

# Jeomorfolojik Arařtırmalar Dergisi

## Journal of Geomorphological Researches

© Jeomorfoloji Derneđi

www.dergipark.gov.tr/jader

E - ISSN: 2667 - 4238



### Arařtırma Makalesi / Research Article

## AKÇASU DERESİ HAVZASI'NDA (İNEGÖL, BURSA) HEYELAN DUYARLILIĐININ MAKİNE ÖĐRENMESİ MODELLERİ İLE KARŐILAŐTIRMALI ANALİZİ

### Comparative Analysis of Landslide Susceptibility Using Machine Learning Models in the Akcasu Stream Basin (İnegöl, Bursa)

Melike DURAK<sup>a</sup>, Muhammed Mustafa ÖZDEL<sup>b</sup>

<sup>a</sup> Sorumlu Yazar / Corresponding Author

Balıkesir Üniversitesi, Sosyal Bilimler Enstitüsü, Cođrafya Anabilim Dalı, Balıkesir, Türkiye  
durakmelike1919@gmail.com  <https://orcid.org/0000-0003-3102-9132>

<sup>b</sup> Bađımsız Arařtırmacı, Kayseri, Türkiye

m.mustafaozdel@gmail.com  <https://orcid.org/0000-0003-0715-4566>

#### Makale Tariđesi

Geliř 6 Őubat 2026  
Kabul 2 Mart 2026

#### Article History

Received 6 February 2026  
Accepted 2 March 2026

#### Anahtar Kelimeler

Akçasu Deresi Havzası, Heyelan Duyarlılıđı, Makine Öđrenmesi, Afet Risk Yönetimi

#### Keywords

Akçasu Stream Basin, Landslide Susceptibility, Machine Learning, Disaster Risk Management

#### Atıf Bilgisi / Citation Info

Durak, M. & Özdel, M. M. (2026) Akçasu Deresi Havzası'nda (İnegöl, Bursa) Heyelan Duyarlılıđının Makine Öđrenmesi Modelleri ile KarŐılaŐtırmalı Analizi / Comparative Analysis of Landslide Susceptibility Using Machine Learning Models in the Akcasu Stream Basin (İnegöl, Bursa), Jeomorfolojik Arařtırmalar Dergisi / Journal of Geomorphological Researches, 2026 (16): 148-172.

doi: 10.46453/jader.1883674

#### ÖZET

Heyelan önleme ve risk azaltma stratejilerinin temel yapı taşıını oluŐturan heyelan duyarlılık analizleri, sahaya ait fiziksel parametreleri deđerlendirerek tehdit altındaki alanların önceden belirlenmesine imkan tanır. Bu çalıŐma kapsamında, makine öđrenmesi algoritmaları aracılıđıyla Akçasu Deresi Havzası'nın heyelan duyarlılık potansiyelinin modellenmesi ve bu duyarlılıđın mekânsal dađılımının ortaya konulması amaçlanmıŐtır. Bu amaç dođrultusunda belirlenen 10 farklı bađımsız deđerŐken temel alınarak; Rastgele Orman (RO), Destek Vektör Makineleri (DVM), Lojistik Regresyon (LR), Yapay Sinir Ađları (YSA) ve Maksimum Entropi (MaxEnt) gibi makine öđrenmesi algoritmalarıyla heyelan duyarlılık modelleri üretilmiŐtir. Hazırlanan heyelan duyarlılık haritaları düşük, orta, yüksek ve çok yüksek Őeklinde dört sınıfa ayrılmıŐtır. Model sonuçları, heyelan envanteri ve AFAD verileriyle çakıŐtırılarak sahadaki gerçek kütle hareketleriyle uyumu sayısal olarak ortaya konulmuŐtur. Model çıktıları, Akçasu Deresi Havzası'nda heyelan duyarlılıđının orta çıđırda yer alan ve akarsular tarafından derince yarılmıŐ platoluk sahalarda kümelenildiđini göstermektedir. Bu alanlar aynı zamanda antropojenik baskıların da en üst seviyeye ulaŐtıđı bölgeleri temsil etmektedir. Aktif kütle hareketlerinin gözlemlendiđi Çayyaka, Çayyaka (Kümlük), Dipsizgöl, Hamidiye (Gençalı), Hayriye, İclaliye, Kestanealanı, Konurlar, Lütfiye ve Muratbey kırsal mahalleleri yüksek ve çok yüksek duyarlılık bölgeleri içerisinde yer almaktadır. Bu tür afetlerin zararlarının minimize edilmesi amacıyla; yüksek ve çok yüksek duyarlılık sahalarda imar planlarında yerleŐime kapatılması ve bu bölgelerdeki mevcut yapıların kademeli olarak tahliyesi önerilmektedir. YerleŐimin sürdüđüğü orta ve yüksek duyarlı alanlarda ise geoteknik iyileŐtirmeler (fore kazık, ankraj vb.) ve drenaj sistemleriyle entegre edilmiŐ teraslama çalıŐmaları titizlikle uygulanmalı; yamaç dengesini korumak için kontrolsüz mühendislik müdahaleleri denetim altına alınmalıdır.

#### ABSTRACT

Landslide susceptibility analyses, which constitute the fundamental component of landslide prevention and risk reduction strategies, enable the early identification of areas under threat by evaluating the physical parameters of the terrain. In this study, it is aimed to model the landslide susceptibility potential of the Akçasu Stream Basin using machine learning algorithms and to reveal the spatial distribution of this susceptibility. In line with this objective, landslide susceptibility models were generated using machine learning algorithms—such as Random Forest (RF), Support Vector Machines (SVM), Logistic Regression (LR), Artificial Neural Networks (ANN), and Maximum Entropy (MaxEnt)—based on 10 different independent variables determined for the study. The landslide susceptibility maps produced were classified into four categories: low, moderate, high, and very high. The model outputs were overlaid with the landslide inventory and AFAD data, and their consistency with actual mass movements in the field was quantitatively assessed. The model outputs indicate that landslide susceptibility within the Akçasu Stream Basin is concentrated in the middle course, particularly in plateau-like areas that have been deeply incised by fluvial processes. These areas also correspond to the regions where anthropogenic pressures reach their highest intensity. The rural neighborhoods of Çayyaka, Çayyaka (Kümlük), Dipsizgöl, Hamidiye (Gençalı), Hayriye, İclaliye, Kestanealanı, Konurlar, Lütfiye, and Muratbey—where active mass movements have been observed—are located within the high and very high susceptibility zones. In order to minimize the impacts of such hazards, it is recommended that high and very high susceptibility

areas be excluded from settlement in zoning plans, and that existing structures within these zones be gradually evacuated. In medium and high susceptibility areas where settlement continues, geotechnical stabilization measures (such as bored piles, anchors, etc.) and terracing works integrated with drainage systems should be implemented meticulously; and uncontrolled engineering interventions must be regulated in order to maintain slope stability.

© 2026 Jeomorfoloji Derneđi / Turkish Society for Geomorphology  
Tüm hakları saklıdır / All rights reserved.

## EXTENDED ABSTRACT

### Introduction

Landslides are defined as the downslope mass movement of materials such as rock, soil, and debris, constituting a significant geomorphological hazard that can be triggered by both natural and anthropogenic processes (Varnes, 1978). Prolonged or intense rainfall, rapid snowmelt, earthquakes, volcanic activity, and engineering-related interventions are among the principal triggers of landslide occurrence (Cruden and Varnes, 1996; Guzzetti, 2006). Globally, landslides cause thousands of fatalities and substantial economic losses each year, ranking among the most frequent and destructive natural hazards (Petley, 2012; Froude and Petley, 2018). Similar impacts are observed in Turkey: according to AFAD, 71 disaster events have been recorded in İnegöl district since 1956, affecting 1,521 dwellings. Of these, 22 occurred within the Akçasu Stream Basin, where a total of 433 dwellings were impacted (İnegöl İstatistik Raporu, 2024).

Landslide susceptibility mapping is a critical decision-support component for risk reduction, spatial planning, and hazard management. A range of approaches is used to produce susceptibility maps, including expert-based assessments, geomorphological mapping, statistical methods, and machine-learning-based, data-driven models (Merghadi et al., 2020). In particular, machine learning algorithms are widely adopted due to their capacity to model complex, non-linear relationships between conditioning factors (e.g., slope, aspect, lithology, drainage characteristics, and proximity to faults, streams, or roads) and the landslide inventory (Zhou et al., 2018; Dai Liu et al., 2023).

Comparative studies consistently show that model performance varies across regions and

data characteristics. In the Wanyuan region of China, Chen et al. (2017) compared Artificial Neural Networks (ANN), Support Vector Machines (SVM), and Maximum Entropy (MaxEnt) models, reporting the highest individual performance for ANN and the best ensemble performance for the ANN–SVM combination. In South Korea, Park and Kim (2019) found that the Relative Operating (RO) model outperformed the Boosted Regression Trees (BRT) model. In Turkey, the RO model achieved >98% performance metrics across coastal districts of Artvin (Akıncı, Kılıçođlu ve Dođan, 2020), while in the Güzelyalı–Lapseki sector of Çanakkale, ANN delivered the highest predictive accuracy (Berber, Ercanođlu ve Ceryan, 2024). Collectively, these findings underscore the need to compare multiple algorithms on a common dataset to select the most suitable model for a given study area.

In this study, ten environmental conditioning factors identified through field observations and literature review as influential on landslide occurrence were incorporated to model the spatial distribution of landslide susceptibility in the Akçasu Stream Basin. Susceptibility maps were generated using multiple machine learning algorithms, and model performance was evaluated using statistical indicators such as the Receiver Operating Characteristic (ROC) curve and the Area Under the Curve (AUC). In addition, susceptibility classes were spatially overlaid with the landslide inventory to assess the agreement between model outputs and observed field reality. The results contribute to identifying the most reliable model at the basin scale and to improving the interpretation of potential high-susceptibility zones, thereby informing local risk reduction and planning efforts.

## Methods and Materials

Landslide inventory data were obtained from the General Directorate of Mineral Research and Exploration (MTA) using the 1:100,000 online drawing editor, including both fossil and active landslides, while geological units and fault lines were derived from 1:25,000 geological maps. The soil map was produced using the 1:25,000 scale soil data obtained from the General Directorate of Rural Services. A digital elevation model generated from 10 m contours was used to compute slope, Topographic Wetness Index (TWI), Topographic Position Index (TPI), and Terrain Ruggedness Index (TRI) in a GIS environment; drainage networks were digitized from topographic maps, land-use data were obtained from CORINE 2018, and precipitation records were provided by the Turkish State Meteorological Service. All datasets were transformed to UTM WGS84 and resampled to a common 10 × 10 m grid. Landslide susceptibility modelling was conducted using ten conditioning factors—slope, drainage density, fault density, TPI, TWI, TRI, geology, land use, soil, and precipitation—with multicollinearity assessed via Pearson correlation ( $|r| \geq 0.7$ ), Variance Inflation Factor (VIF), and Tolerance (Tol). Artificial Neural Networks (ANN), Random Forest (RF), Logistic Regression (LR), Support Vector Machine (SVM), and Maximum Entropy (MaxEnt) were applied. The dataset was split into 70% training and 30% testing. Model performance was evaluated using the Area Under the ROC Curve (AUC), and, for accuracy assessment, the generated susceptibility maps were spatially overlaid with observed landslide areas derived from the inventory to evaluate model reliability and predictive consistency.

## Findings

According to the Pearson correlation analysis (Figure 5a), the independent variables used in the study generally exhibit low to moderate relationships. The highest positive correlation was identified between land use and geology ( $r = 0.52$ ), while the highest negative correlation was found between soil and slope, and between soil and drainage density ( $r = -0.52$ ). These values do not indicate a severe multicollinearity problem and suggest that the variables can provide independent contributions to the

modeling process. The performance comparison of the machine learning algorithms (Figure 5b) showed that all models achieved accuracies above random classification. The highest statistical performance was obtained with Artificial Neural Networks (ANN, AUC = 0.949), followed by Random Forest (RF, AUC = 0.926), Logistic Regression (LR, AUC = 0.912), and Support Vector Machines (SVM, AUC = 0.911). Although MaxEnt produced a lower value (AUC = 0.874), it still delivered an acceptable performance. Overlaying the landslide inventory with the susceptibility maps revealed that the best spatial performance was achieved by the Random Forest model. RF captured 89.2% of known landslides within the High and Very High susceptibility classes. This was followed by SVM with 83.5%, LR with 79.5%, ANN with 77.4%, and MaxEnt with a markedly lower coverage of 46.9%. Across all models, areas of high susceptibility were predominantly concentrated in the middle reach of the basin, where drainage density is high and where weak lithological units (e.g., Miocene limestone, marl, clay, sand, and conglomerate formations) are widely distributed.

## Results, Discussion, Conclusions

In this study, landslide susceptibility in the Akçasu Stream Basin was assessed using five machine learning algorithms: Random Forest, Support Vector Machines, Logistic Regression, Artificial Neural Networks, and MaxEnt. Susceptibility maps were generated based on ten conditioning factors and classified into four categories (low, moderate, high, and very high). Model outputs were validated through spatial overlay with the landslide inventory and AFAD records, enabling a quantitative assessment of their ability to represent actual mass-movement patterns. Among the algorithms, ANN achieved the highest statistical performance (AUC = 0.949), whereas Random Forest exhibited the highest spatial agreement with observed landslides (89.2%). The comparatively low performance of MaxEnt is consistent with previous studies, indicating that model success is more strongly governed by dataset characteristics and site-specific conditions than by the algorithm itself. The literature further confirms that no single method consistently outperforms others, as model accuracy varies

according to geological, geomorphological, and environmental settings.

Overall, the models produced coherent and comparable results, with Random Forest and ANN standing out in terms of both classification accuracy and spatial reliability. High-susceptibility zones were predominantly concentrated in the middle reach of the basin, coinciding with areas characterized by high

drainage density, weak Miocene lithologies, and intensive human activity. Furthermore, the rural settlements of ayyaka, Dipsizgöl, Hamidiye, Hayriye, İclaliye, Kestanealanı, Konurlar, Lütfiye, and Muratbey were identified within high-susceptibility areas. Historical records indicate that ayyaka experienced the most severe damage, whereas Muratbey exhibited the highest recurrence frequency of landslides.

## 1. GİRİŐ

Heyelanlar, yamacı oluřturan kaya, toprak ve molozların ya da bu unsurların birleřiminden oluřan materyalin belirli bir eđim boyunca hareket etmesi řeklinde tanımlanmaktadır (Varnes, 1978). Frekansı en yüksek dođal afetler arasında yer alan heyelanlar; ani ya da uzun süreli sađanak karakterli yađıřlar, ani kar erimeleri, depremler, volkanik süreçler ve çeřitli antropojenik müdahaleler sonucunda ortaya çıkabilmektedir (Varnes, 1978; Cruden ve Varnes, 1996; Guzzetti, 2006). Heyelanlar, dünya genelinde her yıl binlerce kiřinin hayatını kaybetmesine neden olan ve milyarlarca dolarlık ekonomik zarara yol ačan bařlıca dođal afetlerden biridir (Dai vd., 2002; Petley, 2012; Kloze vd., 2015; Froude ve Petley, 2018; Haque vd., 2019; Fidan ve Görüm, 2020). AFAD istatistiklerine göre Bursa ili İnegöl ilçesinde 1956 yılından günümüze kadar toplam 71 afet olayı kaydedilmiř olup, bu afetler sonucunda 1.521 konut etkilenmiřtir. Bu afetlerin 22'si Akçasu Deresi Havzası'nda meydana gelmiř ve yalnızca bu havzada afetten etkilenen konut sayısı 433 olarak raporlanmıřtır (İnegöl İstatistik Raporu, 2024).

Heyelan riskinin azaltılmasında, olası heyelanların mekânsal dađılımını ortaya koyan duyarlılık haritaları önemli bir karar destek bileřenidir (Merghadi vd., 2020). Heyelan duyarlılık haritalarının hazırlanmasında literatürde farklı yaklařımlar kullanılmaktadır. Bu yaklařımlar; uzman görüşüne dayalı modelleme (Zhu vd., 2014), jeomorfolojik temelli haritalama teknikleri (Görüm ve Nefesliođlu, 2015), istatistiksel ya da makine öğrenmesine dayanan veri odaklı modelleme yöntemleri (Youssef vd., 2024; Abdo vd., 2025) ve birden fazla yöntemi karřılařtırmalı olarak kullanan (Jari vd., 2023; Saha, Villuri ve Bhardwaj, 2025) çalıřmaları kapsamaktadır. Özellikle makine öğrenmesi algoritmalarının kullanılmasıyla geliřtirilen haritalar, geçmiř heyelan kayıtları ile eđim, bakı, litoloji, drenaj ađı özellikleri ve fay, akarsu ya da yol gibi unsurlara olan mesafe gibi çevresel faktörler arasındaki iliřkileri analiz ederek, çalıřma alanındaki her bir hücre için heyelan duyarlılık düzeyinin nicel olarak belirlenmesine

dayanmaktadır (Zhou vd., 2018; Merghadi vd., 2020; Liu vd., 2023).

Makine öğrenmesine dayalı yaklařımlar, karmařık ve dođrusal olmayan iliřkileri modelleyebilme kapasiteleri sayesinde heyelan oluřumunu etkileyen çok sayıda çevresel faktörün birlikte deđerlendirilmesine olanak tanımakta ve literatürde yüksek dođruluk ve güvenilirlik deđerleri ile rapor edilmektedir. Örneđin, Çin'in Wanyuan bölgesinde gerçekteřirilen heyelan duyarlılık analizinde 11 çevresel faktör kullanılarak Yapay Sınır Ađı (YSA), Destek Vektör Makinesi (DVM) ve Maksimum Entropi (MaxEnt) modelleri hem bireysel hem de ensemble (topluluk) yaklařımıyla deđerlendirilmiřtir. Performans sonuçlarına göre YSA modeli en yüksek bireysel performansı gösterirken, bunu DVM ve MaxEnt modelleri izlemiř, en yüksek istatistiki bařarının ise YSA ve DVM ile oluřturulan topluluk modelinden elde edildiđi ifade edilmiřtir (Chen vd., 2017). Güney Kore'deki Woomyeon Dađı'nda yapılan bir çalıřmada, RO ve BRT (Boosted Regression Tree) modelleri kullanılarak 140 heyelan noktasıyla duyarlılık haritaları üretilmiř; RO modelinin BRT modeline göre daha yüksek performans gösterdiđi ve haritaların bölgesel yayılımını daha dođru biçimde tahmin ettiđi bildirilmiřtir (Park ve Kim, 2019). Artvin'in Arhavi, Hopa ve Kemalpařa ilçelerini kapsayan bir bařka çalıřmada, RO modeli ile eđim, bakı, litoloji ve hidrografik faktörler gibi 10 deđiřken kullanılmıř ve modelin bařarı oranı %98,3, tahmin oranı %97,7 olarak elde edilmiřtir; bu sonuç heyelan duyarlılık haritalarının yerel risk yönetimi ve planlama için güvenilir olduđunu göstermiřtir (Akıncı, Kılıçođlu ve Dođan, 2020). Çanakkale'nin Güzelyalı-Lapseki kesiminde gerçekteřirilen çalıřmada, Lojistik Regresyon (LR), YSA ve DVM yöntemleri kullanılarak heyelan duyarlılık haritaları üretilmiř; yapılan performans deđerlendirmeleri sonucunda YSA modelinin diđer yöntemlere kıyasla daha yüksek tahmin dođruluđu sađladıđı ve heyelan olasılık dađılımını daha bařarılı biçimde temsil ettiđi rapor edilmiřtir (Berber, Ercanođlu ve Ceryan, 2024). Bu örnekler, farklı veri yapıları ve bölgesel kořullar altında yöntemlerin performansının deđiřebildiđini ve çalıřma alanına özgü en uygun modelin seđimi için

karşılařtırılmalı analizlerin gerekli olduđunu göstermektedir. Bu nedenle yerel ölçekte, güvenilir bir heyelan envanterine dayalı olarak çevresel kořulların bütüncül biçimde deđerlendirildiđi ve birden fazla algoritmanın aynı veri seti üzerinde sınıandıđı çalıřmalar, risk azaltma ve planlama süreçleri açısından kritik önem taşımaktadır.

Bu çalıřmada, Akçasu Deresi Havzası'nda heyelan duyarlılıđının mekânsal dađılımının belirlenmesi amacıyla gerçekteřtirilen saha çalıřmaları ve kapsamlı literatür incelemeleri sonucunda heyelan oluřumunu etkilediđi belirlenen 10 çevresel faktör modele dâhil edilmiřtir. Bu faktörler kullanılarak farklı makine öğrenmesi algoritmaları aracılıđıyla duyarlılık haritaları üretilmiř ve modellerin performansları istatistiksel ölçütler temelinde deđerlendirilmiřtir. Bu kapsamda, modellerin ayırt edicilik gücü ROC eđrisi altında kalan alan (AUC) gibi göstergelerle nicel olarak test edilmiř; ayrıca duyarlılık sınıfları ile gözlenen heyelan noktalarının mekânsal çakıřtırılması yoluyla tahmin dođruluđu analiz edilmiřtir. Böylece hem istatistiksel başarı düzeyi hem de sahadaki gerçekte dađılımla uyum birlikte dikkate alınarak havza ölçeğinde en güvenilir modelin belirlenmesi ve heyelan riskinin daha sađlıklı biçimde yorumlanması amaçlanmıřtır.

### 1.1. İnceleme Alanının Konumu ve Genel Özellikleri

Akçasu Deresi Havzası Türkiye'nin kuzeybatısında Marmara Bölgesi'nin Güney Marmara Bölümü'nde yer almaktadır. İstatistiki Bölge Birim Sınıflamasına (İBBS) göre ise Düzey I'de TR4 Dođu Marmara Bölgesi, Düzey II'de TR41 Bursa Alt Bölgesi'nde Düzey III'de ise TR411 Bursa En Alt Bölgesi'nde yer almaktadır (Şekil 1). Kaynaklarını Uludađ'ın güneydođu uzantısının zirveleri ile Domaniç Dađlarının zirvelerinden alan İnegöl İlçe Merkezi'nin kuzeyinde Kocaçay'a katılan Akçasu Deresi Havzası 227,8 km<sup>2</sup> yüzölçümüne sahiptir. Akçasu Deresi'nin toplam uzunluđu 396,4 km olup bunun 95,7 km'si sürekli, 300,7 km'si ise mevsimlik akarsu niteliğindedir. Akarsu, yukarı ve orta çığırında genel olarak kuzeydođu-güneybatı (NE-SW), ařađı çığırında ise kuzey-güney (N-S) dođrultusunda uzanım göstermektedir. Havzada yükselti özellikleri

2045 m ile 265 m arasında deđişiklik göstermektedir.

Havzanın jeolojik özelliklerini deđerlendirdiđimizde Paleozoik yařlı řistler İclaliye ve Çayyaka kırsal mahallelerinin güneyinde Hamidiye Kırsal Mahallesi'nin batısında yer almaktadır. Jura-Kretase yařlı mermerler Hamidiye Kırsal Mahallesi'nin batısında Paleozoik yařlı řistlerin içinde merceler halinde, havzanın doğusunda ve güneydoğusunda yer almaktadır. Üst Kretase yařlı Metakırıntılılar ve Metakarbonatlar havzanın doğusunda ve batısında Oligosen yařlı granit ve granodiyoritlerin sınırında yer almaktadır. Oligosen yařlı granit ve granodiyoritler havzanın yukarı çığırında çok geniř bir alanda yayılıř göstermektedir. Miyosen yařlı kireçtařı-marn-kil-kum-konglomera depoları havzanın orta çığırında çok geniř bir alanda yayılıř gösterir. Üst Miyosen yařlı gösel karbonatlar Miyosen yařlı kireçtařı-marn-kil-kum-konglomera depoları içinde merceler halinde yer almaktadır. Kuvaterner yařlı alüvyonlar ise havzanın kuzeyinde yer almaktadır (Şekil 5a). Havzadaki tektonik hatlar genel olarak NW-SE yönünde uzanıř göstermektedir (Şekil 4c).

Akçasu Deresi Havzası'nda eđim kořulları genel olarak havzanın yukarı ve orta çığırında akarsu vadi yamaçlarında yüksek deđerler gösterirken ařađı çığırında İnegöl Ovası'nın bulunduđu kesimlerde düşük deđerler göstermektedir (Şekil 4a). Eski toprak taksonomisine göre havzada İnegöl Ovası'nın bulunduđu kesimde alüvyal topraklar, havzanın orta çığırında alüvyal topraklar ile kireçsiz kahverengi orman toprakları arasında kahverengi orman toprakları, havzanın yukarı çığırında kireçsiz kahverengi orman toprakları ve Deydinler Kırsal Mahallesi'nin kuzeyinde ise kolüvyal topraklar olmak üzere dört farklı toprak türü mevcuttur (Şekil 5d).

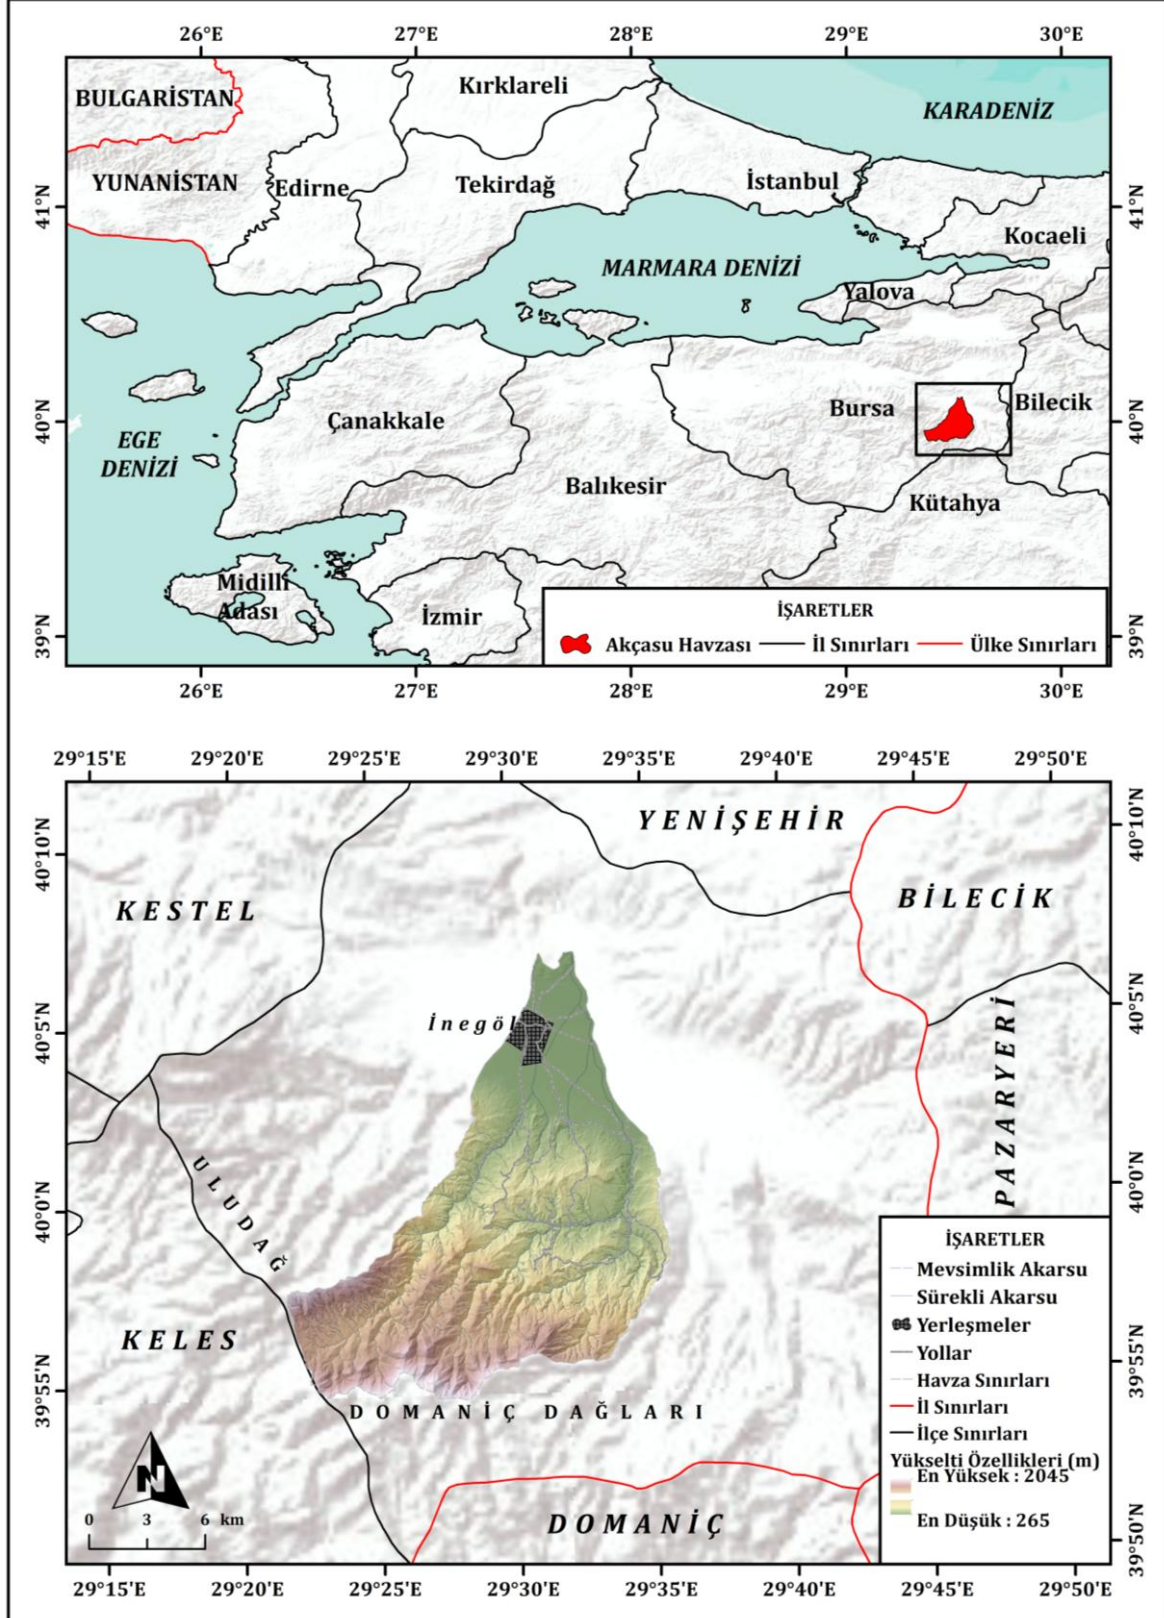
İnceleme alanı Marmara Geçiř İklimi'nin etkisi altındadır. Yıllık ortalama sıcaklıklar 13,8 °C'dir. Yıllık ortalama en yüksek sıcaklıklar 23,5 °C ile Ađustos ayında, yıllık ortalama en düşük sıcaklıklar ise 3,6 °C ile Ocak ayında gözlemlenmektedir. Yıllık toplam yađıř miktarı ise 568,6 mm'dir. En az yađıř 13,4 mm ile Ađustos ayında gözlemlenmektedir. En fazla

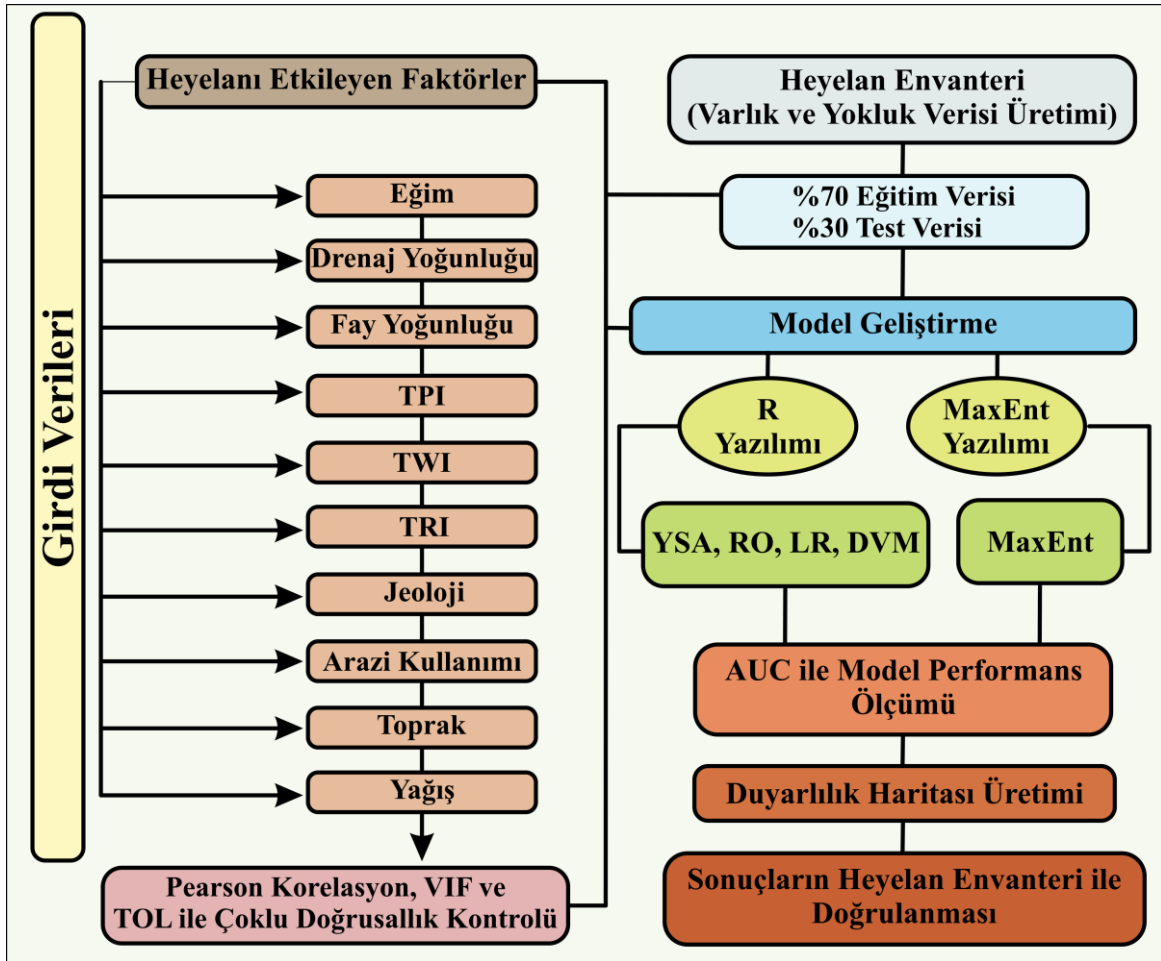
yağış ise 80,4 mm ile Haziran ayında gözlemlenmektedir (MGM, 2022).

## 2. MATERYAL VE YÖNTEM

Çalışmada izlenen metodoloji; heyelanı etkileyen çevresel faktörlerin temini, veri ön

işleme, çoklu doğrusal analizleri, eğitim-test veri setlerinin oluşturulması, farklı makine öğrenmesi algoritmaları ile model geliştirme, AUC (Area Under the Curve) tabanlı performans değerlendirmesi ve sonuçların envanter verisi ile doğrulanması aşamalarını kapsamakta olup, tüm süreç Şekil 2'te özetlenmiştir.





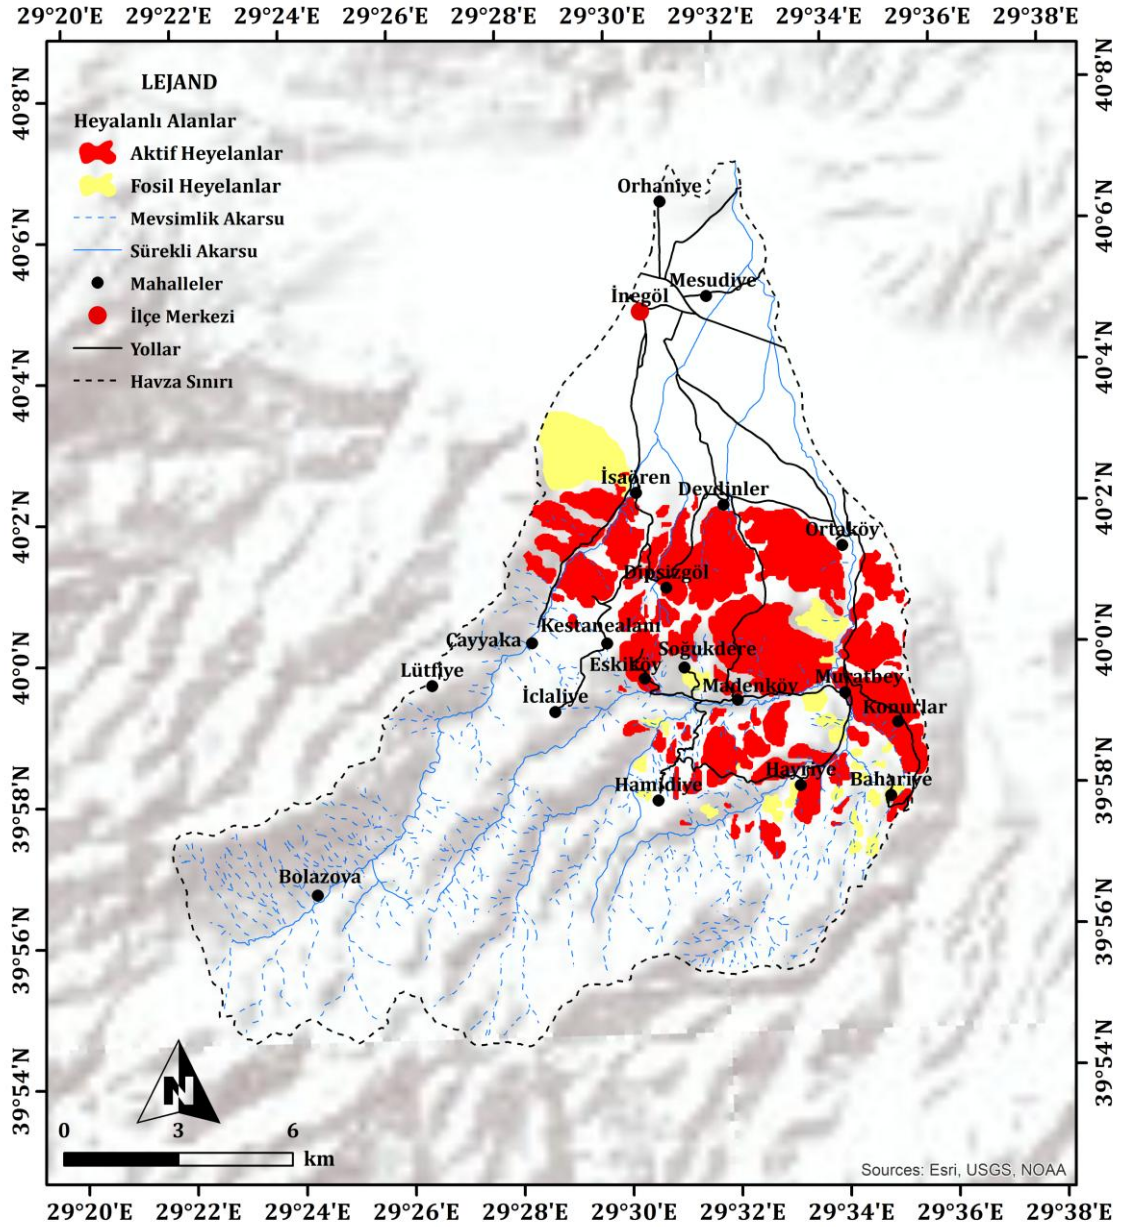
**Şekil 2:** Heyelan duyarlılık modellemesine ait veri ve yöntem sürecinin genel iş akışı / **Figure 2:** General workflow of the data and methodological process for landslide susceptibility modeling.

## 2.1. Veri

### 2.1.1. Kullanılan Veriler

Bu çalışmada kullanılan heyelan envanteri, Maden Tetkik ve Arama (MTA) Genel Müdürlüğü tarafından hazırlanan ve çevrimiçi olarak erişilebilen 1:100.000 ölçekli çizim editörü kullanılarak hazırlanmıştır (<https://yerbilimleri.mta.gov.tr/>). Heyelan envanteri, farklı dönemlerde meydana gelmiş eski (fosil) heyelanlar ile güncel olarak aktif durumda bulunan heyelanları kapsamaktadır (Şekil 3). Jeolojik veriler ve fay hatları, MTA tarafından hazırlanan 1:25.000 ölçekli jeoloji haritaları temel alınarak oluşturulmuştur. Toprak haritası, Köy Hizmetleri Genel Müdürlüğü'nden temin edilen 1:25.000 ölçekli toprak verileri kullanılarak üretilmiştir. Çalışmada kullanılan sayısal yükseklik modeli (SYM), 10 m aralıklarla çizilmiş izohipslerden türetilmiş olup, türetilen bu model yardımıyla da eğim, topografik nemlilik indeksi (TWI), topografik pozisyon indeksi (TPI) ve topografik

pürüzlülük indeksi (TRI) Coğrafi Bilgi Sistemleri (CBS) ortamında hesaplanmıştır. Akarsu verileri, çalışma alanına ilişkin 1:25.000 ölçekli topografya haritalarından manuel olarak sayısallaştırılmıştır. Arazi kullanım verileri CORINE 2018 veri setinden (<https://land.copernicus.eu/pan-european/corine-land-cover>), yağış verileri ise Meteoroloji Genel Müdürlüğü'nden temin edilmiştir (MGM 2022). Aylık ortalama toplam yağış verileri temel alınarak, yağışın yükselti arttıkça her 100 metrede 54 mm değiştiğini varsayan "Schreiber Formülü" (Schreiber, 1904) kullanılmış ve bu doğrultuda yağış değerleri sahaya enterpole edilerek haritalanmıştır. Buna bağlı olarak yağış verisi kategorik bir değişken olarak değerlendirilmiştir. Tüm veriler, mekânsal uyumluluk ve karşılaştırılabilirliğin sağlanabilmesi için UTM WGS84 koordinat sistemine dönüştürülmüş ve 10 m × 10 m hücre boyutunda ortak bir raster yapısına getirilerek analizlere hazır hale getirilmiştir.

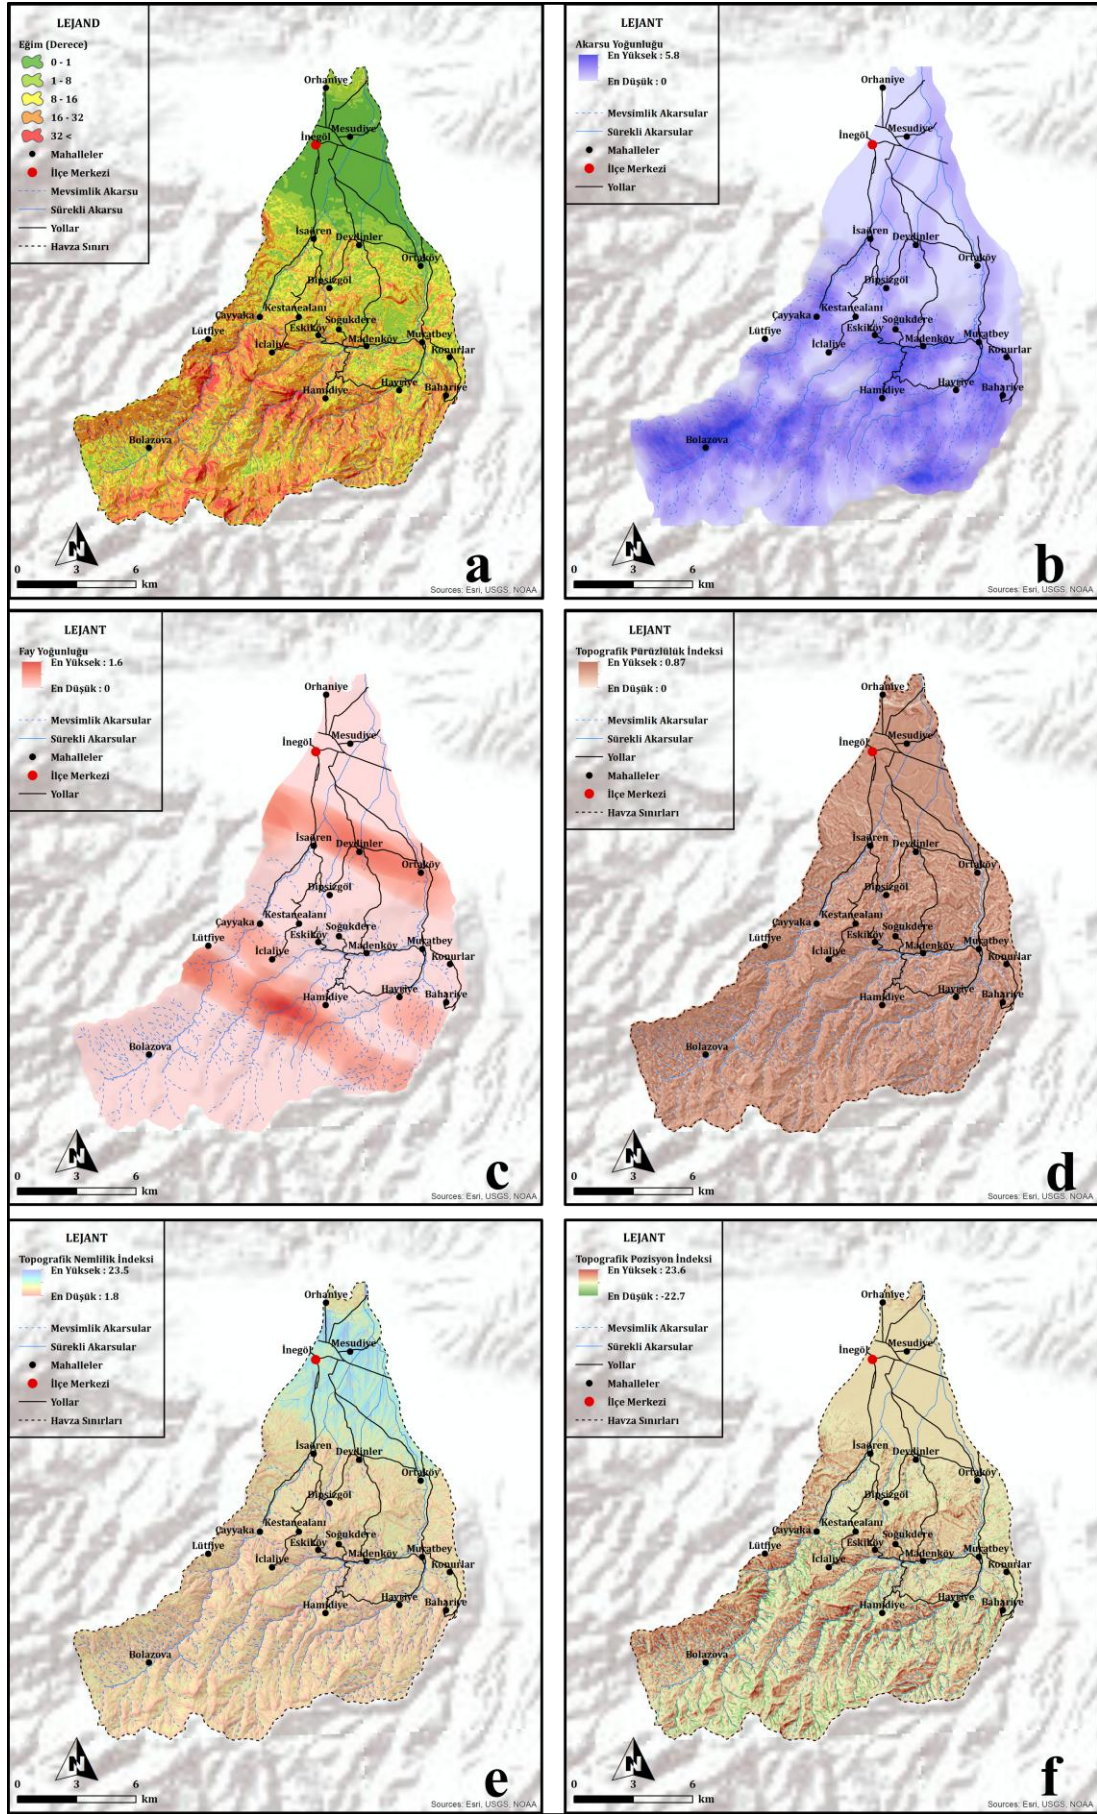


**Şekil 3:** Çalışmada kullanılan heyelan envanteri / **Figure 3:** Landslide inventory used in the study.

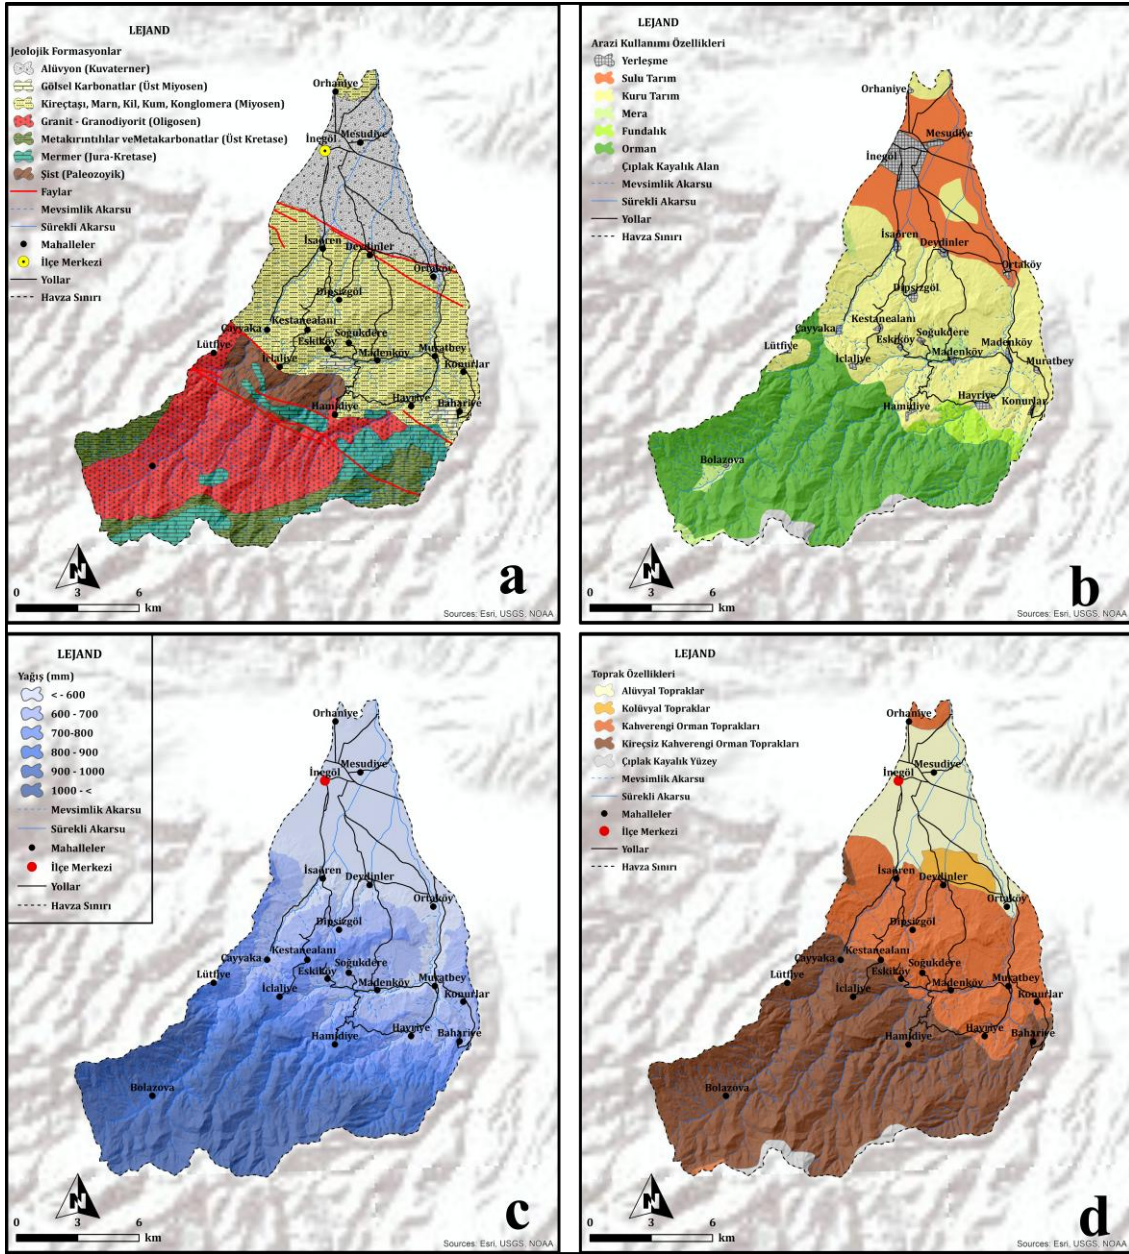
### 2.1.2. Heyelanı Etkileyen Faktörler

Heyelan duyarlılık modellemesinin en kritik aşamalarından biri, modelin tahmin doğruluğunu doğrudan belirleyen bağımsız değişkenlerin seçimidir. Literatürde bu değişkenlerin belirlenmesi için uluslararası düzeyde kabul görmüş standart bir metodoloji bulunmamaktadır (Reichenbach vd., 2018). Bu bağlamda, çalışmada kullanılacak faktörler; çalışma sahasının jeolojik ve jeomorfolojik karakteristikleri, veri temini olanakları ve değişkenlerin heyelan mekanizmalarıyla olan fiziksel ilişkisi gibi çoklu kriterler göz önünde bulundurulurken belirlenmiştir. Bu seçim süreci, ayrıca kapsamlı bir literatür taraması ve arazi gözlemleriyle de desteklenmiştir.

Heyelanı etkileyen faktörler literatürde genellikle iki ana veri tipinde ele alınmaktadır: sürekli ve kategorik değişkenler (Chowdhuri vd., 2021). Sürekli değişkenler sayısal değerleriyle doğrudan modellemeye dahil edilirken, kategorik değişkenler ise sınıflar arasındaki tematik farklılıkları ortaya koymaktadır. Makine öğrenimi tabanlı yöntemlerde her iki veri tipinin birlikte kullanılabilmesi, modelin mekânsal ve tematik çeşitliliği yansıtmaya gücünü artırmaktadır. Bu çalışmada heyelan oluşumunu etkileyen 10 bağımsız değişken kullanılmıştır. Bunlardan sürekli veri olarak eğim, drenaj yoğunluğu, fay yoğunluğu, TPI, TWI ve TRI (Şekil 4); kategorik veri olarak ise jeolojik formasyonlar, arazi kullanımı, toprak ve yağış değişkenleri dikkate alınmıştır (Şekil 5).



**Şekil 4:** Makine öğrenimi sürecinde kullanılan heyelanı etkileyen sürekli değişkenlerin ((a) eğim, (b) drenaj yoğunluğu, (c) fay yoğunluğu, (d) TPI, (e) TWI ve (f) TRI) çalışma alanındaki mekânsal dağılımı / **Figure 4:** Spatial distribution of the continuous variables influencing landslides ((a) slope, (b) drainage density, (c) fault density, (d) TPI, (e) TWI, and (f) TRI) used in the machine learning process.



**Şekil 5:** Makine öğrenimi sürecinde kullanılan heyelanı etkileyen kategorik değişkenlerin (a) jeoloji, (b) arazi kullanımı, (c) yağış ve (d) toprak çalışma alanındaki mekânsal dağılımı / **Figure 5:** Spatial distribution of the categorical variables influencing landslides (a) geology, (b) land use, (c) precipitation and (d) soil used in the machine learning process.

## 2.2. Yöntem

### 2.2.1. Çoklu Doğrusallık (Multicollinearity) Analizi

Bağımsız değişkenler arasındaki ilişkiler Pearson Korelasyon Katsayısı ( $r$ ) ile incelenmiş ve  $|r| \geq 0,7$  değerleri yüksek korelasyon eşiği olarak belirlenmiştir (Habumugisha vd., 2022; Ma, Shao ve Xu, 2023). Bu yaklaşım, değişkenler arası yüksek bağımlılığın model performansını bozmasını önleyerek çoklu bağlantı (multicollinearity) sorunlarını minimize etmek ve modelin istatistiksel güvenilirliğini korumak amacıyla uygulanmıştır (Zhao vd., 2022). Ayrıca, çoklu bağlantı sorununun daha kapsamlı

değerlendirilmesi amacıyla Varyans Şişirme Faktörü (VIF) ve Tolerans (TOL) değerleri hesaplanmış, VIF değerinin 10'dan küçük ve TOL değerinin 0,1'den büyük olması ölçütleri esas alınmıştır (Chen vd., 2019).

### 2.1.2. Makine Öğrenmesi

Çalışmada makine öğrenmesi süreci iki farklı ortamda yürütülmüştür. Yapay sinir ağları, rastgele orman, lojistik regresyon ve destek vektör makinesi modelleri R yazılımı ortamında çeşitli paketler aracılığıyla uygulanırken; maksimum entropi (MaxEnt) analizi MaxEnt 3.4.4 yazılımı (<https://biodiversityinformatics.amnh.org/open>

\_source/maxent/) kullanılarak gerekleřtirilmiřtir. Her iki ortamda yrtlen modelleme srecinde, temel girdi olan varlık verilerinin elde edilmesinde heyelan envanterinden yararlanılmıřtır. Bu kapsamda, envanterde kayıtlı heyelan poligonları nokta verisine dnřtrlmř ve varlık verisi olarak kullanılmıřtır. Varlık noktaları, her bir heyelan poligonunun orta noktası esas alınarak oluřturulmuřtur. Yokluk verilerinin oluřturulmasında ise farklı yntemler izlenmiřtir: MaxEnt yazılımı, algoritmasının alıřma prensibi geređi varlık noktaları dıřındaki alanlardan otomatik olarak yokluk (arka plan/pseudo-absence) verisi retirken; R ortamında uygulanan modeller iin alıřma alanı sınırları ierisinde rastgele dađılım gsteren yokluk verileri uygun kodlar aracılıđıyla retilmiřtir. Tm modellerin performanslarının gvenilir řekilde deđerlendirilebilmesi amacıyla veri setleri %70 eđitim ve %30 test olacak řekilde ikiye ayrılmıřtır (Pham vd., 2019). Bu ayırım, modellerin bir blm veriden renmesini, geri kalan bađımsız veri ile de dođruluklarının sınanmasını sađlayarak ařırı uyum (overfitting) riskini azaltmakta ve tahmin gcnn nesnel biimde llmesine olanak tanımaktadır. Elde edilen heyelan duyarlılık modellerinin sonuları, modellerin birbiriyle karřılařtırılabilmesi amacıyla eřit aralıklar (Equal Interval) kullanılarak sınıflandırılmıřtır. Ayrıca tm heyelan duyarlılık modelleri heyelan envanteri ile CBS ortamında meknsal olarak rtřtrlerek analiz edilmiř ve modellerin ngr gc ile tutarlılık dzeyleri deđerlendirilmiřtir.

### 2.1.2.1. Yapay Sinir Ađları (YSA)

Yapay Sinir Ađları (YSA), biyolojik sinir sistemlerinin alıřma prensibinden esinlenerek geliřtirilen, ok katmanlı ve dđmler arası bađlantılara dayalı bir hesaplama modelidir (Huqqani, Tay ve Mohamad-Saleh, 2023). Karmařık ve dođrusal olmayan iliřkileri yakalama kapasitesi nedeniyle heyelan duyarlılık analizlerinde etkin olarak kullanılmaktadır (Uzun, 2025). Bu alıřmada, R ortamında "neuralnet" paketi (Fritsch vd., 2019) ile ileri beslemeli (feedforward) MLP (Multi-Layer Perceptron) mimarisi uygulanmıřtır (Harmouzi vd., 2019). Oluřturulan

YSA modeli iki gizli katmandan oluřmakta olup, ilk gizli katmanda 5 nron, ikinci gizli katmanda ise 3 nron kullanılmıřtır.

### 2.1.2.2. Rastgele Orman (RO)

Rastgele Orman (RO), ok sayıda karar ađacını bir araya getirerek tahmin yapan, bir makine renimi yntemidir (Lu vd., 2024). Veri setlerini hızlı bir řekilde iřleyebilmesi, kullanıcıya esnek ayar seenekleri sunabilmesi ve farklı veri trleriyle uyumlu alıřabilmesi gibi zellikleri sayesinde RO, eřitli disiplinlerde yaygın olarak kullanılmakta ve heyelan duyarlılık alıřmalarında da tercih edilmektedir (Kavzoglu ve Teke, 2022). alıřma kapsamında retilen RO modeli "randomForest" paketi yardımıyla oluřturulmuřtur (Breiman vd., 2024). Modelde ađa sayısı 500 olarak belirlenmiřtir.

### 2.1.2.3. Lojistik Regresyon (LR)

Lojistik regresyon (LR), parametrik bir istatistiksel yntem olup, olasılık temelli zmler retme kapasitesi sayesinde sınıflandırma problemlerinde yaygın olarak kullanılmaktadır. Heyelan duyarlılık analizlerinde, bađımlı deđerlenin (heyelan var/yok) ikili yapısı nedeniyle zellikle ikili lojistik regresyon modelleri tercih edilmektedir. Bununla birlikte, ikili lojistik regresyon modelleri, veri setlerinde sıklıkla karřılařılan tam (complete) veya yarı-tam (quasi-complete) ayrıřma sorunlarına duyarlıdır. Bu tr ayrıřma durumları, tahmin edilen katsayıların sonsuz deđerlere yaklařmasına ve dolayısıyla model sonularında yanlılık (bias) oluřmasına neden olabilmektedir. Bu alıřmada sz konusu etkinin en aza indirilmesi amacıyla, "brglm2" paketinde yer alan yanlılık azaltma (bias-reduction) yaklařımı uygulanmıřtır (Kosmidis vd., 2025). Bu yntem, zellikle heyelan gibi meknsal verilerde ortaya ıkabilen dengesiz sınıf dađılımlarında daha gvenilir ve istikrarlı parametre tahminleri elde edilmesine olanak sađlamaktadır. Bylece, lojistik regresyon modelinden elde edilen heyelan duyarlılık tahminlerinin istatistiksel olarak daha sađlam bir řekilde yorumlanması mmkn hale gelmiřtir.

### 2.1.2.4. Destek Vektr Makinesi (DVM)

Gzetimli bir makine renmesi tekniđi olan Destek Vektr Makinesi (DVM), renme teorisine ve optimizasyon teorisine

dayanmaktadır (Chen vd., 2017). Parametre ayarlamalarına olanak tanınması ve farklı veri tipleriyle uyumlu çalışabilmesi, yöntemi çevresel tehlike analizleri ve heyelan duyarlılık modellemeleri gibi uygulamalarda etkili kılmaktadır. DVM modeli, 'e010711' paketi (Mayer vd., 2024) kullanılarak oluşturulmuş ve bu model, heyelan varlığı ve yokluğunu temsil eden iki sınıfı ayırmak amacıyla C-sınıflandırma yaklaşımını temel alan Destek Vektör Makinesi ile uygulanmıştır; karmaşık ve doğrusal olmayan ilişkileri yakalayabilmek için ise modelde Radial Tabanlı (RBF) çekirdek fonksiyonu kullanılmıştır (He vd., 2025). Model parametreleri paket tarafından önerilen varsayılan (default) değerlerde kullanılmıştır.

#### 2.1.2.5. Maksimum Entropi (MaxEnt)

Maksimum entropi (MaxEnt) yöntemi, çoğunlukla, tür dağılımı ve ekolojik niş modelleme çalışmalarında kullanılmakla birlikte (Phillips, Anderson ve Schapire, 2006), heyelan duyarlılık analizleri gibi çevresel tehlike modellemelerinde de kullanılmaktadır (Javidan vd., 2021). Modelleme sürecinde MaxEnt yazılımı kullanılarak subsample yöntemi ile 15 tekrarlı modelleme gerçekleştirilmiş; çıktı formatı olarak "Cloglog" seçilmiş ve tüm modeller otomatik özellikler (auto features) ile üretilmiştir. Analizlerde rastgelelik kontrolü sağlamak amacıyla random seed aktif edilmiştir ve maksimum iterasyon sayısı 1000 olarak belirlenmiştir. Üretilen modeller arasında en yüksek performans gösteren model, çalışmada tek bir heyelan duyarlılık haritasının oluşturulmasında kullanılmıştır.

#### 2.1.3. Model Performans Değerlendirmesi

Makine öğrenmesi yöntemleriyle oluşturulan heyelan duyarlılık modellerinin performansını değerlendirmek için ROC (Receiver Operating Characteristic) eğrisi altında kalan alan, yani AUC (Area Under the Curve) ölçütü kullanılmıştır (Tien Bui vd., 2019). AUC, modelin ayırt etme gücünü nicel olarak ifade eden bir istatistiktir. Genel kabul gören sınıflandırmaya göre; 0.5-0.6; düşük, 0.6-0.7; orta, 0.7-0.8; iyi, 0.8-0.9; çok iyi ve 0.9-1.0 ise modelin mükemmel performans gösterdiğini belirtmektedir. AUC değerinin

yükselmesi, modelin sınıfları daha doğru bir şekilde ayırabildiğini ifade ederken; 1.0 değeri teorik olarak kusursuz sınıflandırmayı işaret etmektedir (Chen vd., 2018).

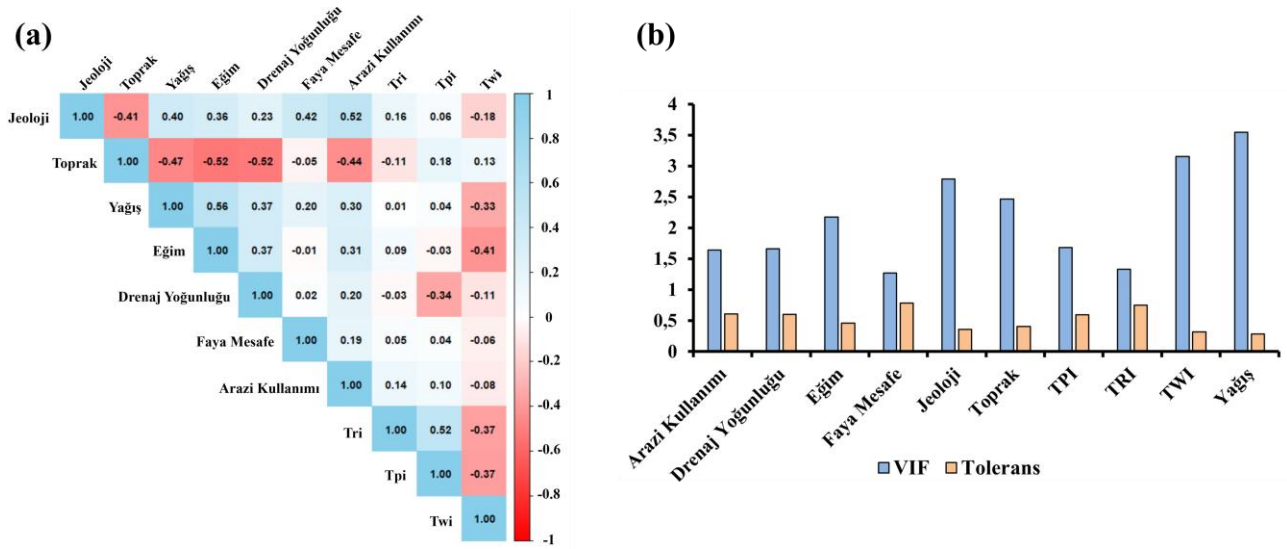
### 3. BULGULAR

#### 3.1. Çoklu Doğrusallık ve Model Performans Değerlendirmesi


Pearson korelasyon analizi sonuçlarına göre (Şekil 6a), çalışmada kullanılan bağımsız değişkenler arasında genellikle düşük ve orta düzeyde ilişkiler bulunmaktadır. En yüksek pozitif korelasyon arazi kullanımı ile jeoloji ( $r=0.52$ ) arasında, en yüksek negatif korelasyon ise toprak ile eğim ve toprak ile drenaj yoğunluğu ( $r=-0.52$ ) arasında tespit edilmiştir. Bu değerler, güçlü bir çoklu bağlantı sorununa işaret etmemekte olup, değişkenlerin modelleme sürecine bağımsız katkılar sunabileceğini göstermektedir. Ayrıca, çoklu doğrusal bağlantının daha ayrıntılı değerlendirilmesi ve doğruluğun sınanması amacıyla hesaplanan Varyans Şişirme Faktörü (VIF) ve Tolerans (TOL) değerleri incelendiğinde, tüm değişkenlere ait VIF değerlerinin kabul edilebilir eşik değeri olan 10'un oldukça altında, TOL değerlerinin ise 0.1'in üzerinde olduğu belirlenmiştir (Şekil 6b). Bu sonuçlar, modelde çoklu bağlantı sorunu bulunmadığını ve bağımsız değişkenlerin modelleme sürecinde güvenle kullanılabilirliğini doğrulamaktadır.

#### 3.2. Duyarlılık Sınıflarının Mekânsal Dağılımı

Çalışmada kullanılan beş farklı makine öğrenmesi algoritması (YSA, RO, LR, DVM, MaxEnt) ile elde edilen heyelan duyarlılık haritaları (Şekil 8), çalışma alanındaki duyarlılık bölgelerinin mekânsal dağılımını detaylı bir biçimde ortaya koymuştur. Tüm modellerde duyarlılık, Düşük, Orta, Yüksek ve Çok Yüksek olmak üzere dört sınıfta kategorize edilmiştir. Haritalar genel mekânsal eğilimler bakımından benzerlik gösterse de özellikle Yüksek ve Çok Yüksek Duyarlılık sınıflarının alansal dağılımı ve yoğunluğu açısından belirgin farklılıklar ortaya çıkmıştır.



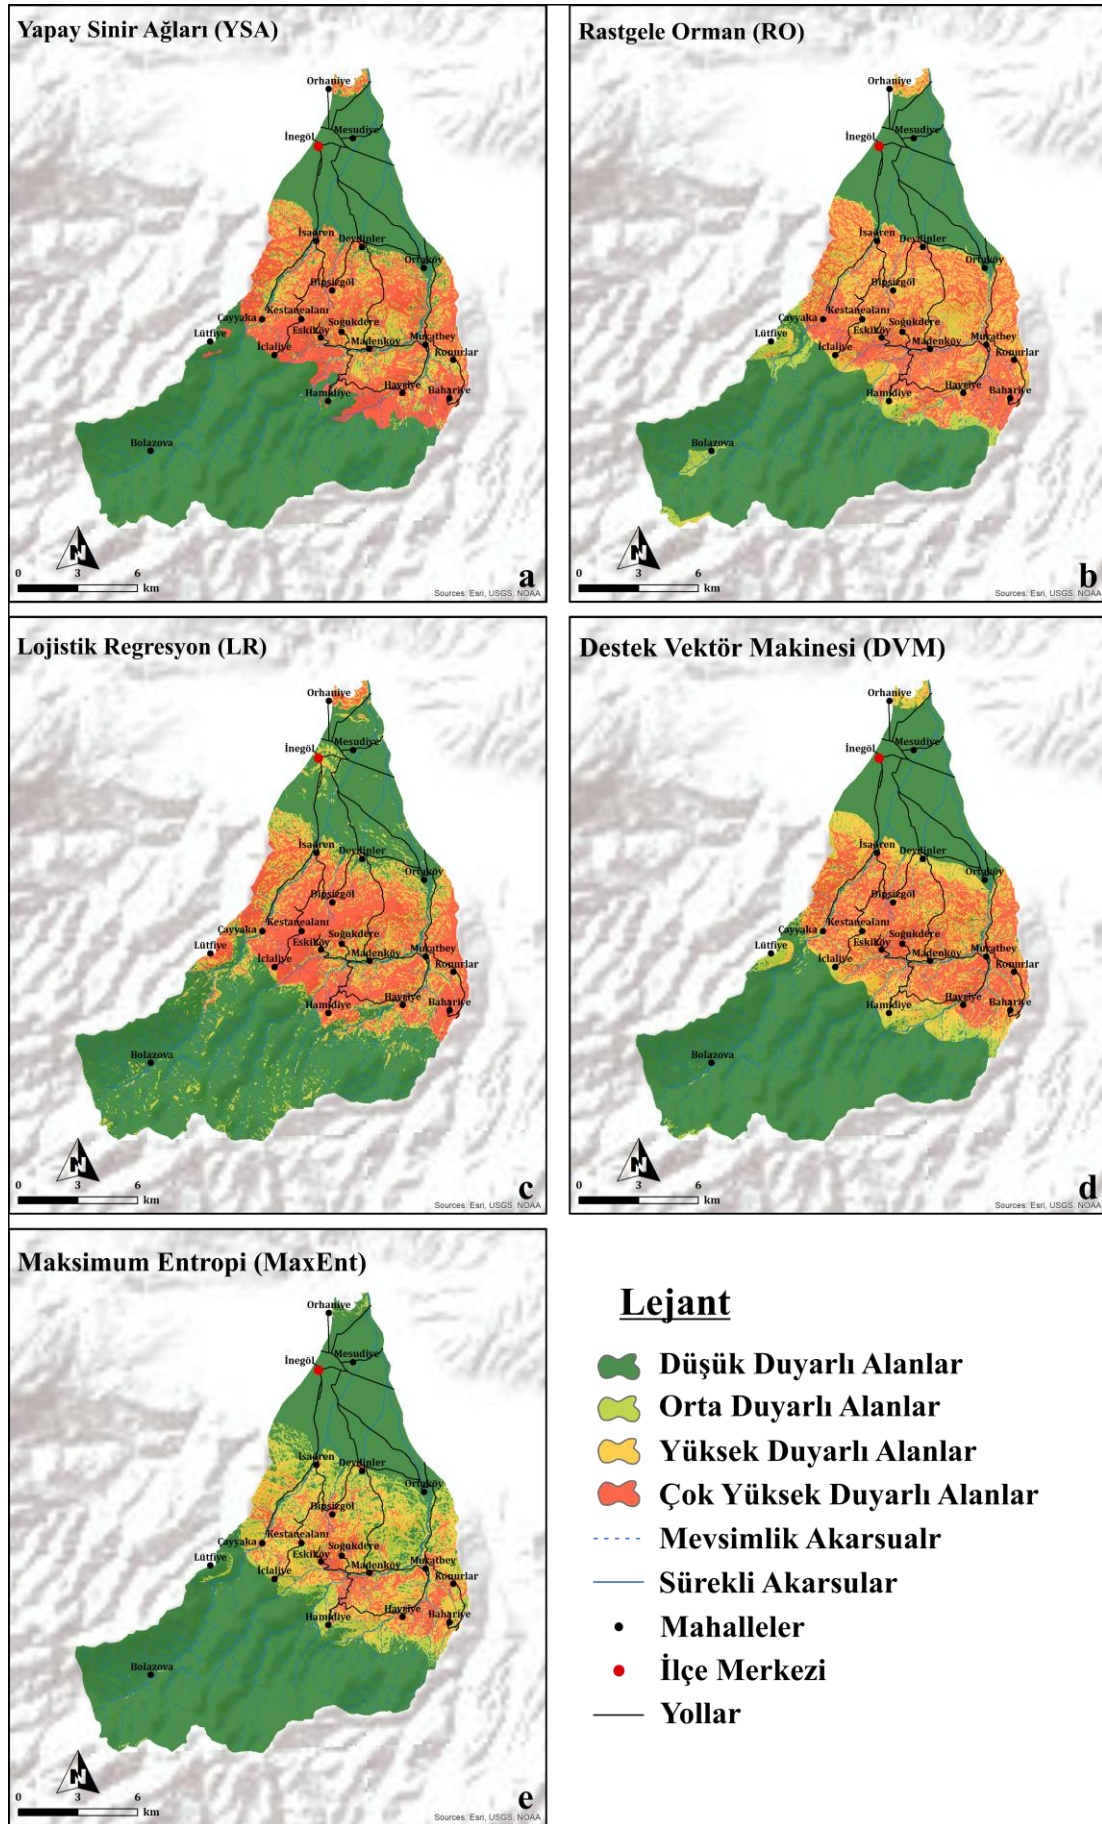
**Şekil 6:** Pearson korelasyon analizi sonuçları (a) ile VIF ve Tolerans analizi sonuçları (b) / **Figure 6:** Results of the Pearson correlation analysis (a) and the VIF and Tolerance analysis (b).



**Şekil 7:** Modellerin performans (AUC) deęerleri / **Figure 7:** Performance (AUC) values of the models.

Modellerin mevcut heyelan alanlarını ne kadar doğru bir şekilde yansıttığını ve kullanılabilirliğini deęerlendirmek amacıyla, her bir modelin duyarlılık haritası mevcut heyelan envanteri ile karşılaştırılmıştır. Bu analiz, modellerin istatistiksel başarısından bağımsız bir yaklaşımla, geçmişteki heyelanların farklı duyarlılık sınıflarındaki (Düşük, Orta, Yüksek, Çok Yüksek) dağılım oranlarını ortaya koyarak modelin tahmin başarısını ölçen temel yöntemdir. Analiz sonuçları (Tablo 1) incelendiğinde, modellerin heyelanları Yüksek ve Çok Yüksek Duyarlılık sınıflarında konumlandırma performansları bakımından belirgin farklılık gösterdiği görülmektedir: RO

modeli, mevcut heyelanlarla en yüksek örtüşme oranını sağlamıştır. RO modeli, Yüksek Duyarlılık (%42.1) ve Çok Yüksek Duyarlılık (%47.1) sınıflarının toplamı ile, bilinen heyelan alanlarının yaklaşık %89.2'sini kapsayarak, modeller arasında en üstün mekânsal başarıyı sunmuştur. Bu modeli, Yüksek (%35.4) ve Çok Yüksek (%48.1) Duyarlılık sınıflarının toplamıyla heyelanların %83.5'ini kapsayan DVM modeli takip etmiştir. Diğer modellerin kritik duyarlılık sınıflarındaki toplam kapsama oranları ise sırasıyla LR için %79.5 (%24.6 + %54.9), YSA için %77.4 (%27.7 + %49.7) ve MaxEnt için belirgin derecede düşük bir oran olan %46.9 (%31.1 + %15.8) olarak hesaplanmıştır.



**Şekil 8:** Farklı makine öğrenmesi yöntemlerine göre Akçasu Havzasının heyelan duyarlılığı. a; Yapay sinir ağları, b; Rastgele orman, c; Lojistik regresyon, d; Destek vektör makinesi, e; Maksimum entropi (MaxEnt) / **Figure 6:** Landslide susceptibility of the Akçasu Basin according to different machine learning methods. a; Artificial Neural Networks, b; Random Forest, c; Logistic Regression, d; Support Vector Machines, e; Maximum Entropy (MaxEnt).

Bu bulgular, YSA modelinin ROC eğrisi (AUC=0.949) ile en yüksek istatistiksel sınıflandırma başarısını göstermesine karşın, RO modelinin mevcut heyelanları 'Yüksek' ve 'Çok Yüksek Duyarlılık' alanlarında kapsama oranı bakımından en üstün performansı sergilediğini ortaya koymaktadır. Bu durum, modelin istatistiksel geçerliliği (AUC) ile mekânsal başarısının doğrudan bir ilişki içinde olmadığını ve her iki performans ölçütünün de bilimsel değerlendirmede birlikte ele alınması gerektiğini göstermektedir. Özellikle MaxEnt modelinin kritik duyarlılık sınıflarındaki toplam kapsama oranının belirgin şekilde düşük olması (%46.9), modelin çalışma alanı özelinde diğer modellere kıyasla heyelanlı alanları tahmin etmede görece düşük bir mekânsal başarı sergilediğini ortaya koymaktadır. Bu değerlendirmeler sonucunda, RO ve DVM gibi modellerin, heyelan alanlarının büyük bir çoğunluğunu Yüksek ve Çok Yüksek Duyarlılık sınıflarında toplayarak, bu çalışma için pratik uygulamada ve arazi kullanım planlamasında daha güvenilir haritaları ürettiği sonucuna varılmıştır (Tablo 1).

Tüm modellerin çıktıları incelendiğinde (Şekil 8), Yüksek Duyarlılık ve Çok Yüksek Duyarlılık sınıflarının genel olarak akarsu havzasının orta çığırında; drenaj yoğunluğunun yüksek olduğu, miyosen kireçtaşı, marn, kil, kum ve konglomera

formasyonlarının bulunduğu ve beşeri faaliyetlerin yoğun olarak sürdürüldüğü alanlarda yoğunlaştığı gözlemlenmektedir. Bu durum, gerçekleştirilen saha gözlemlerinde de açık bir şekilde doğrulanmıştır. Bununla birlikte, modellerin ürettiği değişken katkı değerleri bu bulguları nicel olarak desteklemektedir. Örneğin, MaxEnt modelinin standart çıktılarından biri olan değişken katkı yüzdeleri incelendiğinde, jeolojik formasyonlar %55,5 katkı oranı ile model performansına en fazla katkı sağlayan değişken olarak belirlenmiştir. Ayrıca, aynı model kapsamında gerçekleştirilen Jackknife testi sonuçlarına göre, tek başına kullanıldığında en yüksek kazanç değerini sağlayan değişkenin jeoloji olduğu, dolayısıyla bu değişkenin heyelan oluşumunu açıklamada tek başına en yüksek bilgi içeriğine sahip olduğu anlaşılmaktadır. Öte yandan, modelden çıkarıldığında kazanç değerinde en fazla azalmaya neden olan değişkenin arazi kullanımı olduğu belirlenmiş olup, bu durum arazi kullanımının diğer değişkenler tarafından temsil edilmeyen özgün ve tamamlayıcı bilgiler içerdiğini göstermektedir. Bu sonuçlar, yüksek duyarlılık sınıflarının özellikle belirli jeolojik formasyonlar ve yoğun beşeri faaliyetlerin bulunduğu alanlarda yoğunlaşmasının yalnızca görsel yorumlara değil, aynı zamanda model tabanlı nicel değerlendirmelere de dayandığını ortaya koymaktadır.

**Tablo 1: Model Çıktıları ile Mevcut Heyelanların Çakışma Oranları (%) / Table 1: Overlay Ratios (%) of Existing Landslides with Model Outputs.**

| Heyelan Duyarlılığı   | RO (%) | DVM (%) | LR (%) | YSA (%) | Maxent (%) |
|-----------------------|--------|---------|--------|---------|------------|
| Düşük Duyarlılık      | 0.2    | 4.8     | 7.1    | 9.7     | 18.4       |
| Orta Duyarlılık       | 10.7   | 11.7    | 13.3   | 12.9    | 34.7       |
| Yüksek Duyarlılık     | 42.1   | 35.4    | 24.6   | 27.7    | 31.1       |
| Çok Yüksek Duyarlılık | 47.1   | 48.1    | 54.9   | 49.7    | 15.8       |

#### 4. TARTIŞMA, SONUÇ VE ÖNERİLER

Bu çalışmada, Akçasu Deresi Havzası'nın heyelan duyarlılığı RO, DVM, LR, YSA ve MaxEnt makine öğrenmesi algoritmaları kullanılarak mekânsal olarak analiz edilmiş ve heyelan duyarlılık haritaları üretilmiştir. Modelleme sürecinde 10 farklı bağımsız değişken kullanılmıştır. Oluşturulan heyelan duyarlılık haritaları düşük, orta, yüksek ve çok yüksek olmak üzere dört sınıfa ayrılmıştır. Elde edilen

model çıktıları, heyelan envanter haritası ve AFAD istatistiksel verileri ile karşılaştırılarak; üretilen haritaların sahadaki gerçek kütle hareketleri ile olan ilişkisi nicel olarak ortaya konulmuştur. Modellerin performans değerleri incelendiğinde; istatistiksel açıdan en yüksek başarıyı YSA (AUC=0.949) modeli gösterirken, gerçek heyelanlar ile yapılan karşılaştırma analizi sonucunda mekânsal doğruluk oranı

bakımından en yüksek performansı ise RO modeli (%89.2) göstermiştir.

Bu çalışmada geliştirilen modellerin istatistiksel performansları karşılaştırıldığında, en düşük başarı düzeyinin MaxEnt algoritması ile elde edilen modelde gerçekleştiği belirlenmiştir. Benzer şekilde, önceki arařtırmalarda da MaxEnt modelinin diğer makine öğrenmesi yöntemlerine kıyasla görece daha düşük performans değerleri sunduğu rapor edilmiştir (Chen vd., 2017; Pandey, Pourghasemi ve Sharma, 2020; Shahzad, Ding ve Abbas, 2022; Hossain vd., 2025). Bu bulgu, yöntemler arasındaki performans farklılıklarının tek başına algoritmaya atfedilemeyeceğini ve sonuçların çalışma alanına ve kullanılan veri setinin özelliklerine göre değerlendirilmesi gerektiğini göstermektedir. Makine öğrenmesi algoritmalarının başarı düzeyleri incelendiğinde, literatürde tek bir yöntemin her koşulda üstünlük sağladığına dair tutarlı bir bulgu bulunmamaktadır. Aksine, model performanslarının kullanılan veri setinin özelliklerine, örneklem dağılımına, değişken seçimine ve çalışma alanının jeolojik, jeomorfolojik ve diğer çevresel karakteristiklerine bağlı olarak farklılaştığı görülmektedir. Örneğin Çin’de gerçekleştirilen bir arařtırmada RO modeli en yüksek tahmin doğruluğunu (AUC=0,92) sağlarken DVM modelinin daha düşük performans gösterdiği (AUC=0,82) bildirilmiştir (Ma vd., 2026). Buna karşılık, Hindistan’ın Uttarakhand bölgesinde yürütölen bir çalışmada DVM modelinin (AUC=0,950) diğer algoritmalarından daha yüksek başarı sergilediği belirlenmiştir (Pham vd., 2016). Türkiye’de Artvin-Ardanuç yöresinde gerçekleştirilen çalışmada RO modeli en yüksek performansa ulařırken (AUC=0,977), DVM ve LR modelleri bunu izlemiştir (Akıncı ve Zeybek, 2021). Benzer biçimde Arhavi-Kabisre Havzası’nda YSA modelinin en yüksek doğruluğu sağladığı (AUC=0,918), RO modelinin ise görece daha düşük kaldığı rapor edilmiştir (Orhan vd., 2022). Cezayir örneğinde ise RO algoritmasının en başarılı sonuçları verdiği belirtilmektedir (Achour ve Pourghasemi, 2020). Bu bulgular, model performansının yöntemden ziyade veri yapısı ve çalışma alanına özgü koşullarla yakından ilişkili olduğunu ve tek bir algoritmanın evrensel olarak üstün kabul

edilemeyeceğini ortaya koymaktadır. Nitekim Abdelkader ve Csámermodeller (2025) tarafından gerçekleştirilen çalışmada, modeller arası karşılaştırma sonucunda RO modelinin (AUC=0,95), aynı çalışmada kullanılan DVM (AUC=0,90) ve LR (AUC=0,88) modellerine kıyasla istatistiksel olarak daha yüksek performans sergilediği ve özellikle heyelan duyarlılığı açısından kritik alanlarda daha az yanlış sınıflandırma yaparak en güvenilir model olarak öne çıktığı ortaya konmuştur. Buna karşılık, DVM ve LR modellerinin hem yüksek riskli hem de güvenli alanlarda daha fazla yanlış sınıflandırma üretmesi, yüksek AUC değerlerinin her zaman pratik güvenilirlik ile örtüşmediğini göstermektedir.

Bu çalışmada elde edilen istatistiksel göstergeler ve mekânsal uyum analizleri birlikte ele alındığında, kullanılan modellerin heyelan duyarlılığının belirlenmesinde tutarlı ve karşılaştırılabilir sonuçlar ürettiği belirlenmiştir. RO modeli mevcut heyelan dağılımlarıyla en yüksek mekânsal örtüşmeyi sağlarken, YSA modeli sınıflandırma doğruluğu açısından öne çıkmıştır. Bu bulgular, bu çalışma kapsamında, farklı algoritmaların birlikte değerlendirilmesinin belirsizliği azaltarak daha kapsamlı mekânsal değerlendirmelerin yapılmasına olanak sağladığını ve risk yönetimi ile arazi kullanım planlaması süreçlerinde karar destek açısından katkı sunduğunu göstermektedir.

Tüm model çıktıları bütüncöl bir şekilde incelendiğinde, heyelan duyarlılığının Akçasu Deresi Havzası’nın orta çığırında yoğunlaştığı gözlemlenmektedir. Bu bölgelerin; Miyosen yaşlı kireçtaşı, marn, kil, kum ve konglomera formasyonlarından oluşan litolojik birimlerle örtüştüğü, drenaj yoğunluğunun yüksek olduğu ve aynı zamanda beşerî faaliyetlerin yoğunlaştığı alanlar olduğu tespit edilmiştir. Ayrıca aktif kütle hareketlerinin gözlemlendiği, Çayyaka, Çayyaka (Kümlük), Dipsizgöl, Hamidiye (Gençali), Hayriye, İclaliye, Kestanealanı, Konurlar, Lütfiye ve Muratbey kırsal mahalleleri de yüksek duyarlılık bölgeleri içerisinde yer almaktadır (Şekil 9, 10, 11, 12, 13, 14, 15).

İnegöl İstatistikleri Raporu incelendiğinde, hasar şiddeti bakımından Çayyaka Kırsal Mahallesi, 1989 yılında gerçekleşen kütle hareketinden etkilenen toplam 146 konut ile en

yüksek kayıp oranına sahip lokasyon olarak belirlenmiştir. Heyelan tekerrür sıklığı açısından yapılan incelemede ise Muratbey Kırsal Mahallesi, 1959 ile 2016 yılları arasında rapor edilen 6 farklı olayla frekans oranı en yüksek heyelan sahası olarak öne çıkmaktadır (Şekil 9, 10, 11, 12, 13, 14, 15). Ayrıca 2002 yılının Şubat

ve Mart aylarında Hamidiye, Hayriye, Dipsizgöl, Konurlar ve Lütfiye kırsal mahallelerinde eş zamanlı heyelan aktivitesinin kaydedilmesi, bölgedeki yerleşim alanlarının geniş ölçekli kütle hareketlerine olan duyarlılığını bilimsel olarak ortaya koymaktadır (Tablo 2).

**Tablo 2:** İnceleme alanındaki yerleşmelere ait heyelan kayıtları / **Table 2:** Landslide records of the settlements in the study area.

| Adı                       | Tarihi     | Etkilenen Konut Sayısı |
|---------------------------|------------|------------------------|
| <b>Çayyaka</b>            | 01.09.1989 | 140                    |
| <b>Çayyaka (Kümlük)</b>   | 01.09.1989 | 6                      |
| <b>Dipsizgöl</b>          | 06.01.1963 | -                      |
|                           | 05.03.1963 | 40                     |
|                           | 28.02.2002 | 1                      |
|                           | 14.04.2015 | 1                      |
| <b>Hamidiye (Gençali)</b> | 27.02.2002 | 5                      |
| <b>Hayriye</b>            | 24.10.1964 | 4                      |
|                           | 24.04.1992 | 4                      |
|                           | 26.02.2002 | 3                      |
| <b>İclaliye</b>           | 22.03.1990 | 77                     |
| <b>Kestanealanı</b>       | 05.05.1989 | 39                     |
| <b>Konurlar</b>           | 01.08.1995 | -                      |
|                           | 25.06.1996 | -                      |
|                           | 29.03.2002 | -                      |
| <b>Lütfiye</b>            | 19.03.2002 | -                      |
| <b>Muratbey</b>           | 27.05.1959 | 95                     |
|                           | 22.06.1963 | 2                      |
|                           | 20.05.1997 | -                      |
|                           | 09.10.2000 | 9                      |
|                           | 01.03.2006 | 15                     |
|                           | 24.08.2016 | 4                      |

\*İnegöl İstatistik Raporu (2024).

İnceleme alanı ve yakın çevresindeki heyelan duyarlılığını konu alan çalışmalar değerlendirildiğinde; Uzun ve Garipoğlu (2022a) tarafından Mekânsal otokorelasyon ve kümeleme analizi yaklaşımı ile Göksu Çayı Havzası'nın (Sakarya Nehri Havzası) bütünleşik ve sürdürülebilir havza yönetim modeli analiz edilmiştir. Söz konusu çalışmada, İnegöl Havzası'nın erozyon, sel, taşkın ve heyelan riskleri barındırdığı; arazi kullanımı bakımından da yoğun antropojenik baskı altında olduğu vurgulanmıştır. Uzun (2024), Yenişehir Havzası'nın jeoekolojik risk modelini Analitik Hiyerarşi Süreci (AHS) temelinde 24 ana ve 142 alt kriteri kullanarak kurgulamıştır. Bu model;

antropojenik deformasyon ve kirlilik, erozyon, kütle hareketleri, kuraklık ve yangın duyarlılığı olmak üzere altı temel bileşenin çarpan etkisine dayanmaktadır. Çalışmanın bulguları, İnegöl formasyonlarının kütle hareketlerini tetikleyici bir unsur olduğunu ortaya koymuştur. Uzun ve Garipoğlu (2022b), İnegöl ve Yenişehir alt havzalarını içeren Göksu Çayı Havzası'nda duyarlılık analizlerini havza yönetimi açısından incelemiştir. Analitik Hiyerarşi Süreci (AHS) yöntemi kullanılarak erozyon, heyelan, sel/taşkın, kuraklık, kaya düşmesi, orman yangını, fırtına ve antropojenik kaynaklara ilişkin duyarlılık haritaları üretilmiştir. Heyelan duyarlılığı çok yüksek olan alanların büyük

ölçüde İnegöl Ovası'nın güneyinde yer alan, plato sahasında yoğunlařtıđı belirtilmiřtir. Öncü (2021) tarafından, Bursa ilinin dođal bütünleřik tehlike analizi gerekleřtirilmiřtir. alıřmanın bulgularına göre, Bursa ilinde meydana gelen heyelanların %58'i İnegöl'de gözlemlenmiřtir.

Bu tür afetlerin tekrar yařanmaması veya yařanması durumunda oluřabilecek zararların minimuma indirgenmesi için öncelikle; Heyelan duyarlılıđı yüksek ve ok yüksek olarak sınıflandırılan alanlar üzerine daha derinlemesine arařtırmalar yapılarak, imar

planlarında “Yerleřime Uygun Olmayan Alanlar” (YUOA) olarak iřaretlenmelidir. Bu alanlardaki mevcut yapı stođu için kademeli bir tahliye ve yeniden yerleřim programı oluřturulmalıdır. Duyarlılıđın orta ve yüksek olduđu, ancak yerleřimin devam ettiđi bölgelerde; řev stabilitesini sađlamak adına geoteknik iyileřtirmeler (zemin ivileri, fore kazıklar, ankrajlı istinat yapıları) uygulanmalıdır. Yama dengesini bozmamak adına kontrolsüz kazı ve dolgu iřlemleri katı bir denetime tabi tutulmalı, teraslama alıřmaları morfolojik yapıya uygun drenaj sistemleri ile entegre edilmelidir.



**řekil 9:** Muratbey Kirsal Mahallesi heyelan alanı kaynak noktasından güneybatı yönlü ekilmiř fotođraf (2015)  
Kaynak: URL1 / **Figure 9:** Photograph taken from the source point of the landslide area in Muratbey rural neighborhood, looking southwest (2015). Source: URL1



**řekil 10:** Muratbey Kirsal Mahallesi heyelan alanı kaynak noktasından güneybatı yönlü ekilmiř fotođraf (28.06.2025) / **Figure 10:** Photograph taken from the landslide source point in Muratbey rural neighborhood, looking southwest (28.06.2025).



**Şekil 11:** Muratbey Kırsal Mahallesi heyelan alanı batıdan doğuya doğru çekilmiş fotoğraf (28.06.2025) / **Figure 11:** Photograph of the Muratbey rural neighborhood landslide area, taken from west to east.




**Şekil 12:** Heyelan nedeniyle deformasyona uğramış olan Muratbey Kırsal Mahallesi eski yolu ve heyelan yarasının görüntüsü (28.06.2025) / **Figure 12:** View of the old road of Muratbey rural neighborhood deformed by the landslide and the resulting landslide scar (28.06.2025).



**Őekil 13:** Muratbey Kırsal Mahallesi ve Hayriye Kırsal Mahallesi Arasındaki Yolda Heyelan Yarası Yeniden Oluřum Ařamasında (28.06.2025) / **Figure 13:** Landslide scar in the process of reactivation on the road between Muratbey and Hayriye rural neighborhoods.



**Őekil 14:** Muratbey Kırsal Mahallesi ve Hayriye Kırsal Mahallesi Arasındaki Yol (2015) Kaynak: URL1 / **Figure 14:** The road between Muratbey and Hayriye rural neighborhoods (2015). Source: URL1



**Şekil 15:** Muratbey Kırsal Mahallesi heyelandan 2016 yılında yaşanan heyelandan zarar görmüş ev (28.06.2025).  
**Figure 15:** House damaged by the landslide that occurred in 2016 in Muratbey rural neighborhood (28.06.2025).

## KATKI BELİRTME VE TEŞEKKÜR

Çalışmanın tüm aşamalarında yapıcı değerlendirmeleri ve akademik rehberliğiyle bizlere yol gösteren saygıdeğer hocamız Prof. Dr. İsa Cürebal'a katkılarından dolayı içtenlikle teşekkür ederiz. Ayrıca arazi çalışmaları sırasında yardımları için Muratbey Köyü muhtarı Murat Balcielmas'a teşekkür ederiz.

## KAYNAKÇA

- Abdelkader, M. M., & Csámer, Á. (2025). Comparative assessment of machine learning models for landslide susceptibility mapping: a focus on validation and accuracy. *Natural Hazards*, 1-23. <https://doi.org/10.1007/s11069-025-07197-0>
- Abdo, H. G., Richi, S. M., Prasad, P., Katipoğlu, O. M., Halder, B., Niknam, A., ... & Mallick, J. (2025). Mapping landslide susceptibility in the Eastern Mediterranean mountainous region: a machine learning perspective. *Environmental Earth Sciences*, 84(9), 250. <https://doi.org/10.1007/s12665-025-12242-z>
- Achour, Y., & Pourghasemi, H. R. (2020). How do machine learning techniques help in increasing accuracy of landslide susceptibility maps?. *Geoscience Frontiers*, 11(3), 871-883. <https://doi.org/10.1016/j.gsf.2019.10.001>
- Akıncı, H., Kılıçoğlu, C., & Doğan, S. (2020). Random forest-based landslide susceptibility mapping in coastal regions of Artvin, Turkey. *ISPRS International Journal of Geo-Information*, 9(9), 553. <https://doi.org/10.3390/ijgi9090553>
- Akıncı, H., & Zeybek, M. (2021). Comparing classical statistic and machine learning models in landslide susceptibility mapping in Ardanuc (Artvin), Turkey. *Natural Hazards*, 108(2), 1515-1543. <https://doi.org/10.1007/s11069-021-04743-4>
- Berber, S., Ercanoglu, M., & Ceryan, S. (2024). Landslide susceptibility evaluation of southeastern Çanakkale strait (NW Türkiye) using logistic regression, artificial neural network and support vector machine. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 48(6), 4575-4591. <https://doi.org/10.1007/s40996-024-01367-z>
- Breiman, L., Cutler, A., Liaw, A., & Wiener, M., (2024). randomForest: Breiman and Cutlers Random Forests for Classification and Regression [R paketi randomForest version 4.7-1.2]. <https://doi.org/10.32614/CRAN.package.randomForest>
- Chen, W., Yan, X., Zhao, Z., Hong, H., Bui, D. T., & Pradhan, B. (2019). Spatial prediction of landslide susceptibility using data mining-based kernel logistic regression, naive Bayes and RBFNetwork models for the Long County area (China). *Bulletin of Engineering geology and the Environment*, 78(1), 247-266. <https://doi.org/10.1007/s10064-018-1256-z>
- Chen, W., Peng, J., Hong, H., Shahabi, H., Pradhan, B., Liu, J., ... & 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>
- Chen, W., Pourghasemi, H. R., Kornejady, A., & Zhang, N. (2017). Landslide spatial modeling: Introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques. *Geoderma*, 305, 314-327. <https://doi.org/10.1016/j.geoderma.2017.06.020>

- Chowdhuri, I., Pal, S. C., Chakraborty, R., Malik, S., Das, B., & Roy, P. (2021). Torrential rainfall-induced landslide susceptibility assessment using machine learning and statistical methods of eastern Himalaya. *Natural Hazards*, 107(1), 697-722. <https://doi.org/10.1007/s11069-021-04601-3>
- CORİNE. (2018). Land cover/landuse maps [Arazi kullanımı haritaları]. Eriřim: <https://land.copernicus.eu/paneuropean/corine-land-cover>
- Cruden, D. M. & Varnes, D. J. (1996). Landslides: investigation and mitigation. Chapter 3- Landslide types and processes. Transportation research board special report, (247).
- Dai, FC., Lee, CF., Ngai, YY. (2002) Landslide risk assessment and management: an overview. *Eng Geol*, 64(1):65-87. [https://doi.org/10.1016/S0013-7952\(01\)00093-X](https://doi.org/10.1016/S0013-7952(01)00093-X)
- Fidan, S. & Görüm, T. (2020). Türkiye’de ölümcül heyelanların dađılım karakteristikleri ve ulusal ölçekte öncelikli alanların belirlenmesi. *Türk Cođrafya Dergisi*, 74, 123-134. <https://doi.org/10.17211/tcd.731596>
- Fritsch, S., Guenther, F., Wright, M. N. Suling, M. & Mueller, S. M. (2019). neuralnet: Training of Neural Networks [R paketi neuralnet version 1.44.2]. <https://doi.org/10.32614/CRAN.package.neuralnet>
- Froude, M. J., & Petley, D. N. (2018). Global fatal landslide occurrence from 2004 to 2016. *Natural Hazards and Earth System Sciences*, 18, 2161-2181. <https://doi.org/10.5194/nhess-18-2161-2018>
- Görüm, T., & Nefesliođlu, H. (2015). Çok zamanlı heyelan aktivitesinin belirlenmesinde jeomorfolojik bir yaklařım. *Türk Cođrafya Dergisi*, (65), 47-58. <https://doi.org/10.17211/tcd.19041>
- Guzzetti, F. (2006). Landslide hazard and risk assessment (PhD Thesis). Mathematisch Naturwissenschaftlichen Fakultät der Rheinischen Friedrich-Wilhelms- Universität, University of Bonn, Bonn, Germany.
- Habumugisha, J. M., Chen, N., Rahman, M., Islam, M. M., Ahmad, H., Elbeltagi, A., ... & Dewan, A. (2022). Landslide susceptibility mapping with deep learning algorithms. *Sustainability*, 14(3), 1734. <https://doi.org/10.3390/su14031734>
- Haque U da Silva PF, Devoli G, Pilz J, Zhao B, Khaloua A, Wilopo W, Andersen P, Lu P, Lee J, Yamamoto T, Keellings D, Wu J-H. & Glass GE. (2019). The human cost of global warming: deadly landslides and their triggers (1995-2014). *Sci Tot Environ*, 682:673-684. <https://doi.org/10.1016/j.scitotenv.2019.03.415>
- Harmouzi, H., Nefeslioglu, H. A., Rouai, M., Sezer, E. A., Dekayir, A., & Gokceoglu, C. (2019). Landslide susceptibility mapping of the Mediterranean coastal zone of Morocco between Oued Laou and El Jebha using artificial neural networks (ANN). *Arabian Journal of Geosciences*, 12(22), 696. <https://doi.org/10.1007/s12517-019-4892-0>
- He, Q., Wu, S., Zhao, X., Hui, Z., Wang, Z., Tsangaratos, P., ... & Hao, Y. (2025). Evaluation of landslide susceptibility of mountain highway based on RF and SVM models. *Scientific Reports*, 15(1), 24991. <https://doi.org/10.1038/s41598-025-08774-w>
- Hossain, M. I., Ferdous, M. N., Bhattacharjee, S., & Rahman, M. (2025). Remote sensing and GIS-driven landslide susceptibility mapping using machine learning for sustainable land management: a study from the Chittagong Hill Tracts of Bangladesh. *Discover Sustainability*, 6(1), 1200. <https://doi.org/10.1007/s43621-025-02084-x>
- Huqqani, I. A., Tay, L. T., & Mohamad-Saleh, J. (2023). Spatial landslide susceptibility modelling using metaheuristic-based machine learning algorithms. *Engineering with Computers*, 39(1), 867-891. <https://doi.org/10.1007/s00366-022-01695-6>
- İnegöl Belediyesi (2024). İnegöl istatistik raporu. Bursa: İnegöl Belediyesi.
- Jari, A., Khaddari, A., Hajaj, S., Bachaoui, E. M., Mohammedi, S., Jellouli, A., ... & Barakat, A. (2023). Landslide susceptibility mapping using multi-criteria decision-making (MCDM), statistical, and machine learning models in the Aube Department, France. *Earth*, 4(3), 698-713. <https://doi.org/10.3390/earth4030037>
- Javidan, N., Kavian, A., Pourghasemi, H. R., Conoscenti, C., Jafarian, Z., & Rodrigo-Comino, J. (2021). Evaluation of multi-hazard map produced using MaxEnt machine learning technique. *Scientific reports*, 11(1), 6496. <https://doi.org/10.1038/s41598-021-85862-7>
- 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(6), 7367-7385. <https://doi.org/10.1007/s13369-022-06560-8>
- Klose, M., Damm, B. & Highland L.M. (2015). Databases in geohazard science: an introduction. *Geomorphology*, 249:1-3.

- Kosmidis, I., Pagui, E. C. K., Boiocchi, F., Sterzinger, P., Konis, K. & Sartori, N. (2025). brglm2: Bias Reduction in Generalized Linear Models [R paketi brglm2 version 1.0.0]. <https://doi.org/10.32614/CRAN.package.brglm2>
- Köy Hizmetleri Genel Müdürlüğü (1995). Bursa ili arazi varlığı. Rapor no: 16, Ankara: T.C. Tarım ve Orman Bakanlığı.
- Liu, S., Wang, L., Zhang, W., He, Y., & Pijush, S. (2023). A comprehensive review of machine learning-based methods in landslide susceptibility mapping. *Geological Journal*, 58(6), 2283-2301. <https://doi.org/10.1002/gj.4666>
- Lu, Z., Liu, G., Song, Z., Sun, K., Li, M., Chen, Y. & Zhang, W. (2024). Advancements in technologies and methodologies of machine learning in landslide susceptibility research: current trends and future directions. *Applied Sciences*, 14(21), 9639. <https://doi.org/10.3390/app14219639>
- Ma, S., Shao, X., & Xu, C. (2023). Estimating the quality of the most popular machine learning algorithms for landslide susceptibility mapping in 2018 Mw 7.5 Palu earthquake. *Remote Sensing*, 15(19), 4733. <https://doi.org/10.3390/rs15194733>
- Ma, T., Yi, X., Ci, H., Wang, R., Yang, H., & Yan, Z. (2026). Landslide Susceptibility Evaluation Integrating Machine Learning and SBAS-InSAR-Derived Deformation Characteristics: A Case Study of Yining County, Xinjiang. *Sensors*, 26(2), 707. <https://doi.org/10.3390/s26020707>
- Maden Tetkik ve Arama Genel Müdürlüğü Yerbilimleri Çizim Editörü (2023). 1:100.000 ölçekli İnegöl heyelan envanteri haritası. Eriřim: <https://yerbilimleri.mta.gov.tr/>
- Maden Tetkik ve Arama Genel Müdürlüğü. (2023). 1:25.000 ölçekli İnegöl jeoloji haritaları. Ankara: Maden Tetkik ve Arama Genel Müdürlüğü.
- Mayer, D., Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F., Chang, C. C., & Lin, C.C. (2024). e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien [R paketi e1071 version 1.7 – 16]. <https://doi.org/10.32614/CRAN.PACKAGE.E1071>
- Merghadi, A., Yunus, A. P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D. T., ... & Abderrahmane, B. (2020). Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance. *Earth-Science Reviews*, 207, 103225. <https://doi.org/10.1016/j.earscirev.2020.103225>
- Meteoroloji Genel Müdürlüğü. (2022). İnegöl sıcaklık ve yağış verileri [Veri Seti]. Ankara: Meteoroloji Genel Müdürlüğü.
- 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. <https://doi.org/10.1080/10106049.2020.1837258>
- Öncü, S. (2021). CBS yöntemiyle Bursa'nın bütünleşik doğal tehlike analizi (Tez No: 696829) [Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi]. Yükseköğretim Kurulu Başkanlığı Tez Merkezi.
- Pandey, V. K., Pourghasemi, H. R., & Sharma, M. C. (2020). Landslide susceptibility mapping using maximum entropy and support vector machine models along the Highway Corridor, Garhwal Himalaya. *Geocarto International*, 35(2), 168-187. <https://doi.org/10.1080/10106049.2018.1510038>
- Park, S., & Kim, J. (2019). Landslide susceptibility mapping based on random forest and boosted regression tree models, and a comparison of their performance. *Applied Sciences*, 9(5), 942. <https://doi.org/10.3390/app9050942>
- Petley, D. (2012). Global patterns of loss of life from landslides. *Geology*, 40 (10), 927-930. <https://doi.org/10.1130/G33217.1>
- Pham, B. T., Pradhan, B., Bui, D. T., Prakash, I., & Dholakia, M. B. (2016). A comparative study of different machine learning methods for landslide susceptibility assessment: A case study of Uttarakhand area (India). *Environmental modelling & software*, 84, 240-250. <https://doi.org/10.1016/j.envsoft.2016.07.005>
- Pham, B. T., Shirzadi, A., Shahabi, H., Omidvar, E., Singh, S. K., Sahana, M., ... & Lee, S. (2019). Landslide susceptibility assessment by novel hybrid machine learning algorithms. *Sustainability*, 11(16), 4386. <https://doi.org/10.3390/su11164386>
- Phillips, S. J., Anderson, R. P., & Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological modelling*, 190(3-4), 231-259. <https://doi.org/10.1016/j.ecolmodel.2005.03.026>
- 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>

- Saha, A., Villuri, V. G. K., & Bhardwaj, A. (2025). Development and assessment of a novel hybrid machine learning-based landslide susceptibility mapping model in the Darjeeling Himalayas. *Stochastic Environmental Research and Risk Assessment*, 39(10), 4145-4168. <https://doi.org/10.1007/s00477-023-02528-8>
- Schreiber P (1904) Über die beziehungen zwischen dem niederschlag und der wasserführung der flüsse in Mitteleuropa. *Meteor* 21: 441–452.
- 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(5), 2280. <https://doi.org/10.3390/app12052280>
- Tien Bui, D., Shahabi, H., Omidvar, E., Shirzadi, A., Geertsema, M., Clague, J. J., ... & Lee, S. (2019). Shallow landslide prediction using a novel hybrid functional machine learning algorithm. *Remote Sensing*, 11(8), 931. <https://doi.org/10.3390/rs11080931>
- URL 1: <https://www.olay.com.tr/bursada-heyelan-iki-mahalleyi-tehdit-ediyor-343543>
- Uzun, M. (2024). Yenişehir (Bursa) Havzası'nın coğrafi karakterizasyonuna dayalı jeoekolojik risk duyarlılığı analizi. *International Journal of Geography and Geography Education (IGGE)*, 51, 85-114. <http://dx.doi.org/10.32003/igge.1326841>
- Uzun, M. (2025). Frekans Oranı ve Yapay Sinir Ağları Yöntemleri İle Samanlı Dağları Kütlesinde Heyelan Duyarlılık Analizi. *Doğal Afetler ve Çevre Dergisi*, 11(2), 538-556. <https://doi.org/10.21324/dacd.1663672>
- Uzun, M., & Garipağaoğlu, N. (2022a). Mekânsal otokorelasyon ve kümeleme analizi yaklaşımı ile Göksu Çayı Havzası'nın (Sakarya Nehri Havzası) bütünleşik ve sür-dürülebilir havza yönetim modeli. *Türk Coğrafya Dergisi*, (81), 23-38. <https://doi.org/10.17211/tcd.1173420>
- Uzun, M., & Garipağaoğlu, N. (2022b). Göksu Çayı Havzası'nın (Sakarya Nehri Havzası) tehlike duyarlılık analizleri kapsamında havza yönetimi. *Ege Coğrafya Dergisi*, 31(2), 2022, s. 449-471. <https://doi.org/10.51800/ecd.1160134>
- Varnes, D. J. (1978). Slope movement types and processes. *Special report*, 176, 11-33.
- Youssef, A. M., El-Haddad, B. A., Skilodimou, H. D., Bathrellos, G. D., Golkar, F., & Pourghasemi, H. R. (2024). Landslide susceptibility, ensemble machine learning, and accuracy methods in the southern Sinai Peninsula, Egypt: Assessment and Mapping. *Natural Hazards*, 120(15), 14227-14258. <https://doi.org/10.1007/s11069-024-06769-w>
- Zhou, C., Yin, K., Cao, Y., Ahmed, B., Li, Y., Catani, F., & Pourghasemi, H. R. (2018). Landslide susceptibility modeling applying machine learning methods: A case study from Longju in the Three Gorges Reservoir area, China. *Computers & geosciences*, 112, 23-37. <https://doi.org/10.1016/j.cageo.2017.11.019>
- Zhao, B., Zhu, J., Hu, Y., Liu, Q., & Liu, Y. (2022). Mapping landslide sensitivity based on machine learning: A case study in Ankang City, Shaanxi Province, China. *Geofluids*, 2022(1), 2058442. <https://doi.org/10.1155/2022/2058442>
- Zhu, A. X., Wang, R., Qiao, J., Qin, C. Z., Chen, Y., Liu, J., ... & Zhu, T. (2014). An expert knowledge-based approach to landslide susceptibility mapping using GIS and fuzzy logic. *Geomorphology*, 214, 128-138. <https://doi.org/10.1016/j.geomorph.2014.02.003>