Adıyaman University
Journal of Engineering Sciences
Adyü J Eng Sci 2026;13:e260109
Adıyaman Üniversitesi
Mühendislik Bilimleri Dergisi
Adyü Müh Bil Derg 2026;13:e260109
https://doi.org/10.54365/adyumbd.1817408

Research Article / Araştırma Makalesi

Bayesian Optimizasyon Destekli XGBoost Modeli ile Konsol İstinat Duvarlarının Güvenlik Sayısının Tahmini

Estimation of the Safety Factor of Retaining Walls Using a Bayesian Optimization Supported XGBoost Model

Utku Köktan [1] *

[1] Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Samsun, Türkiye.

Öz

Bu çalışmada, kohezyonsuz zemin ortamında inşa edilen dikdörtgen kesitli konsol istinat duvarları için dolgu zeminine ait içsel sürtünme açısı ve birim hacim ağırlık, duvara ait genişlik, yükseklik ve birim hacim ağırlık ile yatay deprem ivme katsayısının kombinasyonlarından 1880 farklı senaryo oluşturulmuştur. Ardından her bir senaryo için Mononobe-Okabe yöntemine dayalı hesaplamalar gerçekleştirilerek kayma, devrilme ve taşıma gücüne karşı güvenlik sayıları elde edilmiştir. Bu güvenlik sayılarının en küçüğü, ilgili senaryonun çıktı değeri kabul edilerek bir veri seti oluşturulmuş ve minimum güvenlik sayısını tahmin edebilen Bayesian optimizasyon destekli XGBoost (XGBoost-BO) modeli geliştirilmiştir. Modelin tahmin performansı R^2, VAF, RMSE, MAE ve MSE gibi istatistiksel metrikler ve performans eğrilerine ilaveten yapılan artık analizi ve buna bağlı oluşturulan histogram ve Q-Q grafikleri üzerinden değerlendirilmiştir. Geliştirilen model, R^2:0.9921 ve RMSE:0.0129 ile yüksek başarı sergilemiş ve ayrıca SHAP analizi ile girdilerin çıktı üzerindeki etkileri yorumlanarak karar mekanizması detaylıca açıklanmıştır.

Anahtar Kelimeler: *İstinat duvarları, Bayesian optimizasyonu, XGBoost algoritması, SHAP analizi*

Abstract

In this study, 1880 distinct scenarios were generated for rectangular cantilever retaining walls constructed in cohesionless soil backfill from combinations of six input parameters such as internal friction angle and unit weight of the backfill soil, width, height, and unit weight of the wall, and horizontal seismic acceleration coefficient. Subsequently, safety factors against sliding, overturning, and bearing capacity failure were calculated for each scenario based on the Mononobe-Okabe method. The minimum among these safety factors was accepted as the output value for the respective scenario, thereby creating a dataset, and a Bayesian optimization-supported XGBoost (XGBoost-BO) model was developed to predict this minimum safety factor. The model's predictive performance was evaluated using statistical metrics such as R^2, VAF, RMSE, MAE, and MSE, in addition to performance curves, residual analysis, and associated histogram and Q-Q plots. The developed model demonstrated high success, achieving R^2:0.9921 and RMSE:0.0129, and the decision-making mechanism was explained in detail by interpreting the influence of the inputs on the output via SHAP analysis.

Keywords: *Retaining walls, Bayesian optimization, XGBoost algorithm, SHAP analysis*

* Sorumlu yazar e-posta (Corresponding e-mail): utku.koktan@omu.edu.tr
Geliş Tarihi (Received):05.11.2025, **Kabul Tarihi (Accepted):** 08.02.2026

1. Giriş

İstinat duvarları, yatay doğrultuda etkiyen toprak basınçlarına karşı koyarak zeminin iki farklı seviyede tutulmasını sağlayan mühendislik yapılarıdır. Oldukça yaygın bir kullanım alanına sahip bu yapılar, sismik açıdan aktif bölgelerde ve geoteknik açıdan çeşitli zemin ortamlarında inşa edilebilmektedir [1]. Karayolları, demiryolları, köprüler, kıyı koruma yapıları, binaların bodrum katları vb. alanlarda sıklıkla kullanılan bu yapılarda meydana gelebilecek tahribatlar ciddi can ve mal kayıplarına sebep olabilmektedir. Bu sebeple bu yapıların doğru malzeme seçimi, uygun tasarım ve mühendislik hesaplamalarıyla güvenli şekilde inşa edilmesi oldukça önemlidir [2].

Konsol istinat duvarlarının tasarımı için duvar üzerine etkiyen yüklerin doğru şekilde belirlenmesi gerekmektedir. Deprem etkisi altında duvara etkiyen yükleri belirlemek için ortaya koyulan ilk yöntem Okabe (1926) [3] ve Mononobe (1929) [4] tarafından geliştirilen ve kendi adlarıyla anılan Mononobe-Okabe (M-O) yöntemidir. M-O yöntemi, Coulomb (1776) [5] tarafından geliştirilen ve statik durumda yanal zemin basınçlarını ve buna bağlı zemin itkilerini ortaya koyan klasik Coulomb teorisinin dinamik durumlara uyarlanmış bir versiyonudur. Yani dinamik deprem kuvvetini belirli katsayılar yardımıyla statik kuvvetlere dönüştüren ve analitik bir çözüm sunan yarı-statik (pseudo-static) bir yöntemdir. Uygulamadaki kolaylığı ve sonuçlarına duyulan güvenden dolayı günümüzde hala en yaygın kullanılan hesap yöntemlerinden biri olan M-O yöntemi dünya genelindeki pek çok yönetmelikte olduğu gibi ülkemizdeki mevcut deprem yönetmeliği olan TBDY (2018)'de de [6] istinat duvarlarının tasarımında rehber olarak sunulmaktadır [7]. Ayrıca pek çok araştırmacı M-O yönteminin farklı türevlerini geliştirerek alternatif yarı-statik yaklaşımlar ortaya koymuştur [8-10].

Günümüzde, gelişen bilgisayar teknolojileri ve yazılım dünyasındaki ilerlemeler neticesinde pek çok alanda olduğu gibi geoteknik mühendisliği alanında da yapay zeka kullanımı giderek yaygınlaşmaktadır [11]. İlgili literatürde istinat duvarlarıyla ilgili çalışmalar ise güvenlik analizi ve optimum boyutlandırma gibi iki gruba ayrılabilmektedir. İlk grupta duvarın güvenlik sayısını (GS) ya da duvar üzerindeki deformasyonları tahmin edebilen çalışmalar yer almaktadır [12-24]. İkinci grupta ise duvarın optimum boyutlarını ve/veya maliyetini belirleyebilen yapay zeka modelleri yer almaktadır [25-32]. Bu çalışmalarda yapay zekanın alt grupları olan makine öğrenmesi ve optimizasyon algoritmaları ile bunların kombinasyonları kullanılmaktadır. Analitik veya nümerik yollarla veriler türetilmekte ve daha sonra bu veriler yardımıyla modeller geliştirilmektedir.

Mevcut literatürdeki çalışmalardan farklı olarak bu çalışma, istinat duvarlarının stabilitesini yalnızca tekil bir güvenlik sayısı üzerinden değil; kayma, devrilme ve taşıma gücü risklerinin en kritiğini minimize eden bütüncül bir yaklaşımla ele almaktadır. Ayrıca klasik yöntemlere kıyasla parametre optimizasyonunda üstün performans gösteren Bayesian Optimizasyonu (BO) ile güçlendirilmiş XGBoost mimarisinin kullanılması ve modelin karar mekanizmasının SHAP analizi ile şeffaf hale getirilmesi, çalışmayı literatürdeki benzer uygulamalardan ayıran temel özelliklerdir. Ayrıca modelin güvenilirliği, literatürdeki yaygın trend analizlerinin ötesine geçilerek, artık analizi ve istatistiksel testlerle kapsamlı şekilde incelenmiştir.

Bu kapsamda 1880 adet senaryo oluşturularak M-O yöntemine göre analizler gerçekleştirilmiştir. Analizlerde zemine ait içsel sürtünme açısı ve birim hacim ağırlık, duvara ait genişlik, yükseklik ve birim hacim ağırlık ile yatay deprem ivme katsayısı değerleri girdi olarak kullanılmış ve çıktı olarak kayma, devrilme ve taşıma gücüne karşı güvenlik sayıları elde edilmiştir. Bu üç farklı tahkike göre elde edilen güvenlik sayılarından en küçük olanı o analizin sonucu olarak kabul edilmiş ve veri setinin çıktısını oluşturmuştur. Ardından bu veri seti %70'i eğitim (1316 adet) %30'u ise test (564 adet) verisi olmak üzere rastgele ayrılmıştır. Elde edilen veriler makine öğrenmesi modelinde kullanılmak üzere 0 ile 1 arasında normalize edilmiştir. Daha sonra bu veriler ile Bayesian optimizasyonu (BO) ile optimize edilmiş XGBoost (extreme gradient boosting) modeli (XGBoost-BO) geliştirilmiştir. Oluşturulan modelin performansı determinasyon katsayısı (R^2), kök ortalama kare hatası (RMSE), ortalama karesel hata (MSE), ortalama

mutlak hata (MAE) ve varyans hesap faktörü (VAF) gibi istatistiksel metriklerle ve performans eğrileriyle değerlendirilmiştir. Ayrıca artık (residual) analizi gerçekleştirilerek bu analiz sonuçlarına göre elde edilen histogram ve Q-Q (kantil-kantil) grafikleri vasıtasıyla modelin hata yapma biçimi ortaya koyulmuştur. Son olarak SHAP (Shapely additive explanation) analizi ile her bir girdi değişkeninin modelin ürettiği çıktı üzerindeki etkisi sayısal veriler üzerinden görsel olarak sunulmuştur. Elde edilen bulgular modelin çok geniş bir aralıkta yüksek doğruluklu tahminler gerçekleştirebildiğini göstermektedir.

2. Materyal ve Metod

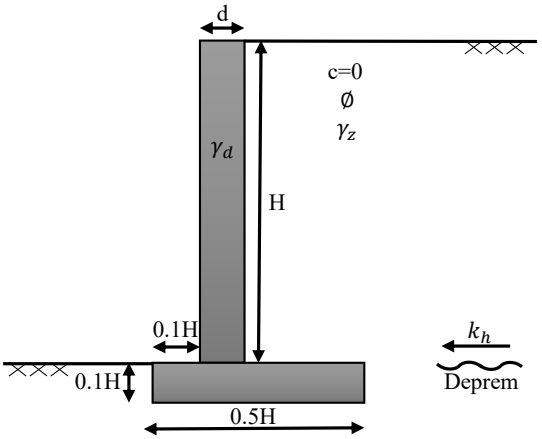
2.1. Fiziksel Model ve Girdi Parametreleri

Çalışmanın ilk aşamasında XGBoost-BO modelini geliştirmek için kullanılacak veri seti elde edilmiştir. Bu maksatla zemine ait içsel sürtünme açısı ve birim hacim ağırlık, duvara ait genişlik, yükseklik ve birim hacim ağırlık ile yatay deprem ivme katsayısı değerlerini girdi olarak kabul eden ve karşılığında kayma, devrilme ve taşıma gücüne karşı güvenlik sayılarının elde edildiği M-O analizleri gerçekleştirilmiştir. Analizlerde kullanılan parametreler Çizelge 1'de sunulmuştur. Çalışmada kohezyonsuz zemin durumu değerlendirildiği için kohezyon değeri sıfır (c=0) olarak alınmıştır ve duvar önündeki pasif itki ihmal edilmiştir. Çizelge 1'de görülen değerlerden 1880 farklı kombinasyon oluşturulmuş ve her bir durum için M-O analizleri gerçekleştirilerek kayma, devrilme ve taşıma gücüne karşı güvenlik sayıları elde edilmiştir.

Çizelge 1. Modelde kullanılan girdi ve çıktı parametreleri

Parametre	Birimi	Değerler
İçsel Sürtünme Açısı (Ø)	Derece	15, 20, 25, 30, 35, 40
Zeminin Birim Hacim Ağırlığı (γ_z)	kN/m^3	15, 18, 21, 24
Duvar Yüksekliği (H)	Metre	3, 5, 7, 9
Duvar Genişliği (d)	Metre	0.25, 0.5, 0.75, 1.0, 1.25, 1.50, 1.75, 2.0
Duvarın Birim Hacim Ağırlığı (γ_d)	kN/m^3	15, 18, 21, 24, 27
Yatay Deprem İvme Katsayısı (k_h)	g	0.1, 0.2, 0.3, 0.4, 0.5
Güvenlik Sayısı (GS)	-	-

Analizlerde dikkate alınan istinat duvarı dikdörtgen kesitli konsol istinat duvarı olup temel genişliği duvar yüksekliğinin yarısı (0.5H), temel plakasının kalınlığı ve ön ampatman genişliği ise duvar yüksekliğinin 1/10'u kadar (0.1H) dikkate alınmıştır (Şekil 1).



Şekil 1. İncelenen konsol istinat duvarının şematik gösterimi

2.2. Mononobe-Okabe Analizi

M-O yöntemi, istinat duvarlarının deprem etkisi altındaki davranışlarını analiz etmek amacıyla geliştirilen ilk yaklaşımdır. Bu yöntem, statik koşullarda duvara uygulanan yanal zemin basınçlarını ve kuvvetlerini açıklayan Coulomb teorisinin dinamik koşullara uyarlanmış bir versiyonudur. Yöntemde, Coulomb kamasına hem aktif hem de pasif durumlar için yarı-statik ivmeler uygulanmakta ve tıpkı statik analizde olduğu gibi kuvvet dengesi kurularak, deprem sırasında oluşması muhtemel suni zemin itkisinin büyüklüğü hesaplanmaktadır [2].

k_h yatay, k_v ise düşey deprem ivme katsayısı olmak üzere statik koşullarda var olan kuvvetlere ilaveten duvara etkiyen yatay ve düşey yarı statik ivmeler sırasıyla Denklem (1) ve Denklem (2)'de sunulduğu gibi hesaplanmaktadır. Burada g, yer çekimi ivmesidir ve aktif durumda duvara etkiyen toplam zemin itkisi (P_{ae}) kuru ve kohezyonsuz durumda aşağıdaki gibi hesaplanmaktadır (Denklem (5)).

$$k_h = \frac{\text{maksimum deprem ivmesinin yatay bileşeni}}{g} \tag{1}$$

$$k_v = \frac{\text{maksimum deprem ivmesinin düşey bileşeni}}{g} \tag{2}$$

$$\bar{\beta} = \tan^{-1}\left[\frac{k_h}{(1-k_v)}\right] \tag{3}$$

$$K_a = \frac{\cos^2(\emptyset - \theta - \bar{\beta})}{\cos^2\theta.\cos\bar{\beta}.\cos(\delta+\theta+\bar{\beta})\left[1+\sqrt{\frac{\sin(\delta+\emptyset).\sin(\emptyset-\alpha-\bar{\beta})}{\cos(\delta+\theta+\bar{\beta}).\cos(\theta-\alpha)}}\right]^2} \tag{4}$$

$$P_{ae} = \frac{1}{2}.\gamma.H^2.(1-k_V)K_a \tag{5}$$

Burada H duvar yüksekliğini, K_a toplam aktif zemin basınç katsayısını, ∅ içsel sürtünme açısını, θ duvar ile dolgu zemini arasındaki açıyı (duvar arka yüzünün eğimi), $\bar{\beta}$ eşdeğer deprem katsayısını, α dolgu zemininin yatayla yaptığı açıyı, δ ise zemin ile duvar arasındaki sürtünme açısını temsil etmektedir. Aktif zemin basınç katsayısı hesaplanırken $\sin(\emptyset-\alpha-\bar{\beta}) < 0$ olduğu durumda K_a için gerçel bir çözüm elde edilememekte ve aktif itki hesaplanamamaktadır. Dolayısıyla bu koşullarda M-O yöntemi geçerli olmadığı için hesaplamalarda bu durumlar dikkate alınmamıştır. Pasif durum için ise Coulomb yöntemine benzer şekilde hesaplamalar yapılabilmektedir [33]. Ancak bu çalışmada güvenli tarafta kalmak maksadıyla pasif itkiler ihmal edilmiştir.

Ayrıca M-O analizlerinde düşey deprem ivme katsayısı genellikle sıfır alınarak ihmal edilmektedir. (k_v=0). Bu yaklaşım, düşey ivmenin yatay ivmeye göre çok küçük etkiye sahip olması ve hesaplamalarda sadeleştirme sağlaması sebebiyle tercih edilmektedir. M-O yöntemi, dinamik itkinin etkidiği nokta için ise H/3 yüksekliğini işaret etse de Seed ve Whitman (1970) [34] bu yüksekliğin H/3 ile H/6 arasında olduğunu ifade etmiştir. Bu çalışmada düşey ivme ihmal edilmiş, dinamik itkinin etki noktası için H/3 yüksekliği esas alınmıştır.

2.3. Güvenlik Sayısının Elde Edilmesi

M-O analizlerinden elde edilen veriler ışığında konsol istinat duvarının kayma, devrilme ve taşıma gücüne göre stabilite tahkikleri yapılarak güvenlik sayıları elde edilmiştir. Ardından her bir durum için elde edilen güvenlik sayılarının en küçüğü, o durumu temsil eden güvenlik sayısı olarak esas alınmıştır.

İlk olarak kaymaya karşı güvenlik analizleri gerçekleştirilmiştir. $\sum F_R$ karşı koyan, $\sum F_0$ ise kaydıran kuvvetleri göstermek üzere kayma tahkiki bu ikisinin birbirlerine oranı şeklinde hesaplanmaktadır (Denklem (6)). Duvarı kaydıran kuvvetler M-O analizi neticesinde elde edilen arka dolgudaki itkiden

oluşmakta iken karşı koyan kuvvetler varsa pasif itki ve duvarın ağırlığı ile temel zemini arasında oluşan sürtünme direncinden meydana gelmektedir.

$$GS_{kayma} = \frac{\sum F_R}{\sum F_0} \quad (6)$$

Devrilme tahkiki için ise duvara etkiyen kuvvetlerin burun noktasına göre momentlerinin alınması gerekmektedir. Burada duvarı devirmeye çalışan momentlerin ($\sum M_R$) karşı koymaya çalışan momentlere ($\sum M_0$) oranı devrilmeye karşı güvenlik sayısını vermektedir (Denklem (7)). Duvarı devirmeye çalışan momentler arka dolgudaki aktif itkiden meydana gelirken karşı koyan momentler duvarın arka ampatmanının üzerindeki dolgu zemininin ağırlığı ve duvarın kendi ağırlığından ve varsa pasif itkiden meydana gelmektedir.

$$GS_{devrilme} = \frac{\sum M_R}{\sum M_0} \quad (7)$$

Son olarak taşıma gücü tahkiki gerçekleştirilerek güvenlik sayısı elde edilmiştir. Taşıma gücü tahkiki zeminin emniyetle taşıyabileceği sınır (nihai) taşıma gücünün (q_u), duvardan dolayı zeminde oluşacak maksimum gerilmeye (q_{max}) oranı şeklinde tanımlanmaktadır (Denklem (10)). Bu çalışmada nihai taşıma gücü Terzaghi (1943) [35] tarafından geliştirilen ve kendi adıyla anılan Terzaghi taşıma gücü formülüne göre elde edilmiştir (Denklem (8)). Burada c kohezyonu, N_c, N_q, N_γ taşıma gücü katsayılarını, K_1 ve K_2 şekil katsayılarını, P_0 derinlik basıncını, B kısa kenarı, γ_z zeminin birim hacim ağırlığını, e ise temelde meydana gelebilecek eksantristeyi ifade etmektedir. Stabilite tahkikleri hakkında detaylı bilgi için Das (2011) [36] kaynağına başvurulabilir.

$$q_u = cN_cK_1 + P_0N_q + \frac{1}{2}\gamma_z BN_\gamma K_2 \quad (8)$$

$$q_{max,min} = \frac{\sum N}{B}\left(1 \pm \frac{6e}{B}\right) \quad (9)$$

$$GS_{taşıma\ gücü} = \frac{q_u}{q_{max}} \quad (10)$$

2.4. Veri Setinin Oluşturulması

Stabilite tahkikleri neticesinde 1880 farklı durum için kayma, devrilme ve taşıma gücüne karşı güvenlik sayıları elde edilmiştir. Her bir duruma karşılık gelen güvenlik sayılarından en küçüğü seçilerek ilgili senaryoda esas alınacak güvenlik sayısı değeri elde edilmiştir ve bu değer o senaryonun çıktısını oluşturmaktadır. Böylece girdi ve çıktıları içeren 1880 satırlık bir veri seti oluşturulmuştur.

Oluşturulan bu veri seti 0 ile 1 arasında normalize edilerek XGBoost-BO modelinin geliştirilmesinde kullanılmıştır. Makine öğrenmesi uygulamalarında veri hazırlama sürecinin önemli parçalarından biri olan veri normalizasyonu, hesaplamalı analizlerde kritik bir ön işleme aşamasıdır. Bu aşamada değişkenler arasındaki ölçek farklılıklarının ortadan kaldırılması ve boyutsal etkilerin modele olumsuz yansımalarının minimize edilmesi amaçlanmaktadır [37].

Bu çalışmada min-maks veri normalizasyonu kullanılarak veriler 0 ile 1 arasında normalize edilmiştir. Bu işlem için $[((x-x_{min}))/((x_{maks}-x_{min}))]$ formülü kullanılmış ve bu formülde x normalize edilen veriyi, x_{maks} ve x_{min} ise o serideki verilerin maksimum ve minimum değerlerini temsil etmektedir.

Veri normalizasyonunun ardından 1880 farklı senaryodan oluşan veri seti %70 eğitim (1316 adet) ve %30 test (564 adet) olacak şekilde rastgele ayrılmıştır. Eğitim safhasında kullanılacak veri setiyle XGBoost-BO modeli eğitilecek ve ardından test safhasında kullanılacak veri setiyle modelin performansı değerlendirilecektir.

2.5. XGBoost (Extreme Gradient Boosting)

Karar ağacı tabanlı bir yöntem olan XGBoost algoritması milyarlarca örnek içeren büyük veri kümelerine ölçeklenebilme yeteneğine sahiptir. Karar ağaçları, veri üzerinde karar verme sürecini dallanarak yapılandıran hiyerarşik modellerdir ve dış dünyadaki örneklerden ağaç mekanizmasını oluşturmak ve sonrasında bu örnekler üzerinden tahmin gerçekleştirmek üzere kurgulanmaktadırlar. İkili bölme mantığıyla bir dizi evet ya da hayır kuralı geliştirerek çalışan bu teknik, bir kök kriteri test ederek başlar ve yaprak düğümlere doğru dallanarak nihai tahminin yer aldığı terminal düğümüne ulaşmaktadır. Bu algoritma özel bir düzenleme tekniği kullanarak aşırı öğrenmeyi (overfitting) kontrol etmektedir. Burada amaç giriş vektörü x^i ile çıkış vektörü y^i arasında bir eşleşme elde etmektir (Denklem (11-12)). İlgili denklemlerde L kayıp fonksiyonunu, f_k zayıf öğreniciyi, α_k öğrenme oranını, T yaprak sayısını, w_k yaprak ağırlığını, γ ve λ ise ceza (penaltı) katsayılarını temsil etmektedir. XGBoost karar ağaçlarında olduğu gibi tek ve zayıf tahminleri birleştirerek güçlü bir tahmin oluşturmaktadır [38, 39].

$$\hat{y}^i = \phi(x^i) = \sum_{k=1}^{K} \alpha_k f_k(x^i) \tag{11}$$

$$L(\phi) = \sum_i (y^i - \hat{y}^i)^2 + \sum_k \gamma T + \frac{1}{2}\lambda \|w_k\| \tag{12}$$

2.6. Bayesian Optimizasyonu

XGBoost modelinin hiperparametre optimizasyonu için Bayesian optimizasyonu uygulanmıştır. Modelin eğitimi aşamasında hiperparametrelerin en uygun kombinasyonunun belirlenmesi, performansını doğrudan etkileyebilmektedir. Hiperparametre ayarlama için Grid Search, kullanıcı tarafından deneme yanılma yolu (Manual Tuning), Genetik Algoritma ve Random Search gibi geleneksel yöntemler kullanılabilmektedir ancak bu yöntemler yüksek zaman maliyeti ve düşük verimlilik gibi dezavantajlara sahiptir [40, 41]. XGBoost modelinin pek çok hiperparametresinin ayarlanabilir olmasından dolayı optimizasyon sürecinde genellikle geleneksel yöntemler pek tercih edilmemektedir. Bu sorunun üstesinden gelebilmek için Bayesian optimizasyonu etkili bir yöntem olarak ön plana çıkmakta ve hiperparametre ayarlamada doğruluk-verimlilik dengesini sağlamada sıklıkla tercih edilmektedir [42].

Hiperparametre ayarlama sürecinde kullanılan hedef fonksiyon genellikle bilinmeyen ve hesaplama maliyeti yüksek bir fonksiyondur [43]. Bayesian optimizasyonunun temelinde Bayes kuralı yer almakta ve bu kural, öncül bilgileri kullanarak sonradan elde edilen olasılıkları tahmin etmeye olanak tanımaktadır. Bu süreç matematiksel olarak Denklem 13'teki gibi ifade edilmektedir [44]:

$$p(f|D) = \frac{p(D|f)p(f)}{p(D)} \tag{13}$$

Burada *f* hedef fonksiyonu, *D* örneklenmiş hiperparametrelerin miktarını, *p(D)* öncül dağılımı, $p(D|f)$ örnekleme noktasındaki olasılığı, $p(f|D)$ ise hedef fonksiyonun sonradan elde edilen dağılımını ifade etmektedir.

Bayesian optimizasyonu örneklenmiş hiperparametrelerden elde edilen öncül dağılımı kullanarak hedef fonksiyonun yönünü tahmin etmekte ve yeni örnekleme noktalarını seçmek için bu dağılımı sürekli

güncellemektedir [45]. Böylece, Bayesian optimizasyonu tüm hiperparametre kombinasyonlarını taramadan en uygun yönü bulabilmektedir [40].

Bu çalışmada, Bayesian optimizasyon sürecinde öğrenme oranı (learning rate) (eta), maksimum ağaç derinliği (max_depth), örnekleme oranı (subsample) ve özellik örnekleme oranı (colsample_bytree) olmak üzere XGBoost modelinin dört temel hiperparametresi optimize edilmiştir. Bu parametreler, modelin öğrenme hızı, yapısal karmaşıklığı ve genelleme kapasitesi üzerinde doğrudan etkilidir ve aşırı öğrenmenin kontrolü ve tahmin doğruluğunun artırılması amacıyla optimize edilmiştir. Optimize edilen bu hiperparametrelerden öğrenme oranı, XGBoost algoritmasında her bir ağacın katkısını kontrol eden hiperparametredir. Maksimum ağaç derinliği ise her bir karar ağacının maksimum dallanma seviyesini belirlemektedir. Örnekleme oranı her boosting iterasyonunda kullanılacak rastgele örnek oranını, özellik örnekleme oranı ise her ağacın oluşturulmasında kullanılacak değişken oranını belirtmektedir.

Modelin hiperparametre optimizasyon sürecinde, arama uzayının sınırları ve optimizasyon algoritmasının ayarları literatürdeki yaygın kullanımlar ve ön denemeler dikkate alınarak belirlenmiştir. Bu maksatla Bayesian optimizasyon sürecinde 5 başlangıç noktası ve 20 iterasyon adımı kullanılarak toplam 25 değerlendirme gerçekleştirilmiştir. Modelde optimize edilen hiperparametreler ve taranan arama aralıkları ise Çizelge 2'de sunulmuştur.

Çizelge 2. Bayesian optimizasyon sürecinde kullanılan hiperparametre aralıkları

Hiperparametre	Arama Aralığı
Öğrenme oranı (eta)	0.01 – 0.3
Maksimum ağaç derinliği (max_depth)	3 – 12
Örnekleme oranı (subsample)	0.50 – 1.00
Özellik örnekleme oranı (colsample_bytree)	0.50 – 1.00

2.7. Performans Metrikleri

XGBoost-BO modelinin tahmin performansını değerlendirmek amacıyla çeşitli istatistiksel metrikler kullanılmıştır. Bu metrikler, modelin tahmin ettiği çıktılar ile gözlenen (gerçek) çıktılar arasındaki ilişkiyi nicel olarak analiz ederek, modelin doğruluk ve açıklayıcılık düzeyini ortaya koymaktadır. Bu maksatla trend değerlendirmesi için R^2 ve VAF metrikleri, hata değerlendirmesi için ise RMSE, MSE ve MAE metrikleri hesaplanmıştır.

Model performansının istatistiksel açıdan değerlendirilmesinde en yaygın kullanılan trend metriklerinden biri olan R^2, modelin gözlenen değerlerdeki toplam varyansın ne kadarını açıklayabildiğini ifade etmekte ve modelin genel açıklayıcılık düzeyini ortaya koymaktadır. Model performansını değerlendirmede kullanılan bir diğer trend metriği olan VAF ise modelin gözlenen değerlerdeki varyansın yüzde kaçını açıkladığını ifade etmektedir. Yine makine öğrenmesi modellerinin performansını değerlendirmede en yaygın kullanılan hata metriklerinden biri olan RMSE ise modelin tahmin ettiği değerlerin gözlenen değerlerden ortalama olarak ne kadar saptığını göstermektedir. MSE, modelin tahmin ettiği değerlerin gözlenen değerlerden ne kadar saptığını kareler toplamı üzerinden ölçen hata metriklerinden biridir. Son olarak MAE ise modelin tahmin ettiği değerlerin gözlenen değerlerden ortalama olarak ne kadar mutlak sapma gösterdiğini ifade etmektedir.

Tüm bu metrikler aşağıda sunulan denklemlere göre hesaplanmaktadır. Burada g_i ve t_i, sırasıyla i'inci analize ait gözlenen ve tahmin edilen değerlerdir. g_{ort} gözlenen değerlerin ortalamasını, n toplam analiz sayısını ifade etmektedir. Bu çalışmada 1880 adet analiz gerçekleştirilmiş olup bunların %70'i eğitim aşamasında, %30'u ise test aşamasında kullanılmıştır.

$$R^2 = \frac{\sum_{i=1}^{n}(g_i - g_{ort})^2 - \sum_{i=1}^{n}(g_i - t_i)^2}{\sum_{i=1}^{n}(g_i - g_{ort})^2} \quad (14)$$

$$VAF = \left(1 - \frac{var(g_i - t_i)}{var(g_i)}\right) x100 \quad (15)$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(g_i - t_i)^2} \quad (16)$$

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(t_i - g_i)^2 \quad (17)$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|(t_i - g_i)| \quad (18)$$

3. Bulgular ve Tartışma

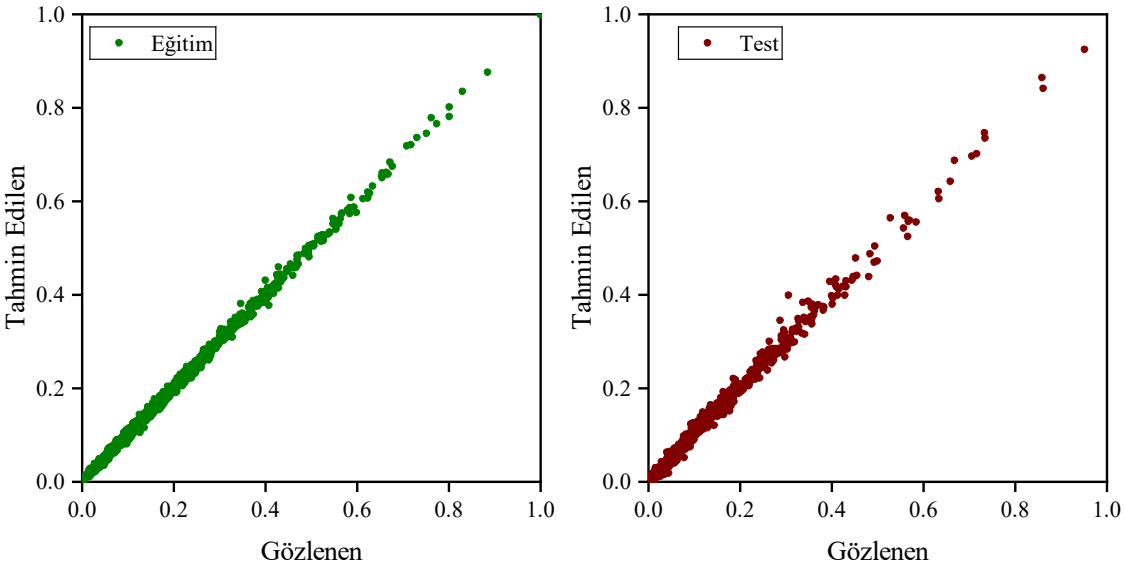
Elde edilen XGBoost-BO modelinin performansı önceki bölümde detaylandırılan çeşitli istatistiksel metriklerle değerlendirilmiştir. Bu maksatla model önce veri setinin rastgele seçilmiş %70'lik kısmıyla eğitilmiş ve ardından kalan %30'luk kısımla test edilmiştir. Ardından geliştirilen modele eğitim verileri tekrar verilerek bu veriler için de tahmin yapması sağlanmış ve böylece model performansının hem eğitim hem de test verileri ile değerlendirilmesi yapılmıştır (Çizelge 3).

Oluşturulan XGBoost-BO modelinde modelin gözlenen değerlerdeki değişimi ne ölçüde açıklayabildiğini ifade eden trend metrikleri için sonuçlar eğitim ve test aşamasında sırasıyla R^2: 0.9980 ve 0.9921, VAF: 99.8008 ve 99.2032 olarak elde edilmiştir. Modelin tahminlerinin gözlenen değerlerden ne kadar saptığını açıklayan hata metrikleri için ise eğitim ve test aşamasında sonuçlar sırasıyla RMSE: 0.0065 ve 0.0129, MAE: 0.0049 ve 0.0094, MSE: 0.00004 ve 0.0002 olarak elde edilmiştir. Görüldüğü üzere hem trend hem de hata metrikleri için model oldukça başarılı bir performans göstermektedir. Çizelge 3'te de özetlendiği gibi istatistiksel metrikler ideal değerlere oldukça yakındır. Bu durum modelin gerçekçi ve tutarlı tahminler yapabildiğini, yani güvenlik sayılarını oldukça yüksek doğrulukla tahmin edebildiğini göstermektedir.

Çizelge 3. Tahmin performansı

	Metrik	Eğitim Aşaması	Test Aşaması	İdeal Değer
Trend	R^2	0.9980	0.9921	1
	VAF	99.8008	99.2032	100 (%)
Hata	RMSE	0.0065	0.0129	0
	MAE	0.0049	0.0094	0
	MSE	0.00004	0.0002	0

Ayrıca modelin tahmin performansını görselleştirmek adına hem eğitim hem de test verileri için performans eğrileri çizilmiştir (Şekil 2). Performans eğrisi x ekseninde gözlenen, y ekseninde ise tahmin edilen değerlerin bulunduğu bir saçılım diyagramıdır. Performans eğrileri ilk olarak test aşamasında modelin tahmin ettiği değerler için oluşturulmuştur. Ardından modelin eğitim veri seti modele tekrar girdi olarak verilmiş ve bu veriler ile gerçekleştirdiği tahminler için de çizilmiştir. Performans eğrileri oldukça düşük saçılım ve doğrusal bir görüntü sergilemektedir. Bu da modelin tahmin başarısını ortaya koymaktadır.



Şekil 2. Performans eğrileri

3.1. Artık Analizi

Modelin tahmin performansını değerlendirmek maksadıyla gerçekleştirilen artık analizi, tahmin edilen değerler ile gözlenen değerler arasındaki farkların (artıkların) dağılım özelliklerini inceleyerek modelin hata yapma biçimini ortaya koymaktadır. Hata olarak da adlandırılabilecek bu artık değerlerinin pozitif çıkması, modelin tahmininin gözlenen (gerçek) değerden büyük çıkması anlamına gelirken negatif çıkması, modelin tahminlerinin gözlenen değerden daha küçük olduğunu ifade etmektedir. r_i gözleme ait artık değeri, y_i gözleme ait gözlenen değeri ve $\hat{y}_i$ gözleme ait tahmin edilen değeri ifade etmek üzere artık değerleri Denklem (19)'daki gibi hesaplanmaktadır.

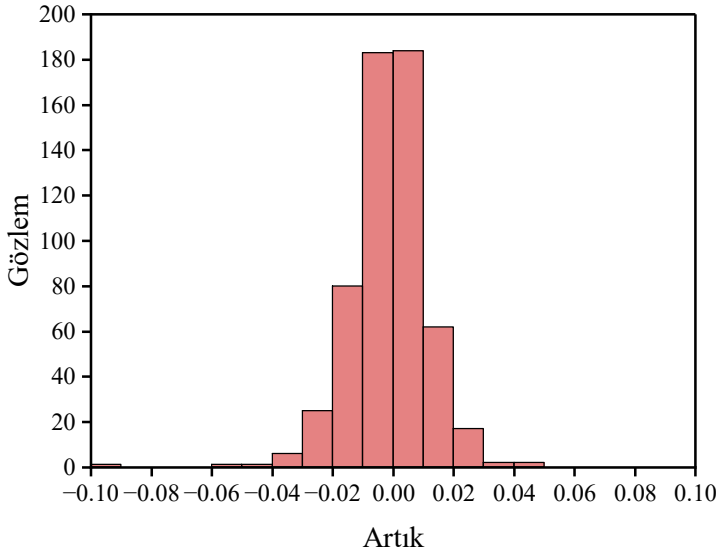
$$r_i = y_i - \hat{y}_i \tag{19}$$

Artık analizi, sistematik sapmaların varlığını, varyansın homojenliğini ve normal dağılıma uygunluğunu görsel ve istatistiksel olarak değerlendirmeyi mümkün kılmaktadır. Bu maksatla, test aşaması için elde edilen artıklar hem histogram hem de Q-Q grafiği ile görsel olarak analiz edilmiş, ayrıca Anderson-Darling (A-D) testi ile istatistiksel olarak değerlendirilmiştir.

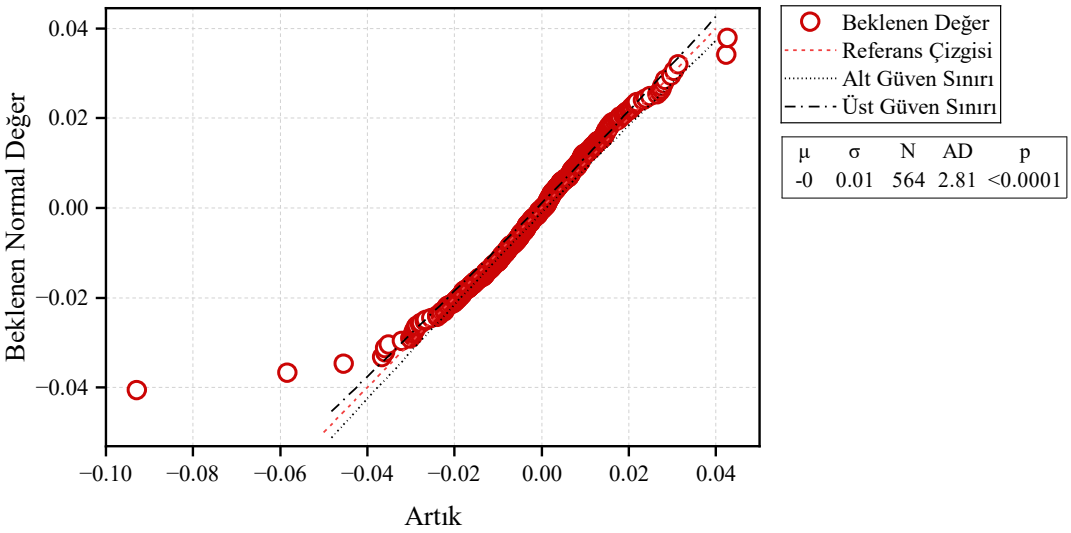
Şekil 3'te artıkların dağılımı histogram olarak sunulmaktadır. Burada x ekseni artık değerlerini, y ekseni ise bu artık aralığına düşen gözlem sayısını (toplam 564 adet) ifade etmektedir. Histogram incelendiğinde artıkların yaklaşık simetrik ve merkezi bir dağılım sergilediği görülmektedir. Artıkların büyük bölümü sıfır çevresinde yoğunlaşmakta olup, bu durum modelin genel olarak dengeli tahminler ürettiğini göstermektedir. Bununla birlikte, uç değerlerde gözlemlenen düşük frekanslı sapmalar, belirli veri aralıklarında modelin daha az tutarlı tahminler üretebildiğine işaret etmektedir.

Şekil 4'de yer alan Q–Q grafiği, artıkların teorik normal dağılım ile karşılaştırılmasını sunmaktadır. Noktaların referans çizgisi etrafında yoğunlaşması normal dağılıma kısmi bir uyumu gösterse de, özellikle uç kantillerdeki sapmalar normalite varsayımının tam olarak sağlanmadığını ortaya koymaktadır. Grafik üzerinde sunulan istatistiksel özetler bu gözlemi desteklemektedir: Ortalama artık değeri ($\mu \cong 0$) ve düşük standart sapma ($\sigma \cong 0.01$), artıkların merkezi ve dar bir dağılım sergilediğini göstermektedir. Örneklem büyüklüğü (N=564) analiz kapsamını belirtirken, Anderson–Darling test istatistiği (AD=2.81) ve buna karşılık gelen p<0.0001 değeri, normal dağılım varsayımının istatistiksel olarak reddedildiğini ortaya koymaktadır.

Her ne kadar XGBoost gibi ağaç tabanlı modeller normalite varsayımına dayanmasa da, artıkların dağılımını analiz etmek modelin hata karakteristiğini anlamak açısından oldukça önemlidir. Bu analiz, özellikle SHAP gibi açıklayıcı yöntemlerle birlikte değerlendirildiğinde, modelin hangi koşullarda daha tutarsız tahminler ürettiğini ortaya koymak açısından değerli bir katkı sunmaktadır.



Şekil 3. Artık değerlerine ait histogram



Şekil 4. Q-Q grafiği

3.2. SHAP Analizi

SHAP analizi, makine öğrenmesi modellerinin karar mekanizmalarını açıklamak amacıyla geliştirilmiş bir yöntemdir. Bu yöntemde her bir girdi değişkeninin modelin ürettiği çıktı üzerindeki etkisi sayısal olarak elde edilebilmekte ve görselleştirilebilmektedir. Bu katkılar SHAP değerleri olarak adlandırılmakta ve her bir girdi için ayrı ayrı hesaplanmaktadır. Ayrıca SHAP değerleri her bir girdi değişkeni arasındaki bağımlılıkları da ölçebilmektedir. Oyun teorisine dayalı bu algoritmada çıkış modelini sadeleştirilmiş giriş vektörlerinin doğrusal birleşimi olarak tanımlayan katkı temelli (additive) özellik atama yöntemini kullanılmaktadır ve Denklem (20)'de gösterildiği gibi ifade edilmektedir [46].

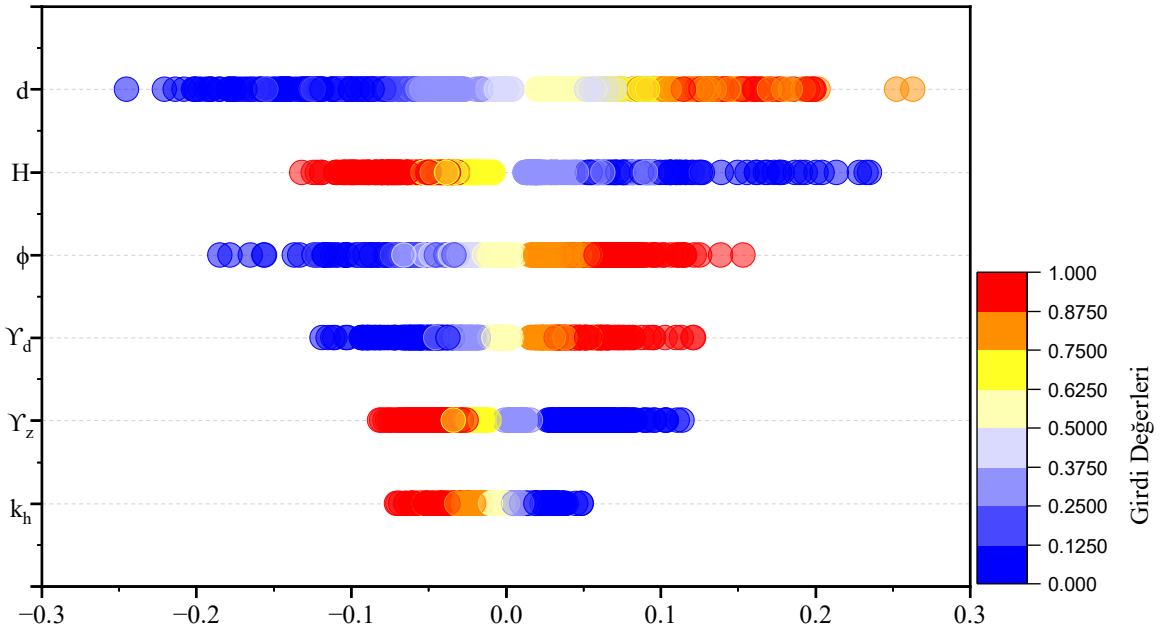
$$f(x) = g(x') = \phi_0 + \sum_{i=1}^{M} \phi_i x_i' \tag{20}$$

Denklem (20)'de f ve g sırasıyla orijinal tahmin modeli ve açıklama modelini temsil etmektedir. M girdi değişkenlerinin toplam sayısını, x girdi değişkenleri vektörünü, x_i' sadeleştirilmiş girdi vektörlerini ve ϕ_i SHAP değerlerini ifade etmektedir. SHAP değerleri Denklem (21) kullanılarak hesaplanmaktadır [26]. Literatürde SHAP analizi ile ilgili detaylı bilgi için başvurulabilecek çeşitli çalışmalar mevcuttur [27, 47-51].

$$\phi_i(f,x) = \sum_{z' \subseteq x'} \frac{|z'|!\,M - |z'| - 1)!}{M!} [f_x(z') - f_x(z'/i)] \tag{21}$$

Şekil 5'te XGBoost-BO modeli için elde edilen SHAP özeti grafiğinde her bir girdi değişkeninin çıktı üzerindeki etkisi görsel olarak sunulmaktadır. Grafiğin sağında yer alan renk skalasında her bir girdinin aldığı değer sunulmaktadır. Buradaki girdi değerleri, makine öğrenmesi modelinde kullanıldığı gibi 0 ile 1 arasında normalize edilmiş değerlerdir. Küçük girdi değerleri (0'a yakın) mavi, büyük girdi değerleri ise (1'e yakın) kırmızı renkle temsil edilmektedir. Negatif SHAP değerleri o girdinin çıktı değerini azaltıcı etkisi olduğunu, pozitif SHAP değerleri ise tam tersi şekilde o girdinin çıktı değerini artırıcı etkisi olduğunu göstermektedir. Tüm SHAP değerleri yaklaşık olarak -0.3 ile +0.3 arasında değerler almaktadır ve tüm değerlerin renk karşılığı sağ taraftaki renk skalasında görülmektedir. Aynı SHAP değerine sahip noktalar üst üste geldiğinde renk yoğunluğu artmaktadır. Böylece hangi aralıklarda SHAP değerlerinde bir yığılma oluştuğu da grafik üzerinde görülebilmektedir.

Grafik incelendiğinde $\emptyset$, d ve γ_d girdilerinin mavi renkle temsil edilen küçük değerleri için negatif SHAP değerleri elde edilmiştir. Bu durum, bu girdi değerlerindeki artışın model çıktısı olan güvenlik sayısını artırdığını göstermektedir. Benzer şekilde γ_z, H ve k_h girdilerindeki artış ise güvenlik sayısını azaltmaktadır. Bir başka ifadeyle içsel sürtünme açısı, duvar genişliği ve duvarın birim hacim ağırlığındaki artış duvarın stabilitesine olumlu katkı sağlarken, dolgu zemininin birim hacim ağırlığındaki, duvar yüksekliğindeki ve yatay deprem ivme katsayısındaki artış duvar stabilitesini olumsuz yönde etkilemektedir. Ayrıca negatif SHAP değerleri, ilgili girdinin model çıktısını azaltıcı etkisini temsil etse de, mühendislik bağlamında bu etki istenen bir sonuç olabilmektedir. Örneğin güvenlik sayısının artması hedefleniyorsa, çıktıyı azaltan bir değişkenin artışı bu hedefe katkı sağlayabilmektedir. Bu yönüyle SHAP analizi, hem istatistiksel hem mühendislik açısından modelin davranışını anlamak ve yorumlamak için güçlü bir araçtır.



Şekil 5. SHAP özeti grafiği

Model girdilerinin çıktı üzerindeki global etkilerini nicel olarak ortaya koymak amacıyla hesaplanan ortalama mutlak SHAP değerleri (feature importance) ve önem sıralaması Çizelge 4'te sunulmuştur. Elde edilen bulgular, klasik istinat duvarı tasarımı ilkeleriyle tutarlı sonuçlar ortaya koymaktadır.

Çizelge 4. Girdi değişkenlerinin çıktı üzerindeki global etki düzeyleri (Feature Importance)

Önem Sırası	Girdi	Ortalama Mutlak SHAP Değeri
1	Duvar Genişliği (d)	0.0870
2	Duvar Yüksekliği (H)	0.0588
3	İçsel Sürtünme Açısı (∅)	0.0441
4	Duvarın Birim Hacim Ağırlığı (γ_d)	0.0378
5	Zeminin Birim Hacim Ağırlığı (γ_z)	0.0320
6	Yatay Deprem İvme Katsayısı (k_h)	0.0185

Analiz sonuçlarına göre, güvenlik sayısı üzerinde en belirleyici etkiye sahip parametrelerin başında geometrik değişkenler gelmektedir. İlk sırada yer alan duvar genişliği (d); hem duvar ağırlığını hem de ağırlık merkezi moment kolunu artırarak devrilmeye karşı koyan (direnen) momenti karesel düzeyde etkilemekte ve bu sayede stabiliteye en yüksek pozitif katkıyı sağlayan parametre olarak öne çıkmaktadır. İkinci sıradaki duvar yüksekliği (H) ise güvenlik sayısını en çok düşüren faktörlerden bir diğeri olmuştur. Özellikle M-O yönteminde aktif itki kuvvetinin duvar yüksekliğinin karesiyle (H^2), devirici momentin ise küpüyle (H^3) orantılı olarak artması, H parametresinin model çıktısı üzerindeki bu yüksek negatif etkisini teorik olarak doğrulamaktadır. Geometrik parametreleri takiben, zeminin kayma dayanımını belirleyen içsel sürtünme açısı (∅) üçüncü en etkili parametre olarak tespit edilmiştir. İçsel sürtünme açısındaki artış, aktif toprak basıncı katsayısını (K_a) düşürerek stabiliteyi iyileştirmektedir. Yatay deprem ivme katsayısının (k_h) etki düzeyi ise diğer parametrelere kıyasla daha düşük seviyede kalmıştır; bu durum, tasarımda duvar geometrisinin ve zemin özelliklerinin sismik yüklerden daha baskın bir rol oynayabildiğini göstermektedir.

4. Sonuç ve Öneriler

Bu çalışmada kohezyonsuz zemin ortamında inşa edilen dikdörtgen kesitli konsol istinat duvarlarının güvenlik sayısını tahmin edebilen bir XGBoost-BO modeli geliştirilmiştir. Bu maksatla farklı içsel sürtünme açısı, zemin ve duvar birim hacim ağırlığı, duvar genişliği ve yüksekliği, yatay deprem ivme katsayısı değerlerinden oluşan 1880 farklı senaryo oluşturularak M-O yöntemine göre analiz edilmiştir. Analizler neticesinde istinat duvarının kayma, devrilme ve taşıma gücüne karşı güvenlik sayıları elde edilmiş ve bu güvenlik sayılarının en küçüğü, ilgili senaryonun çıktı değeri olarak kabul edilmiştir. Ardından bu veri setiyle XGBoost-BO modeli geliştirilmiştir ve modelin performansı çeşitli yöntemlerle değerlendirilmiştir. Aşağıda çalışma neticesinde ulaşılan sonuçlar özetlenmektedir:

- Elde edilen model R^2, VAF, RMSE, MSE, MAE metriklerine göre oldukça yüksek doğrulukla tahminler yapabilmektedir. Bu metriklerin tamamı ideal değerlere oldukça yakın sonuçlar göstermektedir.
- Performans eğrileri düşük saçılımlı ve doğrusal bir davranış göstermektedir. Bu da modelin tahmin performansının ne kadar başarılı olduğunu görsel olarak sunmaktadır.
- Artık değerleri için çizilen histogram değerlendirildiğinde artıkların yaklaşık simetrik ve merkezi bir dağılım sergilediği görülmektedir. Bu durum modelin çok geniş bir aralıkta dengeli tahminler üretebildiğini ortaya koymaktadır.
- Artıkların normal dağılım ile karşılaştırılmasını sunan Q–Q grafiği incelendiğinde normal dağılıma kısmi bir uyum görülse de uç kantillerdeki sapmalar normalite varsayımının tam olarak sağlanmadığını ortaya koymaktadır. XGBoost gibi ağaç tabanlı modeller normalite varsayımına dayanmasa da, artıkların dağılımını analiz etmek modelin hata karakteristiğini anlamak açısından yol gösterici olmaktadır.

- Her bir girdi değişkeninin modelin ürettiği çıktı üzerindeki etkisini sayısal olarak elde eden ve görselleştiren SHAP analizi incelendiğinde ise $\emptyset$, d ve γ_d değişkenlerindeki artış duvarın stabilitesine olumlu katkı sağlarken, γ_z, H ve k_h değişkenlerindeki artış duvar stabilitesini olumsuz yönde etkilemektedir.
- Girdilerin çıktı üzerindeki etki büyüklüklerine (ortalama mutlak SHAP değerlerine) göre yapılan sıralamada, d ve H gibi geometrik parametreler sırasıyla güvenlik sayısını belirleyen en baskın faktörler olarak öne çıkmıştır. Bu parametreleri sırasıyla $\emptyset$, γ_d, γ_z ve k_h takip etmektedir.

Bu çalışmanın sonuçları değerlendirilirken, genellenebilirlik açısından bazı sınırlılıklar ve varsayımsal ön kabullerin dikkate alındığı unutulmamalıdır. İlk olarak, geliştirilen makine öğrenmesi modeli tamamen analitik çözümlemeler yapan ve gerçek saha koşullarında karşılaşılan pek çok etkiyi ihmal eden Mononobe-Okabe yöntemiyle elde edilmiş sentetik bir veri seti ile eğitilmiştir. Dolayısıyla modelin tahmin yeteneği, bu yöntemin teorik varsayımları ile sınırlıdır. Ayrıca analizlerde, sahada sürekliliği her zaman garanti edilemeyen pasif direnç ihmal edilerek, stabiliteye olumlu katkı sağlayan bu kuvvetin yokluğunda tasarımın güvenli tarafta kalması hedeflenmiştir. Düşey deprem ivmesi ise, yatay ivmeye kıyasla etkisinin görece sınırlı olması ve literatürdeki yaygın kabullerle uyumluluk adına analizlerde dikkate alınmamıştır (k_v=0). Öte yandan, bu çalışma yalnızca duvarın iç stabilitesine (kayma, devrilme ve taşıma gücü) odaklanmış olup, şev stabilitesi veya toptan göçme durumlarını dikkate almamaktadır. Her geoteknik problemin kendine özgü saha koşulları barındırdığı göz önüne alındığında, sunulan bu modelin nihai bir tasarım aracı değil, bir ön tasarım veya kontrol rehberi niteliği taşıdığı bilinmelidir. Gerçek saha uygulamalarında tüm çevresel etkiler ve zemin davranışları, uzman geoteknik mühendisleri tarafından detaylıca değerlendirilmelidir.

Tüm bu bilgiler ışığında, bu çalışmada konsol istinat duvarlarının kayma, devrilme ve taşıma gücü tahkikleri açısından en olumsuz durumdaki güvenlik sayısını hızlı ve güvenilir biçimde tahmin edebilen bir makine öğrenmesi modeli ortaya koyulmuştur ve geliştirilen modelin performansı detaylıca değerlendirilmiştir.

Katkı Beyanı

Bu makalenin hazırlanmasındaki tüm aşamalar Utku KÖKTAN tarafından gerçekleştirilmiştir.

Çıkar Çatışması Beyanı

Makalenin yazarı herhangi bir kurum, kuruluş, kişi ile kişisel ve finansal çıkar çatışması olmadığını beyan etmektedir.

Kaynaklar

[1] Köktan U. Konsol İstinat duvarlarının dinamik davranışının yapay zeka yöntemleriyle belirlenmesi. [Doktora Tezi]. Samsun, Türkiye: Ondokuz Mayıs Üniversitesi; 2024.
[2] Kramer SL. Geotechnical earthquake engineering. Pearson Education India; 1996.
[3] Okabe S. General theory of earth pressures, j. Japan soc. Civil Engineering 1926; 12(1).
[4] Mononobe N. On determination of earth pressure during earthquake. In: Proc. World Engrg. Congress, Tokyo, Japan; 1929.
[5] Coulomb C. An attempt to apply the rules of maxima and minima to several problems of stability related to architecture. Mémoires de l'Académie Royale des Sciences 1776; 7: 343-382.
[6] TBDY: Türkiye bina deprem yönetmeliği. Afet ve Acil Durum Yönetimi Başkanlığı, 2018.
[7] Cakir T. Evaluation of the effect of earthquake frequency content on seismic behavior of cantilever retaining wall including soil–structure interaction. Soil Dynamics and Earthquake Engineering 2013; 45: 96-111.
[8] Richards Jr R, Elms DG. Seismic behavior of gravity retaining walls. Journal of the Geotechnical Engineering Division 1979; 105(4): 449-464.
[9] Nadim F, Whitman RV. Seismically induced movement of retaining walls. Journal of Geotechnical Engineering 1983; 109(7): 915-931.

[10] Steedman R, Zeng X. The influence of phase on the calculation of pseudo-static earth pressure on a retaining wall. Geotechnique 1990; 40(1): 103-112.
[11] Baghbani A, Choudhury T, Costa S, Reiner J. Application of artificial intelligence in geotechnical engineering: A state-of-the-art review. Earth-Science Reviews 2022; 228: 103991.
[12] Ghaleini EN, Koopialipoor M, Momenzadeh M, Sarafraz ME, Mohamad ET, Gordan B. A combination of artificial bee colony and neural network for approximating the safety factor of retaining walls. Engineering with Computers 2019; 35(2): 647-658.
[13] Chen H, Asteris PG, Jahed Armaghani D, Gordan B, Pham BT. Assessing dynamic conditions of the retaining wall: Developing two hybrid intelligent models. Applied Sciences 2019; 9(6): 1042.
[14] Gordan B, Koopialipoor M, Clementking A, Tootoonchi H, Tonnizam Mohamad E. Estimating and optimizing safety factors of retaining wall through neural network and bee colony techniques. Engineering with Computers 2019; 35(3): 945-954.
[15] Özturk TE. Artificial neural networks approach for earthquake deformation determination of geosynthetic reinforced retaining walls. International Journal of Intelligent Systems and Applications in Engineering 2014; 2(1): 1-9.
[16] Xu C, Gordan B, Koopialipoor M, Armaghani DJ, Tahir M, Zhang X. Improving performance of retaining walls under dynamic conditions developing an optimized ann based on ant colony optimization technique. IEEE Access 2019; 7: 94692-94700.
[17] Yang H, Koopialipoor M, Armaghani DJ, Gordan B, Khorami M, Tahir M. Intelligent design of retaining wall structures under dynamic conditions. Steel and Composite Structures, An International Journal 2019; 31(6): 629-640.
[18] Koopialipoor M, Murlidhar BR, Hedayat A, Armaghani DJ, Gordan B, Mohamad ET. The use of new intelligent techniques in designing retaining walls. Engineering with Computers 2020; 36(1): 283-294.
[19] Mishra P, Samui P, Mahmoudi E. Probabilistic design of retaining wall using machine learning methods. Applied Sciences 2021; 11(12): 5411.
[20] Mustafa R, Samui P, Kumari S. Probabilistic analysis of gravity retaining wall using anfis-based optimization techniques. Innovative Infrastructure Solutions 2022; 7(6): 366.
[21] Mustafa R, Samui P, Kumari S. Reliability analysis of gravity retaining wall using hybrid anfis. Infrastructures 2022; 7(9): 121.
[22] Mustafa R, Samui P, Kumari S. Seismic performance of gravity retaining walls under quasi-static approach using probabilistic analysis. Transportation Infrastructure Geotechnology 2023; 11(2): 1-38.
[23] Mustafa R, Samui P, Kumari S, Mohamad ET, Bhatawdekar RM. Probabilistic analysis of gravity retaining wall against bearing failure. Asian Journal of Civil Engineering 2023: 1-21.
[24] Kumar A, Burman A. Reliability analysis of gravity retaining wall under seismic conditions using a novel hybrid paradigm of elm and improved grey wolf optimizer. Modeling Earth Systems and Environment 2025; 11(3): 214.
[25] Azad SK, Akış E. Cost efficient design of mechanically stabilized earth walls using adaptive dimensional search algorithm. Teknik Dergi 2020; 31(4): 10167-10188.
[26] Bekdaş G, Cakiroglu C, Kim S, Geem ZW. Optimal dimensioning of retaining walls using explainable ensemble learning algorithms. Materials 2022; 15(14): 1-15.
[27] Cakiroglu C, Islam K, Bekdaş G, Nehdi ML. Data-driven ensemble learning approach for optimal design of cantilever soldier pile retaining walls. Structures 2023; 51: 1268-1280.
[28] Ertosun Karabulut Z, Kurt Z, Kalemci E, Dede T, Ikizler SB. Reinforced concrete cantilever retaining wall design consisting of two stage stem using rao1 algorithm. Engineering Computations 2025.
[29] Kalemci EN, İkizler SB, Dede T, Angın Z. Design of reinforced concrete cantilever retaining wall using grey wolf optimization algorithm. Structures 2020; 23: 245-253.
[30] Liu W, He L, Liu J, Xie X, Hao N, Shen C, Zhou J. Design optimization of an innovative instrumental single-sided formwork supporting system for retaining walls using physics-constrained generative adversarial network. Buildings 2025; 15(1): 132.
[31] Rhayma N, Khorchani M, Breul P. Reliability-based design optimization of gravity retaining walls. Computers and Concrete 2025; 35(2): 203.
[32] Uray E, Tan Ö, Çarbaş S, Erkan İH. Metaheuristics-based pre-design guide for cantilever retaining walls. Teknik Dergi 2021; 32(4): 10967-10993.
[33] Das BM. Principles of geotechnical engineering, 7th edition. Cengage learning; 2010.
[34] Seed HB, Whitman RV. Design of earth retaining structures for dynamic loads. ASCE, Specialty Conf on Lateral Stresses in Ground and Design of Earth-Retaining Structures; Ithaca, NY 1970: 103-147.
[35] Terzaghi K. Theoretical soil mechanics. 1943.
[36] Das BM. Principles of foundation engineering, si. Seventh Edition ed. 794. USA: Global Engineering; 2011.

[37] Kardani N, Bardhan A, Samui P, Nazem M, Zhou A, Armaghani DJ. A novel technique based on the improved firefly algorithm coupled with extreme learning machine (elm-iff) for predicting the thermal conductivity of soil. Engineering with Computers 2021; 38(4): 1-20.
[38] Chen T, Guestrin C. Xgboost: A scalable tree boosting system. In: Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining, San Francisco California, USA; 2016.
[39] Feng D-C, Wang W-J, Mangalathu S, Taciroglu E. Interpretable xgboost-shap machine-learning model for shear strength prediction of squat rc walls. Journal of Structural Engineering 2021; 147(11): 04021173.
[40] Zhang J, Yuan J, Mahmoudi A, Ji W, Fang Q. A data-driven framework for conceptual cost estimation of infrastructure projects using xgboost and bayesian optimization. Journal of Asian Architecture and Building Engineering 2025; 24(2): 751-774.
[41] Wu J, Chen X-Y, Zhang H, Xiong L-D, Lei H, Deng S-H. Hyperparameter optimization for machine learning models based on bayesian optimization. Journal of Electronic Science and Technology 2019; 17(1): 26-40.
[42] Luong P, Nguyen D, Gupta S, Rana S, Venkatesh S. Adaptive cost-aware bayesian optimization. Knowledge-Based Systems 2021; 232: 107481.
[43] Shi R, Xu X, Li J, Li Y. Prediction and analysis of train arrival delay based on xgboost and bayesian optimization. Applied Soft Computing 2021; 109: 107538.
[44] Shin S, Lee Y, Kim M, Park J, Lee S, Min K. Deep neural network model with bayesian hyperparameter optimization for prediction of nox at transient conditions in a diesel engine. Engineering Applications of Artificial Intelligence 2020; 94: 103761.
[45] Shahriari B, Swersky K, Wang Z, Adams RP, De Freitas N. Taking the human out of the loop: A review of bayesian optimization. Proceedings of the IEEE 2015; 104(1): 148-175.
[46] Mangalathu S, Hwang S-H, Jeon J-S. Failure mode and effects analysis of rc members based on machine-learning-based shapley additive explanations (shap) approach. Engineering Structures 2020; 219: 110927.
[47] Lundberg SM, Lee S-I. A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems 2017; 30.
[48] Lundberg SM, Erion GG, Lee S-I. Consistent individualized feature attribution for tree ensembles. arXiv preprint arXiv:1802.03888 2018.
[49] Mangalathu S, Jang H, Hwang S-H, Jeon J-S. Data-driven machine-learning-based seismic failure mode identification of reinforced concrete shear walls. Engineering Structures 2020; 208: 110331.
[50] Mangalathu S, Jeon J-S. Machine learning–based failure mode recognition of circular reinforced concrete bridge columns: Comparative study. Journal of Structural Engineering 2019; 145(10): 04019104.
[51] Somala SN, Chanda S, Karthikeyan K, Mangalathu S. Explainable machine learning on new zealand strong motion for pgv and pga. In: Structures; Elsevier; 2021.