



A new approach to combating landslides: Optimum weighted ensemble learning (OPWE)

Seyfullah Arslan^a, Safa Dörterler^{*b}, Muammer Akçay^c

ABSTRACT

This study is critically important in the early prediction of landslides, aiming to minimize the impacts of natural disasters. The development of early warning systems is vital to prevent loss of life and property. This study aims to predict landslide occurrences by using an ensemble learning model to predict landslide probability. Furthermore, a new ensemble learning approach called OPAT, based on Hybrid K-Means- Battle Royale Optimization Algorithm (HBROA) is proposed to improve the accuracy of the predictions. The weighted voting method is used instead of Majority Voting, which is commonly used in ensemble learning studies, and the classifier weights used in this method are optimized with the help of a hybrid metaheuristic algorithm called HBROA. In the study, basic classifiers such as Random Forest (RF), Support Vector Machine (SVM), and Artificial Neural Network (ANN) are used and the results of these classifiers are combined with the bagging method. The proposed method outperformed the baseline classifiers and other methods in the existing literature with an accuracy of 81.89%. As a result, this study presents a new approach to landslide prediction using different classifier methods. Furthermore, an ensemble learning approach based on metaheuristic algorithms is proposed to identify landslide-prone areas and mitigate potential damages more accurately. This new method represents a significant step forward in detecting landslides in advance and minimizing the impacts of such natural disasters.

^a Kutahya Dumlupınar University,
Engineering Faculty,
Dept. of Computer Engineering
43000 - Kütahya, Türkiye
ORCID: 0000-0002-2573-273X

^{b,*} Kutahya Dumlupınar University,
Engineering Faculty,
Dept. of Computer Engineering
43000 - Kütahya, Türkiye
ORCID: 0000-0001-8778-081X

^c Kutahya Dumlupınar University,
Engineering Faculty,
Dept. of Computer Engineering
43000 - Kütahya, Türkiye
ORCID: 0000-0003-0244-1275

*Corresponding author.
e-mail: safa.dorteler@dpu.edu.tr

Heyelanlarla mücadelede yeni bir yaklaşım: Optimum ağırlıklı topluluk öğrenmesi (OPAT)

ÖZ

Bu çalışma heyelanların önceden tahmin edilmesi konusunda kritik bir öneme sahiptir, doğal afetlerin etkilerini en aza indirmeyi amaçlamaktadır. Can ve mal kayıplarını engellemek için erken uyarı sistemlerinin geliştirilmesi hayati bir ihtiyaçtır. Bu çalışmada, heyelan olasılığını tahmin etmek için bir topluluk öğrenme modeli kullanılarak, heyelan oluşumlarını öngörmek amaçlanmıştır. Ayrıca, tahminlerin doğruluğunu artırmak için Hibrit K-Means - Ölüm Oyunu Optimizasyon Algoritması (HBROA)'na dayalı OPAT adı verilen yeni bir topluluk öğrenme yaklaşımı önerilmiştir. Topluluk öğrenme çalışmalarında sıkça kullanılan çoğunluk oylaması yerine, ağırlıklı oylama yöntemi kullanılmıştır ve bu yöntemde kullanılan sınıflandırıcı ağırlıkları HBROA adlı hibrit meta sezgisel algoritma yardımıyla optimize edilmiştir. Çalışmada, Rastgele Orman (RF), Destek Vektör Makinesi (SVM) ve Yapay Sinir Ağı (ANN) gibi temel sınıflandırıcılar kullanılmış ve bu sınıflandırıcıların sonuçları bagging (torbalama) yöntemi ile birleştirilmiştir. Önerilen yöntem, %81,89 doğruluk oranı ile hem temel sınıflandırıcıları hem de mevcut literatürdeki diğer yöntemleri geride bırakmıştır. Sonuç olarak, bu çalışma farklı sınıflandırıcı yöntemlerini kullanarak heyelan tahmini konusunda yeni bir yaklaşım sunmaktadır. Ayrıca, meta sezgisel algoritmalar temelinde geliştirilen bir topluluk öğrenme yaklaşımı, heyelan riski taşıyan bölgelerin daha doğru bir şekilde tespit edilmesi ve olası zararların azaltılması amacıyla önerilmiştir. Bu yeni yöntem, heyelanların önceden tespit edilmesi ve bu tür doğal afetlerin etkilerinin en aza indirilmesi konusunda önemli bir adımı temsil etmektedir.

Keywords: Landslide prediction, Deep learning, Ensemble learning, Weighted voting method, Meta-heuristic algorithms

Anahtar Kelimeler: Heyelan tahmini, Derin öğrenme, Topluluk öğrenme, Ağırlıklı oylama yöntemi, Meta-sezgisel algoritmalar


Submitted: 23.06.2026
Revised: 29.06.2026
Accepted: 30.06.2026

doi:10.30855/ais.2026.09.01.02

1. Giriş (Introduction)


Heyelan, dünya genelinde önemli bir jeolojik olay olarak karşımıza çıkmaktadır ve birçok bölgede doğal afetlere neden olabilen ciddi sonuçlar doğurabilmektedir [1]. Bu doğal afet, insanlar, yapılar ve altyapılar için büyük bir tehdit oluşturmaktadır [2]. Heyelan, toprak ve kaya parçalarının eğimli yamaçlardan aşağı doğru hareket etmesiyle gerçekleşmektedir ve genellikle ani yağışlar, depremler, jeolojik yapılar, eğim, bitki örtüsü gibi çeşitli faktörler tarafından etkilenmektedir [3], [4].

Dünya genelinde 1980 ile 2018 yılları arasında, yaklaşık olarak 15,500,000 önemli yağış nedenli heyelanın meydana geldiği tahmin edilmektedir [5]. Bu verilere dayalı olarak, küresel olarak meydana gelen önemli yağış nedenli heyelanların ortalama yıllık sayısının yaklaşık olarak 400,000 olduğu tahmin edilmektedir. Ayrıca, önemli deprem nedenli heyelanların ortalama yıllık sayısının yaklaşık olarak 130,000 olduğu tahmin edilmektedir [5]. Dünya Bankası'nın heyelanla ilgili bir araştırma raporundan alınan verilere göre, Şekil 1 ve Şekil 2, 1980-2018 yılları arasındaki tahmini ortalama yıllık önemli yağışla ve depremle tetiklenen, heyelan tehlikesi en yüksek on ülkeyi göstermektedir [5], [6].



Şekil 1. 1980-2018 yılları arasındaki yağışla tetiklenen önemli heyelanların tahmini yıllık ortalama sayısı
(The estimated annual average number of significant landslides triggered by rainfall between 1980 and 2018)

Grafikte yer alan ülkeler, 1980 ile 2018 yılları arasında yaşanan ortalama yıllık önemli heyelan sayılarına göre sıralanmıştır. ABD, Çin ve Hindistan, heyelan tehlikesi açısından önde gelen ülkelerdendir. Bu ülkeler, yüksek yıllık ortalama heyelan sayılarına sahiptir. ABD, yaklaşık 36,150 heyelan ile bu listede ilk sıradadır. Bu ülkeler, yoğun yağışlar nedeniyle heyelan tehlikesi konusunda önemli bir risk altındadır. Güneydoğu Asya Ülkeleri: Filipinler, Endonezya ve Vietnam gibi Güneydoğu Asya ülkeleri de yıllık ortalama heyelan sayılarının yüksek olduğu bir diğer bölgelerdir. Bu ülkeler, iklimsel etkenlere ve coğrafi koşullara bağlı olarak heyelanların daha sık yaşandığı bölgeler olarak öne çıkmaktadır. Bu veriler, söz konusu ülkelerde erken uyarı ve tahmin sistemlerinin ve risk azaltma önlemlerinin geliştirilmesinin ne kadar önemli olduğunu göstermektedir. Yoğun yağış dönemlerinde, bu ülkelerde daha fazla dikkatli ve etkili önlemler alınması gerekmektedir. Bu hem insan hayatını korumak hem de altyapıyı sürdürülebilir bir şekilde korumak için kritik bir gerekliliktir. Şekil 2, tahmini yıllık ortalama depremle tetiklenen, heyelan tehlikesi en yüksek on ülkeyi göstermektedir [5].



Şekil 2. 1980-2018 yılları arasındaki depremle tetiklenen önemli heyelanların tahmini yıllık ortalama sayısı
(The estimated annual average number of significant landslides triggered by earthquakes between 1980 and 2018)

Grafikte yer alan ülkeler, ortalama yıllık önemli deprem nedenli heyelan sayılarına göre sıralanmıştır. Çin, yaklaşık 20,950 deprem nedenli heyelanla bu listede açık ara önde gelmektedir. Bu veri, Çin'in coğrafi olarak deprem tehlikesine açık bir bölgede yer aldığını ve bu nedenle deprem nedenli heyelanların daha sık yaşandığını göstermektedir. Kırgızistan, Tacikistan ve Afganistan gibi Orta Asya ülkeleri, yıllık ortalama deprem nedenli heyelan sayılarının yüksek olduğu bölgelerdir. Bu bölgeler, sismik aktivite açısından önemli risk taşımaktadır. ABD ve Türkiye, bu listede önemli deprem nedenli heyelan sayıları bakımından öne çıkan diğer iki ülkedir. Bu ülkeler de deprem riskine sahiptir. Bu veriler, deprem nedenli heyelanlar konusundaki riskin coğrafi olarak farklı bölgelerde farklı seviyelerde olduğunu göstermektedir. Deprem nedenli heyelanlar, deprem etkisi altındaki bölgelerde daha yaygın görülmektedir. Bu nedenle, bu bölgelerde deprem hazırlığı ve risk azaltma önlemlerine daha fazla önem verilmesi gerekmektedir.

Heyelan, dünya genelinde yaşanan ciddi doğal afetler arasında önemli bir tehdit oluştururken, erken tespitin önemli bir rol oynadığı unutulmamalıdır. Heyelanlar, ani yağışlar, depremler ve diğer jeolojik faktörler nedeniyle meydana gelirken, bu doğal olayların yol açabileceği hasar ve kayıpların azaltılması için erken uyarı ve tahmin sistemlerinin geliştirilmesi büyük bir öneme sahiptir [7]. Erken tespit sistemleri, özellikle heyelan tehlikesinin yüksek olduğu bölgelerde, yaşamları korumak ve altyapıyı sürdürülebilir bir şekilde korumak için kritik bir rol oynar. Bu sistemler, meteorolojik verilerin takibi, jeolojik koşulların izlenmesi ve riskli alanlarda sürekli gözlem yapılması gibi bir dizi teknolojik ve bilimsel yöntemi içerebilir [8]. Bu sayede, potansiyel heyelan tehlikesi olan bölgelerde halkın ve yerel yönetimlerin önceden uyarılması, acil durum planlarının hazırlanması ve gerekli tahliye önlemlerinin alınması mümkün hale gelir. Bu nedenle, bilim, teknoloji ve kamu yönetimi alanlarında yapılan çalışmalar, heyelanlarla mücadelede önemli bir rol oynamaktadır ve bu çalışmaların desteklenmesi ve yaygınlaştırılması, toplumların güvenliğini artırmak için hayati öneme sahiptir.

Heyelanların tahmin edilmesi, karmaşık bir süreçtir ve birçok değişkeni içerir [9]. Yağış miktarı ve yoğunluğu, toprak yapısı, jeolojik yapılar, eğim ve bitki örtüsü gibi faktörler, heyelan riskini etkileyen önemli parametrelerdir [10]. Bu nedenle, heyelan tahmini için doğru ve güvenilir bir modelin geliştirilmesi hayati önem taşımaktadır.

Heyelan tahmininde Rastgele Orman (RF), Destek Vektör Makinesi (SVM) ve Yapay Sinir Ağı (ANN) gibi makine öğrenimi yöntemleri yaygın olarak kullanılmaktadır [11], [12]. Bu yöntemler, farklı özneliliklerin heyelan tahminindeki etkisini belirlemek ve karmaşık ilişkileri modellemek için kullanılan güçlü araçlardır. Rastgele Orman, veri setindeki özneliliklerin önem sıralamasını sağlarken [13], [14], SVM uygun parametre ayarlarıyla yüksek doğruluk ve genellenebilirlik sağlayabilir [15], [16]. ANN ise doğrusal olmayan ilişkileri modelleyebilme yeteneği ve öğrenme yeteneği sayesinde heyelan tahmininde başarılı sonuçlar elde edebilir [17], [18]. Her bir yöntemin avantajları ve dezavantajları bulunmaktadır ve seçim, veri seti özelliklerine ve hedeflenen performansa bağlı olarak yapılmalıdır. Bu yöntemlerin kullanımı, heyelanların tahmin edilmesi ve erken uyarı sistemlerinin geliştirilmesi için önemli bir adımdır.

Makine öğrenmesi algoritmalarının sınıflandırma problemlerinde karşılaştıkları bazı güçlüklerden dolayı sınıflandırma problemini doğru bir şekilde yapamamaktadır. Her makine öğrenmesi sınıflandırıcısının belli bir veri seti üzerinde sınıflandırma yaparken güçlü ve zayıf yönleri bulunmaktadır. Bu zayıflıklar karşımıza düşük Doğru Pozitif (TP), Doğru Negatif (TN) veya yüksek Yanlış Pozitif (FP), Yanlış Negatif (FN) oranı olarak çıkmaktadır. Bu durumdan kaçınmak için literatürde birkaç sınıflandırıcıyı torbalama (bagging), arttırma (boosting) gibi yöntemlerle birleştirerek oluşturulan topluluk öğrenme yöntemleri kullanılmıştır. Ancak bu topluluk öğrenme yöntemleri her sınıflandırıcıya eşit ağırlık veren çoğunluk oylaması yöntemini veya elle verilen ağırlıklara dayalı ağırlıklı oylama yöntemlerini kullanmaktadır. Fakat her problemde sınıflandırıcılara eşit veya rastgele farklı ağırlıklar atamak topluluktaki güçlü sınıflandırıcıların performansını kısıtlayabilmektedir. Çalışmamızda bu problemin çözümü için aşağıdaki yenilikler önerilmiştir.

- Her sınıflandırıcıya rassal ağırlık yerine en yüksek performansı sağlayacak olan optimum ağırlıklar verilmiştir.
- Optimum ağırlıkların belirlenmesi için sınıflandırıcıların tahmin değerleri ve veri setindeki gözlemlenmiş sonuçları girdi alan ve ağırlık değerlerini optimize eden hibrit bir meta sezgisel algoritma önerilmiştir.

- Önerilen bu yenilikler ile literatürdeki benzer çalışmalara kıyasla heyelan tahminindeki başarımları artmıştır.

Bu çalışmada, heyelanların erken uyarı sistemlerini geliştirmek amacıyla heyelan tahmini yapacak bir model geliştirilmiştir. Çoğunluk oylaması yöntemi yerine bu çalışmada önerilen bir meta sezgisel algoritma olan Hibrit K-Means - Ölüm Oyunu Optimizasyon Algoritması (HBROA) kullanılarak sınıflandırıcıların ağırlıkları belirlenmiştir. HBROA algoritması, sınıflandırıcılardan gelen heyelan karar sisteminde kullanılan değerlerinin önem derecelerini belirlemek için kullanılmıştır. Bu yöntemle, heyelan tespiti için etkisi yüksek olan sınıflandırıcının değerlerinin önemi artırılmış ve etkisi düşük olan sınıflandırıcının önemi azaltılarak daha doğru tespitlerin yapılması ve yanlış tespitlerin önlenmesi hedeflenmiştir. Bu sayede, heyelan riski taşıyan bölgelerin doğru şekilde belirlenmesi ve ilgili önlemlerin alınması için daha kesin bir analiz sağlanmıştır. Bu çalışma, heyelanların erken tahmin edilmesi ve müdahale stratejilerinin geliştirilmesi için bir temel oluşturarak, gelecekte daha etkili ve güvenilir heyelan uyarı sistemlerinin tasarlanmasına katkıda bulunmayı amaçlamaktadır.

Önerilen model, Rastgele Orman (RF), Destek Vektör Makinesi (SVM) ve Yapay Sinir Ağı (ANN) gibi üç farklı sınıflandırıcıyı içermektedir. Her bir sınıflandırıcı, heyelanın gerçekleşip gerçekleşmediğini belirlemek için 13 farklı parametre değeri kullanmaktadır. Bu parametreler, 2021 yılında yayınlanan bir makalede kullanılan heyelan tahmini veri setinden elde edilmiştir [19]. Heyelanın etkilerini azaltmak için mevcut tahmin yöntemlerinde bir yenilik önerilmiştir.

Bu makale beş ana bölümden oluşmaktadır. İkinci bölümde literatür taraması yapılmıştır, bu bölümde mevcut çalışmaların ve ilgili konseptlerin incelenmesi gerçekleştirilmiştir. Üçüncü bölümde ise yöntemler ayrıntılı bir şekilde açıklanmıştır. Bu bölümde, veri seti, performans metrikleri, Ölüm Oyunu Optimizasyon algoritması, kullanılan sınıflandırıcılar ve topluluk öğrenme yöntemleri ile ilgili bilgilere yer verilir. Ayrıca özgün bir yaklaşım olan Hibrit K-Means- Ölüm Oyunu Optimizasyon Algoritması (HBROA)'nın detayları, önerilen modelin oluşturulması ve çalışmanın temel önerisi hakkında bilgi sunulur. Bölüm 4'te deneysel sonuçlar sunulur, verilerin analizi ve modelin performansının değerlendirilmesi yapılır. Son olarak, beşinci bölümde ise makalenin sonuçları ve önemi özetlenmektedir.

2. Literatür Araştırması (Literature Review)

Yapay zekâ tabanlı yöntemler, farklı veri türlerinden elde edilen karmaşık ve çok boyutlu örüntülerin modellenmesi, yorumlanması ve karar destek süreçlerinde kullanılmasına olanak sağlayarak birçok mühendislik probleminde etkili sonuçlar sunmaktadır [20], [21], [22], [23]. Bu bağlamda, doğal afetlerin etkisini azaltmak ve insan hayatını kurtarmak için önemli olan heyelan erken uyarı sistemleri, coğrafi bilgi sistemleri (CBS) ve sayısal modelleme tekniklerini kullanarak heyelan riski tahminleri yapabilir [24], [25], [26]. Heyelan oluşumunu tetikleyen önemli doğa olayları arasında aşırı yağışlar, çığ düşmesi, toprağın nemi, bölgedeki fay hatlarındaki kırılmalar, yer değişiklikleri ve kaya düşmesi gibi faktörler yer alır [27]. Heyelanların meydana gelmesini doğru tahmin etmek için uygun sensörlerin seçimi ve uygun veri işleme yöntemleri belirlenmeli ve karar verme süreçleri yapılmalıdır. Heyelan erken uyarı sistemleriyle ilgili birçok araştırma yapılmış ve makine öğrenmesi [28], yapay sinir ağları [29], veri madenciliği [30] ve bazı hibrit yöntemler [31] gibi farklı teknikler geliştirilmiştir.

Thirugnanam ve arkadaşları [28], heyelan erken uyarı sistemleri geliştirmişlerdir. Bu sistemleri veri toplama, veri iletimi, modelleme, analiz, tahmin ve uyarı bileşenleri olarak ayırdılar. Veri toplama ve iletimi aşamasında çeşitli yağmur, nem ve eğim ölçer sensörleri kullandılar ve geliştirdikleri IoT sistemi ile verilerini bir merkezde topladılar. Sahadan gelen bu veriler gerçek zamanlı olarak analiz ettiler ve geliştirdikleri makine öğrenmesi algoritması ile heyelan tahminini başarı ile yapmışlardır. Hemalatha ve arkadaşları [32] yağış, nem, su basıncı ve hareket sensörleri ile topladıkları heyelana etki eden parametreleri gerçek zamanlı toplayarak heyelan erken uyarı sistemi geliştirdiler. Destek Vektör Regresyon yöntemine dayalı olan Current-PWP ve 24-PWP algoritmaları ile modellerini eğittiler. Geliştirilen uyarı sisteminin devamlılığı sensörlerden gelen parametrelere bağlıdır ve sistem sensörleri elektriğe bağlı olarak 7/24 çalışmaktadır. Elektrik kesintisi durumunda güneş enerjisi ile çalışan sensörler sistemin devamlılığını sağlar. Ayrıca araştırmacılar ikinci önlem olarak makine öğrenmesi algoritmalarını sensör değerlerini tahmin etmek için kullanmışlardır. Collini ve arkadaşları [33] İtalya'nın Floransa kentinde meydana gelmiş 341 heyelan olayını inceledi. Çeşitli sensörlerle elde edilmiş yağış, eğim vb. jeolojik ve meteorolojik verileri RF, XGBoost, Konvolüsyonel Sinir Ağı (CNN) gibi makine öğrenmesi yöntemleri ile eğiterek 24 saat öncesinden heyelan tahmini yapan modeli

geliştirdiler. Geliştirdikleri modelleri çeşitli performans ölçüm metrikleri ile test ettiler ve sonuç olarak XGBoost modeli ile en başarılı sonuçlar elde etmişlerdir. Ng ve arkadaşları [34], heyelanların tahmin edilmesi için farklı topografik ve meteorolojik parametreler arasında yağış, nem, bitki örtüsü ve eğim gibi faktörleri toplayarak bir tahmin modeli geliştirmişlerdir. Bu çalışmada, Lojistik regresyon, RF, Adaboost, SVM ve Çok Katmanlı Algılayıcı gibi makine öğrenmesi algoritmalarını kullanmışlardır. Daha sonra araştırmacılar modellerin performansını farklı ölçütlerle değerlendirmişler ve RF modeli en iyi sonuçları vermiştir.

Veri toplama ve analiz etme, makine öğrenmesi yöntemleriyle geliştirilen modellerin ana bileşenleri arasındadır. Tarihsel ve gerçek zamanlı veriler kullanılarak anlamlı hale getirilen modeller, tahminlerin üretilmesine ve erken uyarı sistemlerinin geliştirilmesine olanak sağlar. Bu nedenle, Lojistik regresyon (LR), Destek Vektör Makinesi (SVM), Rastgele Orman (RF), CNN gibi makine öğrenmesi ve derin öğrenme algoritmaları, veriye dayalı tahmin modellerinin geliştirilmesinde başarıyla kullanılabilmektedir.

Heyelan risk tahmininde kullanılan bir başka teknik, veri madenciliğidir. Sensörler veya coğrafi bilgi sistemleri aracılığıyla toplanan veriler, toprak kayması, nem ölçümleri, GPS verileri, hava koşulları ve yer değişimleri gibi çeşitli makine öğrenmesi algoritmalarıyla analiz edilerek heyelan riski tahmin edilir. İtalya'da yapılan bir çalışmada, Franceschini ve arkadaşları [35], açık kaynaklı web sitesi kaynaklarını ve veri madenciliği yöntemlerini kullanarak çeşitli jeolojik ve hidrolojik veriler içeren bir toprak kayması envanteri oluşturmuşlardır. Çalışmada, önceden belirlenmiş tanımlayıcı anahtar kelimeler kullanılarak 2010-2019 yılları arasındaki web sayfaları taranmış ve toprak kayması ile ilgili olanlar bir envantere toplanmıştır. Daha sonra, bu envanter, nüfus yoğunluğu, eğim, yağış miktarı ve jeolojik yapı gibi toprak kaymasını etkileyebilecek faktörleri içeren çeşitli coğrafi veri tabanları ile ilişkilendirilmiştir. Bu ilişkiler sayesinde, heyelan tehlikesi olan bölgeler için bir risk haritası oluşturulmuş ve gelecekte oluşabilecek heyelan olayları öngörülmüştür. Sonuç olarak, yazarlar, toprak kayması envanterinin otomatik veri madenciliği yöntemleri kullanılarak oluşturulabileceğini ve bu yöntemlerin çeşitli coğrafi faktörlerle ilişkilendirilmesinin toprak kayması risk analizinde ne kadar faydalı olduğunu göstermişlerdir. Başka bir çalışmada Qian [36], çeşitli veri kaynaklarından gelen verileri toplamış ve analiz etmiştir. Bu verileri veri madenciliği yöntemiyle kullanarak afet acil durum yönetim sistemi geliştirmiştir. Bu büyük veri platformunun çeşitli kaynaklardan toplanan verilerle başarılı bir şekilde kullanıldığı ve geleneksel yöntemlere kıyasla daha etkili olduğunu kanıtlamıştır.

Görüntü işleme tekniklerinin doğal afetlerin izlenmesi ve yönetilmesinde kullanılmaktadır. Çin'de yapılan bir çalışmada 146 adet heyelan felaketi yaşanmış, 26 farklı dağ ve vadi görüntüsü elde edilmiştir [37]. Bu heyelanlar, çeşitli makine öğrenme algoritmaları kullanılarak sınıflandırıldı ve sonuçlar karşılaştırıldı. Uzaktan algılama teknolojileri ve belirli bir ağ üzerinden, herhangi bir düzeyde insan müdahalesi olmaksızın veri aktarımı gerçekleştirebilen [38] IoT sensörleri kullanarak heyelan felaketlerinin önlenmesi ve kırsal endüstrilerin sürdürülebilirliğinin sağlanması için çözümler sunulmuştur. Pennington ve arkadaşları [39], sosyal medya ve çeşitli kaynaklardan elde ettikleri fotoğraf verilerini ve yapay zekâ algoritmalarını kullanarak küresel bir toprak kayması olayı raporlama aracı tanıttılar. Bu araç, X gibi sosyal medya platformlarından veri toplayarak, doğal dil işleme ve makine öğrenimi tekniklerini kullanarak toprak kayması olaylarını tespit ediyor. Ardından, bu veriler, kullanıcılar için küresel bir harita üzerinde görselleştiriliyor.

Dünya genelinde birçok ülke, heyelan felaketinin etkisini araştırmak, hasar ve can kayıplarını düşürmek, tehlikeli bölgeleri belirlemek ve benzeri amaçlardan dolayı sosyal medya ve haber kaynaklarından veri toplayarak ulusal ve bölgesel heyelan veri tabanları oluşturmuştur [40], [41], [42], [43], [44], [45]. Bu veri tabanları daha sonra çeşitli yapay zekâ uygulamalarıyla işlenip analiz edilerek afet etkileri hafifletilmeye veya erken uyarı sistemi geliştirilerek afet gerçekleşmeden karar vericilerin ve halkın uyarılması sağlanmıştır [39]. Coğrafi Bilgi Sistemleri (CBS) doğal afetlerin yerel ve küresel düzeyde gerçek zamanlı olarak takip edilmesi ve acil durumlarda müdahale edilmesi için önemli bir araçtır. CBS'lere, hava ve uydu görüntüleri [46], [47], [48], radarlar [46], [49], [50] ve farklı sensörler [51], [52], [53] ile veri toplanmaktadır. Ayrıca CBS teknolojisi, heyelanların erken teşhis edilmesi ve önlenmesinde de başarılı bir şekilde kullanılmaktadır [49]. Son yıllarda, CBS kullanımıyla ilgili birçok araştırma yapılmış ve bu çalışmalar, heyelanların tespitinde CBS'nin etkililiğini göstermiştir. Can ve ark. [54], vatandaşların gönüllü olarak heyelan fotoğraflarını yükleyebileceği bir coğrafi veri sistemi oluşturmuşlardır. Daha sonra sistemdeki görüntü verilerinden heyelan fotoğraflarının otomatik olarak tespiti ve heyelan olaylarının doğruluğunun değerlendirilmesi için bir

CNN mimarisi önermişlerdir. CNN mimarisi, heyelan fotoğraflarını otomatik olarak tespit ederek, manuel veri değerlendirmesinin zaman alıcı ve maliyetli olduğu durumlarda, veri kalitesinin hızlı bir şekilde değerlendirilmesine yardımcı olmuştur. Sonuç olarak, CNN mimarisi heyelan fotoğraflarını %94 doğrulukla tanımlayabilmiştir ve toplum tabanlı acil durum yanıt sistemlerinde başarı ile kullanılabileceğini göstermiştir. Goniewicz ve ark. [49], coğrafi veri sistemleri teknolojilerinin, afet risk analizi, acil durum yönetimi ve afet sonrası kurtarma ve yeniden yapılanma süreçlerinde nasıl kullanılabileceğini çalışmalarında sunmuşlardır. Aynı zamanda Polonya'da afet ve acil durum yönetimi için coğrafi bilgi sistemlerinin kullanımını sınırlayan yasal düzenlemelerin yetersizliği, verilerin uygun şekilde güncellenememesi, coğrafi bilgi sistemleri teknolojisinin yeterli kullanımı için gereken insan kaynaklarına erişimdeki sınırlamalar ve coğrafi bilgi sistemleri teknolojisi hakkında yeterli farkındalığın olmayışı gibi faktörleri ele almışlardır. Sonuç olarak, coğrafi bilgi sistemleri teknolojisinin afet ve acil durum yönetimi için nasıl kullanılabileceği konusunda örnekler sunarak, bu teknolojilerin kullanımının afet ve acil durum yönetimi için önemli bir araç olduğunu ortaya koymuşlardır.

Heyelan erken uyarı sistemleri, heyelanların meydana gelme olasılığını tahmin etmek için makine öğrenmesi, yapay sinir ağları ve veri madenciliği gibi çeşitli teknikleri kullanır. Ancak, bu tekniklerin çoğu, heyelan tahmininde önemli bir rol oynayan sınıflandırıcıların ağırlıklarını belirlemek için çoğunluk oylaması yöntemini kullanır. Çoğunluk oylaması yöntemi, her bir sınıflandırıcının verdiği sonucun ağırlığının eşit olduğu varsayımını yapar. Bu varsayım, her sınıflandırıcının aynı doğruluk seviyesine sahip olduğu durumlarda geçerlidir. Ancak, heyelanların tahmini gibi karmaşık görevlerde, her sınıflandırıcının farklı doğruluk seviyelerine sahip olma olasılığı yüksektir. Bu durumda, çoğunluk oylaması yöntemi, daha doğru sonuçlar veren sınıflandırıcıların ağırlıklarını düşük olarak tahmin edebilir. Bu da yanlış tespitlerin artmasına ve heyelan riski taşıyan bölgelerin doğru şekilde belirlenmesinin zorlaşmasına neden olabilir.

Bu çalışmada, heyelan tahmini için bir model geliştirilmiştir. Önerilen model, RF, SVM ve ANN gibi üç farklı sınıflandırıcıyı içermektedir. Her bir sınıflandırıcı, heyelanın gerçekleşip gerçekleşmediğini belirlemek için 13 farklı parametre değeri kullanmaktadır. Bu parametreler, 2021 yılında yayınlanan bir makalede kullanılan heyelan tahmini veri setinden elde edilmiştir. Heyelanın etkilerini azaltmak için mevcut tahmin yöntemlerinde bir yenilik önerilmiştir. Bu çalışmada, çoğunluk oylaması yöntemi yerine HBROA kullanılarak sınıflandırıcıların ağırlıkları belirlenmiştir. HBROA algoritması, sınıflandırıcılardan gelen heyelan karar sisteminde kullanılan değerlerinin önem derecelerini belirlemek için kullanılmıştır. Bu yöntemle, heyelan tespiti için etkisi yüksek olan sınıflandırıcının değerlerinin önemi artırılmış ve etkisi düşük olan sınıflandırıcının önemi azaltılarak daha doğru tespitlerin yapılması ve yanlış tespitlerin önlenmesi hedeflenmiştir. Bu sayede, heyelan riski taşıyan bölgelerin doğru şekilde belirlenmesi ve ilgili önlemlerin alınması için daha kesin bir analiz sağlanmıştır.

Yeniliğimiz, çoğunluk oylaması yönteminin yerine HBROA algoritmasını kullanmamızdır. HBROA algoritması, sınıflandırıcıların ağırlıklarını belirlemek için daha doğru ve güvenilir bir yöntemdir. Bu algoritma, her sınıflandırıcının verdiği sonucun doğruluk seviyesini hesaba katarak ağırlıklarını belirler. Bu sayede, daha doğru tespitlerin yapılması ve yanlış tespitlerin önlenmesi sağlanır.

Literatürdeki boşlukları aşağıdaki gibi doldurulmaktadır:

- Heyelan tahmini için yeni bir topluluk öğrenme yapısı önerilmektedir. Bu yöntem, mevcut yöntemlere göre daha doğru ve güvenilir tahminler yapmaktadır
- Heyelan tahmininde sınıflandırıcıların ağırlıklarını belirlemek için yeni bir meta sezgisel algoritma önerilmektedir. Bu yöntem ile çoğunluk oylaması yöntemine göre daha doğru sonuçlar veren ağırlıklar üretilmektedir.

3. Materyal ve Metot (Materials and Methods)

3.1. Veri Seti (Data set)

Veri seti olarak, 2021 yılında yayınlanan bir makalede kullanılan heyelan veri seti kullanılmıştır [19]. Bu veri seti 13 sütundan oluşmaktadır bu sütunlar şu şekilde sıralanmaktadır: Landslide (Heyelan), Aspect (Bakı), Curvature (Eğrilik), Earthquake (Deprem), Elevation (Yükseklik), Flow (Akış), Lithology (Litoloji), NDVI, NDWI, Plan, Precipitation (Yağış), Profile (Profil), Slope (Eğim). Bu sütunlardan

Landslide (Heyelan) verileri 0 ve 1 olarak değişmektedir. Bu sütun heyelanın gerçekleşip gerçekleşmediğini belirtmektedir. Diğer tüm sütunlardaki veriler 1 ve 5 arasında değişen değerler almaktadır. Landslide (Heyelan) verileri diğer 12 sütundaki verilere göre değer alan etiket değerleridir. Veri seti toplam 1212 değerden oluşmaktadır. Etiket değeri olan Landslide (Heyelan) dışındaki diğer sütunlar aşağıdaki şekilde açıklanabilir.

Veri setinde heyelan yıkımında kullanılan tüm özellikleri tek tek ele alınmaktadır. Özellik bilgilerini jeologlar aracılığıyla toplanmıştır. Heyelan, büyük toprak kütesinin, kayaların veya malzemenin yokuş aşağı hareket etmesi anlamına gelir. Parametre yönü esas olarak iklimin durumu ile ilgilidir.

Aspect (Bakı) parametresi güneş ışığının yönünü, yağmur, nem toprak vb. parametreleri belirtmektedir. Heyelanları dolaylı olarak tetikleyen en önemli faktör olarak kabul edilmektedir. Jeolojide Curvature (Eğrilik), eğimde meydana gelen değişim anlamına gelmektedir. Eğimin kenarı keskin ise ortalama yüksek eğrilik ve ayrıca heyelan akışını arttırırken, kenar düzgünse düşük eğrilik olur. Earthquake (Deprem) yerin aniden sarsılması demektir. Çoğunlukla engebeli alanlar depremden daha çok etkilenir. Deprem olduğunda kararsız kayalar yokuş aşağı akar ve heyelan adını veririz. Yabancı ülkelerde meydana gelen heyelanların başlıca nedeni depremdir çünkü kayalar kütle olarak stabil değildir. Elevation (Yükseklik), deniz seviyesinden uzaklık anlamına gelir. Yüksek rakımlı alanlarda daha fazla heyelan olasılığı bulunmaktadır. Flow (Akış), kaya kütesinin veya malzemenin tıpkı su ve sonunda çökme gibi yüksek alandan alçak alana doğru hareket etmesi anlamına gelen bir heyelan türüdür. Lithology (Litoloji), yükseklik farklılıkları, eğimli eğim vb. ile ilgili merkezi bir bileşendir. NDVI standardize formu, normalleştirilmiş fark bitki örtüsü endeksidir; bu ne kadar kayalık alanın bitki örtüsüyle kaplı olduğu anlamına gelmektedir. Bitkiyle ve ağaçlarla kaplı alanlardaki heyelan riski olmayan alanlara göre daha azdır. NDWI standardize formu normalleştirilmiş fark su endeksidir. Plan, açılı kayanın kalabileceği açı anlamına gelir. Açının 45°'nin üzerinde olduğunu varsayalım, bu durumda heyelan meydana gelmelidir. Basit bir ifadeyle, plan dikey ise heyelan olasılığının daha fazla veya yatay olması durumunda daha az şans olduğunu söylenebilir. Precipitation (Yağış) kayalara zarar veren ve heyelanlara neden olan yağışlar içinde en sık olanı yağmurdur. Şiddetli yağışlar toprağın aşağı kaymasına neden olur, bunun nedeni toprağın suya doymasındır, bu da kayayı, toprağı, bitki örtüsünü veya araziye kaybeder, ayrıca moloz akışı olarak da bilinir. Profil, farklı kaya katmanları anlamına gelir ve birbiri üzerine binerler. Örnek: Yatay olması durumunda heyelan olasılığı daha az iken, dikey kayanın altında yatay olan bir kaya varsa o zaman heyelan meydana gelmelidir. Slope (Eğim), eğim veya düşüş açısı anlamına gelir. Elde edilen bu veriler, heyelan tespiti yapması hedeflenen modelin eğitiminde kullanılacaktır.

3.2. Performans metrikleri (Performance metrics)

Topluluk öğrenme ve temel öğrenenlerle oluşturulan önerilen modelin performansı, aşağıdaki performans ölçüm metriklerinin formülleri kullanılarak istatistiksel olarak sunulmuştur [55], [56].

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (3)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (4)$$

$$F1 \text{ Skor} = 2 \times \frac{\text{duyarlılık} \times \text{kesinlik}}{\text{duyarlılık} + \text{kesinlik}} \quad (5)$$

3.3. Ölüm Oyunu Optimizasyon Algoritması (Battle Royale Optimization Algorithm)

Ölüm Oyunu Optimizasyon algoritması, PlayerUnknown's Battlegrounds (PUBG) isimli oyundan esinlenilerek geliştirilmiştir [57]. PUBG oyununda, oyuncular uçaktan atlayarak oyun alanına gelirler. Güçlü konumda olan oyuncular, zayıf olanları etkisiz hale getirerek hayatta kalan son oyuncu olmaya çalışırlar. Aynı zamanda, oyun alanı daralmakta ve oyuncuları belirli bir bölgede toplamaktadır. Oyun alanının daralmasıyla birlikte daha iyi konumda olan oyuncu avantaj elde ederek diğer oyuncuları saf

dışı bırakabilir [58].

Ölüm Oyunu Optimizasyon algoritması, bir popülasyon tabanlı algoritmadır. Her oyuncu, popülasyonun bir üyesini temsil etmektedir. Popülasyon üyeleri, komşu askerlere zarar vermeye çalışır. Hasar alan askerlerin hasar seviyeleri Eş. 6'ya göre hesaplanır.

$$x_i.damage = x_i.damage + 1 \quad (6)$$

Burada x_i , i. askerin hasar seviyesini göstermektedir. Eğer i. asker komşu bir askere hasar verir veya hasar seviyesi belirli bir eşik değerini geçerse, hasar değeri sıfırlanır. Hasar alan asker, oyuna devam etmek için farklı bir konuma geçer. Bu durum, Eş. 7 kullanılarak sağlanır.

$$x_{damage,d} = x_{damage,d} + r(x_{best,d} - x_{damage,d}) \quad (7)$$

Burada $x_{damage,d}$, yaralanan askerin konumunu temsil ederken, $x_{best,d}$, şu ana kadar en iyi askerin konumunu göstermektedir. r, 0 ile 1 arasında rassal bir sayıdır. Eğer hasar seviyesi belirli eşik değerini aşarsa, asker öldürülür ve Eş. 8 kullanılarak oyuna farklı bir konumdan tekrar dahil edilir.

$$x_{damage,d} = r(u_d - l_d) + l_d \quad (8)$$

Burada u ve l, sırasıyla d-boyutlu problem uzayında üst ve alt sınırları ifade etmektedir. Askerler birbirleriyle çatışırken, aynı zamanda problem uzayı küçülür ve en iyi çözümü bulmaya çalışır. Bu süreç, Eş. 9'u kullanarak aşağıdaki şekilde gerçekleştirilir:

$$\phi = \phi + round(\frac{\phi}{2}) \quad (9)$$

Burada ϕ , iterasyon sayısını temsil etmektedir ve başlangıç değeri logaritmik olarak hesaplanır. Bu süreç devam ettikçe, alt ve üst sınırlar Eş. 10 ve Eş. 11 kullanılarak güncellenir:

$$l_d = x_{best,d} - SD(\bar{x}_d) \quad (10)$$

$$u_d = x_{best,d} + SD(\bar{x}_d) \quad (11)$$

Alt ve üst sınırlar olan l ve u değerleri, orijinal sınırları aştığında sınırların değerini alır. Ayrıca burada $SD(\bar{x}_d)$ değeri, d-boyutlu arama uzayında tüm popülasyonun standart sapmasını ifade eder. Tüm bu aşamalar, durdurma kriteri sağlanana kadar devam eder. İterasyonların sonunda, en iyi sonucu veren askerin konumu, problemin optimum çözümünü temsil eder.

3.4. Kullanılan sınıflandırıcılar ve topluluk öğrenme (Used classifiers and Ensemble Learning)

Bu çalışmada, temel sınıflandırıcılar olarak RF, SVM ve ANN sınıflandırıcıları kullanılmıştır. Veriler önce bu sınıflandırıcılar kullanılarak sınıflandırılmış, daha sonra bu üç sınıflandırıcıyı içeren bir topluluk öğrenme yöntemiyle sınıflandırılarak sonuçlar karşılaştırılmıştır.

Rastgele Orman, makine öğrenmesi alanında kullanılan bir sınıflandırma ve regresyon yöntemidir [59]. Birçok karar ağacının bir araya getirilmesiyle oluşturulan bir yöntemdir. Her bir karar ağacı, rastgele örneklerden oluşturulmuş alt kümelerle eğitilir ve ardından bu ağaçlar bir araya getirilerek sonuç üretilir. Rastgele Orman, veri setinin farklı özelliklerini değerlendirebilir, aşırı uydurma (overfitting) eğilimini azaltabilir ve genel olarak yüksek bir tahmin doğruluğuna sahip olabilir.

SVM, doğrusal olmayan bir sınıflandırma yöntemidir [60]. SVM, verileri bir hiperdüzlemde ayırmaya çalışır. Verilerin konumlarına göre, bir hiperdüzlem belirlenir ve verilerin bu düzleme göre pozisyonlarına göre sınıflandırılır. SVM, sınıflandırma kararını hiperdüzlemin pozisyonuna göre verir.

ANN, biyolojik nöronlardan esinlenerek oluşturulmuş yapay sinir ağlarıdır [61]. ANN, bir dizi gizli katman ve çıkış katmanı içerir. Veriler, giriş katmanından geçer ve her gizli katmanda özellikleri işlenir. Son katmanda, verilerin sınıfı belirlenir.

Topluluk öğrenme, bir dizi sınıflandırıcıyı bir araya getirerek, her birinin performansını artırmak için kullanılır [62]. Bu çalışmada, topluluk öğrenme yöntemi olarak bagging (torbalama) yöntemi kullanılmıştır. Bagging, rastgele örnekleme yöntemi kullanarak, farklı veri kümeleri oluşturur ve her

kümeyi ayrı bir sınıflandırıcıda kullanarak, sınıflandırma performansını artırmayı amaçlamaktadır.

3.5. Hibrit K-Means – Ölüm Oyunu Optimizasyon Algoritması (HBROA) (Hybrid K-Means – Battle Royale Optimization Algorithm (HBROA))

K-Means algoritması, verileri kümelerle ayırmak için kullanılan bir kümeleme algoritmasıdır [55], [63]. Amacı, veri noktalarını birbirine benzeyen gruplara bölmektir. Algoritma, veri noktalarının uzaklık ölçüsüne dayalı olarak en yakın merkeze atanması ve ardından bu merkezlerin güncellenmesi sürecini iteratif olarak gerçekleştirir.

Algoritmanın çalışma mantığı şu şekildedir: Başlangıçta, K adet rastgele merkez noktası seçilir. Daha sonra her veri noktası, en yakın merkeze atanır. Atama işlemi tamamlandıktan sonra, her bir kümenin merkezi, o kümeye ait veri noktalarının ortalaması olarak güncellenir. Bu adımlar, küme merkezlerindeki değişim olmadığı sürece tekrarlanır [55]. K-means algoritmasının amaç fonksiyonu Eş. 12’de verilmiştir.

$$j = \sum_{j=1}^k \sum_{i=1}^n \|mesafe\|^2 \quad (12)$$

Burada mesafe $x_i^{(j)} - c_j$ arasındaki farktır. Amaç en düşük j değerini bularak veri noktalarını $x_i^{(j)}$ en yakın merkez noktasına c_j yerleştirmektir.

K-means algoritmasıyla Ölüm Oyunu Optimizasyon Algoritmaları, lokal optimum problemini aşma ve kümeleme başarısını artırma amacıyla birleştirilmiştir. İlk aşamada, verinin tüm boyutlarına rastgele üretilmiş bir ağırlık uygulanmaktadır, bu amaçla 0 ile 1 arasında ölçeklendirilmektedir. Bu işlem için verinin boyutu kadar bir ağırlık havuzu W oluşturulmuştur. Ağırlık havuzu, Ölüm Oyunu Optimizasyon Algoritmalarının optimize edeceği değerleri içermektedir. Heyelanın belirlenmesindeki başarı derecesine göre her bir W_i değeri, Ölüm Oyunu Optimizasyon algoritması tarafından belirlenmektedir.

Verinin tüm boyutları (X_n) (Sınıflandırma algoritmalarının bulduğu değerler), bir ağırlık parametresi (W_m) ile çarpılarak önceliklendirilir ($X_{n,m} = W_m * X_{n,m}$). Bu işlemle, her boyutun önemi belirlenir ve ağırlıklandırılır. Burada n toplam veri sayısını, m ise verinin boyutunu temsil etmektedir. Ardından, Eş. 13 kullanılarak verilerin merkez noktaları hesaplanır.

$$C_k = \frac{\sum_{n=1}^N a_{n,k} * X_n}{\sum_{n=1}^N a_{n,k}}, \quad a_{n,k} = \begin{cases} 1 & y_n = k \\ 0 & y_n \neq k \end{cases}, \quad k = 1, 2, \dots, K \quad (13)$$

Burada a, 0 ile 1 arasında rastgele oluşturulmuş bir sayıdır. k, küme sayısını temsil ederken, y_n , verinin bilinen gerçek kümesini ifade etmektedir. Eğer verinin değeri k. kümeyle ilişkilendiriliyorsa, a değeri 1 alır. Ardından, k. kümenin elemanları toplanarak k. kümenin merkez noktası bulunur. Bu süreç, tüm kümelerin merkez noktaları bulunana kadar devam eder daha sonra Eş. 14 kullanılarak verilerin hangi kümeye ait olduğu belirlenir.

$$f_n = k \text{ if } \min(|x_n - c_1|, |x_n - c_2|, \dots, |x_n - c_K|) \quad (14)$$

Veriler, merkez noktalarına olan yakınlıklarına göre atanır. Bu işlemde f_n , verilerin hangi kümeye ait olduğunu göstermektedir. İşlenen verilerle birlikte, optimum sonucu veren ağırlık değerleri bulunur. Amaç fonksiyonu Eş. 15’te verilmiştir.

$$\max f(v) = \frac{100}{N} * \sum_{n=1}^N b_n, \quad b_n = \begin{cases} 1 & y_n = f_n \\ 0 & y_n \neq f_n \end{cases} \quad (15)$$

Bulunan değer ile gerçek değer eşit olduğunda, b değeri 1 olarak belirlenir. Aksi durumda, b, 0 değerini alır. Bu aşamalar, sonlandırma kriteri sağlanana kadar devam eder. Ardından, optimum sonucu sağlayan ağırlık değerleri bulunur.

Sınıflandırıcıların ağırlıklarını belirlemek için HBROA algoritması önerilmiştir. HBROA algoritmasını ve sınıflandırıcı sonuçlarını kullanarak optimum ağırlık tahminlerini gerçekleştiren modelin yapısı Şekil 3’te verilmiştir. Bu çalışmada, çoğunluk oylaması yöntemi yerine farklı bir teknik uygulanmıştır. Sınıflandırıcılardan gelen heyelan karar sisteminde kullanılan parametre değerlerinin önem dereceleri,


Ölüm Oyunu Optimizasyon algoritması tarafından belirlenerek daha başarılı bir tahmin işlemi gerçekleştirilmiştir. Bu yöntemle, heyelan tespiti için etkisi yüksek olan parametre değerlerinin önem derecesi artırılmış veya etkisi düşük olan parametrelerin önem derecesi azaltılarak daha doğru tespitlerin konulması ve yanlış tespitlerin önlenmesi amaçlanmıştır.



Şekil 3. HBROA kullanarak optimum ağırlıkların belirlenmesi
(Determining optimum weights using HBROA)

3.6. Önerilen model (Proposed model)


Bu makalede, bir topluluk öğrenme modeli kullanarak sınıflandırma performansını artırmak için RF, SVM ve ANN yöntemlerinin OPAT yöntemiyle birleştirilerek bir topluluk öğrenme modeli oluşturulmuştur. Optimum ağırlıklı oylama işlemi için önce sınıflandırıcılar bireysel olarak eğitilmiş ve test verisi üzerindeki olasılıksal sonuçları kaydedilmiştir. Daha sonra her sınıflandırıcıya ait olasılıksal sonuç ile gerçek çıktı değeri kullanılarak her sınıflandırıcıya optimum ağırlık değeri ataması yapılmıştır. Bu ağırlık değerleri, yine bu çalışmada önerilen HBROA algoritması yardımıyla belirlenmiştir. OPAT yöntemi ile her sınıflandırıcıdan gelen sonuca eşit ağırlık vermek yerine HBROA algoritması yardımıyla belirlenen optimum ağırlıklar ile çarpılarak nihai sonuca ulaşılmıştır. Önerilen model Şekil 4'te verilmiştir. Ayrıca önerilen bu model ile, topluluk öğrenme yöntemlerinde kullanılan Çoğunluk Oylaması yöntemi karşılaştırılmıştır. Bu yöntemde, sınıflandırıcıların çoğunluğunun seçtiği sınıf, topluluk öğrenme modelinin sonucu olarak kabul edilmektedir. Dolayısıyla her veri için tüm sınıflandırıcılara eşit ağırlık verildiği için sınıflandırıcıların güçlü yanlarını kullanmak zorlaşmaktadır.



Şekil 4. OPAT modelinin yapısı
(Structure of the OPAT model)

Eğitim sürecinde her sınıflandırıcı için veri seti %80 eğitim ve %20 test seti olarak ayrılmıştır. RF sınıflandırıcı için rastgele orman oluşturmak için ağaç sayısı 200 olarak verilmiştir. SVM için ise durma kriteri toleransı 1e-4 olarak belirlenmiştir. ANN için ise Şekil 5'teki ağ mimarisi kullanılarak 0.001 öğrenme oranıyla eğitim yapılmıştır. Kayıp fonksiyonu olarak Eş. 16'da formülü verilen ikili çapraz entropi kullanılmıştır. Kayıp fonksiyonunun optimizasyonu için ADAM optimizasyon algoritması kullanılmıştır.

$$L_{BCE} = -\frac{1}{n} \sum_{i=1}^n (Y_i \cdot \log \hat{Y}_i + (1 - Y_i) \cdot \log(1 - \hat{Y}_i)) \quad (16)$$



Şekil 5. ANN için kullanılan ağ mimarisi
(Network architecture used for ANN)

Sınıflandırıcıların ağırlıklarını rassal olarak belirlemek yerine optimum ağırlıkları veren HBROA algoritması kullanılmıştır. Bu çalışmada, çoğunluk oylaması yöntemi yerine farklı bir teknik uygulanmıştır. Sınıflandırıcılardan gelen heyelan karar sisteminde kullanılan parametre değerlerinin önem dereceleri, Ölüm Oyunu Optimizasyon algoritması tarafından belirlenerek daha başarılı bir tahmin işlemi gerçekleştirilmiştir. Bu yöntemle, heyelan tespiti için etkisi yüksek olan sınıflandırıcı tahminlerinin önem derecesi artırılmış veya etkisi düşük olan parametrelerin önem derecesi azaltılarak daha doğru tespitlerin konulması ve yanlış tespitlerin önlenmesi amaçlanmıştır. Sonuç olarak, K-means algoritmasının lokal optimuma takılıp kalma sorunu giderilmiş ve aynı zamanda katsayıların optimize edilmesiyle kümeleme yönteminin başarısı artırılmıştır.

4. Deneyisel Sonuçlar (Experimental Results)

Ölüm Oyunu Optimizasyon algoritması ve K-means algoritmalarının kullanımıyla yeni bir gelişmiş heyelan tahmin modeli geliştirilmiştir. Ölüm Oyunu Optimizasyon algoritması için "cross type" parametresi 1 olarak belirlenmiş ve "max fault" parametresi 4 olarak seçilmiştir. Ayrıca, popülasyon sayısı 40 ve iterasyon sayısı 100 olarak belirlenmiştir. Geliştirilen model, 15 kez çalıştırılmış ve en başarılı sonucu veren ağırlık değerleri kullanılmıştır. Elde edilen veri seti için RF, SVM ve ANN sınıflandırıcılarından gelen sonuçlarla birlikte Ölüm Oyunu Optimizasyon algoritmasıyla bulunan ağırlık değerleri Tablo 1'de sunulmaktadır.

Tablo 1. HBROA modelinin bulduğu ağırlık değerleri (The weight values determined by the HBROA model)

Sınıflandırıcı (Ağırlık)	HBROA Optimum Ağırlık Değerleri
RF (ω_1)	0,1499475
SVM (ω_2)	0,4605725
ANN (ω_3)	0,390079

Test veri setinin X_{test} isimli girdileri kullanılarak her bir sınıflandırıcıdan 0 ve 1 arasında tahmin değerleri alınmıştır. Daha sonra bu tahmin değerleri Eş. 17'de gösterildiği şekilde ağırlıklandırılarak, Eş. 18'de gösterilen, sonuç vektörü olan $\bar{Y}$ elde edilmiştir. Son olarak $\bar{Y}$ ile test veri setindeki gerçek sonuçları içeren Y_{test} karşılaştırılarak önerilen yöntemin performansı hesaplanmıştır.

$$\delta_i = R_i \cdot \omega_1 + S_i \cdot \omega_2 + A_i \cdot \omega_3 \quad (17)$$

$$\bar{Y}_i = \begin{cases} 1, & \delta_i \geq 0.5 \\ 0, & otherwise \end{cases} \quad (18)$$

Bu eşitliklerde R_i , S_i ve A_i sırasıyla RF, SVM ve ANN sınıflandırıcılar ile test veri seti üzerinde elde edilen tahmin vektörlerini ifade etmektedir. Her bir tahmin değeri 0 ve 1 arasında değişmektedir. İndeks değeri olan i , 0 ile test veri setindeki toplam eleman sayısı olan N arasında değerler almaktadır. ω_1, ω_2 ve ω_3 değerleri, sınıflandırıcılar için HBROA algoritması kullanılarak elde edilen ağırlık değerlerini ifade etmektedir. δ , her bir test girdisi için elde edilen ağırlıklı toplamı yani nihai tahmin değerini, $\bar{Y}$ ise bu nihai tahmin değerlerinin tamamını içeren sonuç vektörünü ifade etmektedir.

Bu kısımda, önceki bölümde detaylı şekilde açıklanan veri seti ile eğitilen sınıflandırıcıların ve önerilen modelin belirtilen performans metriklerine göre sonuçları incelenmektedir. Şekil 6-10'da üç temel sınıflandırıcıya ve topluluk öğrenme yöntemine ait sonuçların karmaşıklık matrisi verilmektedir. RF sınıflandırıcıya ait karmaşıklık matrisi Şekil 6'da görülmektedir.

RF			
GERÇEK \ TAHMİN	Heyelan Var	Heyelan Yok	TOPLAM
Heyelan Var	80 32.92%	28 11.52%	108 74.07% 25.93%
Heyelan Yok	25 10.29%	110 45.27%	135 81.48% 18.52%
TOPLAM	105 76.19% 23.81%	138 79.71% 20.29%	190 / 243 78.19% 21.81%

Şekil 6. Rastgele Orman sınıflandırıcıya ait karmaşıklık matrisi
(Confusion matrix of RF classifier)

Yukarıdaki şekilde, RF sınıflandırıcıya ait TP oranının nispeten düşük, FN oranının ise yüksek olduğu görülmektedir. Bu durum, Doğruluk ve Duyarlılık metriklerinin düşük olmasına sebep olmaktadır. Ancak TN değeri diğer iki sınıflandırıcıya göre daha yüksek ve FP değeri de daha düşüktür. Bu durum Özgüllük metriğinin yüksek değer almasını sağlasa da F1-Skor ve Doğruluk gibi iki önemli kriterde diğer sınıflandırıcıların altında kalmasına engel olamamıştır. Şekil 7'de SVM sınıflandırıcıya ait karmaşıklık matrisi verilmiştir.

SVM			
GERÇEK \ TAHMİN	Heyelan Var	Heyelan Yok	TOPLAM
Heyelan Var	87 35.80%	34 13.99%	121 71.90% 28.10%
Heyelan Yok	18 7.41%	104 42.80%	122 85.25% 14.75%
TOPLAM	105 82.86% 17.14%	138 75.36% 24.64%	191 / 243 78.60% 21.40%

Şekil 7. SVM sınıflandırıcıya ait karmaşıklık matrisi
(Confusion matrix of SVM)

SVM sınıflandırıcı, diğer sınıflandırıcılara göre daha yüksek TP değerine ve daha düşük FN değerine sahiptir. Yukarıdaki şekilde incelendiğinde, SVM sınıflandırıcının çoğu veriyi pozitif olarak

sınıflandırma eğiliminde olduğu görülmektedir. Bu durum Duyarlılık değerinin yüksek çıkmasını sağlasa da FP oranı çok yüksek olduğu için Kesinlik değerinin çok düşmesine neden olmuştur. Genel olarak bakıldığında ise nispeten iyi bir F1-Skor değerine sahip olsa da Doğruluk olarak istenen seviyeye ulaşmamıştır. Şekil 8’de ANN sınıflandırıcıya ait karmaşıklık matrisi verilmiştir.

ANN			
GERÇEK \ TAHMİN	Heyelan Var	Heyelan Yok	TOPLAM
Heyelan Var	85 34.98%	31 12.76%	116 73.28% 26.72%
Heyelan Yok	20 8.23%	107 44.03%	127 84.25% 15.75%
TOPLAM	105 80.95% 19.05%	138 77.54% 22.46%	192 / 243 79.01% 20.99%

Şekil 8. ANN sınıflandırıcıya ait karmaşıklık matrisi
(Confusion matrix of ANN)

Karmaşıklık matrisine bakıldığında ANN sınıflandırıcısının, diğer iki sınıflandırıcıya kıyasla daha dengeli sonuçlar verdiği görülmektedir. Bu tutarlı ve doğru sonuçlar Duyarlılık ve Kesinlik değerlerini de önceki sınıflandırıcılara kıyasla dengelemiş ve Doğruluk değerini de artırmıştır. Bu sınıflandırıcılardan alınan tahminlerin çoğunluk oylaması yöntemiyle yeniden değerlendirilmesi sonucunda elde edilen tahmin değerlerine yönelik sonuçlar Şekil 9’da gösterilmektedir.

ÇOĞUNLUK OYLAMASI			
GERÇEK \ TAHMİN	Heyelan Var	Heyelan Yok	TOPLAM
Heyelan Var	82 33.74%	26 10.70%	108 75.93% 24.07%
Heyelan Yok	23 9.47%	112 46.09%	135 82.96% 17.04%
TOPLAM	105 78.10% 21.90%	138 81.16% 18.84%	194 / 243 79.84% 20.16%


Şekil 9. Çoğunluk Oylaması yöntemine ait karmaşıklık matrisi
(Confusion matrix of majority voting method)

Çoğunluk oylaması yöntemi, sınıflandırıcıların güçlü yönlerinin kullanılması ve zayıf yönlerinin getirdiği performans düşüklüğünün giderilmesine dayanan bir topluluk öğrenme yöntemidir. Yukarıdaki şekilde görülmektedir ki topluluk öğrenme yöntemi, sınıflandırıcıların güçlü yönlerini kullanma konusunda oldukça başarılı olmuştur. Çoğunluk oylaması yöntemi ile TN değerlerin arttığı, FP değerlerin ise azaldığı görülmektedir. Yani gerçekte negatif değere sahip olan verilerin tahmininde çok daha iyi bir performans gösterilmiştir. Bu durum Özgüllük ve Doğruluk değerlerine de yansımıştır. Bu çalışmada, her sınıflandırıcıya eşit ağırlık veren Çoğunluk Oylaması yöntemi yerine OPAT yöntemi sunulmaktadır. Önerilen modele ait karmaşıklık matrisi Şekil 10’da görülmektedir.

ÖNERİLEN MODEL			
GERÇEK \ TAHMİN	Heyelan Var	Heyelan Yok	TOPLAM
Heyelan Var	89 36.63%	28 11.52%	117 76.07% 23.93%
Heyelan Yok	16 6.58%	110 45.27%	126 87.30% 12.70%
TOPLAM	105 84.76% 15.24%	138 79.71% 20.29%	199 / 243 81.89% 18.11%

Şekil 10. Önerilen modele ait karmaşıklık matrisi
(Confusion matrix of proposed model)

Yukarıdaki karmaşıklık matrisinde, önerilen OPAT yönteminin Çoğunluk Oylaması yöntemine kıyasla TP oranını yükselttiği, FN oranını düşürdüğü ve bu sebeple oldukça yüksek bir Duyarlılık değerine ulaştığı görülmektedir. Bunlara ek olarak TN ve FP değerleri de temel sınıflandırıcılara kıyasla daha iyi seviyededir. Sonuç olarak görülmektedir ki önerilen model tahmin doğruluğunu yani Doğruluk değerini %81,89 gibi oldukça iyi bir seviyeye çıkarmıştır. Ayrıca F1-Skor değeri olarak da karşılaştırılan tüm yöntemlerden daha iyi bir sonuç vermiştir. Bu sonuçlara ek olarak, temel sınıflandırıcıların eğitim grafikleri Şekil 11’de görülebilmektedir.



Şekil 11. Temel sınıflandırıcılara ait öğrenme eğrileri
(Learning curves of basic classifiers)

Yukarıdaki öğrenme eğrilerine bakıldığında RF ve SVM sınıflandırıcıların eğitimleri sırasında doğruluk değerinin hızlı bir şekilde yükseldiği, ancak daha sonra öğrenme işleminin yavaşladığı görülmektedir. ANN sınıflandırıcıda ise nispeten daha yavaş bir doğruluk artışı olduğu ve değişken bir doğruluk değeri olduğu görülmektedir.

Karmaşıklık matrislerindeki değerler ve önceki bölümde belirtilen performans metrikleri kullanılarak sınıflandırma yöntemlerinin performansları karşılaştırılmıştır. Bu karşılaştırma Tablo 2’de görülebilmektedir.

Tablo 2. Sınıflandırma yöntemlerinin performansları (Performances of classification methods)

Model	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor
RF	0,7819	0,7619	0,7971	0,7407	0,7511
SVM	0,7860	0,8286	0,7536	0,7190	0,7699
ANN	0,7901	0,8095	0,7754	0,7328	0,7692
Çoğunluk Oylaması	0,7984	0,7810	0,8116	0,7593	0,7700
OPAT(Önerilen)	0,8189	0,8476	0,7971	0,7607	0,8018

Yukarıdaki tabloda görüldüğü üzere topluluk öğrenme yöntemleri, bireysel sınıflandırıcıların performanslarını daha da geliştirerek daha iyi bir sonuç elde etmektedir. Bunun yanında Çoğunluk Oylaması yöntemine kıyasla önerilen OPAT yöntemi daha iyi bir performans göstermiştir. Bu sonuçlara göre, optimize edilmiş ağırlıkların kullanımıyla temel sınıflandırıcıların güçlü yanlarının daha baskın olmasının sağlandığı görülmektedir.

Kullanılan veri setinin alındığı makalede, veri setini sınıflandırmak için farklı yöntemler denenmiştir ve bu yöntemlerden en iyi sonuç veren CNN ve Lineer Regresyon modellerini içeren yöntem olmuştur. Bu yöntem ile veri setinin sınıflandırılma doğruluğu %81,677 olarak bulunmuştur [26]. Tablodan elde edilen sonuçlar göstermektedir ki, her ne kadar bireysel sınıflandırıcıların elde ettiği sonuçlar bu doğruluk değerinin altında kalsa da meta sezgisel optimizasyon algoritması olan Ölüm Oyunu Optimizasyon algoritması ile elde edilen ağırlık değerleri ile sınıflandırıcıların ürettiği olasılık değerleri çarpılarak üretilen nihai sonuç kullanıldığında %81,89 ile referans makalede önerilen yöntemden daha yüksek bir sınıflandırma doğruluğuna ulaşılmaktadır. Bu çalışmada ve bahsedilen çalışmada kullanılan yöntemlere ait doğruluk değerlerinin karşılaştırması Tablo 3'te gösterilmektedir.

Tablo 3. Kullanılan yöntemlerin karşılaştırılması (Comparison of the applied methods)

Yöntem	Doğruluk (%)
RF	78,19
SVM	78,60
CNN-RF [19]	79,83
CNN-SVM [19]	81,21
CNN-LR [19]	81,67
Çoğunluk Oylaması	79,84
OPAT(Önerilen)	81,89

Elde edilen sonuçlar göstermektedir ki, önerilen optimum ağırlıklı oylamaya dayalı topluluk öğrenme modeli, literatürde bu alanda yapılan çalışmalara göre daha yüksek sınıflandırma doğruluğu sağlamaktadır. Bu yöntem sayesinde birden fazla sınıflandırıcının güçlü yönlerinin kullanılarak nihai sınıflandırma yapılmıştır ve bunun sonucunda sınıflandırıcılardan alınan sonuçları eşit olarak değerlendiren yöntemlerden daha iyi bir performans elde edilmiştir.

5. Sonuçlar (Conclusions)

Heyelanların önceden tahmin edilmesi, doğal afetlerin etkilerinin azaltılması açısından oldukça önemlidir. Can ve mal kayıplarının önüne geçebilecek olan erken uyarı sistemleri hayati önem taşımaktadır. Bu çalışmada heyelan oluşmasında etkili olan parametreleri kullanarak heyelanların tahmin edilmesine yönelik bir topluluk öğrenme modeli oluşturulmuştur. Ayrıca yapılan tahminlerin doğruluğunu artırmak için yeni bir topluluk öğrenme yöntemi önerilmiştir. Önerilen OPAT yönteminin minimum hata ile tahmin yapmasını sağlamak için sınıflandırıcı ağırlıkları hibrit bir meta sezgisel algoritma olan HBROA kullanılarak belirlenmiştir.

Çalışmada temel sınıflandırıcılar olarak RF, SVM ve ANN sınıflandırıcılar kullanılmış ve bu sınıflandırıcılardan alınan sonuçlar bagging (torbalama) isimli topluluk öğrenme yöntemi kullanılarak birleştirilmiştir. Önerilen yöntem, %81,89 doğruluk oranı ile hem temel sınıflandırıcıları hem de literatürdeki diğer yöntemleri geride bırakmıştır. Temel sınıflandırıcıların ve önerilen yöntemin sonuçları analiz edildiğinde her temel sınıflandırıcının farklı güçlü ve zayıf yönler sahip olduğu görülmüştür. Ancak önerilen topluluk öğrenme yöntemi ile zayıf yönler tolere edilerek daha iyi tahminler yapılmış ve daha yüksek doğruluğa ulaşılmıştır. Sonuç olarak, bu çalışmada farklı sınıflandırıcı yöntemleri kullanılmış, topluluk öğrenme yönteminin etkisi incelenmiş ve meta sezgisel algoritmalara dayalı yeni bir topluluk öğrenme yöntemi önerilmiştir. Bu yeni yöntem ile heyelan oluşabilecek bölgelerin daha yüksek doğrulukla önceden tespit edilmesi ve meydana gelebilecek zararların önüne geçilmesi hedeflenmiştir.

Teşekkür (Acknowledgment)

Yazarlar, makalenin kalitesinin önemli ölçüde artırılmasına katkı sağlayan değerli öneri ve yorumları için editör ve hakemlere teşekkür eder.

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

Kaynaklar (References)

- [1] R. Ali, A. Kuriqi, and O. Kisi, "Human-environment natural disasters interconnection in China: a review," *Climate*, vol. 8, no. 4, p. 48, 2020.
- [2] Z. Guo, L. Chen, K. Yin, D. P. Shrestha, and L. Zhang, "Quantitative risk assessment of slow-moving landslides from the viewpoint of decision-making: A case study of the Three Gorges Reservoir in China," *Eng. Geol.*, vol. 273, p. 105667, 2020.
- [3] S. N. R. Jamalullail, S. Sahari, A. A. Shah, and N. Batnanathan, "Preliminary analysis of landslide hazard in Brunei Darussalam, SE Asia," *Environ. Earth Sci.*, vol. 80, no. 16, p. 512, 2021.
- [4] L. Yan, Q. Gong, F. Wang, L. Chen, D. Li, and K. Yin, "Integrated Methodology for Potential Landslide Identification in Highly Vegetation-Covered Areas," *Remote Sens. (Basel)*, vol. 15, no. 6, p. 1518, 2023.
- [5] P. Redshaw and J. Bottomley, "The Global Landslide Hazard Map," Jun. 2020.
- [6] The World Bank, "The World Bank - Data Catalog." Accessed: Oct. 14, 2023. [Online]. Available: <https://datacatalog.worldbank.org/search/dataset/0037584/Global-landslide-hazard-map>
- [7] M. Calvellido et al., "LandAware: a new international network on Landslide Early Warning Systems," 2020, Springer.
- [8] L. Piciullo, D. Tiranti, G. Pecoraro, J. M. Cepeda, and M. Calvellido, "Standards for the performance assessment of territorial landslide early warning systems," *Landslides*, vol. 17, pp. 2533–2546, 2020.
- [9] F. Abbas et al., "Landslide Susceptibility Mapping: Analysis of Different Feature Selection Techniques with Artificial Neural Network Tuned by Bayesian and Metaheuristic Algorithms," *Remote Sens. (Basel)*, vol. 15, no. 17, p. 4330, 2023.
- [10] I. W. Diara, R. Suyarto, and M. Saifulloh, "Spatial Distribution Of Landslide Susceptibility In New Road Construction Mengwitani-Singaraja, Bali-Indonesia: Based On Geospatial Data," *Geomate Journal*, vol. 23, no. 96, pp. 95–103, 2022.
- [11] H. Wang, L. Zhang, K. Yin, H. Luo, and J. Li, "Landslide identification using machine learning," *Geoscience Frontiers*, vol. 12, no. 1, pp. 351–364, 2021.
- [12] V. C. SS and E. Shaji, "Landslide identification using machine learning techniques: Review, motivation, and future prospects," *Earth Sci. Inform.*, vol. 15, no. 4, pp. 2063–2090, 2022.
- [13] D. Sun, H. Wen, D. Wang, and J. Xu, "A random forest model of landslide susceptibility mapping based on hyperparameter optimization using Bayes algorithm," *Geomorphology*, vol. 362, p. 107201, 2020.
- [14] X. Zhou, H. Wen, Y. Zhang, J. Xu, and W. Zhang, "Landslide susceptibility mapping using hybrid random forest with GeoDetector and RFE for factor optimization," *Geoscience Frontiers*, vol. 12, no. 5, p. 101211, 2021.
- [15] W. Xie, W. Nie, P. Saffari, L. F. Robledo, P.-Y. Descote, and W. Jian, "Landslide hazard assessment based on Bayesian optimization-support vector machine in Nanping City, China," *Natural Hazards*, vol. 109, no. 1, pp. 931–948, 2021.
- [16] J. Dou et al., "Improved landslide assessment using support vector machine with bagging, boosting, and stacking ensemble machine learning framework in a mountainous watershed, Japan," *Landslides*, vol. 17, pp. 641–658, 2020.
- [17] A. M. Rajabi, M. Khodaparast, and M. Mohammadi, "Earthquake-induced landslide prediction using back-propagation type artificial neural network: case study in northern Iran," *Natural Hazards*, vol. 110, no. 1, pp. 679–694, 2022.
- [18] D. Zhang, J. Yang, F. Li, S. Han, L. Qin, and Q. Li, "Landslide risk prediction model using an attention-based temporal convolutional network connected to a recurrent neural network," *IEEE Access*, vol. 10, pp. 37635–37645, 2022.
- [19] B. Aslam, A. Zafar, and U. Khalil, "Development of integrated deep learning and machine learning algorithm for the assessment of landslide hazard potential," *Soft comput.*, vol. 25, pp. 13493–13512, 2021.
- [20] F. Sabaz, Ü. Atilla, M. Dörterler, and A. Uçan, "Challenges and enhancements in Turkish automatic lip reading using deep learning models," *Signal Image Video Process.*, vol. 20, no. 4, p. 237, 2026.
- [21] E. Şahin and D. Özdemir, "ThinkSTra: a transformer-driven architecture for decoding imagined speech from EEG with spatial-temporal dynamics," *Med. Biol. Eng. Comput.*, pp. 1–26, 2025.
- [22] S. Dörterler, E. Şahin, and D. Özdemir, "A dynamic subject-invariant fragment mixing strategy to suppress subject variability in EEG imagined speech classification," *Neuroscience*, 2026.
- [23] S. Dörterler, E. Şahin, and D. Özdemir, "Evaluating Scene Text Recognition Models Through Multidimensional Error Analysis: Insights from Turkish Scene Text Data," *Gazi Journal of Engineering Sciences*, vol. 11, no. 3, pp. 494–517, 2025.
- [24] I. Fustos-Toribio, N. Manque-Roa, D. Vásquez Antipan, M. Hermosilla Sotomayor, and V. Letelier Gonzalez, "Rainfall-induced landslide early warning system based on corrected mesoscale numerical models: an application for the southern Andes," *Natural Hazards and Earth System Sciences*, vol. 22, no. 6, pp. 2169–2183, 2022.
- [25] F. Guzzetti et al., "Geographical landslide early warning systems," *Earth. Sci. Rev.*, vol. 200, p. 102973, 2020.
- [26] B. Ahmed et al., "Developing a dynamic Web-GIS based landslide early warning system for the Chittagong Metropolitan Area, Bangladesh," *ISPRS Int. J. Geoinf.*, vol. 7, no. 12, p. 485, 2018.
- [27] W. Chen, C. Zhong, X. Qin, and L. Wang, "Geological Disaster: An Overview," *Intelligent Interpretation for Geological Disasters: From Space-Air-Ground Integration Perspective*, pp. 1–23, 2023.
- [28] H. Thirugnanam, M. V. Ramesh, and V. P. Rangan, "Enhancing the reliability of landslide early warning systems by machine learning," *Landslides*, vol. 17, pp. 2231–2246, 2020.
- [29] N. Hongtao, "Smart safety early warning model of landslide geological hazard based on BP neural network," *Saf. Sci.*, vol. 123, p. 104572, 2020.
- [30] W. Zhang, "Geological disaster monitoring and early warning system based on big data analysis," *Arabian Journal of*

Geosciences, vol. 13, no. 18, p. 946, 2020.

- [31] W. Luo et al., "A Novel Hybrid LMD-ETS-TCN Approach for Predicting Landslide Displacement Based on GPS Time Series Analysis," *Remote Sens. (Basel)*, vol. 15, no. 1, p. 229, 2022.
- [32] T. Hemalatha, M. V. Ramesh, and V. P. Rangan, "Effective and accelerated forewarning of landslides using wireless sensor networks and machine learning," *IEEE Sens. J.*, vol. 19, no. 21, pp. 9964–9975, 2019.
- [33] E. Collini, L. A. I. Palesi, P. Nesi, G. Pantaleo, N. Nocentini, and A. Rosi, "Predicting and understanding landslide events with explainable AI," *IEEE Access*, vol. 10, pp. 31175–31189, 2022.
- [34] C. W. W. Ng, B. Yang, Z. Q. Liu, J. S. H. Kwan, and L. Chen, "Spatiotemporal modelling of rainfall-induced landslides using machine learning," *Landslides*, vol. 18, pp. 2499–2514, 2021.
- [35] R. Franceschini, A. Rosi, F. Catani, and N. Casagli, "Exploring a landslide inventory created by automated web data mining: the case of Italy," *Landslides*, vol. 19, no. 4, pp. 841–853, 2022.
- [36] X. Qian, "Regional Geological Disasters Emergency Management System Monitored by Big Data Platform," *Processes*, vol. 10, no. 12, p. 2741, 2022.
- [37] X. Chen, "Early Warning of Regional Landslide Disaster and Development of Rural Ecological Industrialization Based on IoT Sensor," *Sci. Program*, vol. 2022, 2022.
- [38] F. Aydemir and S. Arslan, "Covid-19 pandemi sürecinde çocukların el yıkama alışkanlığının nesnelerin interneti tabanlı sistem ile izlenmesi," *Mühendislik Bilimleri ve Araştırmaları Dergisi*, vol. 3, no. 2, pp. 161–168, 2021.
- [39] C. V. L. Pennington et al., "A near-real-time global landslide incident reporting tool demonstrator using social media and artificial intelligence," *International Journal of Disaster Risk Reduction*, vol. 77, p. 103089, 2022.
- [40] G. Herrera et al., "Landslide databases in the Geological Surveys of Europe," *Landslides*, vol. 15, pp. 359–379, 2018.
- [41] K. Sassa and P. Canuti, *Landslides-disaster risk reduction*. Springer Science & Business Media, 2008.
- [42] B. Rosser, S. Dellow, S. Haubrock, and P. Glassey, "New Zealand's national landslide database," *Landslides*, vol. 14, pp. 1949–1959, 2017.
- [43] C. S. Juang, T. A. Stanley, and D. B. Kirschbaum, "Using citizen science to expand the global map of landslides: Introducing the Cooperative Open Online Landslide Repository (COOLR)," *PLoS One*, vol. 14, no. 7, p. e0218657, 2019.
- [44] M. J. Froude and D. N. Petley, "Global fatal landslide occurrence from 2004 to 2016," *Natural Hazards and Earth System Sciences*, vol. 18, no. 8, pp. 2161–2181, 2018.
- [45] Q. Han, K. Sassa, and M. Mikoš, "International programme on landslides (ipl): a programme of the icl for landslide disaster risk reduction," *Understanding and Reducing Landslide Disaster Risk: Volume 1 Sendai Landslide Partnerships and Kyoto Landslide Commitment 5th*, pp. 187–203, 2021.
- [46] A. C. Teodoro and L. Duarte, "The synergy of remote sensing and geographical information systems in the management of natural disasters," in *Nanotechnology-Based Smart Remote Sensing Networks for Disaster Prevention*, Elsevier, 2022, pp. 217–230.
- [47] Z. Yang, J. Li, J. Hyppä, J. Gong, J. Liu, and B. Yang, "A comprehensive and up-to-date web-based interactive 3D emergency response and visualization system using Cesium Digital Earth: taking landslide disaster as an example," *Big Earth Data*, pp. 1–23, 2023.
- [48] M. N. I. Sarker, Y. Peng, C. Yiran, and R. C. Shouse, "Disaster resilience through big data: Way to environmental sustainability," *International Journal of Disaster Risk Reduction*, vol. 51, p. 101769, 2020.
- [49] K. Goniewicz et al., "Geographic information system technology: review of the challenges for its establishment as a major asset for disaster and emergency management in Poland," *Disaster Med. Public Health Prep.*, vol. 15, no. 5, pp. 573–578, 2021.
- [50] C. Nefros, G. Kitsara, and C. Loupasakis, "Geographical Information Systems and Remote Sensing Techniques to Reduce the Impact of Natural Disasters in Smart Cities," *IFAC-PapersOnLine*, vol. 55, no. 11, pp. 72–77, 2022.
- [51] P. V. Gorsevski, M. K. Brown, K. Panter, C. M. Onasch, A. Simic, and J. Snyder, "Landslide detection and susceptibility mapping using LiDAR and an artificial neural network approach: a case study in the Cuyahoga Valley National Park, Ohio," *Landslides*, vol. 13, pp. 467–484, 2016.
- [52] N. M. Abdullah, N. Sulaiman, U. Nazir, M. Ismail, S. K. K. A. Latib, and N. P. N. Mahmud, "Geographical Information System (GIS) and Remote Sensing (RS) Applications in Disaster Risk Reduction (DRR) in Malaysia," *International Journal of Integrated Engineering*, vol. 14, no. 5, pp. 25–37, 2022.
- [53] I. Alcántara-Ayala and R. J. Garnica-Peña, "Landslide Warning Systems in Upper Middle-Income Countries: Current Insights and New Perspectives," in *Progress in Landslide Research and Technology*, Volume 1 Issue 2, 2022, Springer, 2023, pp. 159–168.
- [54] R. Can, S. Kocaman, and C. Gokceoglu, "A convolutional neural network architecture for auto-detection of landslide photographs to assess citizen science and volunteered geographic information data quality," *ISPRS Int. J. Geoinf.*, vol. 8, no. 7, p. 300, 2019.
- [55] S. Dörterler, H. Dumlu, D. Özdemir, and H. Temurtaş, "Hybridization of K-means and Meta-Heuristics Algorithms for Heart Disease Diagnosis," in *NEW TRENDS IN ENGINEERING AND APPLIED NATURAL SCIENCES*, Duvar Publishing, 2022, p. 55.
- [56] F. Aydemir and S. Arslan, "A System Design With Deep Learning and IoT to Ensure Education Continuity for Post-COVID," *IEEE Transactions on Consumer Electronics*, 2023.
- [57] T. Rahkar Farshi, "Battle royale optimization algorithm," *Neural Comput. Appl.*, vol. 33, no. 4, pp. 1139–1157, 2021.
- [58] S. Dörterler, "Kanser Hastalığı Teşhisinde Ölüm Oyunu Optimizasyon Algoritmasının Etkisi," *Mühendislik Alanında Uluslararası Araştırmalar VIII*, p. 15, 2023.
- [59] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, pp. 5–32, 2001.
- [60] S. Ghosh, A. Dasgupta, and A. Swetapadma, "A study on support vector machine based linear and non-linear pattern classification," in *2019 International Conference on Intelligent Sustainable Systems (ICISS)*, IEEE, 2019, pp. 24–28.
- [61] A. K. Jain, J. Mao, and K. M. Mohiuddin, "Artificial neural networks: A tutorial," *Computer (Long Beach, Calif.)*, vol. 29, no. 3, pp. 31–44, 1996.
- [62] S. Cui, Y. Wang, Y. Yin, T. C. E. Cheng, D. Wang, and M. Zhai, "A cluster-based intelligence ensemble learning method for classification problems," *Inf. Sci. (N. Y.)*, vol. 560, pp. 386–409, 2021.
- [63] S. Dörterler, H. Dumlu, D. Özdemir, and H. Temurtaş, "Melezlenmiş K-means ve Diferansiyel Gelişim Algoritmaları ile Kalp Hastalığının Teşhisi," in *International Conference on Engineering and Applied Natural Sciences*, Konya, 2022, pp. 1840–1844.

