

Gümüşhane'nin Heyelan Duyarlılığının Makine Öğrenmesi Algoritmaları Kullanılarak Değerlendirilmesi

Assessment of Landslide Susceptibility of Gümüşhane Using Machine Learning Algorithms

Hasan Tahsin Bostancı^{1*} 

¹Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Gümüşhane/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Hasan Tahsin Bostancı
htbostanci@gumushane.edu.tr

doi: 10.48123/rsgis.1836037

Yayın süreci

Geliş tarihi: 04.12.2025
Kabul tarihi: 10.02.2026
Basım tarihi: 26.03.2026

Özet

Gümüşhane, jeolojik yapısı, engebeli topografyası ve iklimsel özellikleri nedeniyle ülkemizde heyelan, kaya düşmesi ve çığ gibi kütle hareketlerinin sıkça yaşandığı illerden biridir. 2021 yılında hazırlanan il afet risk azaltma planında il genelinde meydana gelen doğal afetlerin %49'unu heyelanların oluşturduğu belirtilmiştir. Dolayısıyla bu çalışmada, makine öğrenmesi algoritmaları kullanılarak Gümüşhane'nin Merkez ilçesinin heyelan duyarlılık haritalarının üretilmesi amaçlanmıştır. Çalışmada makine öğrenmesi algoritmaları olarak lojistik regresyon (LR), yapay sinir ağları (ANN) ve destek vektör makineleri (SVM) tercih edilmiştir. Adı geçen algoritmalarla oluşturulan duyarlılık modellerinde; bakı, drenaj ağlarına uzaklık, yola uzaklık, yükseklik, arazi örtüsü, litoloji, plan eğriliği, profil eğriliği, eğim ve topografik nemlilik indeksi (TWI)'nden oluşan 10 faktör kullanılmıştır. Modellerin eğitim ve doğrulama aşamasında MTA Genel Müdürlüğünden temin edilen heyelan envanter haritası kullanılmıştır. LR, ANN ve SVM modellerinin performansı ROC eğrisi altında kalan alan (area under the ROC curve - AUC) metriği kullanılarak değerlendirilmiştir. LR, ANN ve SVM modellerinin AUC değerleri, sırasıyla, 0.784, 0.865 ve 0.888 olarak belirlenmiştir. Bu sonuçlar SVM modelinin diğer modellerden daha iyi performans gösterdiğini ortaya koymuştur. Ayrıca, çalışma alanında heyelanların meydana gelmesinde en etkili faktörlerin sırasıyla eğim, yükseklik, TWI ve yola yakınlık olduğu belirlenmiştir.

Anahtar kelimeler: Heyelan, Makine öğrenmesi, LR, ANN, SVM, Gümüşhane

Abstract

Gümüşhane is one of the provinces in Turkey where mass movements such as landslides, rockfalls, and avalanches frequently occur due to its geological structure, rugged topography, and climatic characteristics. The provincial disaster risk reduction plan prepared in 2021 states that landslides account for 49% of all natural disasters occurring throughout the province. Therefore, this study aims to produce landslide susceptibility maps for the Central District of Gümüşhane using machine learning algorithms. In this study, logistic regression (LR), artificial neural networks (ANN), and support vector machines (SVM) were preferred as machine learning algorithms. Ten factors were used in the susceptibility models created with the aforementioned algorithms: aspect, distance to drainage networks, distance to roads, elevation, land cover, lithology, plan curvature, profile curvature, slope, and topographic wetness index (TWI). The landslide inventory map obtained from the General Directorate of the MTA was used in the training and validation stages of the models. The performance of the LR, ANN, and SVM models was evaluated using the area under the ROC curve (AUC) metric. The AUC values of the LR, ANN, and SVM models were determined to be 0.784, 0.865, and 0.888, respectively. These results indicate that the SVM model performed better than the other models. Additionally, it was determined that the most influential factors in the occurrence of landslides in the study area were slope, elevation, TWI, and distance to roads, in that order.

Keywords: Landslides, Machine learning, LR, ANN, SVM, Gümüşhane

1. Giriş

Heyelanlar, dünya çapında sık görülen, çok sayıda can kaybına ve günlük yaşamı etkileyen altyapı hasarlarına neden olan doğal afetlerdir (Zhou vd., 2024). Dünya Sağlık Örgütü, 1998-2017 yılları arasında yaşanan heyelanların yaklaşık 4,8 milyon kişiyi etkilediğini ve 18.000’den fazla kişinin ölümüne neden olduğunu bildirmiştir (World Health Organization, 2025). Araştırmacılar, artan demografik baskılar ve arazi kullanımı değişiklikleri nedeniyle kırsal ve kentsel alanlarda heyelanların sıklığının ve etkilerinin artacağını tahmin etmektedir (Fidan vd., 2024).

Heyelanların neden olduğu risklerin ve ekonomik zararların azaltılması, can ve mal kayıplarının önlenmesi ve doğru arazi kullanım planlaması için heyelan duyarlılık haritalaması büyük önem taşımaktadır. Guzzetti vd. (2006), heyelan duyarlılığını, “bir bölgenin heyelanlara maruz kalma eğilimi” olarak tanımlamıştır. Şahin (2018) ile Tekin & Çan (2019) ise heyelan duyarlılık haritalarının, bir bölgede heyelanların gelecekte nerede gerçekleşebileceğini gösteren haritalar olduğunu dile getirmiştir. Heyelan duyarlılık haritalaması için son yirmi yılda çok sayıda nitel (qualitative) ve nicel (quantitative) yöntem geliştirilmiştir. Ancak heyelan duyarlılık değerlendirmesi günümüzde geleneksel istatistiksel yöntemler ve makine öğrenimi yöntemleri olmak üzere iki ana kategoriye indirgenmiştir (Xu vd., 2024).

Frekans Oranı (Frequency Ratio - FR) yöntemi (Pal & Chowdhuri, 2019; Akinci & Yavuz Ozalp, 2021), Kanıt Ağırlığı (Weight of Evidence - WoE) yöntemi (Ozdemir & Altural, 2013; Akinci vd., 2015a; Kilicoglu, 2021), Analitik Hiyerarşi Süreci (Analytical Hierarchy Process - AHP) (Akinci vd., 2015b; Erenur vd., 2016; Huang vd., 2020), Entropi İndeksi (Index of Entropy - IOE) (Demir, 2019; Barman vd., 2023), Kanıt İnanç Fonksiyonu (Evidence Belief Function - EBF) (Abidi vd., 2019; Roy vd., 2023) ve Kesinlik Faktörü (Certainty Factor - CF) (Wubalem, 2021; Zhao vd., 2021) gibi istatistiksel yöntemler dünya genelinde heyelan duyarlılık haritalama çalışmalarında yaygın olarak kullanılmıştır. Ancak, heyelanı etkileyen faktörler arasındaki karmaşık ve doğrusal olmayan (non-linear) ilişkileri modellemedeki başarıları, yüksek boyutlu veri setleriyle başa çıkabilme yetenekleri ve istatistiksel yöntemlere kıyasla daha yüksek tahmin doğruluğu sağlamaları nedeniyle makine öğrenmesi yöntemleri ya da teknikleri günümüzde heyelan duyarlılık haritalamada ön plana çıkmıştır (Pradhan & Kim, 2020; Tang vd., 2020; Akinci, 2022).


Literatür incelediğinde, özellikle son yıllarda, Destek Vektör Makineleri (Support Vector Machines - SVM)(Akinci vd., 2022; Gómez-Miranda vd., 2025), Lojistik Regresyon (Logistic Regression - LR)(Kaya Topaçlı vd., 2024; Tezel & Akgün, 2024), Naive Bayes (Segue vd., 2024; Gómez-Miranda vd., 2025), Rastgele Orman (Random Forest - RF)(Akinci & Zeybek, 2021; Xu vd., 2024), Yapay Sinir Ağları (Artificial Neural Networks - ANN)(Akinci, 2022; Alcântara vd., 2025), Gradyan Artırma Makineleri (Gradient Boosting Machines - GBM)(Akinci, 2022; Sahin, 2022; Lokesh vd., 2025), Hafif Gradyan Artırma Makinesi (Light Gradient Boosting Machine - LightGBM)(Sahin, 2022; Sun vd., 2024), Aşırı Gradyan Artırma (eXtreme Gradient Boosting - XGBoost) (Teke & Kavzoglu, 2023; Yavuz Ozalp vd., 2023; Akinci & Yavuz Ozalp, 2025), Doğal Gradyan Artırma (Natural Gradient Boosting - NGBoost) (Kavzoglu & Teke, 2022) ve Kategorik Gradyan Artırma (Categorical Boosting - CatBoost) (Sahin, 2022; Usta vd., 2024; Alcântara vd., 2025) gibi makine öğrenmesi algoritmalarının, heyelan duyarlılık haritalamada daha fazla tercih edildiği görülmektedir.

Çok sayıda farklı makine öğrenmesi algoritması kullanılmasına rağmen heyelan duyarlılık haritalama için en uygun algoritma konusunda araştırmacılar arasında bir fikir birliği oluşmamıştır (Aditian vd., 2018; Shahzad vd., 2022; Akinci & Yavuz Ozalp, 2025). Bununla birlikte, LR, SVM, ANN ve RF’nin heyelan duyarlılık değerlendirmesinde en yaygın uygulanan makine öğrenmesi algoritmaları olduğu görülmektedir (Gómez-Miranda vd., 2025).

Afet olay sayısı bakımından Türkiye genelinde ilk yirmi (20) il içerisinde yer alan Gümüşhane, heyelanların sıklıkla yaşandığı illerden biridir. Gümüşhane’nin Kürtün, Torul, Kelkit ve Merkez ilçeleri engebeli topografyaları, meteorolojik koşulları, jeolojik yapıları ve insan etkileri nedeniyle heyelanlardan daha fazla etkilenmektedir. Heyelanlar yağışın fazla görüldüğü Mart, Nisan, Mayıs ve Eylül aylarında daha sık meydana gelmektedir (Gümüşhane Afet ve Acil Durum Müdürlüğü, 2021). Bu ilçelerde, özellikle antropojenik faaliyetler de (yeni inşaat alanlarının açılması için derin kazı çalışmalarının yapılması gibi) kaya düşmesi ve heyelan gibi olayların yaşanmasını tetiklemektedir. Dolayısıyla bu çalışmada, literatürde yaygın kullanılan LR, ANN ve SVM makine öğrenmesi algoritmaları kullanılarak Gümüşhane’nin Merkez ilçesinin heyelan duyarlılık haritalarının üretilmesi amaçlanmıştır.

2. Materyal ve Metot

Çalışmada izlenen yöntemin iş akışı genel hatlarıyla Şekil 1’de verilmiştir. Çalışmada ilk olarak heyelan oluşumunda etkili olduğu belirlenen nedensel faktörlerin 10 m konumsal çözünürlükle raster haritaları hazırlanmıştır. Daha sonra çoklu doğrusallık (multicollinearity) analizi yapılarak faktörler arasında korelasyon olup olmadığı test edilmiştir. Heyelan envanter veri setinin %70’lik bölümü kullanılarak makine öğrenmesi modelleri eğitilmiş, envanterin geri kalan %30’luk bölümü ise modellerin doğrulanması aşamasında kullanılmıştır. Son adımda, alıcı işletim karakteristik eğrisi (receiver operating characteristic curve) veya kısa adıyla ROC eğrisi kullanılarak modellerin performansı değerlendirilmiştir.



Şekil 1. Çalışmada izlenen yöntemin iş akış şeması

2.1. Çalışma Alanı

Gümüşhane'nin; Merkez ilçe, Kelkit, Köse, Kürtün, Şiran ve Torul olmak üzere toplam 6 ilçesi bulunmaktadır. Bu çalışmada, araştırma sahası olarak Merkez ilçe seçilmiştir. 188.720 hektarlık yüzölçüme sahip olan Merkez ilçe, coğrafi olarak, 40° 15' 25,46" – 40° 43' 29,67" kuzey enlemleri ile 39° 15' 39,73" – 40° 7' 25,83" doğu boylamları arasında yer almaktadır (Şekil 2). Türkiye İstatistik Kurumu (TÜİK)'nin 2024 yılı adrese dayalı nüfus kayıt sistemi sonuçlarına göre Merkez ilçenin nüfusu 54.341'dir (Türkiye İstatistik Kurumu, 2025).



Şekil 2. Çalışma alanı haritası

Ortalama yüksekliğin 1952 m olduğu Merkez ilçede yükseklik 920 m ile 3080 m arasında değişmektedir. Oldukça engebeli bir araziye sahip olan ve ortalama eğimin 22° olduğu çalışma alanında eğim ise 0° ile $75,13^\circ$ arasında değişmektedir. Çalışma alanının %60'ında eğim 20° 'nin üzerindedir.

Yazların sıcak ve kurak, kışların soğuk ve kar yağışlı geçtiği Gümüşhane, Karadeniz Bölgesinin iç kesimlerinde yer aldığı için karasal bir iklime sahiptir. Meteoroloji Genel Müdürlüğü (MGM)'nin 1961-2024 yıllarını kapsayan uzun dönemli ölçüm verilerine göre Gümüşhane'nin ortalama sıcaklığı $9,6^\circ\text{C}$ dir. İl genelinde ortalama en yüksek sıcaklık $29,1^\circ\text{C}$ ile Ağustos ayında, ortalama en düşük sıcaklık ise $-5,4^\circ\text{C}$ ile Ocak ayında görülmüştür. Yarı kurak-az nemli bir iklimin hakim olduğu Gümüşhane'de aylık toplam yağış miktarı ortalaması 462,5 mm'dir (Meteoroloji Genel Müdürlüğü, 2025).

2.2. Çalışma Alanının Jeolojisi

Çalışma alanının 1/100.000 ölçekli jeoloji haritaları MTA Genel Müdürlüğünden temin edilmiştir (Keskin, 2016; Tunçdemir, 2018). Jeoloji haritalarına göre çalışma alanında 18 farklı litolojik birim bulunmaktadır (Şekil 3). Litolojik birimlerle ilgili detaylı bilgi Tablo 1'de verilmiştir.

Tablo 1. Çalışma alanındaki litolojik birimler ve özellikleri


Birim Adı	Sembol	Yaş	İçerik	Referans
Alüvyon	Qal	Kuvaterner	Akarsu yataklarında, vadi tabalarında ve ovalarda gelişmiş çakıl, kum, silt ve çamurdan oluşan çökellerdir.	Tunçdemir, 2018
Traverten	Qtr	Kuvaterner	Traverten (Karbonat çökel)	Keskin, 2016
Yeşilce Formasyonu	Tey	Orta Eosen	Andezit, bazalt ve piroklastikleri ile konglomera, kumtaşı, kireçtaşı ve kumlu kireçtaşları ara düzeylerinden oluşur.	Kurt vd., 1995
Erenler Formasyonu	Tee	Orta Eosen	Çamurtaşı, kilaşı ve kumtaşı gibi türbitidik kırıntılı kayalar ile olistostromal çökellerden oluşur.	Keskin, 2013
Kumru Formasyonu	Tek	Erken-Orta Eosen	Kumtaşı, kumlu kireçtaşı, çamurtaşı, silttaşı, marn aralanması ile yer yer çakıltaşı ara düzeyleri içerir.	Yergök vd., 1998
Bakırköy Formasyonu	KTb	Paleosen-Erken Eosen	Silttaşı, kilaşı, kumtaşı konglomera, killi-kumlu kireçtaşı ve marndan oluşan türbitidik istif	Keskin, 2013
Kuvars porfir	Tkp	Paleosen	Kuvars porfir	
Kaçkar Granitoyidi-I	Kk1	Geç Kretase-Eosen	Granit, granodiyorit, kuvars diyorit, diyorit, mikro granit, gabro, mikro gabro, piroksenit gibi asidik ve bazik intrüzif kayalar	Keskin, 2013
Cankurtaran Formasyonu	KTc	Geç Kretase-Erken Paleosen	Kumlu kireçtaşı, mikritik kireçtaşı ve kırıntılı kayalardan oluşan istif	Keskin, 2013
Ağıllar Formasyonu	KTa	Geç Kretase-Paleosen	Resifal kireçtaşı ve kumlu kireçtaşından oluşan istif	Keskin, 2013
Çağlayan Formasyonu	Kça	Geç Kretase	Bazaltik, andezitik lav ve piroklastikleri ile çamurtaşı, kumtaşı ve tüflerden oluşur	Keskin, 2013
Kızılkaya Formasyonu	Kk	Geç Kretase	Riyodasitik, dasitik lav ve piroklastiklerinden oluşan volkanitler	Keskin, 2013
Çatak Formasyonu	Kç	Geç Kretase	Bazaltik, andezitik lav ve piroklastikleri ile killi kireçtaşı, marn, silttaşı ve kilaşıdan oluşan volkano-tortul istif	Keskin, 2013
Berdiga Formasyonu	JKb	Geç Jura-Erken Kretase	Kireçtaşı, kumlu-killi kireçtaşı ve çörtlü kireçtaşından oluşur.	Keskin, 2013

Tablo 1'in devamı


Birim Adı	Sembol	Yaş	İçerik	Referans
Hamurkesen Formasyonu	Jh	Erken-Orta Jura	Andezit, bazalt lavı ve piroklastları ile kumtaşı, kireçtaşı, silttaşı, kıltaşı, çamurtaşları ile temsil edilmektedir.	Tunçdemir, 2018
Gümüşhane Granitoyidi	Pzg	Paleozoyik (Karbonifer)	Granit, granodiyorit, kuvars diyorit, kuvars monzonit, mikrogranit ve kuvars porfir gibi kayalar	Keskin, 2016
Dereli Metamorfikleri	Pzd	Paleozoyik	Şist, mermer, metavolkanik ve rekristalize kireçtaşı	Akbaş vd., 1994
Dereli Metamorfikleri, Küçükahmet Şist Üyesi	Pzdk	Paleozoyik	Şist, gnays, amfibolit ve metavolkanikler	Akbaş vd., 1994

2.3. Heyelan Envanteri

Bu çalışmada, heyelan envanteri olarak, Maden Tetkik ve Arama (MTA) Genel Müdürlüğü tarafından üretilen 1/25.000 ölçekli heyelan envanter haritası kullanılmıştır. MTA'nın envanter haritaları heyelanları tiplerine göre Tip 1, Tip 2, Tip 3, Tip 4 ve Tip 5 şeklinde 5 sınıfa ayırmaktadır. Tip 1 eski heyelanları, Tip 2 aktif heyelanları, Tip 3 krip, akma, kayma vb. sığ heyelan alanlarını, Tip 4 alansal haritalanabilen aktif akmaları ve Tip 5 alansal haritalanabilen eski akmaları ifade etmektedir (Erener vd., 2016). Çalışma alanında 196 adet heyelan poligonu bulunmaktadır (Şekil 4). Bunların 106'sı eski heyelan (Tip 1), 57'si aktif heyelan (Tip 2), 33'ü aktif akma (Tip 4) tipindedir. Heyelan poligonlarının en küçüğü 0,61 ha, en büyüğü ise 160,45 ha yüzölçümüne sahiptir. Heyelan poligonlarının toplam yüzölçümü ise 3324,75 ha'dır ve çalışma alanının yaklaşık %1,8'ine denk gelmektedir. Heyelan poligonları 10 m konumsal çözünürlükte 332.422 adet pikselle temsil edilmektedir. Duyarlılık modellerinin gerçekleştirildiği R kodunda, rastgele olarak, aynı sayıda heyelan olmayan piksel seçilmiştir. Heyelan (landslide) piksellerine "1", heyelan olmayan (non-landslide) piksellere "0" değeri atanarak oluşturulan ve toplam 664.844 pikselden oluşan veri setinin %70'i heyelan duyarlılık modellerinin eğitimi, geri kalan %30'u ise doğrulama (test) için kullanılmıştır.



Şekil 3. Çalışma alanının litoloji haritası




Şekil 4. Çalışma alanının heyelan envanter haritası

2.4. Çalışmada Kullanılan Faktörler


Çalışma alanının heyelan duyarlılık analizinde, heyelanların meydana gelmesinde etkili olan 10 faktör kullanılmıştır. Bunlar; eğim, bakı, drenaj ağlarına uzaklık, yola uzaklık, yükseklik, arazi örtüsü, litoloji, topografik nemlilik indeksi (topographic wetness index - TWI), plan eğriliği ve profil eğriliğidir. Faktörler, çalışma alanının koşullarına, veri mevcudiyetine ve literatüre dayanarak belirlenmiştir. Örneğin Liu vd. (2022) tarafından gerçekleştirilen bibliyometrik analiz çalışmasında, heyelan duyarlılık haritalama alanında Web of Science'da yayınlanan 4732 makale analiz edilmiş ve heyelan duyarlılık haritalama çalışmalarında en sık kullanılan 12 faktörün eğim, bakı, litoloji, yükseklik, akarsulara uzaklık, faylara uzaklık, arazi kullanımı/arazi örtüsü, yollara uzaklık, yağış, TWI, plan eğriliği ve profil eğriliği olduğu belirlenmiştir. Bu 12 faktörün 10'u çalışmada kullanılmıştır. Akinci ve Yavuz Ozalp (2025) tarafından yapılan çalışmada da belirtildiği gibi, çalışma alanının yakınında aktif fay bulunmadığından ve bölgede tektonik aktivite olmadığından (deprem tetikli heyelan olmadığı için), çalışmada faylara uzaklık faktörü dikkate alınmamıştır. Ayrıca, çalışma alanında meteoroloji istasyonlarının sayısının yetersiz olması nedeniyle kapsamlı bir yağış dağılım haritası oluşturulmadığından, yağış da bir faktör olarak kullanılmamıştır. Kullanılan faktörlerle ilgili temel bilgiler Tablo 2'de, faktör haritaları ise Şekil 5 ve 6'da verilmiştir.

Tablo 2. Çalışmada kullanılan verilerin kaynakları ve özellikleri

Temel Veri Seti	Üretilen Faktör	Ölçek/Çözünürlük	Veri Kaynağı
Sayısal Yükseklik Modeli (SYM)	Yükseklik	25.000 / 10 m	Harita Genel Müdürlüğü
	Eğim	25.000 / 10 m	
	Bakı	25.000 / 10 m	
	Plan eğriliği	25.000 / 10 m	
	Profil eğriliği	25.000 / 10 m	
	TWI	25.000 / 10 m	
	Drenaj ağlarına uzaklık	10 m	
Jeoloji haritası	Litoloji	25.000 / 10 m	MTA Genel Müdürlüğü
Arazi örtüsü	Arazi örtüsü	10 m	CORINE 2018 (https://land.copernicus.eu/products)
Yol ağı	Yola uzaklık	10 m	Open Street Map



Şekil 5. Çalışmada kullanılan faktörlerin haritaları: a) yükseklik, b) eğim, c) bakı, d) plan eğriliği, e) profil eğriliği, f) TWI



Şekil 6. Çalışmada kullanılan faktörlerin haritaları: a) drenaj ağlarına uzaklık, b) yola uzaklık, c) arazi örtüsü

2.5. Çoklu Doğrusallık Analizi

Heyelan duyarlılık modellerinde kullanılan faktörlerin arasında korelasyon olup olmadığını ve faktörlerin bağımsızlığını test etmek için çoklu doğrusallık (multicollinearity) analizi gerçekleştirilmektedir. Kullanılan faktörler arasındaki güçlü doğrusal ilişki, tahmin sonuçlarının yanlış olmasına ve modelin doğruluğunun azalmasına neden olabilmektedir (Song vd., 2023; Usta vd., 2024). Varyans Şişirme Faktörü (Variance Inflation Factor - VIF) ve Tolerans (TOL) çoklu doğrusallığı test etmek için en sık kullanılan göstergelerdir. VIF değeri 10'dan büyükse veya TOL değeri 0,1'den küçükse bu faktörler arasında çoklu doğrusallık sorunu olduğunu göstermektedir (Teke & Kavzoglu, 2024; Usta vd., 2024; Akinci & Yavuz Ozalp, 2025). Bu durumda çoklu doğrusal değişkenler duyarlılık modellerinden çıkarılmalıdır.

2.6. Modellerin Performanslarının Karşılaştırılması ve Doğrulanması

Heyelan duyarlılık modellerinin performansını değerlendirmek için çeşitli metrikler kullanılmaktadır. Bu metriklerden en yaygın kullanılanı alıcı işletim karakteristik eğrisi altında kalan alan (AUC-ROC)'dır (Chen vd., 2018; Arabameri vd., 2019; Can vd., 2021). Alıcı işletim karakteristik eğrisi (receiver operating characteristic curve) veya kısa adıyla ROC eğrisi, bir sınıflandırma modelinin ne kadar iyi performans gösterdiğini gösteren bir olasılık eğrisidir. İkili sınıflandırma problemleri için yaygın bir değerlendirme ölçütü olan ROC eğrisi iki eksende oluşur: dikey eksen modelin pozitif vakaları (doğru pozitifler) ne sıklıkla doğru tanımladığını, yatay eksen ise negatif vakaları yanlışlıkla pozitif (yanlış pozitifler) olarak tanımladığını gösterir.

Eğri altındaki alan (the area under the curve - AUC), ikili bir sınıflandırıcının sınıfları ayırt etme yeteneğinin ölçüsüdür ve ROC eğrisinin özeti olarak kullanılır (Bhandari, 2025). Heyelan duyarlılık modellerinin doğruluğu veya performansı genellikle AUC değeri ile ölçülür. 0.5 ile 1.0 arasında değişen AUC değeri genellikle beş sınıfa ayrılır. AUC değerinin; 0.5–0.6 arasında olması modelin performansının zayıf olduğunu, 0.6–0.7 arasında olması modelin performansının orta olduğunu, 0.7–0.8 arasında olması modelin performansının iyi olduğunu, 0.8–0.9 arasında olması modelin performansının çok iyi olduğunu ve 0.9–1.0 arasında olması modelin performansının mükemmel olduğunu göstermektedir (Chen vd., 2018; Yavuz Ozalp vd., 2023; Alkan Akinci vd., 2024).

2.7. Çalışmada Kullanılan Makine Öğrenmesi Algoritmaları

2.7.1. Lojistik Regresyon


Lojistik Regresyon (LR), heyelan duyarlılık haritalama çalışmalarında en yaygın kullanılan istatistiksel yöntemlerden biridir (Kavzoglu vd., 2014; Reichenbach vd., 2018; Akinci & Zeybek, 2021; Orhan vd., 2022). Yöntem, genel olarak, bir alandaki heyelan oluşumunu kontrol eden faktörler arasındaki ilişkiyi (regresyon ilişkisini) modelleyerek, benzer faktörlere sahip diğer alanlarda heyelan olasılığını tahmin etmektedir. LR aşağıdaki doğrusal denklemle tanımlanır:

$$z = \beta_0 + \beta_1X_1 + \beta_2X_2 + \dots + \beta_nX_n \quad (1)$$

Bu denklemde; z bağımlı değişkeni, β_0 sabit terimi, $\beta_1, \dots, \beta_n$ bağımsız değişkenlerin regresyon katsayılarını, $X_1, \dots, X_n$ ise bağımsız değişkenleri ifade etmektedir (Kavzoğlu vd., 2012a). Heyelan duyarlılığı açısından düşündüğümüzde, bağımlı değişken heyelan (landslide) ve heyelan olmayan (non-landslide) piksellerden oluşan, “1” ve “0” değerlerini içeren eğitim veri setidir, bağımsız değişkenler ise eğim, arazi örtüsü ve litoloji gibi heyelanı kontrol eden faktörlerdir. Bir faktörün regresyon katsayısı, o faktörün heyelan olasılığını ne kadar ve hangi yönde (pozitif/negatif) etkilediğini göstermektedir (Kavzoğlu vd., 2012a; Akinci & Zeybek, 2021). Bu çalışmada, LR modelini uygulamak için RStudio 2025.09.1 yazılımında “caret” kütüphanesinin (Kuhn, 2008) “glm” metodu kullanılmıştır.

2.7.2. Yapay Sinir Ağları

Yapay Sinir Ağları (Artificial Neural Networks - ANN), heyelan duyarlılık haritalama çalışmalarında yaygın olarak kullanılan makine öğrenmesi algoritmalarından biridir (Aditian vd., 2018; Sevgen vd., 2019; Akinci, 2022; Moayedi vd., 2024). İnsan beyninin bilgi işleme şekline esinlenen ANN, karmaşık ve doğrusal olmayan ilişkileri öğrenmedeki başarısıyla öne çıkmaktadır. ANN’ler, “nöron” adı verilen ve birbirine bağlı basit işlem birimlerinden oluşur. Her nöron gelen verileri alır, işler ve bir sonraki nörona iletir. Tipik bir ANN; girdi katmanları (input layers), gizli katmanlar (hidden layers) ve çıktı katmanı (output layer) olarak adlandırılan 3 nöron katmanına sahiptir (Şekil 7).



Şekil 7. Bir yapay sinir ağının temel mimarisini (Moayedi vd., 2024’ten değiştirilerek üretilmiştir)

Girdi katmanı ANN’nin eğitiminde kullanılan girdi parametrelerini alan katmandır. Buradaki her bir nöron eğim, bakı, litoloji gibi bir heyelan faktörünü temsil eder. Modelin karmaşık ilişkileri öğrendiği yer olan gizli katman, girdi katmanı ile çıktı katmanı arasında yer alır. Model bir veya daha fazla gizli katman içerebilir.

Girdi parametreleri arasındaki etkileşimleri işleyen ve girdiyi çıktı ile eşleştiren, böylece ANN'nin karmaşık ilişkileri öğrenmesini ve modelin önemli özellikleri çıkarmasını sağlayan katman burasıdır. Çıktı katmanı genellikle tek bir nörondan oluşur. Bu nöron, gizli katmandan gelen bilgiyi alır ve bir sigmoid aktivasyon fonksiyonu kullanarak sonucu 0 ile 1 arasında bir heyelan olasılığına dönüştürür (Haykin, 1999; Bragagnolo vd., 2020). Heyelan duyarlılık haritalama çalışmalarında girdi katmanı, çalışmada kullanılan faktörlerden oluşur. Gizli katmanlar, giriş katmanından alınan bilgileri işler. 0 ile 1 arasında değişen değerlerden oluşan heyelan duyarlılık haritası ise çıkış katmanında üretilir (Bragagnolo vd., 2020). Bu çalışmada, ANN modelini uygulamak için RStudio 2025.09.1 yazılımında “caret” paketinin “nnet” metodu kullanılmıştır (Kuhn, 2008). Model, 10 kat çapraz doğrulama yaklaşımıyla uygulanmıştır.

2.7.3. Destek Vektör Makineleri

Heyelan duyarlılık haritalamada yaygın olarak kullanılan algoritmalarından biri olan destek vektör makineleri (support vector machines - SVM), istatistiksel öğrenme teorisine ve yapısal risk minimizasyonu ilkesine dayanan denetimli bir makine öğrenmesi algoritmasıdır (Tien Bui vd., 2012). SVM sınıflandırma, regresyon, aykırı değer tespiti (outlier / anomaly detection) ve görüntü bölütleme (image segmentation) gibi farklı birçok uygulamada kullanılan çok yönlü bir algoritmadır (Yu & Chen, 2024). SVM'nin sınıflandırma uygulamalarındaki temel amacı, iki sınıfı en uygun şekilde ayıran bir hiperdüzlem (sınır) belirlemektir. Bu hiperdüzlem, eğitim veri kümeleri kullanılarak belirlenir ve modelin genelleme yeteneği test veri kümeleri kullanılarak doğrulanır (Kavzoglu & Colkesen, 2009). Heyelan duyarlılık haritalaması da dahil olmak üzere birçok uygulamada, veri noktaları orijinal özellik uzayında doğrusal bir sınırla ayrılamaz. Bunun gibi doğrusal olmayan problemlerin çözümü için kernel fonksiyonları kullanılır. Bu fonksiyonlar, veriyi daha yüksek bir boyutlu bir özellik uzayına taşıyarak, karmaşık yapıların bile doğrusal bir hiperdüzlemle etkili bir şekilde ayrıştırılmasına olanak sağlarlar (Kavzoglu vd., 2012b). SVM'de yaygın olarak kullanılan dört kernel fonksiyonu bulunmaktadır. Bunlar; doğrusal kernel, polinom kernel, radyal tabanlı fonksiyon (RBF) kernel ve sigmoid kernel'dir (Tien Bui vd., 2012). Heyelan duyarlılık haritalamada yaygın kullanılan kernel fonksiyonu RBF'dir (Akinci & Zeybek, 2021; Ullah vd., 2022; Yu & Chen, 2024). SVM modelinin performansı, kernel parametrelerinin seçimine bağlıdır. RBF tabanlı SVM için düzenleme parametresi (C) ve kernel genişliği (γ) olarak adlandırılan iki parametrenin belirlenmesi gerekmektedir. Bu çalışmada, SVM ile heyelan duyarlılık haritası üretmek için RBF kernel fonksiyonu kullanılmıştır. Uygulamada RStudio 2025.09.1 yazılımında “caret” paketinin “svmRadial” metodu kullanılmıştır (Kuhn, 2008).


3. Bulgular ve Tartışma

Heyelan duyarlılık haritalarını üretmeden önce heyelan faktörleri arasında korelasyon olup olmadığını test etmek için çoklu doğrusallık (multicollinearity) analizi gerçekleştirilmiştir. Bu analiz sonucunda elde edilen VIF ve TOL değerleri Tablo 3'de verilmiştir. Tablo 3 incelendiğinde, VIF değerlerinin 10'dan büyük olmadığı, TOL değerlerinin de 0.1'den küçük olmadığı görülmektedir. Bu değerler, heyelan faktörleri arasında çoklu doğrusallık sorunu olmadığını göstermiş ve 10 faktörde LR, ANN ve SVM duyarlılık modellerinde kullanılmıştır.

Tablo 3. Çoklu doğrusallık analizinin çıktıları

Faktör	VIF	TOL
Arazi örtüsü	1.0225	0.9780
Bakı	1.0139	0.9863
Drenaj ağlarına uzaklık	1.2178	0.8212
Eğim	1.4495	0.6899
Litoloji	1.0159	0.9843
Plan eğriliği	1.2272	0.8149
Profil eğriliği	1.1038	0.9060
TWI	1.5582	0.6418
Yola uzaklık	1.0941	0.9140
Yükseklik	1.2440	0.8039


Toplam 664.844 pikselden oluşan heyelan var/yok (landslide / non-landslide) veri setinin %70'i kullanılarak eğitilen duyarlılık modelleri çalışma alanındaki her piksel için heyelan duyarlılık indeks'ini (Landslide Susceptibility Index - LSI) hesaplamıştır. LR, AN ve SVM modelleri için hesaplanan LSI değerleri “doğal kırılmalar (natural breaks)” sınıflandırma yöntemi ile 5 alt sınıfa (çok düşük, düşük, orta, yüksek ve çok yüksek) ayrılarak çalışma alanının heyelan duyarlılık haritaları üretilmiştir (Şekil 8).



Şekil 8. Çalışma alanının heyelan duyarlılık haritaları: a) LR, b) ANN, c) SVM


Doğal kırılmalar, hem faktör haritalarının üretilmesi hem de heyelan duyarlılık haritalarının üretilmesi aşamalarında yaygın kullanılan veri sınıflandırma yöntemidir (Aditian vd., 2018; Akinci & Yavuz Ozalp, 2021; Kavzoglu & Teke, 2022; Xu vd., 2024). Doğal kırılmalar yöntemi, sınıf içi varyansı en aza indirip, sınıflar arası varyansı en üst düzeye çıkararak veri kümesi içindeki doğal kümeleri veya grupları ortaya çıkardığı için diğer sınıflandırma yöntemlerine göre avantajlıdır (Jenks, 1967). Arabameri vd. (2020) tarafından yapılan çalışmada, 3 farklı duyarlılık modeli kullanılarak hazırlanan heyelan duyarlılık haritaları quantile, doğal kırılmalar, eşit aralık ve geometrik aralık sınıflandırma yöntemleri kullanılarak beş sınıfa ayrılmıştır. Araştırmacılar, eğitim ve doğrulama veri setindeki heyelanların, duyarlılık haritalarının yüksek ve çok yüksek sınıflarındaki dağılımını inceleyerek en güvenilir dağılımın doğal kırılmalar sınıflandırma yöntemi ile elde edildiğini tespit etmişlerdir.

LR modeli ile üretilen heyelan duyarlılık haritasında çalışma alanının %24.38'inin çok düşük, %26.61'inin düşük, %22.03'ünün orta, %16.39'unun yüksek ve %10.59'unun ise çok yüksek derecede heyelana duyarlı olduğu belirlenmiştir. ANN modeli ile üretilen haritada çalışma alanının %37.46'sının çok düşük, %24.45'inin düşük, %15.37'sinin orta, %13.15'inin yüksek ve %9.57'sinin ise çok yüksek derecede heyelana duyarlı olduğu tespit edilmiştir. SVM modeli ile üretilen heyelan duyarlılık haritasında ise çalışma alanının %25.64'ünün çok düşük, %30.42'sinin düşük, %19.71'inin orta, %14.44'ünün yüksek ve %9.79'unun ise çok yüksek derecede heyelana duyarlı olduğu tespit edilmiştir (Şekil 9). Şekil 9'daki dağılım verileri karşılaştırıldığında, duyarlılık sınıflarının alansal dağılımında, üç farklı makine öğrenmesi modelinin kendi algoritmik yapılarından kaynaklanan belirgin ayrılmalar görülmektedir. Dağılımda göze çarpan bu farklılıklar, her modelin veri setindeki örüntüleri ve karmaşık ilişkileri kendine özgü bir şekilde öğrenip yorumlamasından ileri gelmektedir.



Şekil 9. Duyarlılık sınıflarının yüzde olarak alansal dağılımı

Modellerin performansını değerlendirmek için üretilen ROC eğrileri Şekil 10a'da sunulmuştur. LR, ANN ve SVM modellerinin AUC değerleri, sırasıyla, 0.784, 0.865 ve 0.888 olarak belirlenmiştir. Bu verilere göre LR modelinin iyi, ANN ve SVM modellerinin ise çok iyi performans gösterdikleri belirlenmiştir. Bununla birlikte, SVM modeli karşılaştırılan modeller içerisinde en üstün performansı gösteren model olarak ön plana çıkmıştır.



Şekil 10. a) Duyarlılık modellerine ait ROC eğrileri ve AUC değerleri, b) SVM modeline göre faktörlerin önem dereceleri

Literatür incelendiğinde LR modelinin, ANN veya SVM ile karşılaştırıldığı her çalışmada daha zayıf performans gösterdiği belirlenmiştir. Örneğin Pradhan ve Lee (2010) ile Aditian vd. (2018) tarafından gerçekleştirilen heyelan duyarlılık haritalama çalışmalarında FR, LR ve ANN modellerinin performansları karşılaştırılmış ve her iki çalışmada da ANN'nin LR'den daha iyi performans gösterdiği belirlenmiştir. Colkesen vd. (2016) tarafından yapılan çalışmada ise LR, Gaussian process regression (GPR) ve SVM modelleri karşılaştırılmıştır. LR modelinin 0.89 AUC değerine sahip olduğu çalışmada SVM 0.932 AUC değeri ile daha üstün performans göstermiştir. Sonuç olarak, heyelanı etkileyen faktörler arasındaki ilişkilerin doğrusal olmaması LR modelinin ANN ve SVM gibi modellere kıyasla performansının düşük olmasına neden olmuştur.

Şekil 10b, SVM modeline göre heyelan faktörlerinin önem derecelerini göstermektedir. Buna göre çalışma alanında heyelanlarının meydana gelmesinde en etkili faktörlerin sırasıyla, eğim, yükseklik, TWI, yola uzaklık ve litoloji olduğu belirlenmiştir. Plan eğriliği, bakı ve profil eğriliği ise en az etkili faktörler olarak belirlenmiştir. Eğimin en belirleyici faktör olarak öne çıkması, heyelanın temel tetikleyicisinin yerçekimi kuvveti olduğu prensibiyle tamamen örtüşmektedir. Bu bulgu, çalışma alanındaki heyelanların eğimli arazilerde meydana gelme eğiliminde olduğunu net bir şekilde ortaya koymaktadır. Bayrak vd. (2010) tarafından yapılan ve Gümüşhane'deki heyelanların sebeplerinin değerlendirildiği çalışmada heyelanların oluş nedenleri göz önüne alındığında suyun etkisinin %42, yol ve temel kazılarının %26, ayrışmanın %26, bitki örtüsü değişikliğinin %4 ve diğer nedenlerin %2 oranında etkili olduğu dile getirilmiştir. Bu değerlendirme TWI, yola uzaklık, litoloji ve arazi örtüsü faktörlerinin önem dereceleriyle büyük oranda örtüşmektedir. Yola uzaklığın en etkili faktörlerden biri olarak belirlenmesinin ise, yol şevlerinin düzenlenmesi ve yollara yakın diğer mühendislik faaliyetlerinin yürütülmesinde yapılan hatalar sonucu meydana gelen heyelanlardan kaynaklandığı değerlendirilmektedir. Gümüşhane kent merkezinde meydana gelen ve büyük maddi kayıplara neden olan iki önemli heyelanın, litolojik özelliklerin dikkate alınmadan yapılan hatalı yol ve temel kazılarından kaynaklandığını ortaya koyan Alemdag vd. (2014) ile Kaya vd. (2016) tarafından yapılan akademik çalışmalar da bu değerlendirmeyi desteklemektedir.

4. Sonuçlar

Bu çalışmada LR, ANN ve SVM makine öğrenmesi algoritmaları kullanılarak Gümüşhane ilinin Merkez ilçesinin heyelan duyarlılık haritaları üretilmiş ve çalışma alanında heyelana eğilimli bölgeler 10 m konumsal çözünürlükte ayrıntılı bir şekilde belirlenmiştir. Çalışmada literatürde yaygın olarak kullanıldığı belirlenen 10 faktör kullanılmıştır. Çoklu doğrusallık analizinden elde edilen VIF ve TOL değerleri, seçilen faktörlerin arasında korelasyon olmadığını ve modellenme aşamasında kullanılabileceklerini göstermiştir. Üretilen duyarlılık haritaları karşılaştırıldığında, duyarlılık sınıflarının alansal dağılımında modeller arasında belirgin farklılıklar gözlenmiş; bu durum, her bir algoritmanın veri setindeki karmaşık ilişkileri farklı biçimlerde öğrenmesiyle ilişkilendirilmiştir. Modellerin AUC değerleri LR için 0.784, ANN için 0.865 ve SVM için 0.888 olarak hesaplanmıştır. Bu sonuçlar, SVM'nin çalışma alanı için en yüksek doğruluğu sağlayan algoritma olduğunu ortaya koymuştur.

Çalışmada en yüksek doğruluk SVM modelinden elde edildiği için faktörlerin önem derecelerinin yorumlanmasında da SVM modeli dikkate alınmıştır. SVM modelinin önem derecelerine göre eğim, yükseklik, TWI ve yola uzaklık çalışma alanında heyelanların meydana gelmesinde en etkili faktörler olarak belirlenmiştir. Bu bulgu, çalışma alanındaki heyelanların büyük ölçüde topoğrafik koşullar ile engebeli yamaçlarda yol kazıları ve arazi örtüsünün değiştirilmesi gibi antropojenik faaliyetlerle yakından ilişkili olduğunu göstermiştir.

Üretilen heyelan duyarlılık haritaları, çalışma alanında heyelan kaynakların risklerin azaltılmasında karar vericilere önemli bir altlık sağlayacaktır. Bununla birlikte, gelecek çalışmalarda faktör sayısının artırılması (örneğin yağışın eklenmesi ve farklı örnekleme stratejilerinin geliştirilmesi (özellikle heyelan olmayan örneklerin seçimi için) veya XGBoost, CatBoost ve LightGBM gibi gelişmiş topluluk öğrenme algoritmalarının kullanılması güvenilirliği yüksek duyarlılık haritalarının üretilmesine olanak sağlayacaktır.

Kaynaklar

- Abidi, A., Demehati, A., & El Qandil, M. (2019). Landslide susceptibility assessment using evidence belief function and frequency ratio models in Taounate city (North of Morocco). *Geotechnical and Geological Engineering*, 37, 5457–5471. <https://doi.org/10.1007/s10706-019-00992-0>
- Adition, A., Kubota, T., & Shinohara, Y. (2018). Comparison of GIS-based landslide susceptibility models using frequency ratio, logistic regression, and artificial neural network in a tertiary region of Ambon, Indonesia. *Geomorphology*, 318, 101–111. <https://doi.org/10.1016/j.geomorph.2018.06.006>
- Akbaş, B., Hacı Arslan, H., Halil Keskin, H., Hamdi Mengi, H., Altun, İ. E., Erdoğan, K., Sevin, M., Deniz, N., Talia, Ş. A., & Köse, Y. Z. (1994). *Giresun-Piraziz-Şebinkarahisar arasında kalan bölgenin jeolojisi*. Maden Tetkik ve Arama Genel Müdürlüğü, Jeoloji Etütleri Dairesi Başkanlığı.
- Akinci, H., Yavuz Özalp, A., Özalp, M., Temuçin Kılıçer, S., Kılıçoğlu, C., & Everan, E. (2015a). Production of landslide susceptibility map using Bayesian probability model. *International Journal of 3-D Information Modeling*, 4(2), 16–33. <https://doi.org/10.4018/IJ3DIM.201504010>
- Akinci, H., Yavuz Özalp, A., & Temuçin Kılıçer, S. (2015b). 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>
- Akinci, H., & Yavuz Ozalp, A. (2021). Landslide susceptibility mapping and hazard assessment in Artvin (Turkey) using frequency ratio and modified information value model. *Acta Geophysica*, 69, 725–745. <https://doi.org/10.1007/s11600-021-00577-7>
- Akinci, H., & Zeybek, M. (2021). Comparing classical statistic and machine learning models in landslide susceptibility mapping in Ardanuç (Artvin), Turkey. *Natural Hazards*, 108, 1515–1543. <https://doi.org/10.1007/s11069-021-04743-4>
- Akinci, H. (2022). Assessment of rainfall-induced landslide susceptibility in Artvin, Turkey using machine learning techniques. *Journal of African Earth Sciences*, 191, Article 104535. <https://doi.org/10.1016/j.jafrearsci.2022.104535>
- Akinci, H., Zeybek, M., & Dogan, S. (2022). Evaluation of landslide susceptibility of Şavşat district of Artvin Province (Turkey) using machine learning techniques. In Y. Zhang & Q. Cheng (Eds.), *Landslides* (pp. 69–96). IntechOpen. <http://dx.doi.org/10.5772/intechopen.99864>
- Akinci, H., & Yavuz Ozalp, A. (2025). Investigating the effects of different data classification methods on landslide susceptibility mapping. *Advances in Space Research*, 75, 3427–3450. <https://doi.org/10.1016/j.asr.2024.12.020>
- Alcântara, E., Baião, C. F., Guimarães, Y. C., Mantovani, J. R., & Marengo, J. A. (2025). Machine learning reveals lithology and soil as critical parameters in landslide susceptibility for Petrópolis (Rio de Janeiro State, Brazil). *Natural Hazards Research*. Advance online publication. <https://doi.org/10.1016/j.nhres.2025.01.008>
- Alemdag, S., Akgun, A., Kaya, A., & Gokceoglu, C. (2014). A large and rapid planar failure: Causes, mechanism, and consequences (Mordut, Gumushane, Turkey). *Arabian Journal of Geosciences*, 7, 1205–1221. <https://doi.org/10.1007/s12517-012-0821-1>
- Alkan Akinci, H., Akinci, H., & Zeybek, M. (2024). Comparison of diverse machine learning algorithms for forest fire susceptibility mapping in Antalya, Türkiye. *Advances in Space Research*, 74, 647–667. <https://doi.org/10.1016/j.asr.2024.04.018>
- Arabameri, A., Saha, S., Roy, J., Chen, W., Blaschke, T., & Tien Bui, D. (2020). Landslide susceptibility evaluation and management using different machine learning methods in the Gallicash River watershed, Iran. *Remote Sensing*, 12(3), Article 475. <https://doi.org/10.3390/rs12030475>
- Barman, J., Ali, S. S., Biswas, B., & Das, J. (2023). Application of index of entropy and geospatial techniques for landslide prediction in Lunglei district, Mizoram, India. *Natural Hazards Research*, 3(3), 508–521.
- Bayrak, T., Ulukavak, M., & Açar, S. (2010). Gümüşhane heyelanları. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 1–12.

- Bhandari, A. (2025, May 1). Guide to AUC ROC curve in machine learning. *Analytics Vidhya*. <https://www.analyticsvidhya.com/blog/2020/06/auc-roc-curve-machine-learning/>
- Bragagnolo, L., da Silva, R. V., & Grzybowski, J. M. V. (2020). Artificial neural network ensembles applied to the mapping of landslide susceptibility. *Catena*, 184, Article 104240. <https://doi.org/10.1016/j.catena.2019.104240>
- Can, R., Kocaman, S., & Gokceoglu, C. (2021). A comprehensive assessment of XGBoost algorithm for landslide susceptibility mapping in the upper basin of Ataturk Dam, Turkey. *Applied Sciences*, 11(11), Article 4993. <https://doi.org/10.3390/app11114993>
- Chen, W., Peng, J., Hong, H., Shahabi, H., Pradhan, B., Liu, J., Zhu, A.-X., Pei, X., & Duan, Z. (2018). Landslide susceptibility modelling using GIS-based machine learning techniques for Chongren County, Jiangxi Province, China. *Science of the Total Environment*, 626, 1121–1135. <https://doi.org/10.1016/j.scitotenv.2018.01.124>
- Demir, G. (2019). GIS-based landslide susceptibility mapping for a part of the North Anatolian Fault Zone between Reşadiye and Koyulhisar (Turkey). *Catena*, 183, Article 104211. <https://doi.org/10.1016/j.catena.2019.104211>
- Erener, A., Mutlu, A., & Düzgün, H. S. (2016). A comparative study for landslide susceptibility mapping using GIS-based multi-criteria decision analysis (MCDA), logistic regression (LR) and association rule mining (ARM). *Engineering Geology*, 203, 45–55. <https://doi.org/10.1016/j.enggeo.2015.09.007>
- Fidan, S., Tanyaş, H., Akbaş, A., Lombardo, L., Petley, D. N., & Görüm, T. (2024). Understanding fatal landslides at global scales: A summary of topographic, climatic, and anthropogenic perspectives. *Natural Hazards*, 120, 6437–6455.
- Gómez-Miranda, I. N., Restrepo-Estrada, C., Builes-Jaramillo, A., & de Albuquerque, J. P. (2025). Advanced AI techniques for landslide susceptibility mapping and spatial prediction: A case study in Medellín, Colombia. *Applied Computing and Geosciences*, 25, Article 100226. <https://doi.org/10.1016/j.acags.2025.100226>
- Guzzetti, F., Reichenbach, P., Ardizzone, F., Cardinali, M., & Galli, M. (2006). Estimating the quality of landslide susceptibility models. *Geomorphology*, 81, 166–184. <https://doi.org/10.1016/j.geomorph.2006.04.007>
- Gümüşhane Afet ve Acil Durum İl Müdürlüğü. (2021). *İl afet risk azaltma planı*. <https://gumushane.afad.gov.tr/kurumlar/gumushane.afad/E-Kutuphane/Gumushane-IRAP-.pdf>
- Haykin, S. (1999). *Neural networks: A comprehensive foundation* (2nd ed.). Prentice Hall.
- Huang, F., Cao, Z., Guo, J., Jiang, S.-H., Li, S., & Guo, Z. (2020). Comparisons of heuristic, general statistical and machine learning models for landslide susceptibility prediction and mapping. *Catena*, 191, Article 104580. <https://doi.org/10.1016/j.catena.2020.104580>
- Jenks, G. F. (1967). The data model concept in statistical mapping. *International Yearbook of Cartography*, 7, 186–190.
- Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11, 352–359.
- Kavzoğlu, T., Şahin, E. K., & Çölkesen, İ. (2012a). Heyelan duyarlılığının incelenmesinde regresyon ağaçlarının kullanımı: Trabzon örneği. *Harita Dergisi*, 147, 21–33.
- Kavzoğlu, T., Çölkesen, İ., & Şahin, E. K. (2012b, 16–19 Ekim). Heyelan duyarlılık haritasının üretilmesinde kullanılan faktörlerin etkilerinin araştırılması: Düzköy örneği. IV. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZAL-CBS 2012)*, Zonguldak, Türkiye.
- Kavzoglu, T., Sahin, E. K., & Colkesen, I. (2014). Landslide susceptibility mapping using GIS-based multi-criteria decision analysis, support vector machines, and logistic regression. *Landslides*, 11(3), 425–439.
- Kavzoglu, T., & Teke, A. (2022). Predictive performances of ensemble machine learning algorithms in landslide susceptibility mapping using random forest, extreme gradient boosting (XGBoost) and natural gradient boosting (NGBoost). *Arabian Journal for Science and Engineering*, 47, 7367–7385.
- Kaya, A., Alemdağ, S., Dağ, S., & Gürocak, Z. (2016). Stability assessment of high-steep cut slope debris on a landslide (Gumushane, NE Turkey). *Bulletin of Engineering Geology and the Environment*, 75, 89–99. <https://doi.org/10.1007/s10064-015-0753-6>
- Kaya Topaçlı, Z., Ozcan, A. K., & Gokceoglu, C. (2024). Performance comparison of landslide susceptibility maps derived from logistic regression and random forest models in the Bolaman Basin, Türkiye. *Natural Hazards Review*, 25(1), Article 04023054. <https://doi.org/10.1061/NHREFO.NHENG-1771>
- Keskin, İ. (2013). *1:100.000 ölçekli Türkiye jeoloji haritaları serisi – Artvin E47 ve F47 paftaları* (No. 179). Maden Tetkik ve Arama Genel Müdürlüğü, Jeoloji Etütleri Dairesi Başkanlığı.
- Keskin, İ. (2016). *1:100.000 ölçekli Türkiye jeoloji haritaları serisi – Trabzon H43 paftası* (No. 239). Maden Tetkik ve Arama Genel Müdürlüğü, Jeoloji Etütleri Dairesi Başkanlığı.
- Kilicoglu, C. (2021). Investigation of the effects of approaches used in the production of training and validation data sets on the accuracy of landslide susceptibility mapping models: Samsun (Turkey) example. *Arabian Journal of Geosciences*, 14, Article 2106. <https://doi.org/10.1007/s12517-021-08312-8>
- Kuhn, M. (2008). Building predictive models in R using the caret package. *Journal of Statistical Software*, 28(5), 1–26. <https://doi.org/10.18637/jss.v028.i05>

- Kurt, İ., Kılınç, M. F., Uysal, Ş., & Bedi, Y. (1995). *Koyulhisar (Sivas) dolayının jeolojisi*. Maden Tetkik ve Arama Genel Müdürlüğü, Jeoloji Etütleri Dairesi Başkanlığı.
- Liu, L. L., Zhang, J., Li, J., Huang, F., & Wang, L. (2022). A bibliometric analysis of the landslide susceptibility research (1999–2021). *Geocarto International*, 37(26), 14309–14334. <https://doi.org/10.1080/10106049.2022.2087753>
- Lokesh, P., Madhesh, C., Mathew, A., & Shekar, P. R. (2025). Machine learning and deep learning-based landslide susceptibility mapping using geospatial techniques in Wayanad, Kerala state, India. *HydroResearch*, 8, 113–126.
- Meteoroloji Genel Müdürlüğü. (2025). *İllere ait genel istatistik verileri*. <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=A&m=GUMUSHANE>
- Moayed, H., Xu, M., Naderian, P., Dehrashid, A. A., & Thi, Q. T. (2024). Validation of four optimization evolutionary algorithms combined with artificial neural network (ANN) for landslide susceptibility mapping: A case study of Gilan, Iran. *Ecological Engineering*, 201, Article 107214. <https://doi.org/10.1016/j.ecoleng.2024.107214>
- Orhan, O., Bilgilioglu, S. S., Kaya, Z., Ozcan, A. K., & Bilgilioglu, H. (2022). Assessing and mapping landslide susceptibility using different machine learning methods. *Geocarto International*, 37(10), 2795–2820.
- Ozdemir, A., & Altural, T. (2013). A comparative study of frequency ratio, weights of evidence and logistic regression methods for landslide susceptibility mapping: Sultan Mountains, SW Turkey. *Journal of Asian Earth Sciences*, 64, 180–197. <https://doi.org/10.1016/j.jseaes.2012.12.014>
- Pal, S. C., & Chowdhuri, I. (2019). GIS-based spatial prediction of landslide susceptibility using frequency ratio model of Lachung River basin, North Sikkim, India. *SN Applied Sciences*, 1, Article 416. <https://doi.org/10.1007/s42452-019-0422-7>
- Pradhan, B., & Lee, S. (2010). Landslide susceptibility assessment and factor effect analysis: Backpropagation artificial neural networks and their comparison with frequency ratio and bivariate logistic regression modelling. *Environmental Modelling & Software*, 25, 747–759. <https://doi.org/10.1016/j.envsoft.2009.10.016>
- Reichenbach, P., Rossi, M., Malamud, B. D., Mihir, M., & Guzzetti, F. (2018). A review of statistically-based landslide susceptibility models. *Earth-Science Reviews*, 180, 60–91. <https://doi.org/10.1016/j.earscirev.2018.03.001>
- Roy, D., Sarkar, A., Kundu, P., Paul, S., & Sarkar, B. C. (2023). An ensemble of evidence belief function (EBF) with frequency ratio (FR) using geospatial data for landslide prediction in Darjeeling Himalayan region of India. *Quaternary Science Advances*, 11, Article 100092. <https://doi.org/10.1016/j.qsa.2023.100092>
- Sahin, E. K. (2022). Comparative analysis of gradient boosting algorithms for landslide susceptibility mapping. *Geocarto International*, 37(9), 2441–2465. <https://doi.org/10.1080/10106049.2020.1831623>
- Segue, W. S., Njilah, I. K., Fossi, D. H., & Nsangou, D. (2024). Advancements in mapping landslide susceptibility in Bafoussam and its surroundings area using multi-criteria decision analysis, statistical methods, and machine learning models. *Journal of African Earth Sciences*, 213, Article 105237. <https://doi.org/10.1016/j.jafrearsci.2024.105237>
- Sevgen, E., Kocaman, S., Nefeslioglu, H. A., & Gokceoglu, C. (2019). A novel performance assessment approach using photogrammetric techniques for landslide susceptibility mapping with logistic regression, ANN and random forest. *Sensors*, 19(18), Article 3940. <https://doi.org/10.3390/s19183940>
- Shahzad, N., Ding, X., & Abbas, S. (2022). A comparative assessment of machine learning models for landslide susceptibility mapping in the rugged terrain of Northern Pakistan. *Applied Sciences*, 12, Article 2280. <https://doi.org/10.3390/app12052280>
- Song, Y., Yang, D., Wu, W., Zhang, X., Zhou, J., Tian, Z., Wang, C., & Song, Y. (2023). Evaluating landslide susceptibility using sampling methodology and multiple machine learning models. *ISPRS International Journal of Geo-Information*, 12(5), Article 197. <https://doi.org/10.3390/ijgi12050197>
- Sun, D., Wang, J., Wen, H., Ding, Y. K., & Mi, C. (2024). Landslide susceptibility mapping (LSM) based on different boosting and hyperparameter optimization algorithms: A case of Wanzhou District, China. *Journal of Rock Mechanics and Geotechnical Engineering*, 16(8), 3221–3232. <https://doi.org/10.1016/j.jrmge.2023.09.037>
- Şahin, E. K. (2018). Heyelan duyarlılık haritası için adimsal regresyona dayalı faktör seçme yönteminin etkinliğinin araştırılması. *Harita Dergisi*, 159, 1–15.
- Tang, Y., Feng, F., Guo, Z., Feng, W., Li, Z., Wang, J., Sun, Q., Ma, H., & Li, Y. (2020). Integrating principal component analysis with statistically-based models for analysis of causal factors and landslide susceptibility mapping: A comparative study from the Loess Plateau area in Shanxi (China). *Journal of Cleaner Production*, 277, Article 124159. <https://doi.org/10.1016/j.jclepro.2020.124159>
- Teke, A., & Kavzoglu, T. (2023). Explainable artificial intelligence empowered landslide susceptibility mapping using extreme gradient boosting (XGBoost). *Advanced Engineering Days*, 6, 74–76.
- Teke, A., & Kavzoglu, T. (2024). Exploring the decision-making process of ensemble learning algorithms in landslide susceptibility mapping: Insights from local and global explainable AI analyses. *Advances in Space Research*, 74, 3765–3785. <https://doi.org/10.1016/j.asr.2024.06.082>
- Tekin, S., & Çan, T. (2019). Yapay sinir ağları yöntemi ile Ermenek Havzası'nın (Karaman) kayma türü heyelan duyarlılık değerlendirmesi. *Bilge International Journal of Science and Technology Research*, 3(1), 21–28.

- Tezel, K., & Akgün, A. (2024). Comparing shallow landslide susceptibility maps in Northeastern Türkiye (Beşikdüzü, Trabzon): A multivariate statistical, machine learning, and physical data-based analysis. *Environmental Earth Sciences*, 83, Article 335. <https://doi.org/10.1007/s12665-024-11627-w>
- Tien Bui, D., Pradhan, B., Lofman, O., & Revhaug, I. (2012). Landslide susceptibility assessment in Vietnam using support vector machines, decision tree, and Naive Bayes models. *Mathematical Problems in Engineering*, 2012, Article 974638. <https://doi.org/10.1155/2012/974638>
- Tunçdemir, V. (2018). 1:100.000 ölçekli Türkiye jeoloji haritaları serisi – Trabzon H42 paftası (No. 243). Maden Tetkik ve Arama Genel Müdürlüğü.
- Türkiye İstatistik Kurumu. (2025). *Adrese dayalı nüfus kayıt sistemi sonuçları*. <https://biruni.tuik.gov.tr/medas/?locale=tr>
- Xu, K., Zhao, Z., Chen, W., Ma, J., Liu, F., Zhang, Y., & Ren, Z. (2024). Comparative study on landslide susceptibility mapping based on different ratios of training samples and testing samples by using RF and FR-RF models. *Natural Hazards Research*, 4, 62–74. <https://doi.org/10.1016/j.nhres.2023.07.004>
- Ullah, I., Aslam, B., Shah, S. H. I. A., Tariq, A., Qin, S., Majeed, M., & Havenith, H.-B. (2022). An integrated approach of machine learning, remote sensing, and GIS data for the landslide susceptibility mapping. *Land*, 11(8), Article 1265. <https://doi.org/10.3390/land11081265>
- Usta, Z., Akıncı, H., & Akın, A. T. (2024). Comparison of tree-based ensemble learning algorithms for landslide susceptibility mapping in Murgul (Artvin), Turkey. *Earth Science Informatics*, 17, 1459–1481. <https://doi.org/10.1007/s12145-024-01259-w>
- World Health Organization. (2025). *Landslides*. https://www.who.int/health-topics/landslides#tab=tab_1
- Wubalem, A. (2021). Landslide susceptibility mapping using statistical methods in Uatzau catchment area, northwestern Ethiopia. *Geoenvironmental Disasters*, 8, Article 1. <https://doi.org/10.1186/s40677-020-00170-y>
- Yavuz Ozalp, A., Akinci, H., & Zeybek, M. (2023). Comparative analysis of tree-based ensemble learning algorithms for landslide susceptibility mapping: A case study in Rize, Turkey. *Water*, 15(14), Article 2661. <https://doi.org/10.3390/w15142661>
- Yergök, A. F., Kara, H., Keskin, İ., Arslan, M., & Dönmez, M. (1998). *Ünye-Fatsa, Kumru-Korgan (Ordu ili) dolayının jeolojisi*. Maden Tetkik ve Arama Genel Müdürlüğü, Jeoloji Etütleri Dairesi Başkanlığı.
- Yu, X., & Chen, H. (2024). Research on the influence of different sampling resolution and spatial resolution in sampling strategy on landslide susceptibility mapping results. *Scientific Reports*, 14, Article 1549. <https://doi.org/10.1038/s41598-024-52145-w>
- Zhao, Z., Liu, Z.-Y., & Xu, C. (2021). Slope unit-based landslide susceptibility mapping using certainty factor, support vector machine, random forest, CF-SVM and CF-RF models. *Frontiers in Earth Science*, 9, Article 589630. <https://doi.org/10.3389/feart.2021.589630>
- Zhou, C., Wang, Y., Cao, Y., Singh, R. P., Ahmed, B., Motagh, M., Wang, Y., Chen, L., Tan, G., & Li, S. (2024). Enhancing landslide susceptibility modelling through a novel non-landslide sampling method and ensemble learning technique. *Geocarto International*, 39(1), Article 2327463. <https://doi.org/10.1080/10106049.2024.2327463>