



Ağırlık istinat duvarlarının makine öğrenmesi tabanlı tasarımı

Machine learning-based design of gravity retaining walls

Kevser Küley¹, Alirıza İlker Akgönen^{2*}, Yavuz Canbay³

¹ Kahramanmaraş Sütçü İmam Üniversitesi, İnşaat Mühendisliği Bölümü, kevser.yildiz@gmail.com

ORCID: <https://orcid.org/0009-0007-8609-355X>

² Kahramanmaraş Sütçü İmam Üniversitesi, İnşaat Mühendisliği Bölümü, ilkerakgonen@ksu.edu.tr

ORCID: <https://orcid.org/0000-0001-7384-8764>

³ Kahramanmaraş Sütçü İmam Üniversitesi, Bilgisayar Mühendisliği Bölümü, yavuzcanbay@ksu.edu.tr

ORCID: <https://orcid.org/0000-0003-2316-7893>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 29 Nisan 2026
Revizyon 31 Mayıs 2026
Kabul 5 Haziran 2026
Online 28 Temmuz 2026

Anahtar Kelimeler:

Ağırlık İstinat Duvarı,
Makine Öğrenmesi,
Regresyon

ÖZ

Ağırlık istinat duvarları, yanal toprak basıncı, hidrostatik basınç ve granüler dolgu malzemelerinden kaynaklanan yatay yükleri kendi ağırlıkları aracılığıyla dengeleyen önemli geoteknik yapı elemanlarıdır. Bu yapıların güvenli bir biçimde tasarlanabilmesi için devrilme, kayma ve temel taşıma gücü göçmesi gibi farklı göçme modlarının birlikte değerlendirilmesi gerekmektedir. Bu çalışmada, ağırlık istinat duvarlarının tasarımını etkileyen temel parametreler sistematik bir yaklaşımla ele alınmış; farklı geometrik özellikler, zemin koşulları ve deprem etkileri dikkate alınarak Sta4CAD programı aracılığıyla toplam 620 adet istinat duvarı tasarımı gerçekleştirilmiştir. Söz konusu analizler, Türkiye Bina Deprem Yönetmeliği (TBDY-2018) esaslarına uygun olarak yürütülmüştür. Elde edilen kapsamlı veri seti, mühendislik problemlerinde veri odaklı yaklaşımların uygulanabilirliğini incelemek amacıyla Python programlama dili kullanılarak analiz edilmiştir. Bu kapsamda, veri seti üzerinde çeşitli makine öğrenmesi algoritmaları uygulanmış, geliştirilen modellerin performansları karşılaştırılmış ve istinat duvarı tasarımına ilişkin kritik parametrelerin tahmin edilmesindeki başarı düzeyleri değerlendirilmiştir. Elde edilen bulgular, geleneksel mühendislik yaklaşımlarına alternatif olarak makine öğrenmesi yöntemlerinin istinat duvarı tasarım süreçlerinde etkin ve güvenilir bir şekilde kullanılabileceğini göstermektedir.

ARTICLE INFO

Article history:

Received 29 April 2026
Received in revised form 31 May 2026
Accepted 05 June 2026
Available online 28 July 2026

Keywords:

Gravity Retaining Wall,
Machine Learning,
Regression

ABSTRACT

Gravity retaining walls are important geotechnical structures that resist lateral loads arising from earth pressure, hydrostatic pressure, and granular backfill materials primarily through their self-weight. In order to achieve a safe design, multiple failure modes—such as overturning, sliding, and bearing capacity failure—must be evaluated in an integrated manner. In this study, the fundamental parameters affecting the design of gravity retaining walls were systematically investigated. A total of 620 retaining wall designs were generated using the Sta4CAD software by considering varying geometric properties, soil conditions, and seismic effects. All analyses were conducted in accordance with the provisions of the Turkish Building Earthquake Code (TBDY-2018). The resulting comprehensive dataset was analyzed using the Python programming language to evaluate the applicability of data-driven approaches in engineering problems. Within this scope, various machine learning algorithms were implemented on the dataset, the performance of the developed models was compared, and their success in predicting critical design parameters of retaining walls was assessed. The findings indicate that machine learning methods can serve as effective and reliable alternatives to conventional engineering approaches in the design process of gravity retaining walls.

Doi: 10.24012/dumf.1940125

* Sorumlu Yazar

Giriş

Ağırlık tipi istinat duvarları, zemin kütlelerini desteklemek ve yanal toprak basıncına karşı koymak amacıyla temel olarak kendi ölü ağırlıklarını kullanan mühendislik yapılarıdır [1]. Karayolu, demiryolu ve kıyı yapıları gibi inşaat mühendisliği uygulamalarında yaygın olarak tercih edilen bu yapılar kargir (taş örgü), donatısız beton (kütle beton), betonarme ve gabion (taş dolgu tel kafesler) gibi farklı malzemelerle inşa edilebilmektedir [2, 3]. Ekonomik açıdan değerlendirildiğinde, 4 metreyi aşmayan yüksekliklerde ağırlık tipi istinat duvarları uygun bir çözüm sunarken, yaklaşık 8 metreye kadar olan yüksekliklerde betonarme konsol istinat duvarları daha ekonomik hale gelmektedir; daha büyük yükseklikler için ise payandalı ve forekazık istinat duvarı sistemleri daha uygun maliyetli alternatifler olarak öne çıkmaktadır [4].

Kayma, devrilme ve taşıma gücü gibi göçme modlarını inceleyen çalışmalar literatürde geniş yer bulmaktadır. [5] numaralı çalışmada yazarlar, kohezyonsuz dolguya sahip istinat duvarlarının deprem etkisi altındaki kayma davranışını inceleyerek kritik ivme katsayısı için analitik çözümler geliştirmiş; duvar-zemin etkileşimini yatay ve düşey sismik etkiler altında değerlendirerek duvar yüzeyi eğimi ve pürüzlülüğünün stabilite üzerinde belirleyici olduğunu, bazı durumlarda düşey deprem ivmesinin ihmal edilemeyeceğini ortaya koymuştur. [6] numaralı çalışmada yazarlar, farklı geometrik tasarımlara sahip istinat duvarlarını karşılaştırmış; 90° köşeli U tipi bir duvarda gerilme analizi yapıldıktan sonra farklı pah uzunluklarına sahip beş alternatif tasarım geliştirerek performanslarını karşılaştırmıştır. [7] numaralı çalışmada yazarlar, segmental ağırlık istinat duvarlarının deprem etkisi altındaki davranışını Mononobe-Okabe yöntemi ile incelemiş, en kritik tasarım kriterinin devrilmeye karşı güvenlik olduğunu ve pozitif duvar eğiminin stabiliteyi artırdığını belirtmiş, ayrıca segmental duvarlar için yeni bir temel tasarım denklemi önermiştir. [8] numaralı çalışmada yazarlar, tabandan kısıtlanmış betonarme istinat duvarlarının (RC-GRW) deformasyon davranışını açıklamak üzere yeni bir hesap modeli ve tasarım yaklaşımı geliştirmiş; duvarın farklı hasar aşamalarını tanımlayarak önerilen yöntemin mevcut yapıların performans değerlendirmesinde etkili olduğunu göstermiştir. [9] numaralı çalışmada yazarlar, Rankine teorisi kapsamında aktif ve pasif toprak basınçlarını hesaplayarak kayma, devrilme ve taşıma gücü stabilitesini incelemiş ve sonuçları ayırık elemanlar yöntemi (DEM) ile karşılaştırmıştır. [10] numaralı çalışmada yazarlar ise sismik koşullarda istinat duvarlarının kayma, devrilme ve taşıma gücü güvenlik katsayılarını tahmin etmek amacıyla Mononobe-Okabe yöntemi ile elde edilen veriler üzerinde GMDH, GPR ve MPMR makine öğrenmesi modellerini uygulamış; MPMR kayma ve devrilmede, GMDH ise taşıma gücü tahmininde daha başarılı performans göstermiştir.


İstinat duvarlarının tasarımında makine öğrenmesi modelleri ile birlikte yapay zekâ tabanlı optimizasyon teknikleri de yaygın olarak kullanılmaktadır. Bu kapsamda, güvenlik katsayısının (SF) doğru tahmini mühendislik risklerinin azaltılmasında kritik bir rol oynamaktadır. [11] numaralı

çalışmada, dinamik koşullar altında istinat duvarlarının SF değerlerini tahmin etmek için ICA-ANN ve GA-ANN hibrit modellerini geliştirmiş ve 8000'den fazla tasarımın analizi sonucunda her iki modelin yüksek doğruluk sağladığını, ancak ICA-ANN modelinin daha üstün performans gösterdiğini ortaya koymuştur. [12] numaralı çalışmada yazarlar, devrilmeye karşı güvenlik katsayısının tahmini için ANFIS tabanlı modelleri PSO, GA, FFA ve GWO algoritmaları ile birleştirerek dört farklı hibrit yaklaşım geliştirmiş ve ANFIS-PSO modelinin en iyi performansı verdiğini belirlemiştir. [13] numaralı çalışmada yazarlar, taşıma gücü göçmesine karşı güvenlik katsayısının tahmini için XGBoost, Random Forest ve Derin Sinir Ağı (DNN) modellerini kullanmış, 100 veri seti ve 6 girdi parametresi ile gerçekleştirilen analizlerde DNN modelinin en yüksek doğruluk performansını gösterdiğini tespit etmiştir. [14] numaralı çalışmada yazarlar ise statik ve sismik etkiler altında istinat duvarlarının güvenilirlik analizini inceleyerek Monte Carlo Simülasyonu ile oluşturulan veri seti üzerinde ELM modelini gri kurt optimizasyonu (IGWO) ile optimize etmiş ve ELM-IGWO hibrit yaklaşımının yüksek doğruluk ve güvenilirlik sağladığını ortaya koymuştur; tüm bu çalışmalar, yapay zekâ tabanlı yöntemlerin istinat duvarlarının güvenlik ve performans değerlendirmesinde etkili ve güçlü araçlar olduğunu göstermektedir.

Literatür taraması, ağırlık tipi istinat duvarlarına ilişkin veri setlerinin oluşturulması ve bu veriler kullanılarak makine öğrenmesi modellerinin uygulanmasına yönelik çalışmaların oldukça sınırlı olduğunu göstermektedir. Mevcut araştırmaların büyük bölümü konsol tipi ve genel istinat duvarı tasarımına odaklanırken, makine öğrenmesi yöntemlerinin bu alana entegrasyonu henüz yeterli düzeyde gelişmemiştir. Mühendislik hesaplamalarında bilgisayar destekli yazılımlar giderek daha önemli hale gelmiştir. Bu kapsamda Python, esnek yapısı ve geniş kütüphane desteği sayesinde mühendislik analizlerinde yaygın olarak kullanılmaktadır. Bu çalışmada Sta4CAD ve Python kullanılarak farklı zemin koşulları ve malzeme özellikleri altında ağırlık tipi istinat duvarı tasarımları yapılmış ve elde edilen veriler analiz edilmiştir. Elde edilen veri seti ile sekiz farklı makine öğrenmesi modeli uygulanarak tahkik analizleri gerçekleştirilmiş ve modellerin performansları karşılaştırılmıştır. Böylece istinat duvarı tasarımında en güvenilir ve doğru sonuçları veren model belirlenerek, tasarım sürecine veri odaklı bir yaklaşım kazandırılması hedeflenmektedir.

Ağırlık İstinat Duvarı Tasarımı

Bu çalışmada, Sta4CAD programı kullanılarak 620 adet ağırlık istinat duvarı analizi tamamlanmıştır. Analizler TBDY-2018 bölüm 16.12'de belirtilen "Deprem Etkisi Altında Dayanma Yapılarının Tasarımı İçin Kurallar" dikkate alınarak yürütülmüştür. Genel olarak yapılan çalışmalar yanal itkinin belirlenmesi, kayma güvenliğinin tespiti, devrilme güvenliğinin tespiti olarak özetlenebilir. Hesaplamalarda kullanılan denklemler (Denklemler 1-6) aşağıda verilmiştir.



Şekil 1. Ağırlık İstinat duvarı

Toplam yatay itki Denklem (1) ile hesaplanır. Burada K , duvarın hareket durumuna bağlı olarak aktif (K_a), pasif (K_p) veya sükunetteki (K_0) toprak basıncı katsayısını temsil eder. $1/2 \cdot K \cdot \gamma \cdot H^2$ terimi, zeminin birim hacim ağırlığı (γ) ve duvar yüksekliği (H) etkisiyle oluşan üçgen dağılımlı toprak basıncının bileşkesini ifade eder. $K \cdot q \cdot H$ ise zemin yüzeyindeki sürşarj yükünün (q) oluşturduğu dikdörtgen yayılı basıncı gösterir. Ayrıca P_{su} durgun sudan kaynaklanan hidrostatik basıncı, ΔP_s ise deprem sırasında oluşan hidrokinamik su basıncını temsil eder. Sismik analizlerde düşey ivme katsayısı (k_v) gibi parametreler de dikkate alınabilir.

$$P_t = K(1 \pm k_v) \left(\frac{1}{2} \gamma H^2 + qH \right) + P_{su} + \Delta P_s \quad (1)$$

Denklem (2), kayma güvenliği kontrolünü gösterir. V_{th} yatay itkiyi (kaydırıcı kuvvet), R_{th} taban sürtünme direncini, R_{pt} ise pasif toprak direncini temsil eder. Pasif direnç tam güvenilir olmadığından yalnızca %30'u dikkate alınır. Bu şart, yapının kaymaması için itkinin dirençten küçük olması gerektiğini ifade eder.

$$V_{th} \leq R_{th} + 0.3R_{pt} \quad (2)$$

Denklem (3), drenajlı koşullarda temel tabanında oluşan kaymaya karşı direnç kuvvetini gösterir. Burada P_{tv} , temele etkiyen düşey kuvveti (üst yapı ve zemin ağırlıkları dahil), δ zemin ile temel arasındaki sürtünme açısını, γ_{Rh} ise yatay direnç için kullanılan güvenlik katsayısını ifade eder. Bu bağıntı, düşey kuvvetin sürtünme yoluyla yatay kaymaya karşı ne kadar direnç sağlayacağını hesaplamak için kullanılır.

$$R_{th-Drenajlı} = \frac{P_{tv} \tan(\delta)}{\gamma_{Rh}} \quad (3)$$

Denklem (4), pasif toprak direncinin tasarım değerini gösterir. Burada R_{pk} , karakteristik pasif toprak direncini, γ_{Rp} ise pasif direnç için kullanılan güvenlik katsayısını ifade eder. Bu bağıntı ile pasif direncin güvenli (azaltılmış) değeri elde edilir.

$$R_{pt} = \frac{R_{pk}}{\gamma_{Rp}} \quad (4)$$

Denklem (5), devrilme (overturning) güvenliği kontrolünü ifade eder. Burada E_{dev} devrilmeye neden olan etkileri (momentleri), R_{dev} devrilmeye karşı koyan direnç momentini, γ_{Rdev} ise devrilme için kullanılan güvenlik katsayısını temsil eder. Bu şart, devrilme etkisinin güvenli tarafta kalması için direnç momentinden küçük veya eşit olması gerektiğini gösterir.

$$E_{dev} \leq \frac{R_{dev}}{\gamma_{Rdev}} \quad (5)$$

Denklem (6), kayma güvenliği analizinde kullanılan bir güvenlik katsayısını ifade eder. Burada c' efektif kohezyonu, ϕ' efektif içsel sürtünme açısını, b dilim genişliğini, W_s dilim ağırlığını, u boşluk suyu basıncını, α kayma yüzeyi açısını, m_a dilimler arası etkileşim katsayısını ve W_t toplam ağırlığı temsil eder. Üstteki ifade direnç kuvvetlerini, alttaki ifade ise kaydırıcı kuvvetleri gösterir.

$$\gamma_{Rk} = \frac{1}{W_t \sin(\alpha)} \sum c' b + \left[\frac{1}{m_a} \left(W_s - \frac{c' b \sin(\alpha)}{\gamma_{Rk}} - ub \right) \right] \tan(\phi') \quad (6)$$

Hesaplamalarda sabit tutulan parametreler ise şöyledir: Duvar özkütlesi 1800 kg/m^3 olarak kabul edilmiştir. Zemin yüzeyi açısı 0° 'dir. Zemin-duvar sürtünme çarpanı $0,55$ olarak alınmıştır. Hareketli yük değeri ise 5 kN/m^2 'dir.

Kaymaya karşı dayanım güvenlik katsayısı (γ_{Rk}) değeri $1,5$ 'tir. Dayanma yapısında devrilmeye karşı tasarım güvenlik katsayısı (γ_{Rdev}) değeri statik durumda $1,5$, depremleri durumda ise $1,3$ olarak alınmıştır. Pasif direnç dayanım katsayısı (γ_{Rp}) değeri $1,4$ 'tür. Sürtünme direnci dayanım katsayısı (γ_{Rh}) değeri ise $1,5$ 'tir.

Makine Öğrenmesi

Makine öğrenimi (ML), geçmiş verilerden öğrenerek geleceğe dair çıkarımlar yapıp karar vermede kullanılan bir yapay zeka (AI) alt kümesidir. Bilgisayarları verilerden öğrenmeyi öğretmeye ve bunu yapmak için açıkça programlanmak yerine deneyimle geliştirmeye odaklanır. Makine öğrenmesinde algoritmalar büyük veri kümelerinde örüntüleri ve korelasyonları bulmak ve bu analize dayalı en iyi kararları ve tahminleri yapmak için eğitilir. Makine öğrenmesi uygulamaları kullanımla gelişir ve daha fazla veri erişimi olduğunda daha doğru hale gelir [15]. Mevcut veri

seti ve kullanılan algoritma ile oluşturulan model, en yüksek performansı vermek üzere kurulmaktadır. Bu sebeple pek çok makine öğrenmesi yöntemi geliştirilmiştir [16].

Yapay zeka, optimizasyon modelleri, makine öğrenmesi gibi bilgisayar destekli tasarımlar mühendislik adımlarını iyileştirmede ve hızlandırmada önemli roller oynamışlardır. Gerçekleştirilen bu çalışmada 8 farklı makine öğrenmesi modeli kullanılıp en iyi sonucu veren model saptanmıştır. Çalışmada kullanılan modeller aşağıda açıklanmıştır;

K-Nearest Neighbors: KNN algoritması ya da diğer adıyla K-En yakın komşu algoritması makine öğrenim algoritmaları içerisinde en çok bilinen ve kullanılan algoritmalarından biridir. Seçilen bir özelliğin kendine en yakın olan özelliklerle arasındaki yakınlığı kullanarak sınıflandırma yapılır [17].

Lineer Regression: Lineer regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkinin doğrusal olduğu varsayımıyla istatistiksel olarak açıklamaya çalışan ve en uygun doğruyu belirlemeyi amaçlayan bir yöntemdir. Doğrusal ilişki, iki değişken arasındaki mümkün olan en basit ilişki türüdür ve bir değişkende meydana gelen her değişime karşılık, diğer değişkende tutarlı ve karşılık gelen bir değişimin gerçekleştiğini ifade eder. Amaç, bağımsız değişkenler kullanılarak bağımlı değişkenin tahmin edilmesini sağlamaktır. Modelin genel yapısında, her bağımsız değişkenin bir katsayısı bulunur ve bu katsayılar, değişkenlerin sonuca ne kadar etkili olduğunu gösterir. Lineer regresyonda, hata payının mümkün olduğunca küçük olması hedeflenir ve veriler arasındaki ilişki doğrusal bir doğrultuda olmalıdır [18].

Decision Tree Regression: Karar ağaçları kullanarak veri noktalarını bölerek tahmin yapar. Hiyerarşik ve ayırık veriler üzerinde etkilidir. Karar ağacı regresyon modeli öncelikle veri kümesindeki bağımsız değişkenleri bilgi kazancına göre aralıklara bölmektedir. Tahmin işlemi gerçekleştirilirken, sorgulanan değer hangi aralıkta ise o aralığın ortalama değeri geri döndürülmektedir. Belli aralıklarda istenen tahminlerin aynı sonucu üretmesi, karar ağacı regresyon modelinin, regresyon modelindeki gibi sürekli olmadığını göstermektedir [19].

Random Forest Regression: Birden fazla karar ağacının oluşturulması ve sonuçlarının ortalamasını alarak tahmin yapar. Gürültülü veri setlerinde ve doğruluğun artırılmasında etkilidir. Random Forest, ağaç yapılı bir grup sınıflandırıcıdan oluşan bir sınıflandırıcıdır. RF, Liaw ve Wiener'e göre topluluk öğrenimi fikri üzerine kurulmuş başka bir ML algoritmasıdır. RF, belirtilen verilerin çok sayıda alt grubunda çeşitli karar ağaçlarını içeren ve bu verilerin tahmin geçerliliğini iletirmek için ortalama alan bir sınıflandırıcıdır. Tek bir karar ağacına bağlı kalmak yerine, RF her bir bireysel ağaçtan tahmini alır ve tahminlerin çoğunluk oylarıyla (ortalama oylama) belirlenen nihai çıktıyı tahmin eder. RF kullanmanın başlıca avantajları, daha az eğitim süresi alması ve çıktıyı büyük bir hassasiyetle tahmin etmesidir. Çok büyük veri kümeleri için bile verimli bir şekilde çalışır [20].

Gradient Boosting Regression: Gradient Boosting Regresyonu, öğrenme süreci yanıt değişkeninin daha doğru bir şekilde tahmin edilmesini sağlamak amacıyla ardışık olarak yeni modellerin eğitilmesine dayanır. Bu algoritmanın temel prensibi, yeni temel öğrencilerin tüm topluluk modeli ile ilişkili kayıp fonksiyonunun negatif gradyanı ile maksimum düzeyde korelasyon gösterecek şekilde oluşturulmasıdır. Kullanılan kayıp fonksiyonları keyfi olarak seçilebilir; ancak daha iyi bir sezgisel anlayış sağlamak adına, hata fonksiyonu klasik karesel hata olarak seçildiğinde, öğrenme süreci ardışık hata uyumlama şeklinde gerçekleşir. Genel olarak, kayıp fonksiyonunun seçimi araştırmacıya bağlıdır ve literatürde türetilmiş çok çeşitli kayıp fonksiyonlarının yanı sıra, probleme özgü yeni kayıp fonksiyonlarının tanımlanması da mümkündür [21].

Ada Boost Regression: Algoritma ilk olarak Yoav Freund ve Robert Schapire tarafından 1995'te geliştirilmiştir. AdaBoost, meta-tahminleme amacıyla kullanılan ve başlangıçta orijinal veri seti üzerinde bir regresyon modeli oluşturulmasıyla başlayan bir yöntemdir. Aynı veri seti üzerinde regresyon modelinin ek kopyaları üretilir. Örnek ağırlıkları, en son tahmin hatasına bağlı olarak güncellenir. Takip eden regresyon modelleri ise daha karmaşık ve hatası yüksek örnekler üzerinde yoğunlaşır [22].

Support Vector Regression: Support Vector Machines (SVM) algoritmasının regresyon versiyonudur. Belirli bir hata marjı içinde en uygun hiperdüzlemi bulur. Küçük veri setlerinde yüksek doğruluk sağlar. Sınıflandırma problemlerinde veya veriler doğrusal olarak ayrılabilir olmadığında sınıf atamada kullanılabilecek en güçlü modellerden biri olduğu söylenebilir [23].

Multi-Layer Perceptron Regressor: Yapay sinir ağları (neural networks) kullanarak doğrusal olmayan ve karmaşık veri ilişkilerini öğrenir. Karmaşık veri setlerinde doğrusal olmayan ilişkiler için güçlüdür. Temel MLP modeli en az üç nöron katmanından (algılayıcıdan) oluşur: giriş, gizli ve çıkış katmanları. Nöronlar üç katmana yerleştirilir ve ağırlıklı bağlantılar aracılığıyla birbirleriyle etkileşime girerler. Her nöron, bir sonraki katmandaki diğer tüm nöronlara bağlıdır [24].

Kullanılan Metrikler

R-Kare (R^2): Gerçek değer ile modelin tahminleri arasındaki uyumun bir ölçüsüdür. Gerçek değerlerin varyansının, tahmin edilen değerlerin varyansına oranlanması ile bulunmaktadır. Bu durum, model uyum iyiliğinin ne kadar iyi olduğunu veya olmadığını ifade etmektedir [25].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

Mse: Gerçek değerler ile tahmin edilen değerler arasındaki farkların karesinin ortalamasıdır. Farkların karesinin alınması, hataların negatif veya pozitif olmasına

bakılmaksızın tüm sapmaları büyütür, bu da özellikle büyük hatalara duyarlı uygulamalarda kritik önem taşır.

$$Mse = \left(\frac{1}{n}\right) * \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

Rmse: MSE'nin kareköküdür. MSE ile benzer şekilde gerçek değerler ile tahmin edilen değerler arasındaki farkın ortalama büyüklüğünü ölçer. Bunu yaparken gerçek değerler ile tahmin edilen değerler arasındaki farkların ortalamasının karekökünü alır [25].

$$Rmse = \sqrt{\left(\frac{1}{n}\right) * \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

Mae: Gerçek değerler ile tahmin edilen değerler arasındaki hataların mutlak değerlerinin ortalamasıdır. Bu metrik doğrudan hataların mutlak değerleri üzerinden çalışmaktadır [25].

$$Mae = \left(\frac{1}{n}\right) * \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

Sayısal Analizler

Bu çalışmada, Sta4CAD yazılımı kullanılarak toplam 620 adet analiz gerçekleştirilmiş ve kapsamlı bir veri seti oluşturulmuştur. Veri setinin oluşturulması sürecinde, Tablo 1'de sunulan ağırlık istinat duvarlarına ait sekiz adet giriş parametresi kontrollü bir şekilde değiştirilerek veri çeşitliliği sağlanmıştır. Yapılan analizler sonucunda ise Tablo 2'de yer alan sekiz adet çıktı parametresi elde edilmiştir.

Girdi verilerinin belirlenmesi aşamasında, ağırlık istinat duvarlarının ön boyutlandırma koşullarına uygunluk esas alınmış ve mühendislik açısından gerçekçi değer aralıkları tercih edilmiştir. Tüm analizler, TBDY-2018 yönetmeliğine uygun olarak yürütülmüştür.

Elde edilen veri seti, mühendislik problemlerinde veri odaklı yaklaşımların uygulanabilirliğini incelemek amacıyla Python programlama dili kullanılarak analiz edilmiştir. Bu kapsamda, veri setine çeşitli makine öğrenmesi algoritmaları uygulanmış, geliştirilen modellerin performansları karşılaştırılmış ve istinat duvarı tasarımına ilişkin kritik parametrelerin tahmin edilmesindeki başarı düzeyleri değerlendirilmiştir.


Tablo 1. Girdi verileri

Girdi Verileri	Açıklama
h	Duvar Yüksekliği
a	İstinat Duvarı Ön Pabuç Genişliği
b	İstinat Duvarı Üst Genişliği
Sds	Kısa Periyot Tasarım Spektral İvme Katsayısı
Slip Resistance Angle	Kayma Direnci Açısı
Cohesion	Kohezyon
Soil Density	Zemin Birim Hacim Ağırlığı
Bearing Capacity Resistance	Taşıma Gücü Kapasitesi

Tablo 2. Çıktı verileri

Çıktı Verileri	Açıklama
Factor Of Safety Against Sliding	Statik Yükler Altında Kayma Güvenliği
Sliding Safety Under Seismic Loading	Sismik Yükler Altında Kayma Güvenliği
Factor Of Safety Against Overturning	Statik Yükler Altında Devrilme Güvenliği
Overturning Safety Under Seismic Loading	Sismik Yükler Altında Devrilme Güvenliği
Bearing Stress Safety	Statik Yükler Altında Gerilme Güvenliği
Bearing Stress Safety Under Seismic Loading	Sismik Yükler Altında Gerilme Güvenliği
Global Stability Safety	Statik Yükler Altında Toptan Göçme
Global Stability Safety Under Seismic Loading	Sismik Yükler Altında Toptan Göçme

Simülasyon sonucu oluşturulan veri seti kullanılarak Python programında algoritmalar aracılığıyla makine öğrenmesi gerçekleştirilmiştir.



Şekil 2. Makine öğrenmesi süreci

Makine öğrenmesi adımları Şekil 2’de gösterildiği üzere gerçekleşmektedir. Her bir girdi verisi çalışmada kullanılan bütün makine öğrenmesi modelleriyle test edilmiş, metrik değerleri ve yakınsama grafikleri kaydedilmiştir. Kullanılan

makine öğrenmesi algoritmaları literatürde yüksek doğruluk ve genelleme yeteneği nedeniyle mühendislik alanında sıklıkla tercih edilmektedir. Model performansları, R^2 (Determinasyon Katsayısı), MSE (Ortalama Kare Hatası), RMSE (Kök Ortalama Kare Hatası), MAE (Ortalama Mutlak Hata) gibi istatistiksel metrikler Tablo 3-10’da belirtildiği üzere değerlendirilmiştir.

Bulgular

Regresyon modellerinin performans değerlendirmesi, tahmin hatalarının büyüklüğünden ziyade, modelin bağımlı değişkendeki varyansı açıklama kapasitesine dayanmaktadır. MAE, MSE ve RMSE gibi yaygın metriklerin veri setine özgü ölçek bağımlılıkları nedeniyle, modelleri kıyaslamada sınırlı bir açıklayıcılığa sahiptir [26].

Tablo 3. Kayma güvenliği hata metrikleri

Algoritma	R^2	Mse	Rmse	Mae
K-Nearest Neighbors Regressor	0.972993683	0.001587961	0.037998097	0.017091642
Linear Regression	0.928977123	0.004155113	0.063893843	0.044262608
Decision Tree Regressor	0.939679351	0.003570855	0.051234436	0.017069656
Random Forest Regressor	0.976348195	0.001396822	0.034054772	0.012595504
Gradient Boosting Regressor	0.982513507	0.001034376	0.030510567	0.015199441
Ada Boost Regressor	0.925677697	0.004338764	0.065154528	0.046531132
Support Vector Regressor	0.985303072	0.000875086	0.026185799	0.012615369
MLP Regressor	0.970973906	0.001705122	0.040653912	0.024977583

Tablo 4. Kayma güvenliği deprem hata metrikleri

Algoritma	R^2	Mse	Rmse	Mae
K-Nearest Neighbors Regressor	0.962054497	0.001403188	0.036172077	0.016856944
Linear Regression	0.893915482	0.003936248	0.062482063	0.04333823
Decision Tree Regressor	0.954656164	0.001722740	0.038587077	0.016901345
Random Forest Regressor	0.971986395	0.001057422	0.029507335	0.011636342
Gradient Boosting Regressor	0.976064052	0.000910803	0.028445386	0.013368945
Ada Boost Regressor	0.898268725	0.003687835	0.060204326	0.042935267
Support Vector Regressor	0.980156954	0.000746866	0.026195057	0.012072183
Mlp Regressor	0.952657434	0.001776529	0.041193853	0.027525967

Tablo 5. Devrilme güvenliği hata metrikleri

Algoritma	R ²	Mse	Rmse	Mae
K-Nearest Neighbors Regressor	0.953788416	0.200394792	0.421851139	0.180995377
Linear Regression	0.774748034	0.977590723	0.981120975	0.620878755
Decision Tree Regressor	0.932550612	0.298521147	0.518164781	0.249851544
Random Forest Regressor	0.95705936	0.185270312	0.414762544	0.172303391
Gradient Boosting Regressor	0.960581903	0.171915475	0.395725909	0.15703527
Ada Boost Regressor	0.880557936	0.516748422	0.709583586	0.423921253
Support Vector Regressor	0.971066673	0.124614315	0.296983359	0.122277321
Mlp Regressor	0.927062888	0.32563602	0.540508908	0.298400621

Tablo 6. Devrilme güvenliği deprem hata metrikleri

Algoritma	R ²	Mse	Rmse	Mae
K-Nearest Neighbors Regressor	0.422639487	2.881735804	1.383110587	0.408405633
Linear Regression	0.446417892	2.792739792	1.356902209	0.460389044
Decision Tree Regressor	0.490163665	2.743551354	1.313376915	0.39931982
Random Forest Regressor	0.514745773	2.753710861	1.285919288	0.35614731
Gradient Boosting Regressor	0.521925834	2.721758483	1.280496771	0.330535322
Ada Boost Regressor	0.482231291	2.76134515	1.323413276	0.396228218
Support Vector Regressor	0.342688305	2.957469041	1.438714245	0.395489075
Mlp Regressor	0.3744714	2.882575777	1.414524166	0.510452077

Tablo 7. Gerilme güvenliği hata metrikleri

Algoritma	R ²	Mse	Rmse	Mae
K-Nearest Neighbors Regressor	0.944816136	0.000803335	0.022774425	0.007874748
Linear Regression	0.927139384	0.001044282	0.027575339	0.015118272
Decision Tree Regressor	0.926840706	0.001026223	0.027990051	0.012337592
Random Forest Regressor	0.94090715	0.000849755	0.022920052	0.00737337
Gradient Boosting Regressor	0.938410711	0.000861857	0.023584061	0.01062751
Ada Boost Regressor	0.852752971	0.001907076	0.041801338	0.026901644
Support Vector Regressor	0.955785789	0.000672759	0.018044873	0.007630196
Mlp Regressor	0.94311992	0.000827674	0.023377002	0.011417009

Tablo 8. Gerilme güvenliği deprem hata metrikleri

Algoritma	R ²	Mse	Rmse	Mae
K-Nearest Neighbors Regressor	0.747151137	0.61093823	0.411473812	0.055110182
Linear Regression	0.389911693	0.633525083	0.507930903	0.100986836
Decision Tree Regressor	0.315345452	0.674556172	0.516204046	0.093780051
Random Forest Regressor	0.319143029	0.636813437	0.519120086	0.072150956
Gradient Boosting Regressor	0.766891129	0.612926178	0.402138311	0.051716447
Ada Boost Regressor	0.689244276	0.610626287	0.436359485	0.101597309
Support Vector Regressor	0.29751254	0.673170355	0.524169768	0.164067152
Mlp Regressor	0.161343287	0.679706643	0.551624504	0.21043549

Tablo 9. Toptan göçme hata metrikleri


Algoritma	R ²	Mse	Rmse	Mae
K-Nearest Neighbors Regressor	0.975769956	0.252423229	0.487795325	0.208998286
Linear Regression	0.666118875	3.306660229	1.804037815	1.231635098
Decision Tree Regressor	0.998394626	0.014746048	0.115332146	0.049112903
Random Forest Regressor	0.998779491	0.011605941	0.099007948	0.034078149
Gradient Boosting Regressor	0.998283426	0.015936213	0.117313899	0.047246749
Ada Boost Regressor	0.981197587	0.175188834	0.411087188	0.27784102
Support Vector Regressor	0.981677477	0.175173301	0.413554264	0.212007245
Mlp Regressor	0.987955575	0.116785572	0.334139091	0.193829798

Tablo 10. Toptan göçme deprem hata metrikleri

Algoritma	R ²	Mse	Rmse	Mae
K-Nearest Neighbors Regressor	0.981998034	0.071767517	0.264759216	0.126687082
Linear Regression	0.783019719	0.850105217	0.917157228	0.642400926
Decision Tree Regressor	0.994741292	0.020199171	0.13975371	0.058475806
Random Forest Regressor	0.995939443	0.015512973	0.116674854	0.043910914
Gradient Boosting Regressor	0.995587532	0.017036568	0.121770644	0.051502528
Ada Boost Regressor	0.958717625	0.160329074	0.393402041	0.247169384
Support Vector Regressor	0.919552518	0.325400505	0.511332285	0.323019147
Mlp Regressor	0.984451014	0.059853702	0.237553406	0.146287771


Tablolardan görüldüğü üzere R^2 değerleri 0 ile 1 arasında değerler almaktadır. Bu metrik değeri 1'e yaklaştıkça modelin mükemmel yakın bir uyumunun olduğunu gösterir. Modelin kullanım amacına göre metriklerin önemi değişmektedir.

Bu metriklerin birlikte kullanımı, model performansının tek boyutlu bir bakış açısıyla değil çok yönlü ve eleştirel bir çerçevede değerlendirilmesini mümkün kılmaktadır.




Şekil 3. Kayma güvenliği yakınsama grafiği

Şekil 3 ve 4'te sunulan Gradient Boosting algoritması için verilen örnek yakınsama grafikleri, geliştirilen makine öğrenmesi modellerinin tahmin performansını görsel olarak değerlendirmek amacıyla oluşturulmuştur. Bu grafiklerde yatay eksen gerçek değerleri, dikey eksen ise model tarafından tahmin edilen değerleri göstermektedir. Grafiklerde ayrıca ideal durumu temsil eden 45°'lik doğrusal referans hattı yer almaktadır. Bu bağlamda veri noktalarının ideal doğru hattında yoğunlaşması, modelin yüksek doğrulukta tahmin yaptığını ve sistem davranışını başarılı bir şekilde öğrendiğini göstermektedir [27].



Şekil 4. Kayma güvenliği deprem yakınsama grafiği

Tablo 3–10'da sunulan sonuçlar incelendiğinde, makine öğrenmesi algoritmalarının ağırlık istinat duvarlarının güvenlik parametrelerinin tahmininde genel olarak yüksek başarı gösterdiği görülmektedir. Özellikle kayma, devrilme, gerilme ve toptan göçme güvenlik analizlerinde ağaç tabanlı yöntemler ile Destek Vektör Regresyonu (SVR) en yüksek performansları sergilemiştir. Statik yükleme durumlarında birçok model için R^2 değerleri 0.95'in üzerine çıkarken, toptan göçme analizlerinde Random Forest ve Gradient Boosting algoritmaları 0.99'un üzerinde doğruluk elde etmiştir. Buna karşın deprem etkilerinin dikkate alındığı devrilme ve gerilme güvenliği analizlerinde tüm modellerin performanslarında belirli düzeyde düşüş gözlenmiştir, bunun temel nedeni deprem yüklerinin oluşturduğu karmaşık ve doğrusal olmayan davranışlar olarak değerlendirilmiştir. Genel olarak elde edilen bulgular, makine öğrenmesi tabanlı yaklaşımların ağırlık istinat duvarlarının ön tasarım ve güvenlik değerlendirme süreçlerinde hızlı, güvenilir ve yüksek doğruluklu tahminler sunabileceğini ortaya koymaktadır.



Şekil 5. Regresyon sonuçları

Grafiksel dağılım dikkate alındığında, bazı durumlarda veri noktalarının ideal doğrudan daha fazla sapma gösterdiği görülmektedir. Bu durum, sistemin daha karmaşık davranış sergilediği yükleme koşullarında model performansının görece azaldığını göstermektedir. Bu durum doğrusal olmayan etkilerin baskın olduğu durumlarda, tahminlerin ideal doğrudan uzaklaşmasının sonucu olarak ortaya çıkar. Sonuç olarak, yakınsama grafikleri geliştirilen modellerin yalnızca istatistiksel olarak değil, aynı zamanda model performansının görsel olarak doğrularak, hata metrikleri ile elde edilen bulguları desteklemekte ve önerilen yaklaşımın güvenilirliğini desteklemektedir.

Sonuç

Bu çalışmada, kapsamlı bir makine öğrenmesi analizi kullanılarak ağırlık istinat duvarlarının tasarımı incelenmiştir. Farklı duvar geometrileri, zemin özellikleri ve tasarım parametreleri dikkate alınarak 620 satırdan oluşan bir veri seti oluşturulmuştur. Oluşturulan veri seti sekiz farklı makine öğrenmesi modeli ile değerlendirilmiş ve elde edilen bulgular aşağıda sunulmuştur.

- Elde edilen sonuçlar doğrultusunda, Gradient Boosting algoritmasının ağırlık istinat duvarı tasarımının belirlenmesinde en yüksek doğruluğa ve en düşük hata oranına sahip olduğu Şekil 3 ve Şekil 4'te görülmektedir. Bu durum, Gradient Boosting algoritmasının zayıf öğrencileri ardışık olarak eğiterek hataları minimize etme yaklaşımından kaynaklanmaktadır. Veri setinin karmaşık ve gürültülü bir yapıya sahip olması nedeniyle, Gradient Boosting algoritmasının yüksek performans gösterdiği söylenebilir. Ayrıca algoritma, ağaç tabanlı yapısı sayesinde değişkenler arasındaki karmaşık ilişkileri etkili bir şekilde öğrenerek başarılı tahminler gerçekleştirebilmektedir.
- Veri setinin karmaşık ve yüksek derecede doğrusal olmayan ilişkiler içermesi, özellikle doğrusal modellerin performansını sınırlandırmıştır. Buna bağlı olarak, Lineer Regresyon modelinin diğer modellere kıyasla daha düşük performans göstermesi, bu modelin sistem davranışını yeterince temsil edemediğini ortaya koymaktadır. Buna karşılık, ağaç tabanlı algoritmaların veri içerisindeki değişkenler arası etkileşimleri daha etkin bir şekilde modelleyebildiği görülmüştür. Özellikle Gradient Boosting algoritmasının karar ağaçlarını kademeli olarak geliştirerek hatalara odaklanması, modelin genelleme kabiliyetini artırmıştır. Bu sayede daha kararlı sonuçlar elde edilmiştir. Bu durum, yakınsama grafiklerinde veri noktalarının ideal doğru etrafında yoğunlaşmasıyla da desteklenmektedir.
- Algoritmalar arasındaki performans farklılıklarının temel nedeni, her algoritmanın veri yapısını ve değişkenler arasındaki ilişkileri farklı biçimlerde modellemesidir. Özellikle topluluk tabanlı yöntemler olan Random Forest, Gradient Boosting

ve AdaBoost algoritmaları, doğrusal olmayan ilişkileri ve karmaşık veri örüntülerini daha başarılı şekilde yakalayabildiklerinden genel olarak daha yüksek performans göstermiştir. Buna karşılık, Lineer Regresyon gibi doğrusal varsayımlara dayanan modeller, özellikle deprem etkilerinin baskın olduğu ve zemin davranışının daha karmaşık hâle geldiği durumlarda daha düşük başarı elde etmiştir. Ayrıca veri setindeki değişkenlerin dağılımı, örnek sayısı, parametreler arasındaki etkileşimler ve gürültü seviyesi gibi faktörler de modellerin genelleme kabiliyetlerini farklı düzeylerde etkileyerek performans farklılıklarına neden olmuştur.

- Deprem etkileri, ağırlık istinat duvarlarında belirgin doğrusal olmayan davranışların ortaya çıkmasına neden olmaktadır. Bu doğrusal olmayan karakter, giriş ve çıkış değişkenleri arasındaki ilişkilerin modellenmesini güçleştirdiğinden, makine öğrenmesi yöntemleri açısından öğrenme sürecini zorlaştırabilmektedir. Ayrıca Mononobe-Okabe yaklaşımında aktif zemin basıncı katsayısı, deprem katsayısındaki küçük değişimlere karşı oldukça hassas davranabilmektedir. Sonuç olarak, deprem katsayısındaki sınırlı değişimlerin tasarım çıktılarında büyük farklılıklar oluşturabilmesi, giriş değişkenleri ile sonuçlar arasındaki ilişkinin doğrusal olmayan bir yapıya sahip olduğunu göstermektedir. Bu durum, makine öğrenmesi modellerinin performansını olumsuz yönde etkileyebilmektedir.
- Elde edilen bulgular, makine öğrenmesi tabanlı yaklaşımların geleneksel mühendislik hesap yöntemlerine kıyasla daha esnek ve yüksek doğrulukta çözümler sunabileceğini göstermektedir. Özellikle karmaşık zemin-yapı etkileşimlerinin söz konusu olduğu istinat duvarı tasarımında, veri odaklı yöntemlerin kullanılması tasarım sürecinin iyileştirilmesinde önemli bir rol oynayabileceğini ortaya koymaktadır.

Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur.

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır

Kaynaklar

- [1] S. Talatahari and R. Sheikholeslami, "Optimum design of gravity and reinforced retaining walls using enhanced charged system search algorithm," *KSCE Journal of Civil Engineering*, vol. 18, no. 5, pp. 1464-1469, 2014.
- [2] S. Talatahari, R. Sheikholeslami, M. Shadfaran, and M. Pourbaba, "Optimum design of gravity retaining walls using charged system search algorithm,"

- Mathematical Problems in Engineering*, vol. 2012, no. 1, p. 301628, 2012.
- [3] J. J. Pons, V. Penadés-Plà, V. Yepes, and J. V. Martí, "Life cycle assessment of earth-retaining walls: An environmental comparison," *Journal of Cleaner Production*, vol. 192, pp. 411-420, 2018.
- [4] B. Kaymak and U. Dağdeviren, "SİMETRİK AĞIRLIK İSTİNAT DUVARLARININ OPTİMUM TASARIMI," *Journal of Science and Technology of Dumlupınar University*, no. 040, pp. 45-57, 2018.
- [5] X. Li, L. Su, Y. Wu, and S. He, "Seismic stability of gravity retaining walls under combined horizontal and vertical accelerations," *Geotechnical and Geological Engineering*, vol. 33, pp. 161-166, 2015.
- [6] Z. Kurt, M. Kurt, and M. F. Yentimur, "A Case Study for Retaining Wall Design," (in en), *Sciennovation*, vol. 2, no. 1, pp. 21-28, September 2020. [Online]. Available: <https://dergipark.org.tr/tr/pub/sciennovation/issue/56784/792029>.
- [7] R. Alsirawan and A. Alnmr, "Dynamic behavior of gravity segmental retaining walls," *Pollack Periodica*, vol. 18, 11/07 2022, doi: 10.1556/606.2022.00722.
- [8] Y. Zhou, S. Shi, Q. Cai, and J. Liang, "Deformation State Analysis and Design Method of Bottom-Confining Gravity Retaining Walls," *Sustainability*, vol. 15, no. 5, p. 4405, 2023. [Online]. Available: <https://www.mdpi.com/2071-1050/15/5/4405>.
- [9] D. Shah, "Stability Analysis of Gravity Retaining Wall by DEM Simulation," pp. 1-5, 10/04 2024, doi: 10.56472/25839233/IJAST-V2I4P101.
- [10] R. Mustafa, P. Samui, and S. Kumari, "Seismic Performance of Gravity Retaining Walls Under Quasi-static Approach Using Probabilistic Analysis," *Transportation Infrastructure Geotechnology*, vol. 11, no. 2, pp. 612-649, 2024/04/01 2024, doi: 10.1007/s40515-023-00298-y.
- [11] H. Chen, P. G. Asteris, D. Jahed Armaghani, B. Gordan, and B. T. Pham, "Assessing Dynamic Conditions of the Retaining Wall: Developing Two Hybrid Intelligent Models," *Applied Sciences*, vol. 9, no. 6, p. 1042, 2019. [Online]. Available: <https://www.mdpi.com/2076-3417/9/6/1042>.
- [12] R. Mustafa, P. Samui, and S. Kumari, "Reliability Analysis of Gravity Retaining Wall Using Hybrid ANFIS," *Infrastructures*, vol. 7, no. 9, p. 121, 2022. [Online]. Available: <https://www.mdpi.com/2412-3811/7/9/121>.
- [13] R. Mustafa, P. Samui, S. Kumari, E. T. Mohamad, and R. M. Bhatawdekar, "Probabilistic analysis of gravity retaining wall against bearing failure," *Asian Journal of Civil Engineering*, vol. 24, no. 8, pp. 3099-3119, 2023/12/01 2023, doi: 10.1007/s42107-023-00697-z.
- [14] A. Kumar and A. Burman, "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*, vol. 11, no. 3, p. 214, 2025/04/12 2025, doi: 10.1007/s40808-025-02390-3.
- [15] SAP. "Makine Öğrenmesi Nedir?," <https://www.sap.com/turkey/products/artificial-intelligence/what-is-machine-learning.html> (accessed).
- [16] M. Atalay and E. Çelik, *Mehmet Akif Ersoy University Journal of Social Sciences Institute*, vol. 9, no. 22, pp. 155-172, December 2017, doi: 10.20875/makusobed.309727.
- [17] D. Kılınç, E. Borandağ, F. Yücalar, V. Tunalı, M. Şimşek, and A. Özçift, "KNN algoritması ve r dili ile metin madenciliği kullanılarak bilimsel makale tasnifi," *Marmara Fen Bilimleri Dergisi*, vol. 28, no. 3, pp. 89-94, 2016.
- [18] S. W. Jarantow, E. D. Pisors, and M. L. Chiu, "Introduction to the use of linear and nonlinear regression analysis in quantitative biological assays," *Current Protocols*, vol. 3, no. 6, p. e801, 2023.
- [19] Z. D. Akşehir and E. Kılıç, "Makine öğrenmesi teknikleri ile banka hisse senetlerinin fiyat tahmini," *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, vol. 12, no. 2, pp. 30-39, 2019.
- [20] A. Liaw and M. Wiener, "Classification and regression by randomForest," *R news*, vol. 2, no. 3, pp. 18-22, 2002.
- [21] A. Natekin and A. Knoll, "Gradient boosting machines, a tutorial," *Frontiers in neurorobotics*, vol. 7, p. 63623, 2013.
- [22] S. Bhanu Koduri, L. Guniseti, C. Raja Ramesh, K. Mutyalu, and D. Ganesh, "Prediction of crop production using adaboost regression method," in *Journal of physics: conference series*, 2019, vol. 1228, no. 1: IOP Publishing, p. 012005.
- [23] G. L. E. Ekibi. "Makine Öğrenmesinde Destek Vektör Regresyonu." <https://www.mygreatlearning.com/blog/support-vector-regression/> (accessed).

- [24] R. M. Durao, M. T. Mendes, and M. J. Pereira, "Forecasting O₃ levels in industrial area surroundings up to 24 h in advance, combining classification trees and MLP models," *Atmospheric Pollution Research*, vol. 7, no. 6, pp. 961-970, 2016.
- [25] Mustafa Erdogan. "Makine Öğrenmesi Regresyon Modellerindeki Hata Metriklerine Güncel Bakış: MAE, MSE, RMSE, R-Kare (R²)."
<https://medium.com/academy-team/makine-ogrenmesi-regresyon-modellerindeki-hata-metriklerine-güncel-bakış-mae-mse-rmse-r-kare-d1ab758c5759> (accessed 2025).
- [26] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *Peerj computer science*, vol. 7, p. e623, 2021.
- [27] M. Almsallti, A. B. Alzubi, and O. R. Adegboye, "Hybrid metaheuristic optimized extreme learning machine for sustainability focused co₂ emission prediction using globalization-driven indicators," *Sustainability*, vol. 17, no. 15, p. 6783, 2025.