

KAZIKLARIN NİHAİ TAŞIMA KAPASİTESİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİN EDİLMESİ

ULTIMATE BEARING CAPACITY OF CLOSED-ENDED PILES USING MACHINE LEARNING METHODS

Emirhan ALTINOK¹, Mehmet Barış Can ÜLKER²

ÖZET

Bu çalışmada, çeşitli zeminlerde kapalı uçlu kazıkların eksenel yük taşıma kapasiteleri veriye dayalı öğrenme algoritmaları ile tahmin edilmiştir. İlk aşamada literatürden toplanan deney verileri ile 219 adet kazık yükleme deneyi ve ilgili kazıkların bulunduğu zeminde yapılan CPT deneyi sonuçlarını içeren geniş bir veri tabanı oluşturulmuştur. Doğrusal ve doğrusal olmayan yöntemleri içeren 9 adet makine öğrenmesi yöntemi, hazırlanan veri tabanı ile eğitilmiş ve eğitilen öğrenme modelleri ile yeni tahminler üretilmiştir. Yöntemlerin eğitime ve test edilme süreci k-fold çapraz doğrulama ilkesine göre yapılmıştır. Üretilen tahminlerin performansı sektörde kullanılan klasik kazık taşıma kapasitesi hesaplama denklemleri ile karşılaştırılmıştır. Sonuçlar doğrusal olmayan makine öğrenmesi yöntemlerinin hem doğrusal olan yöntemlerden hem de klasik hesap yöntemlerinden daha yüksek doğrulukta tahminler yaptığını göstermektedir. Random Forests ve Relevance Vector Regression yöntemleri tüm veri tabanlarında en düşük hata oranıyla tahmin yapmıştır. Bu nedenle kapalı uçlu kazıkların taşıma kapasitesinin bu yöntemler ile tahmin edilebileceği ispatlanmıştır.

Anahtar Kelimeler: Kazık taşıma Kapasitesi, kazık yükleme deneyi, koni penetrasyon deneyi, makine öğrenmesi, Random Forests

ABSTRACT

In this study, the axial bearing capacities of closed-end piles in different soils are estimated using data-based learning algorithms. In the first phase, a large database is created with the test data collected from the literature including 219 pile load tests and the results of the CPT test performed on the soil where the piles are located. 9 Machine learning methods, including linear and nonlinear methods, are trained with the prepared database and new predictions are made with the trained learning models. Training and testing of the methods are performed according to the k-fold cross-validation principle. The performance

¹ Araş. Gör., İstanbul Üniversitesi Cerrahpaşa, emirhanaltinok@iuc.edu.tr (Sorumlu yazar)

² Doç. Dr., Mehmet Barış Can Ülker, İstanbul Teknik Üniversitesi, mbulker@itu.edu.tr

of the estimates is compared with the classical equations commonly used to calculate the bearing capacity of piles. The results show that nonlinear machine learning methods make predictions with higher accuracy than both linear methods and classical calculation methods. The Random Forests and the Relevance Vector Regression methods make predictions with the lowest error rate in all databases. Therefore, it is proved that the bearing capacity of closed-end piles can be estimated by these methods.

Keywords: *Cone penetration test, machine learning, pile bearing capacity, pile load test, Random Forests*

1. GİRİŞ

Kazık sistemleri, yapı temellerinde taşıma kapasitesi ve oturma kriterlerini karşılamak amacıyla yaygın olarak kullanılan bir zemin iyileştirme yöntemidir. Projeye bağlı olarak çok sayıda kazık türü kullanılabilir. Kazıklar, inşaat aşamasından önce nihai yükler altında tasarlanmakta ve imal edilen kazıkların tasarımda hesaplanan taşıma kapasitesini sağlaması gerekmektedir. Bu nedenle, kazıkların taşıma kapasitelerinin şantiyede değerlendirilmesi gerekmektedir. Statik yükleme deneyi, kazıkların eksenel yük taşıma kapasitesini yerinde belirlemek için en güvenilir deney yöntemidir. Ancak pahalı ve zaman alıcı bir yöntemdir. Uygulama için sahada devasa platformlar kurulması veya ek test kazıklarının imal edilmesi gerekmektedir. Ayrıca sahada statik yükleme deneyi ile göçme yüküne kadar yüklenen test kazıkları yeniden kullanılamaz. Bu durum da statik yükleme deneyini daha maliyetli hale getirmektedir.

Kazık taşıma kapasitesi yaygın olarak ampirik yöntemler ile tahmin edilmektedir. Bir kazığın eksenel taşıma kapasitesini CPT deneyi sonuçları ile tahmin etmek için çok sayıda analitik ve ampirik yöntem geliştirilmiştir. Abu-Farsakh ve Titi (2004), bir veri tabanında yaygın olarak kullanılan CPT tabanlı tahmin yöntemlerinin güvenilirliğini araştırmıştır. Bu çalışmaya göre Schmertmann ve Nottingham yöntemi (Schmertmann, 1978), De Ruiter ve Beringen yöntemi (De Ruiter & Beringen, 1979) ve LCPC yöntemi (Bustamante & Ganeselli, 1982) diğer klasik yaklaşımlardan daha iyi tahmin performansı göstermektedir. Bu nedenle bu üç yöntem bu çalışmada klasik yöntemler olarak ele alınmıştır. Bu konudaki bir diğer çalışma ise, Eslami ve Fellenius (1997) tarafından önerilen ve boşluk basıncı ölçümlerini de içeren CPTU sonuçlarından kazık kapasitesini tahmin eden UniCone yöntemidir. Niazi ve Mayne (2016) daha sonra bazı parametreleri değiştirerek ve yeni prosedürler ekleyerek bu yöntemin geliştirilmiş versiyonunu önermiştir. Daha sonraki çalışmalarda farklı kazık ve zemin tiplerine göre farklı tahmin yöntemleri oluşturulmuştur. Kum zeminlerde yapılan çakma kazıklar için farklı parametrelerin etkisini dikkate alan NGI ve ICP yöntemleri önerilmiştir (Clausen et al., 2005; Jardine et al., 2005). Açık deniz ve liman yapılarını desteklemek amacıyla kullanılan açık uçlu kazıkların taşıma kapasitesini tahmin etmek için UWA ve Fugro yöntemleri önerilmiştir (Yang et al., 2015).

Makine öğrenmesi (ML) yöntemlerini kullanarak bir kazığın eksenel taşıma kapasitesini tahmin etmek, son yıllarda yaygın olarak üzerinde çalışılan bir konudur. İlk çalışmalarda nihai taşıma kapasitesi veya sürtünme kapasitesi, yapay sinir ağları (ANN) kullanılarak tahmin edilmektedir (Goh, 1995; Lee & Lee, 1996). Daha sonra destek vektör makinaları (SVM) gibi doğrusal olmayan yöntemler bu probleme uygulanmış ve umut verici sonuçlar elde edilmiştir (Samui, 2008). 2010'dan sonra, kazık taşıma kapasitesini tahmin etmek için makine öğrenmesi kullanılan çok sayıda çalışma yayınlanmıştır (Alkroosh & Nikraz, 2012;

Debnath & Dey, 2018; Ebrahimian & Movahed, 2017; Kordjazi et al., 2014). Fakat bu çalışmaların dikkate almadığı bazı hususların, çalışma sonuçlarını etkilediğini gözlemledik. Örneğin birçok çalışma, veri eksikliğinden dolayı zayıf genellemeler içermektedir. İncelenen çalışmaların büyük çoğunluğu, 100'den az kazık verisi ile ML analizi yapmaktadır. Eksenel kazık taşıma kapasitesi probleminin karmaşıklığı ve birçok farklı parametreden etkilenebileceği göz önüne alındığında, bu sonuçlar genel davranışı temsil etmekten uzaktır. Buna ek olarak birçok çalışma, istatistikte büyük bir sorun olan aşırı uyum problemini dikkate almamaktadır. ML yöntemleri veriye bağlı yaklaşımlar olduğu için aşırı uyum problemi algoritmanın belirli bir veri kümesi üzerinde aşırı eğitilmesine yol açar. Bu problemi önlemek için, farklı kaynaklardan fazla sayıda örnek toplanarak veri varyasyonu artırılabilir. Yöntemleri eğitmek için yalnızca bir kaynaktan örnekler toplayan bazı çalışmalar $0,99 R^2$ ile son derece yüksek bir korelasyon bildirmektedir. Bu derece yüksek bir korelasyonu tek bir veri tabanından elde etmek aşırı uyum sorununun dikkate alınmadığını göstermektedir. Bu sorunu önlemenin bir başka yolu da eğitim aşamasında “k-fold çapraz doğrulama” prensibini kullanmaktır.

Mevcut çalışmaların dezavantajları göz önüne alındığında, kazıkların taşıma kapasitesini mevcut yöntemlerden daha iyi tahmin edebilmek için daha kapsamlı veri tabanlarına ve bu veri tabanlarında eğitilecek daha fazla sayıda ML yöntemine ihtiyaç duyulmaktadır. Bu nedenle, bu çalışmada 2 adet doğrusal ve 7 adet doğrusal olmayan ML yöntemi 219 adet veri içeren veri tabanına uygulanmış ve yöntemlerin tahmin performansları karşılaştırılmıştır. Doğrusal yöntemler Ridge Linear Regression (RLR) ve Multivariate Adaptive Regression Splines (MARS) iken, doğrusal olmayan yöntemler k-Nearest Neighbor (kNNR), Decision Tree (TREE), Random Forests (RF), Extreme Learning Machines (ELM), Relevance Vector Regression (RVR), Gaussian Process Regression (GPR) ve Variational Heteroscedastic Gaussian Process Regression (VHGPR) yöntemleridir. ML yöntemleri ile tahminler üretildikten sonra yöntemlerin tahmin performansı mevcut klasik hesap yöntemleri ile karşılaştırılmıştır.

2. MAKİNE ÖĞRENMESİ YÖNTEMLERİ

Bu çalışmada kullanılan 9 adet ML yöntemi, bu bölümde kısaca açıklanmaktadır.

2.1. Ridge Linear Regression (RLR) Yöntemi

RLR yöntemi pratik bir doğrusal çoklu regresyon yöntemidir. RLR algoritması, klasik lineer regresyon için bir problem haline gelebilecek aşırı uyumu önlemek için bir optimizasyon problemine bir ceza parametresi uygulayarak ağırlıkları azaltma eğilimindedir. Bunu her aşamada tekrardan hesapladığı kayıp fonksiyonu sayesinde yapmaktadır.

2.2. Multivariate Adaptive Regression Splines (MARS) Yöntemi

İlk olarak Friedman (1991) tarafından önerilen MARS yöntemi, kademeli doğrusal regresyon kavramı olarak kabul edilebilecek MARS adı verilen çok değişkenli parametrik olmayan bir regresyon yöntemidir. Birçok girdi özelliği içeren yüksek boyutlu problemler için uygun bir yöntemdir. MARS algoritması, yüksek dereceden polinomlar içeren temel fonksiyonları sağlayarak girdi ve çıktı değişkenleri arasındaki doğrusal olmayanları ve ilişkiyi modelleyebilir.

2.3. k-Nearest Neighbor (kNNR) Yöntemi

kNNR hem sınıflandırma hem de regresyon problemlerine uygulanan parametrik olmayan istatistiksel bir öğrenme yöntemidir. Çıkış değişkeni (y_i), giriş örneklerinden (x_i) iki adımda tahmin edilir. İlk olarak, eldeki örneğin k-en yakın komşuları dikkate alınarak bir komşuluk seti elde edilir. Bu işlem, numuneler arasındaki mesafeyi belirlemek için kullanılan mesafe ölçüsüne bağlıdır. Tahminin ikinci bölümünde, ilgili adımlarda gerçekleşen tüm çıktılarının ortalaması alınarak nihai çıktı değeri hesaplanır. Bu nedenle, kNNR, tahminin her aşamasında doğrudan eğitim örnekleri gerektirdiğinden, çıktı tahmini için açık bir öğrenme modeli sağlamaz (Kuhn & Johnson, 2013).

2.4. Decision Tree (TREE) Yöntemi

Karar Ağacı regresyon yaklaşımı, girdi-çıkı ilişkisini belirli düğümler ve yapraklar olarak dallara ayrılan bir ağaç analojisiyle modelleyen bir yöntemdir. Bir regresyon ağacı oluşturmak için, verilen girdi veri setinin n-boyutlu öznitelik uzayı önce daha küçük altkümelere ayrılır. Bu altkümelere uç düğümler veya ağacın yaprakları denir. Daha sonra, iç düğümlerle girdi özellikleri uzayı oluşturulur. Karar ağaçlarının oluşturulmasında baş aşağı çizim prosedürü izlenir. Bu nedenle, regresyon problemlerinde sayısal olan çıktı değişkenlerini temsil eden yaprak düğümler ağacın altına yerleştirilir. İç düğümler, karar kurallarını temsil eden dallarla yapraklara bağlanır (James et al., 2013). Ağaç regresyonu teorisinde amaç kalan kareler toplamını (RSS) en aza indiren $R_1, \dots, R_j$ bölgelerini oluşturmaktır. Bölge oluşturma işlemi minimum RSS'ye ulaşılan kadar tekrarlanır. Bölgeler belirlendikten sonra, tahminler test gözlemleri ile karşılaştırılır ve sonuçlar istatistiksel metrikler açısından değerlendirilir.

2.5. Random Forests (RF) Yöntemi

RF yöntemi, karar ağaçlarının performansını iyileştirmek için ilk olarak Breiman (2001) tarafından önerilmiştir. Her ağaç sınıflandırıcısı, rastgele girdi seçimi veya rastgele bölme seçimi gibi bazı bölme kuralları tarafından oluşturulur. RF yönteminin arkasındaki öğrenme algoritması, rastgele seçilen girdilere veya bölme işlevlerine sahip ağaçlara dayanır. Giriş çiftlerini analiz ederek hedeflenen çıktı için rasyonel bir kesintiye tahmin etmek için, RF regresyon algoritması rastgele seçilen ağaçların yanıtını değerlendirir. Ardından her bir ağaçtan alınan tüm tahminlerin ortalamasını alarak tahminler yapar.

2.6. Extreme Learning Machines (ELM) Yöntemi

ELM algoritması, doğrusal olmayan çok değişkenli regresyon gerçekleştirmeye izin verir ve çıktı ağırlıklarını analitik olarak belirlemek için en küçük kareler çözümünü kullanır (Huang et al., 2006). Burada gizli katman parametreleri rastgele seçilir. Geleneksel sinir ağlarından farklı olarak ELM yöntemi, gizli katman için ayarlanmış parametreler kullanmak yerine, çıktı ağırlıklarını en küçük karelerle hesaplamak için kayıp fonksiyonunu en aza indirme eğilimindedir. Bu süreç, daha iyi bir genelleme performansı sağladığı gibi öğrenme sürelerini de hızlandırır.

2.7. Relevance Vector Regression (RVR) Yöntemi

RVR yöntemi, SVM algoritmasının regresyon kapasitesini arttırmak için geliştirilmiştir. Bu yöntemin SVM yönteminden farkı, öğrenme sürecine Bayesçi bir perspektifi eklemesidir (Tipping, 2000). RVR yöntemi, destek vektör makinalarına eşit işlevsel formda seyrek bir çekirdek modeli ile olasılıksal tahmin sağlar. RVR yönteminin SVM'ye göre birçok avantajı vardır. Hesaplama maliyetini azaltan daha az sayıda çekirdek işlevi kullanarak rasyonel tahminlere izin verir. Ek olarak, çekirdek fonksiyonlarının Mercer koşulunu sağlaması gerekmez.

2.8. Gaussian Vector Regression (GPR) Yöntemi

Geoistatistikte Kriging yöntemi olarak da bilinen GPR, ortak bir Gauss dağılımına sahip rasgele değişkenler kümesine dayalı rasyonel tahminler yapar (Rasmussen & Williams, 2006). GPR'nin çalışma prensibi, ortak olasılıksal yoğunluk fonksiyonlarına dayanmaktadır. Ortak bir çok değişkenli olasılık yoğunluk fonksiyonu aracılığıyla mevcut bilgiyi kullanarak sistem yanıtını inceler. Ardından, olasılık fonksiyonunu güncellerken aynı anda gözlemleri kullanarak tahminler yapar (Goulet, 2020).

2.9. Variational Heteroscedastic Gaussian Process Regression (VHGPR) Yöntemi

Standart Gauss Süreci regresyonunu iyileştirmek ve homoskedastik olan Gauss regresyonuna bazı yeni değişken varyanslar ekleyerek heteroskedastik yapmak amacıyla Lázaro-Gredilla & Titsias (2011) tarafından önerilmiştir. Öğrenme ve tahmin etme süreçleri GPR yöntemine çok benzer olmasına rağmen aynı veri setlerinde VHGPR yöntemi kullanıldığında daha doğru sonuçlar alındığı görülmüştür.

3. VERİ TABANI ÖZELLİKLERİ

Bu çalışma için tam ölçekli statik kazık yükü test sonuçlarını, kazık geometrik özelliklerini ve kazıkların bulunduğu zeminlerde yapılan CPT sonuçlarını içeren 219 adet veri toplanmıştır. Veri tabanında kapalı uçlu çelik boru kazık, prekast beton kazık veya fore kazık gibi çeşitli kazık türleri bulunmaktadır. Tüm kazık yükleme deneyi sahalarında CPT yapılmıştır. Ancak, CPT sırasında bu 219 vakanın 99'unda çeper sürtünmesi (f_s) ölçümleri kaydedilmemiştir. Bu nedenle, bu 99 kazık sadece koni direnci (q_c) değerlerini içerirken, diğer 120 kazık hem q_c hem de f_s bilgisine sahiptir.

ML yöntemlerini eğitmek için verileri kullanarak girdi özellikleri matrisi hazırlanmalıdır. Bu çalışmada girdi özellikleri kazıkların geometrik özelliklerini ve CPT parametrelerini içermektedir. Seçilen beş girdi özelliği şunlardır: i) Kazığın uzunluğu, L ; ii) Kazığın kesit alanı, A ; iii) Kazık ucu etrafındaki koni ucu direncinin ortalaması, $(q_c)_{end}$; iv) Kazığın uzunluğu boyunca ortalama çeper sürtünmesi, $(f_s)_{ave}$; v) Kazık uzunluğu boyunca ortalama koni ucu direnci, $(q_c)_{ave}$. Ortalama koni direnci, $(q_c)_{ave}$ ve çeper sürtünmesi, $(f_s)_{ave}$ parametreleri hesaplanırken CPT sonuçlarının kazık derinliği boyunca aritmetik ortalaması alınmıştır. Kazık ucundaki koni direnci, $(q_c)_{end}$ parametresi Eslami ve Fellenius (1997) tarafından önerilen etkin kazık boyu yöntemi dikkate alınarak hesaplanmıştır. Bu yöntemle göre etkin kazık boyu, eğer kazık ucunun üzerinde kalan zemin altında kalan zeminden daha zayıf ise, kazık ucunun $4D$ altından $8D$ üstüne kadar ölçülen mesafe olarak tanımlanır. Burada D parametresi dairesel kazığın çapını göstermektedir. Eğer kazık ucunun üzerindeki zemin,

altındakinden daha güçlü ise etkin kazık boyu, kazık ucunun $4D$ altından $2D$ üstüne kadar ölçülen mesafe olmaktadır. $(q_c)_{end}$ parametresi etkin kazık boyu mesafesinde ölçülen tüm q_c değerlerinin geometrik ortalaması alınarak belirlenir. Veri tabanının özellikleri Tablo 1’de gösterilmiştir.

Tablo 1. Veri tabanı özellikleri

	Girdi Özellikleri					Çıktı
	Kazık Boyu (m)	Enkesit Alanı (m ²)	$(q_c)_{end}$ (MPa)	$(q_c)_{ave}$ (MPa)	$(f_s)_{ave}$ (MPa)	Q_u (kN)
Maksimum	45	2.54	65.95	24.64	0.225	14590
Minimum	5.6	0.06	0.17	0.39	0.005	210
Aralık	39.4	2.48	65.79	24.26	0.221	14380
Std. Sapma	8.7	0.35	7.61	4.42	0.039	2224
Ortalama	14.6	0.25	9.42	5.64	0.059	2203
Veri Sayısı	219	219	219	219	120	219

4. EĞİTİM VE DOĞRULAMA

ML yöntemleri veri tabanı içerisinde belirlenen girdi-çıktı değişkenleri ile eğitilerek tahmin modelleri geliştirilir. Bu çalışmada, hem verileri eğitmek hem de eğitilen modellerin yaptığı tahminleri doğrulamak için k-fold çapraz doğrulama tekniği kullanılmıştır. Bu tekniğe göre, eğitim veri seti, ilk önce yaklaşık olarak eşit büyüklükte olan ve farklı verileri içeren 'k' sayıda alt kümeye rastgele bölünür. Bu alt kümelerin her biri “fold” olarak isimlendirilir. ML yöntemi, “k-1” sayıda fold kullanılarak eğitilir ve kalan bir fold, ortaya çıkan öğrenme modelinin performansını test etmek için kullanılır. Bu işlem, her fold sadece bir kez test için kullanılacak şekilde, “k” kez tekrarlanır. Beklenen genelleme performansı, k sayıda deneme üzerinden öğrenme yönteminin performans ölçüsünün ortalaması alınarak belirlenir. Bu yöntemin avantajı, her verinin test veri setinde yalnızca bir kez ve eğitim veri setinde “k-1” kez kullanılmasıdır.

ML yöntemlerinin eğitilmesi sonucunda oluşturulan dahili matematiksel fonksiyonlar ML modeli olarak isimlendirilir (Goulet, 2020). Bu çalışmada her aşamada 9 adet ML tahmin modeli oluşturulmuştur. Eğitim sürecinde kullanılmayan test foldunun girdi özellikleri tahmin modelinde yerine konularak ilgili kazığın taşıma kapasitesi tahmini elde edilir. Yapılan bu tahmin deneyde ölçülen taşıma kapasitesi ile karşılaştırılarak ML yönteminin performansı ölçülür. Bu çalışmada ML yöntemlerinin tahmin performansları belirleme katsayısı (R^2) ve bağıl hata (RE) ile ölçülmüştür. R^2 tahmin edilen değerler ve ölçülen değerler arasındaki uyumun bir regresyon modeli için uygun olup olmadığını gösteren istatistiksel bir ölçü birimidir ve 1. Denklemden tanımlanmıştır.

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (1)$$

Burada y_i ve $\hat{y}_i$ parametreleri ölçülen ve tahmin edilen taşıma kapasitesi değerlerini gösterirken $\bar{y}$ parametresi ise ölçülen değerlerin aritmetik ortalamasını ifade eder. Bağıl

hata (RE), tahmin edilen ve gerçek değer arasındaki farkın gerçek değere oranıdır. Bu parametre, yöntemlerin orantısal karşılaştırmaları açısından böyle bir öneme sahiptir. 2. Denklemden tanımlanmıştır.

$$RE = \frac{\|\hat{y}_i - y_i\|}{\|y_i\|} \quad (2)$$

Bu çalışmada ML yöntemlerinin performansı, yaygın olarak kullanılan klasik ampirik hesap yöntemleri ile karşılaştırılmıştır. Bu yöntemler Schmertmann ve Nottingham yöntemi (Schmertmann, 1978), De Ruiter ve Beringen yöntemi (De Ruiter & Beringen, 1979) ve LCPC yöntemidir (Bustamante & Ganeselli, 1982). Yöntemlerin hesap prosedürleri Tablo 2’de özetlenmiştir.

Tablo 2. Klasik yöntemlerin hesap denklemleri

	<i>Schmertmann Yöntemi</i>	<i>DeRuiter Yöntemi</i>	<i>LCPC Yöntemi</i>
Uç Kapasitesi	Kumlarda $q_p = \frac{q_{c1} + q_{c2}}{2}$	$q_p = \frac{q_{c1} + q_{c2}}{2}$	$q_p = k_c q_c$
	Killerde $q_p = \frac{q_{c1} + q_{c2}}{2}$	$q_p = N_c S_u$	$q_p = k_c q_c$
Çeper Kapasitesi	Kumlarda $Q_s = K \left[\sum_0^{8D} \frac{1}{2} f_s A_s + \sum_{8D}^L f_s A_s \right]$	$q_s = \min \left\{ f_{s,av}, \frac{q_{c,av}}{300} \right\}$	$q_s = \frac{q_{c,ave}}{k_s}$
	Killerde $Q_s = \alpha' f_s A_s$	$q_s = \alpha S_u$	$q_s = \frac{q_{c,ave}}{k_s}$


NOT : q_p : birim uç direnci, q_{c1} : kazık ucunun altındaki zeminin minimum ortalama koni direnci, q_{c2} :kazık ucunun üzerindeki zeminin ortalama koni direnci, K : kazık sürtünmesinin çeper sürtünmesine oranı $\approx 0.4 - 2.4$, α' : sabit bir katsayı $\approx 0.2 - 1.2$, N_c : taşıma kapasitesi faktörü, S_u : drenajsız kayma mukavemeti, q_s : birim çeper sürtünmesi direnci, $k_c = k_s$: zemin ve kazık tiplerine göre belirlenen katsayılar.

5. BULGULAR

Bu çalışmada analizler üç farklı veri seti ile gerçekleştirilmiştir. Öncelikle hem q_c hem de f_s parametrelerine sahip 120 örnek 9 ML yöntemi ile analiz edilmiştir. Burada karışıklığı önlemek için veri örneği sayısı, girdi parametresi sayısı ve kullanılan ML yöntemi sayısına atıfta bulunan bir adlandırma kuralı oluşturulmuştur. Örneğin ilk analiz kümesi 120 örnek, 5 girdi parametresi ve 9 ML yöntemine atıfta bulunan “120S_5F_9ML” olarak isimlendirilecektir. Konuyla ilgili bazı ön araştırmalara dayanarak (Shahin, 2010), ikinci analiz setinde f_s parametresi girdi setinden çıkarılarak analizler aynı örneklerle tekrarlanmış ve bu analizlerde yalnızca ilk analizde başarılı olan ML yöntemleri kullanılmıştır. Bu nedenle ikinci analiz seti “120S_4F_4ML” olarak adlandırılacaktır. f_s parametresinin kullanılmamasının tahmin performansını arttırdığı gözlemlenmiş ve daha sonraki analizde f_s parametresi bulunmayan veri örnekleri de analiz setine dahil edilmiştir. Bu analiz setinde veri tabanındaki tüm veriler belirlenen başarılı ML yöntemleri ile eğitilmiştir. Bu analiz seti de “219S_4F_4ML” olarak isimlendirilecektir.

Sonuçlar, her yöntemin standart sapmasını tanımlamanın yararlı bir yolu olan “boxplot” grafikleri şeklinde R^2 ve RE cinsinden verilmiştir. Şekil 1a, her bir yöntem için R^2 değerlerinin dağılımını ve standart sapmasını göstermektedir. İlk analiz sonuçlarına göre doğrusal olmayan RF, RVR, GPR ve VHGR yöntemleri yüksek R^2 ve düşük RE ile öne çıkmaktadır.

Şekil 1a'de açıkça görüldüğü gibi RF, RVR, GPR ve VHGPGR yöntemlerinin R^2 'si klasik yöntemlere göre daha yüksektir. Ayrıca bu yöntemlerin R^2 dağılımlarının standart sapmaları klasik yöntemlere göre oldukça azdır. Aynı durumu Şekil 1b'de gösterilen RE dağılımlarında da gözlemlemek mümkündür. LCPC yöntemi nispeten daha uyumlu sonuçlar vermesine rağmen, klasik yöntemlerle tahmin edilen kazık kapasiteleri ML yöntemlerine göre daha az doğru sonuçlar vermektedir.




Şekil 1. 120S_5F_9ML analizinde yöntemlerin (a) R^2 dağılımı (b) RE dağılımı


120S_5F_9ML analizinde başarılı sonuçlar veren RF, RVR, GPR ve VHGPGR yöntemleri, 120S_4F_4ML analizinde aynı veri tabanında f_s parametresi çıkarılarak eğitilmiştir. Sonuçlar Şekil 2'de gösterilmiştir. Sonuçlara göre ML yöntemleri 120S_4F_4ML analizinde de klasik yöntemlerden daha başarılı tahminler yapmaktadır. Seçilen tüm ML yöntemlerinin tahmin performansları önceki analize göre artmıştır. Ancak R^2 'deki en belirgin değişiklik RVR yönteminde gözlenmektedir. RVR'nin ortalama R^2 değeri 0,87 olurken, RE 0,27'ye düşmüştür. ML yöntemleri en başarılı tahminleri, 1., 2., 3. Ve 5. Foldlar eğitim için kullanıldığında ve 4. Fold test için kullanıldığında yapmıştır. Bu analiz sonucunda özellikle RVR yönteminin yaptığı tahminlerin, 0,91 R^2 değeri ve 0,27 RE değeri ile gerçek taşıma kapasitelerine güçlü bir korelasyon sağladığı gözlemlenmiştir. Bu analize ait korelasyon grafiği Şekil 3'te gösterilmiştir.

RF yönteminin başarısı artsa da diğer ML yöntemlerinin performansında önemli değişiklikler görülmemiştir. Temel mühendisliği açısından bu sonucu ilginç buluyoruz. Çünkü çeper sürtünmesi, f_s parametresi klasik yöntemlerde kazık taşıma kapasitesini hesaplamak için önemli bir parametre iken ML analizlerinde Q_u ile yüksek derecede ilişkili

olmadığı gözlemlenmiştir. Bu da f_s parametresinin kazık taşıma kapasitesini belirlemede daha az etkili olduğunu savunan önceki çalışmaları doğrulamaktadır (Shahin, 2010).



Şekil 2. 120S_4F_4ML analizinde yöntemlerin (a) R^2 dağılımı (b) RE dağılımı




Şekil 3. RVR yönteminin ve klasik yöntemlerin aynı veri setindeki tahminlerinin korelasyon grafiği (RVR : $R^2 = 0.91$, Schmertmann : 0.80, DeRuiter : 0.52 , LCPC : 0.84)

219S_4F_4ML analizi için veri tabanına f_s parametresi bulunmayan 99 tane daha kazık verisi eklenmiştir. Analiz sonuçları Şekil 4'te gösterilmektedir.

Yeni veri setinde ML tahmin performanslarında bir miktar azalma gözlemlenmiştir. Bu durum veri sayısının artmasıyla veriler arası uyumsuzluğun artışına veya yeni veri setinde f_s 'nin olmamasına da bağlanabilir. Veriye dayalı modeller aracılığıyla Q_u ile zayıf bir

korelasyona sahip olduğu görülmesine rağmen, f_s parametresi Geoteknik Mühendisliği uygulamasında bu tür mekanik açıdan önemli bir parametredir. Kullanılan ML yönteminden bağımsız olarak böylesine önemli bir parametrenin kazıkların Q_u tahmininde görmezden gelinmesi kolay değildir. Bu analizlerde RF yöntemi, 0.84 ortalama R^2 ile kabul edilebilir derecede iyi bir tahmin performansı sağlamıştır. Sonuçlara göre, nispeten büyük veri tabanı göz önüne alındığında, RF'nin hem klasik yöntemlere hem de diğer ML yöntemlerine kıyasla kazık yük kapasitesini en iyi tahmin etme kabiliyetine sahip yöntem olarak tanımlanabileceğini söylemek doğru olur.



Şekil 4. 219S_4F_4ML analizinde yöntemlerin (a) R^2 dağılımı (b) RE dağılımı

6. SONUÇ

Bu çalışmada hem kohezyonlu hem de kohezyonsuz zeminlerde kapalı uçlu kazıkların statik yük taşıma kapasiteleri ML yöntemleri kullanılarak tahmin edilmiştir. Sonuçlar, RF, RVR, GPR ve VHGP yöntemlerinin diğer yöntemlerden daha iyi performans gösterdiğini göstermektedir. Bu dört yöntem arasında Relevance Vector Regression (RVR), hem klasik hesap yöntemlerine hem de diğer ML yöntemlerine göre öne çıkmaktadır. Random Forests (RF) yöntemi de tüm analizlerde başarılı tahminler yapmaktadır. Bu nedenle RF ve RVR yöntemleri farklı geometrik özelliklerdeki kazıkların taşıma kapasitesini doğru bir şekilde tahmin etmek için uygun yöntemler olarak kabul edilebilir. Bu çalışma sonucunda yeterince büyük bir veri tabanı ile analizler yapıldığında ve özellikle bu çalışmada belirlenen ML yöntemleri kullanıldığında hem kohezyonlu hem de kohezyonsuz zeminlerde kapalı uçlu kazıkların statik durumdaki yük taşıma kapasitesini yeterli doğrulukla tahmin etmenin mümkün olduğu sonucuna varıyoruz.

KAYNAKLAR

- Abu-Farsakh, M. Y., & Titi, H. H. (2004). Assessment of direct cone penetration test methods for predicting the ultimate capacity of friction driven piles. *Journal of Geotechnical and Geoenvironmental Engineering*. [https://doi.org/10.1061/\(asce\)1090-0241\(2004\)130:9\(935\)](https://doi.org/10.1061/(asce)1090-0241(2004)130:9(935))
- Alkroosh, I., & Nikraz, H. (2012). Predicting axial capacity of driven piles in cohesive soils using intelligent computing. *Engineering Applications of Artificial Intelligence*, 25(3), 618–627. <https://doi.org/10.1016/j.engappai.2011.08.009>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/a:1010933404324>
- Bustamante, M., & Gianceselli, L. (1982). Pile bearing capacity prediction by means of static penetrometer CPT. *Proceedings of the Second European Symposium on Penetration Testing ESOPT-2*, 493–500. [https://doi.org/https://www.cpt-robertson.com/PublicationsPDF/Pile Bearing Cap%20CPT-LCPC Method-Bustamante et al-ESOPT2-198.pdf](https://doi.org/https://www.cpt-robertson.com/PublicationsPDF/Pile%20Bearing%20Cap%20CPT-LCPC%20Method-Bustamante%20et%20al-ESOPT2-198.pdf)
- Clausen, C. J. F., Aas, P. M., & Karlsrud, K. (2005). Bearing capacity of driven piles in sand, the NGI approach. *Frontiers in Offshore Geotechnics, ISFOG 2005 - Proceedings of the 1st International Symposium on Frontiers in Offshore Geotechnics*, 677–681. <https://doi.org/10.1201/noe0415390637.ch88>
- De Ruiter, J., & Beringen, F. L. (1979). Pile foundations for large North Sea structures. *Marine Geotechnology*, 3(3), 267–314. <https://doi.org/10.1080/10641197909379805>
- Debnath, P., & Dey, A. K. (2018). Prediction of bearing capacity of geogrid-reinforced stone columns using support vector regression. *International Journal of Geomechanics*, 18(2), 1–15. [https://doi.org/10.1061/\(ASCE\)GM.1943-5622.0001067](https://doi.org/10.1061/(ASCE)GM.1943-5622.0001067)
- Ebrahimian, B., & Movahed, V. (2017). Application of an evolutionary-based approach in evaluating pile bearing capacity using CPT results. *Ships and Offshore Structures*, 12(7), 937–953. <https://doi.org/10.1080/17445302.2015.1116243>
- Eslami, A., & Fellenius, B. H. (1997). Pile capacity by direct CPT and CPTu methods applied to 102 case histories. *Canadian Geotechnical Journal*, 34(6), 886–904. <https://doi.org/10.1139/cgj-34-6-886>
- Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *The Annals of Statistics*. <https://doi.org/10.1214/aos/1176347963>
- Goh, A. T. C. (1995). Back-propagation neural networks for modeling complex systems. *Artificial Intelligence in Engineering*, 9(3), 143–151. [https://doi.org/10.1016/0954-1810\(94\)00011-S](https://doi.org/10.1016/0954-1810(94)00011-S)
- Goulet, J.-A. (2020). *Probabilistic Machine Learning for Civil Engineers*. The MIT Press.
- Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), 489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning* (Vol. 103). Springer New York. <https://doi.org/10.1007/978-1-4614-7138-7>
- Jardine, R., Chow, F. C., Overy, R., & Standing, J. (2005). *ICP design methods for driven piles in sands and clays*. Thomas Telford.
- Kordjazi, A., Pooya Nejad, F., & Jaksa, M. B. (2014). Prediction of ultimate axial load-carrying capacity of piles using a support vector machine based on CPT data. *Computers and Geotechnics*, 55, 91–102. <https://doi.org/10.1016/j.compgeo.2013.08.001>

- Kuhn, M., & Johnson, K. (2013). *Applied Predictive Modeling*. Springer New York. <https://doi.org/10.1007/978-1-4614-6849-3>
- Lázaro-Gredilla, M., & Titsias, M. K. (2011). Variational heteroscedastic Gaussian process regression. *Proceedings of the 28th International Conference on Machine Learning, ICML 2011*, 841–848.
- Lee, I. M., & Lee, J. H. (1996). Prediction of Pile Bearing Capacity Using Artificial Neural Networks. *Computers and Geotechnics*, 18(3), 189–200. [https://doi.org/10.1016/0266-352X\(95\)00027-8](https://doi.org/10.1016/0266-352X(95)00027-8)
- Niazi, F. S., & Mayne, P. W. (2016). CPTu-based enhanced UniCone method for pile capacity. *Engineering Geology*, 212, 21–34. <https://doi.org/10.1016/j.enggeo.2016.07.010>
- Rasmussen, C. E., & Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning*. The MIT Press.
- Samui, P. (2008). Prediction of friction capacity of driven piles in clay using the support vector machine. *Canadian Geotechnical Journal*, 45(2), 288–295. <https://doi.org/10.1139/T07-072>
- Schmertmann, J. H. (1978). *Guidelines for Cone Penetration Test (Performance and Design)*. <https://ntl.bts.gov/lib/35000/35400/35414/FHWA-TS-78-209.pdf>
- Shahin, M. A. (2010). Intelligent computing for modeling axial capacity of pile foundations. *Canadian Geotechnical Journal*, 47(8), 928–930. <https://doi.org/10.1139/T10-048>
- Tipping, M. E. (2000). The relevance vector machine. *Advances in Neural Information Processing Systems*, 20.
- Yang, Z., Jardine, R., Guo, W., & Chow, F. (2015). A Comprehensive Database of Tests on Axially Loaded Piles Driven in Sand. In *A Comprehensive Database of Tests on Axially Loaded Piles Driven in Sand*. Academic Press. <https://doi.org/10.1016/c2015-0-01032-2>

SEMBOL LİSTESİ

q_c	CPT ile ölçülen koni ucu direnci	S_u	Drenajsız kayma mukavemeti
f_s	CPT ile ölçülen çeper sürtünmesi	y_i	Ölçülen değer
$(q_c)_{end}$	Kazık ucunda ölçülen uç direnci	$\hat{y}_i$	Tahmin edilen değer
$(f_s)_{ave}$	Ortalama çeper sürtünmesi	$\bar{Y}$	Ölçülen değerlerin ortalaması
$(q_c)_{ave}$	Ortalama koni ucu direnci	K	Kazık sürtünmesinin çeper kapasitesine oranı
Q_u	Eksenel yük taşıma kapasitesi	D	Kazık Çapı
q_{c1}	Kazık ucunun altındaki zeminin ortalama uç direnci	N_c	Taşıma kapasitesi faktörü
q_{c2}	Kazık ucunun üzerindeki zeminin ortalama uç direnci	A_s	Kazık yüzey alanı
q_p	Birim uç direnci	α'	Sürtünme kazıkları için sabit bir katsayı