duyarlılığı, Tehlike ve Risk Bölgelemesi *Engineering Geology*, 102(3–4), 85–98.
<https://doi.org/10.1016/j.enggeo.2008.03.022>
- Gökçe, O., Özden, Ş., ve Demir, A. (2008). Türkiye'de afetlerin mekânsal ve istatistiksel dağılımı: Afet bilgileri envanteri. T.C. Bayındırlık ve İskân Bakanlığı, Afet İşleri Genel Müdürlüğü.
- Gökçeoğlu, C., ve Ercanoğlu, M. (2001). Heyelan duyarlılık haritalarının hazırlanmasında kullanılan parametrelere ilişkin belirsizlikler. *Yerbilimleri*, 22(23), 189-206. <https://izlik.org/JA35DC99XE>
- Gökçeoğlu, C., Sezer, E. (2012). Heyelan Duyarlılığı Değerlendirmesinde Yumuşak Hesaplama Modellemesi. İçinde: Pradhan, B., Buchroithner, M. (eds) Karasal Kütle Hareketleri. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-25495-6_3
- Güneş, B., ve Kömüşcü, A. Ü. (2025). Coğrafi Bilgi Sistemleri (CBS) Tabanlı AHS yöntemi ile Erzincan-Sivas Karayolu ve Çevresinin Heyelan Duyarlılık Analizi. *Doğal Afetler ve Çevre Dergisi*, 11(1), 89-103.
<https://doi.org/10.21324/dacd.1478173>

- Guzzetti, F., Carrara, A., Cardinali, M., ve Reichenbach, P. (1999). Heyelan tehlikesi deęerlendirmesi: Orta İtalya'da çok ölçekli bir çalışmada mevcut tekniklerin ve uygulamalarının incelenmesi. *Geomorphology*, 31(1-4), 181-216. [https://doi.org/10.1016/S0169-555X\(99\)00078-1](https://doi.org/10.1016/S0169-555X(99)00078-1)
- Guzzetti, F., Reichenbach, P., Cardinali, M., Galli, M., ve Ardizzone, F. (2005). Havza ölçeğinde olasılıksal heyelan tehlikesi deęerlendirmesi. *Geomorphology*, 72(1-4), 272-299. <https://doi.org/10.1016/j.geomorph.2005.06.002>
- Goetz, J. N., Brenning, A., Petschko, H., ve Leopold, P. (2015). Heyelan duyarlılığı modellemesi için makine öğrenimi ve istatistiksel tahmin tekniklerinin deęerlendirilmesi *Computers ve Geosciences*, 81, 1-11. <https://doi.org/10.1016/j.cageo.2015.04.007>
- Highland, L.M., ve Bobrowsky, P. (2008). Heyelan El Kitabı - Heyelanları Anlamaya Yönelik Bir Kılavuz (Sürüm 1.0): ABD Jeolojik Araştırmalar Dairesi Genelgesi 1325, xiv, 129 s., <https://doi.org/10.3133/cir1325>.
- Huabin, W., Gangjun, L., Weiya, X., ve Gonghui, W. (2005). GIS tabanlı heyelan tehlikesi deęerlendirmesi: genel bir bakış. Fiziksel Coğrafyada İlerleme: Yer ve Çevre, 29 (4), 548-567. <https://doi.org/10.1191/0309133305pp462ra>
- Intergovernmental Panel on Climate Change (IPCC), (2021). Climate change 2021: De physical science basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change (V. Masson-Delmotte, P. Zhai, A. Pirani, S. L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M. I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T. K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, ve B. Zhou, Ed.). Cambridge University Press. <https://doi.org/10.1017/978100915789>
- Kahya, F. (2019). *Rize il merkezi ve yakın çevresinin heyelan duyarlılığı açısından araştırılması* [Yüksek lisans tezi, Recep Tayyip Erdoğan Üniversitesi].
- Karsli, F., Atasoy, M., Yalcin, A. (2009) Heyelan riski yüksek bir bölgede (Ardesen, Rize, Kuzeydoęu Türkiye) arazi kullanım deęişikliklerinin heyelanlar üzerindeki etkileri. *Environ Monit Assess* 156, 241-255. <https://doi.org/10.1007/s10661-008-0481-5>
- Kapoor, S., ve Narayanan, A. (2023). Makine öğrenmesine dayalı bilimde veri sızıntısı ve yeniden üretilebilirlik krizi. *Patterns* (N Y). Aug 4;4(9):100804. Doi: 10.1016/j.patter.2023.100804. PMID: 37720327; PMCID: PMC10499856.

- Keleş, F. (2018). *Kararlı hidrolojik koşulların ve sonsuz şev modelinin esas alındığı heyelan duyarlılık analizleri (Güneysu su toplama havzası, Rize)* [Yüksek lisans tezi, Akdeniz Üniversitesi].
- Keleş, F., ve Nefeslioğlu, H. A. (2021). Sonsuz eğim stabilitesi modeli ve kararlı hal hidrolojisine dayalı sığ heyelan duyarlılık değerlendirmeleri: Güneysu havzası (Rize, Türkiye). *Catena*, 200, 105161. <https://doi.org/10.1016/j.catena.2021.105161>
- Kramer, Steven L. (2003). *Geoteknik deprem mühendisliği*. Çev.: Kamil Kayabalı. Ankara: Gazi Kitabevi, 708 s.
- Lee, S., Pradhan, B. (2007) Malezya'nın Selangor bölgesinde frekans oranı ve lojistik regresyon modelleri kullanılarak heyelan tehlikesi haritalaması. *Heyelanlar* 4, 33–41 <https://doi.org/10.1007/s10346-006-0047-y>
- Merghadi, A., Yunus, A. P., Dou, J., Whiteley, J., Thai Pham, B., Bui, D. T., Avtar, R., ve Abderrahmane, B. (2020). Heyelan duyarlılık çalışmaları için makine öğrenme yöntemleri: Algoritma performansının karşılaştırmalı bir genel bakışı *Earth-Science Reviews*, 207, 103225. <https://doi.org/10.1016/j.earscirev.2020.103225>
- MGM (Meteoroloji Genel Müdürlüğü). (2023). Türkiye iklim normalleri ve yağış istatistikleri raporu. (24.06.2026)
- MTA (2011). Türkiye jeoloji haritası ve açıklama raporu. Maden Tetkik ve Arama Genel Müdürlüğü. (24.06.2026)
- Molnar, S., Cassidy, JF, Castellaro, S. (2018). Saha Karakterizasyonu için Mikrotremor Yatay-Dikey Spektral Oran (MHVSR) Analizinin Uygulanması: Güncel Durum. *Surv Geophys* 39, 613–631 <https://doi.org/10.1007/s10712-018-9464-4>
- Mutlu, S. (2012). *Sismik kırılma yöntemi ve mikrotremör ölçümlerinden elde edilen dinamik zemin parametrelerinin coğrafi bilgi sistemleri (CBS) kullanılarak haritalanması* [Yüksek lisans tezi, Anadolu Üniversitesi]. Anadolu Üniversitesi Açık Arşivi.
- Nakamura, Y. (1989). A method for dynamic characteristics estimation of subsurface using microtremor. *Quarterly Report of RTRI*, 30(1), 25–33.
- NEHRP. (2003). *Recommended provisions for seismic regulations for new buildings and other structures*. FEMA 450.
- Öncü, S. (2021). *CBS yöntemiyle Bursa'nın bütünleşik doğal tehlike analizi* [Yüksek lisans tezi, Bursa Uludağ Üniversitesi].

- Özşahin, E., ve Eroğlu, İ. (2019). Erzincan kentinde yerel zemin özelliklerinin deprem duyarlılığına etkisi. *Doğal Afetler ve Çevre Dergisi*, 5(1), 41–57. <https://doi.org/10.21324/dacd.428012>
- Ocak, F., ve Bahadır, M. (2022). CBS teknikleri kullanılarak deprem duyarlılık analizi için Analitik Hiyerarşi Prosesi: Samsun Ladik Gölü Havzası örneği, Türkiye. *Kesit Akademi Dergisi*, 8(33), 322–348. <https://doi.org/10.29228/kesit.64705>
- Okay, A. I., ve Şahintürk, Ö. (1997). Doğu Pontidlerin Jeolojisi. *International Geology Review*, 39(3), 291–311. <https://doi.org/10.1306/M68612C15>
- Partigöç, N. S., ve Dinçer, C. (2024). Coğrafi Bilgi Sistemleri (CBS) tabanlı afet risk analizi: Denizli ili örneği. *Geomatik*, 9(1), 27–44. <https://doi.org/10.29128/geomatik.1261051>
- Pektezel, H. (2015). Coğrafi Bilgi Sistemleri ve Analitik Hiyerarşi Yöntemi Kullanılarak Gelibolu Yarımadası'nda Heyelana Duyarlı Alanların Belirlenmesi. *Turkish Studies*, 10(6), 789–814. <https://doi.org/10.7827/TurkishStudies.8182>
- Pham, B. T., Pradhan, B., Bui, D. T., Prakash, I., ve Dholakia, M. B. (2016). Heyelan risk değerlendirmesi için farklı makine öğrenme yöntemlerinin karşılaştırmalı incelenmesi: Uttarakhand bölgesi (Hindistan) örneği *Environmental Modelling ve Software*, 84, 240–250. <https://doi.org/10.1016/j.envsoft.2016.07.005>
- Reichenbach, P., Rossi, M., Malamud, B. D., Mihir, M., ve Guzzetti, F. (2018). İstatistiksel temelli heyelan duyarlılık modellerinin bir değerlendirmesi. *Earth-Science Reviews*, 180, 60–91. <https://doi.org/10.1016/j.earscirev.2018.03.001>
- Sameen, M. I., Pradhan, B., Bui, D. T., ve Alamri, A. M. (2020). Heyelan duyarlılık modellerinin eğitimi için sistematik örnek alt bölme stratejisi. *Catena*, 187, 104358. <https://doi.org/10.1016/j.catena.2019.104358>
- Segoni, S., Pappafico, G., Luti, T. (2020). Karmaşık jeolojik ortamlarda heyelan duyarlılığının değerlendirilmesi: jeolojik bilgilere duyarlılık ve parametreleştirilmesine ilişkin bilgiler. *Heyelanlar* 17, 2443–2453 <https://doi.org/10.1007/s10346-019-01340-2>
- Sidle, R. C., ve Ochiai, H. (2006). *Heyelanlar: Süreçler, Tahmin ve Arazi Kullanımı*. American Geophysical Union. <https://doi.org/10.1029/WM018>
- Şahin, E. K., (2012). *CBS tabanlı çok kriterli karar analizi yöntemi kullanılarak heyelan duyarlılık haritasının üretilmesi: Trabzon ili örneği* [Yüksek lisans tezi, Gebze Yüksek Teknoloji Enstitüsü].
- Şaroğlu F., Emre Ö., ve Kuşçu, İ., (1992). Türkiye Diri Fay Haritası, Maden Tetkik ve Arama Genel Müdürlüğü (MTA), Ankara.

- Şaroğlu, F., Emre, Ö. and Kuşçu, I., (1992). “Active Fault Map of Turkey”, Mineral Res. Explor. Inst. Turkey.
- Şengün, M. T., Şaman, B., ve Karadeniz, E. (2019). Kalaba Yolu (Sivrice-Elazığ) heyelanı ve duyarlılık analizi. 1. *Uluslararası Coğrafya Kongresi Bildiri Kitabı*, 642–652. <https://doi.org/10.26650/PB/PS12.2019.002.063>
- Taş, M. A., Şenol, C., ve Yanık, M. E. (2024). Analitik Hiyerarşi Süreci (AHS) metodu ile Of İlçesi’nde (Trabzon) heyelan risk duyarlılığı analizi. *Afet ve Risk Dergisi*, 7(1), 279–302. <https://doi.org/10.35341/afet.1361149>
- Tehrani, F. S., Santinelli, G., Plini, P., ve Ghalehnoee, M. (2022). Makine Öğrenmesi Kullanarak Heyelan Duyarlılığı Haritalaması: Bir Literatür Taraması. *Remote Sensing*, 14(13), 3029. <https://doi.org/10.3390/rs14133029>
- Tien Bui, D., Pradhan, B., Lofman, O., ve Revhaug, I. (2012). Vietnam’ın Hoa Binh eyaletinde heyelan duyarlılığı değerlendirmesi: Levenberg-Marquardt ve Bayesian düzenlemeli sinir ağlarının karşılaştırılması *Geomorphology*, 171–172, 12–29. <https://doi.org/10.1016/j.geomorph.2012.04.023>
- Tüysüz, O., Genç, Ş. C., Tatar, D. Ü., ve Erturaç, M. K. (2008). *Rize ilinin 1/100.000 ölçekli jeoloji haritası*. Maden Tetkik ve Arama Genel Müdürlüğü (MTA).
- UNDRR. (2015). *Sendai Framework for Disaster Risk Reduction 2015–2030*. United Nations.
- UNISDR. (2009). *UNISDR terminology on disaster risk reduction*.
- Varnes, D. J. (1984). *Heyelan tehlikesi bölgelemesi: İlkeler ve uygulamaların gözden geçirilmesi* (Natural Hazards, 3). UNESCO.
- Wald, D. J., vd (1999). Relationships between PGA, PGV and MMI. *Earthquake Spectra*, 15(3), 557–564.
- Wang, H. B., ve Sassa, K. (2005). Japonya’nın Minamata bölgesinde heyelan riskinin karşılaştırmalı değerlendirmesi, 47(7), 956–966.
- Wills, C. J., vd. (2000). Jeoloji ve Kayma Dalga Hızı Temelinde Kaliforniya İçin Bir Saha Koşulları Haritası. *Bulletin of the Seismological Society of America*, 90(6B), S187–S208. <https://doi.org/10.1785/0120000503>
- Yıldız, T., Dağ, E., Çakan, A. G., ve Afacan, Ö. (2024). Geoteknik ve jeofizik saha araştırma çalışmalarının geomekansal veri yöntemleriyle değerlendirilmesi. 19. *Ulusal Zemin Mekaniği ve Geoteknik Mühendisliği Konferansı Bildiri Kitabı*.
- Yılmaz, I., Keskin, I. (2009) Heyelan duyarlılık haritalamasına yönelik GIS tabanlı istatistiksel ve fiziksel yaklaşımlar (Sebinkarahisar, Türkiye). Mühendislik

Jeolojisi ve Çevre Bülteni 68, 459–471 <https://doi.org/10.1007/s10064-009-0188-z>

Youd, T. L., ve Idriss, I. M. (2001). Toprakların Sıvılaşma Direnci: 1996 NCEER ve 1998 NCEER/NSF Toprakların Sıvılaşma Direncinin Değerlendirilmesi Çalıştaylarından Özet Rapor *Journal of Geotechnical and Geoenvironmental Engineering*, 127(10), 817–833. [https://doi.org/10.1061/\(ASCE\)1090-0241\(2001\)127:10\(817\)](https://doi.org/10.1061/(ASCE)1090-0241(2001)127:10(817))

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Zehra SÜRÜL

Eğitim Durumu

Lisans Öğrenimi : Acil Yardım ve Afet Yönetimi

Yüksek Lisans Öğrenimi : Jeofizik Mühendisliği

Bildiği Yabancı Diller : Bulunmamaktadır.

Bilimsel Faaliyetler ve Yayınlar¹ : Bulunmamaktadır.

İş Deneyimi

Stajlar : Lisans eğitimi süresince Çanakkale İl Afet ve Acil Durum Müdürlüğü (AFAD), Çanakkale İtfaiyesi ve hastane birimlerinde staj çalışmaları gerçekleştirilmiştir. Bu süreçte afet yönetimi, acil durum müdahalesi ve saha uygulamalarına yönelik deneyim kazanılmıştır.

Projeler : Bulunmamaktadır.

Çalıştığı Kurumlar : 2023 yılından itibaren Türk Kızılay bünyesinde Afet Uzmanı olarak görev yapmaktadır. Görev kapsamında afet yönetimi, risk azaltma, saha koordinasyonu, afet hazırlık çalışmaları ve insani yardım faaliyetlerinde yer almaktadır.

Tarih : 19.05.2026

¹ Doktora öğrencilerinin mezuniyet için gerekli yasal yükümlülüğü yerine getirebilmeleri adına bu alanı doldurmaları zorunludur.