



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Makine Öğrenimi Yöntemleriyle Bazaltlarda Tek Eksenli Sıkışma Dayanımının Değerlendirilmesi ve Performanslarının Karşılaştırılması

 Nurgül YEŞİLOĞLU-GÜLTEKİN^{a,*},  Ayhan DOĞAN^b

^a İnşaat Bölümü, Başkent OSB Teknik Bilimler Meslek Yüksekokulu, Hacettepe Üniversitesi, Ankara, TÜRKİYE

^b Mimarlık ve Şehir Planlama Bölümü, Başkent OSB Teknik Bilimler Meslek Yüksekokulu, Hacettepe Üniversitesi, Ankara, TÜRKİYE

* Sorumlu yazarın e-posta adresi: nuryesil@hacettepe.edu.tr

DOI: 10.29130/dubited.1173624

ÖZ

Tek eksenli sıkışma dayanımı (UCS) mühendislik projelerinde en önemli tasarım parametrelerinden biri olup; bir çok projede ve sınıflama sistemlerinde doğrudan kullanılan bir parametredir. UCS'nin elde edilmesindeki güçlükler göz önüne alındığında; makine öğrenimi temelli yaklaşımlar ile tahmin edilmesi dikkat çekmektedir. Çalışma kapsamında bazalt bloklarından alınan 137 adet karot örneği üzerinde gerçekleştirilen laboratuvar deney sonuçları kullanılarak iki ayrı model elde edilmiştir. Bu modellerde görünür gözeneklilik (n), p dalga hızı (V_p) ve birim hacim ağırlık (γ_n) değerleri girdi parametreleri olup; makine öğrenimi yöntemleri ile UCS tahmin edilmeye çalışılmıştır. Bu amaçla; Gauss Süreç Regresyonu (GSR), Destek Vektör Makineleri (DVM) ve Ağaç Toplulukları Yöntemleri (AT) olmak üzere üç farklı makine öğrenimi yöntemi kullanılmıştır. İki ayrı modele ait beş farklı veri seti için uygulanan üç ayrı makine öğrenimi yönteminin performanslarının değerlendirilmesinde R^2 (determinasyon katsayısı), RMSE (kök ortalama kare hata), MSE (ortalama kare hata) ve MAE (ortalama mutlak hata) performans indisleri kullanılmıştır. Buna göre; genel olarak üç ayrı makine öğrenimi yönteminin de UCS' nin tahmininde başarılı olduğu değerlendirilmiş olmakla birlikte AT yönteminin genel olarak daha yüksek tahmin performansı verdiği belirlenmiştir.

Anahtar Kelimeler: Tek eksenli sıkışma dayanımı, Destek vektör makineleri, Gauss süreç yönetimi, Ağaç toplulukları

Evaluation of Uniaxial Compressive Strength of Basalts using Machine Learning Methods and Comparison of Their Performances

ABSTRACT

Uniaxial compressive strength (UCS) is one of the most critical design parameters of engineering projects, which is directly used parameter in many projects and classification systems. Considering the difficulties in obtaining the UCS, it is remarkable that it is estimated using machine learning-based approaches. In this study, two different models were constructed using laboratory results of the 137 core samples. Apparent porosity (n), p wave velocity (V_p), and unit weight (γ_n) values are the input parameters in these models; the UCS was tried to estimated by machine learning-based methods. For this purpose, three different machine learning methods, such as Gaussian Process Regression (GSR), Support Vector Machine (SVM), and Ensembles of Tree (ET) were employed. R^2 (Coefficient of Determination), RMSE (Root Mean Square Error), MSE (Mean Square Error), and MAE (Mean Absolute Error) performance indices were used to evaluate the performances of three different machine learning

methods for five different data sets of two different models. According to these assessments, it was determined that all three different machine learning methods were successful for estimating UCS in general; however, the ET method generally had higher prediction performance.

Keywords: Uniaxial compressive strength, Support vector machine, Gaussian process regression, Ensembles of tree

I. GİRİŞ

Tek eksenli sıkışma dayanımı kaya ve toprak türü zeminlerin en önemli mekanik özelliklerinden biri olup; madencilik, inşaat mühendisliği, jeoteknik projelerde ve sınıflama sistemlerinde kullanılmaktadır. Yüksek kalitede karot örneği gerekliliği, deney aletinin kullanımının zahmetli oluşu, maliyet ve zaman kaybı gibi durumlar nedeniyle sağlam kayanın tek eksenli sıkışma dayanımını (UCS) tahmin edebilmek için literatürde çok sayıda çalışma yapılmıştır. Bu çalışmaların bir kısmı UCS ile ilişkili olan farklı girdi parametreleri kullanılarak ampirik eşitlikler yardımıyla UCS' yi tahmin etmeye yönelik çalışmalardır [1]-[5]. Bir kısmı ise; hem ampirik eşitlikler kullanarak hem de yapay zeka yöntemlerini birlikte kullanarak farklı kaya türleri için UCS' yi tahmin etmeye yönelik çalışmalardır [6]-[13]. Ayrıca kayaların farklı fiziksel ve mekanik parametrelerini kullanarak sadece yapay zeka yöntemleri ile UCS'yi tahmin eden çok sayıda çalışma bulunmaktadır [14]-[19].

Son dönemlerde özellikle yüksek tahmin performansından dolayı makine öğrenimi temelli yaklaşımlar UCS' nin de tahmininde yer bulmaktadır. Bargezar vd. [20] travertenlerde UCS'yi tahmin ettikleri çalışmalarında ağaç toplulukları yöntemlerini, çok değişkenli uyarlanabilir regresyon eğrileri (multivariate adaptive regression splines) ve yapay sinir ağları (ANN) yöntemlerini kullanmışlardır. Travertenlerin fiziksel ve mekanik parametrelerinin girdi olarak kullanıldığı çalışmada ağaç toplulukları yöntemlerine ilave olarak başka makine öğrenimi yöntemlerinin de uygulanabileceği belirtilmiştir. Shahani vd. [21] Pakistan Thar kömür alanında yer alan sedimanter kayaların UCS'lerini tahmin etmeye yönelik dört gradyan artırma (gradient boosting) makine öğrenimi yöntemi uygulamışlardır. Çalışmada XGBoost algoritmasının diğer yöntemlerle karşılaştırıldığında en doğru sonucu verdiği vurgulanmıştır. Kahn vd. [22] mermerlerin fiziksel mekanik ve kimyasal özelliklerini kullanarak UCS ve Young Modülü'nün tahmini için çoklu regresyon, rastgele orman (random forest), yapay sinir ağları ve k-en yakın komşu (k- nearest neighbour) yöntemlerini kullanmışlardır. Yöntemlerin performansını karşılaştırmışlar ve rastgele orman yöntemi ile oluşturulan modelin en başarılı tahmin performansını gösterdiğini belirtmişlerdir.

Bazaltların dayanım parametrelerinin hasarsız yöntemlerle tahmin edilmesine yönelik çalışmalar literatürde yer bulmaktadır [23]-[25]. Bu çalışmalarda tarihi ve kültürel alanlarda kullanılan bazaltların fiziksel ve mekanik özellikleri değerlendirilmiştir. Yine bazaltların yapı malzemesi olarak kullanımına yönelik çalışmalar mevcuttur [26]-[28]. Çanakcı vd. [29] bazaltların fiziksel ve indeks özelliklerini kullanarak UCS ve çekilme dayanımını tahmin ettikleri çalışmalarında çoklu regresyon, yapay sinir ağları ve genetik ifadeli programlama (gene expression programming) yöntemlerini kullanmışlardır. Çalışmada yapay sinir ağlarının diğer iki yöntemden daha iyi performans gösterdiğini vurgulamışlardır. Endait ve Juneja [30] bazaltlarda nokta yükü dayanım indeksi ile UCS arasında ilişkiler bulmaya çalışmışlardır. Teymen ve Mengüç [31] bazaltları da içlerine alan farklı bir çok kaya örneğinden alınan karotlarda kayaların mekanik ve indeks özelliklerini kullanarak UCS'yi tahmin etmeye çalışmışlardır. Çalışmalarında çoklu regresyon, ANFIS, ANN ve genetik ifadeli programlama yöntemlerini kullanmışlar ve yöntemlerin tahmin performanslarını farklı performans indisleri ile karşılaştırmışlardır. Gül vd. [32] üç farklı kaya türünde (bazalt, kireçtaşı ve dolomit) gerçekleştirilen fiziko mekanik deneylerden elde ettikleri sonuçları çok katmanlı algılayıcı yapay sinir ağı (Multilayer Perceptron Neural Network), M5 Model Ağacı (M5 Model Tree), aşırı öğrenme makineleri (Extreme Learning Machine) yöntemlerini kullanarak UCS'yi tahmin etmeye çalışmışlardır. Çalışmanın sonucunda tüm yöntemlerin heterojen kayaların tek eksenli sıkışma dayanımını yüksek doğrulukla tahmin ettiğini ifade etmişlerdir.


tahmininde basit regresyon analizleri yeterli olmamaktadır. Bundan dolayı çalışma kapsamında iki girdi parametrelili modeller oluşturulmuştur.


Tablo 1. Temel istatistiksel analizler

Parametreler	Veri Sayısı	En Küçük	En Büyük	Ortalama	Standart Hata	Standart Sapma
n (%)	137	0.024	9.755	2.343	0.166	1.945
V _p (m/s)	137	2123.00	6167.00	4505.07	67.69	792.27
γ _n (kN/m ³)	137	18.15	27.86	23.98	0.21	2.42
UCS (MPa)	137	13.19	177.39	85.40	3.71	43.38

Tablo 2. Bağımsız değişkenler arasındaki korelasyon (R²)

	n (%)	V _p (m/s)	γ _n (kN/m ³)
n (%)	1	-0.656	-0.786
V _p (m/s)		1	0.554
γ _n (kN/m ³)			1





Şekil 2. Çalışmada kullanılan parametrelere ait histogram grafikleri (a) n (%), (b) V_p , (c) γ_n ve (d) UCS

Tablo 3. Basit regresyon analizleri (R^2)

Modeller	Bağımlı Değişken	n (%)	V_p (m/s)	γ_n (kN/m ³)
Eksponansiyel	UCS (MPa)	0.3870	0.2694	0.5913
Doğrusal	UCS (MPa)	0.3149	0.2671	0.5579
Logaritmik	UCS (MPa)	0.2607	0.2496	0.5479
Üstel	UCS (MPa)	0.2649	0.2527	0.5933

IV. MODELLEME

Çalışma kapsamında UCS'nin tahmin edilmesine yönelik iki parametrelili iki ayrı model oluşturulmuştur. V_p 'nin ve γ_n 'nin girdi parametresi olduğu Model 1 ile V_p 'nin ve n 'nin girdi parametresi olduğu Model 2 çalışmada analiz edilmiştir. Bu iki model rastgele seçilmiş beş ayrı seti için ayrı ayrı değerlendirilmiştir. Çalışmada kullanılan toplam 137 adet veri setinin %80'i eğitim ve %20'si test verisi olmak üzere ikiye bölünmüştür [37]-[39]. Çalışma kapsamında DVM, GSR ve AT olmak üzere üç ayrı makine öğrenimi yöntemi uygulanmıştır.

A. DESTEK VEKTÖR MAKİNELERİ (DVM)

Vapnik 1990'larda destek vektör makinelerini (DVM) ortaya koymuştur [40]. DVM, veri hakkında birleşik dağılım fonksiyonuyla ilgili bilgiye ihtiyaç duymaz ve bu nedenle dağılımdan bağımsız çalışabilir [41]. DVM'de amaç, sınıfları birbirinden ayırmaktır. Bu amaçla en uygun ayırma düzlemi (hiper-düzlem) bulunmaya çalışılır. Böylece farklı sınıflara ait destek vektörleri arasındaki uzaklığın olabildiğince büyük olması sağlanır [42]. DVM'ler sinir ağlarının farklı yöntemlerini birlikte kullanırlar [43], [44]. DVM, yüksek genelleme yeteneğine sahip olduğundan ses tanıma, yüz tanıma, metin sınıflandırma gibi birçok farklı alanda kullanılmaktadır [45], [46].

DVM ilk zamanlarda doğrusal verileri iki sınıfa ayırmak için kullanılmıştır. Günümüzde ise doğrusal olmayan ve çok sınıflı verilerle çeşitli tahminler üretebilmek amacıyla da kullanılabilir [47]. DVM içi en uygun hiper-düzleme ait denklemler Eş. 1'de ve Eş.2'de gösterilmektedir.

$$w \cdot x_i + b \geq +1, y = +1 \quad (1)$$

$$w \cdot x_i + b \leq -1, y = -1 \quad (2)$$

Burada $x \in R^N$ N-boyutlu uzayı, $y \in \{-1, +1\}$ sınıf etiketlerini, w ağırlık vektörünü, b eğilim değerini göstermektedir [48], [49].

B. GAUSS SÜREÇ REGRESYONU (GSR)

Gauss süreç regresyonu (GSR), çoğunlukla doğrusal olmayan regresyon problemlerini çözebilmek amacıyla kullanılır. Parametrik olmayan, olasılıklı problemlerde tercih edilir [50], [51]. GSR, Bayesci bir yaklaşıma sahiptir ve küçük veri kümelerinde bile başarılı sonuçlar elde edilebilir [52]. GSR yönteminde en doğru seçeneğin tespit edilebilmesi için farklı kovaryans fonksiyonları kullanılabilir [53]. Gauss süreç fonksiyonu Eş. 3'te $f(x)$ olarak gösterilmektedir [54].

$$f(x) = GP(m(x), k(x, x')) \quad (3)$$

Eş. 3'te $k(x, x')$ kovaryans fonksiyonu ve $m(x)$ ortalama fonksiyonudur. Kovaryans fonksiyonunun açılımı Eş. 4'te verilirken, ortalama fonksiyonu ise Eş. 5'te verilmektedir.

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (4)$$

$$m(x) = E[f(x)] \quad (5)$$

Gauss sürecinin hiper-parametreleri kovaryans ve ortalama fonksiyonlarıdır [55]. Kovaryans fonksiyonu ortalama fonksiyonunun güven düzeyi ölçüsü olarak kullanılır [56].

C. AĞAÇ TOPLULUKLARI (AT)

Ağaç toplulukları (AT), birden çok ağaçtan gelen bilgileri büyüterek toplayan aşamalı bir süreçtir. Her ağaç daha önce yetiştirilmiş ağaçlardan gelen bilgiler kullanılarak büyütülmektedir. İşleyiş, orijinal verilere bir regresyon ağacı sığdırarak başlamakta ve önceki modelin artıkları üzerine regresyon ağaçları uydurarak sürekli güncellemektedir. Bir model verildiğinde, sonuç değişkeni yerine modelin kalıntılarına bir ağaç yerleştirilmektedir. Bu yeni ağaç daha sonra artıkları güncellemek için takılan fonksiyona eklenmektedir. Her bir ağacın yapısı, yetiştirilmiş olan ağaçlara büyük ölçüde bağlıdır [57].

Ağaç toplulukları bir tür topluluk sınıflandırıcı sistemi olarak kullanılabilir. Çoklu sınıflandırıcılar makine öğreniminde yaygın olarak araştırılan ve kullanılan bir yaklaşımdır. Çok sayıda çalışma, birçok kararsız sınıflandırıcının tek bir toplu sınıflandırıcıda birleştirilmesinin, tek bir kararsız sınıflandırıcı örneğine göre çok daha iyi bir performans ortaya koyduğunu göstermektedir [58]-[61]. Karar ağaçları ve sinir ağları, kararsız sınıflandırıcılara örnek olarak verilebilir [62]. Bu tür kararsız sınıflandırıcıların tahmin yeteneği, eğitim setindeki küçük bir bozulmadan bile büyük ölçüde etkilenmektedir. Bu nedenle çeşitli stratejilere sahip karar ağaçları ve sinir ağları toplulukları önerilmiştir [61], [63]-[65]. Rastgele orman bu tür topluluklara iyi bir örnektir [66]. Sınıflandırma ve regresyon görevlerinde üstün performansa sahip torbalama ve rastgele altuzay yöntemleri kullanılarak oluşturulan karar ağaçlarından oluşan bir komitedir [67].

Ağaç topluluklarında, sınıflandırma performansını iyileştirmek için gradyan artırma ve rastgele orman gibi çeşitli topluluk yöntemleri yaygın olarak kullanılmaktadır. Karar ağaçları, sinir ağı tabanlı sınıflandırıcılar ile karşılaştırıldığında eğitim ve sınıflandırmada çok daha hızlıdır ve ayarlar için çok

daha az parametreye ihtiyaç duymaktadırlar. Kolayca paralelleştirilebilirler ve gürültüyü etiketlemek için güçlü bir yöntemdir [68].

V. PERFORMANSLARIN KARŞILAŞTIRILMASI

İki girdi parametrelili iki farklı model için (Model 1 ve Model 2) DVM, GSR ve AT'nin UCS'nin tahminindeki performansları; determinasyon katsayısı (R^2 - Coefficient of Determination), kök ortalama kare hata (RMSE-Root Mean Square Error), ortalama kare hata (MSE-Mean Square Error) ve ortalama mutlak hata (MAE-Mean Absolute Error) performans indisleri ile değerlendirilmiştir. Bu amaçla analizlerde kullanılan beş ayrı veri setinin test verilerine ait sonuçları karşılaştırılmıştır.

Bir modelde en yüksek tahmin değeri R^2 için 1, RMSE, MSE ve MAE için ise 0'dır (Eş. 6-8).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2} \quad (6)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2 \quad (7)$$

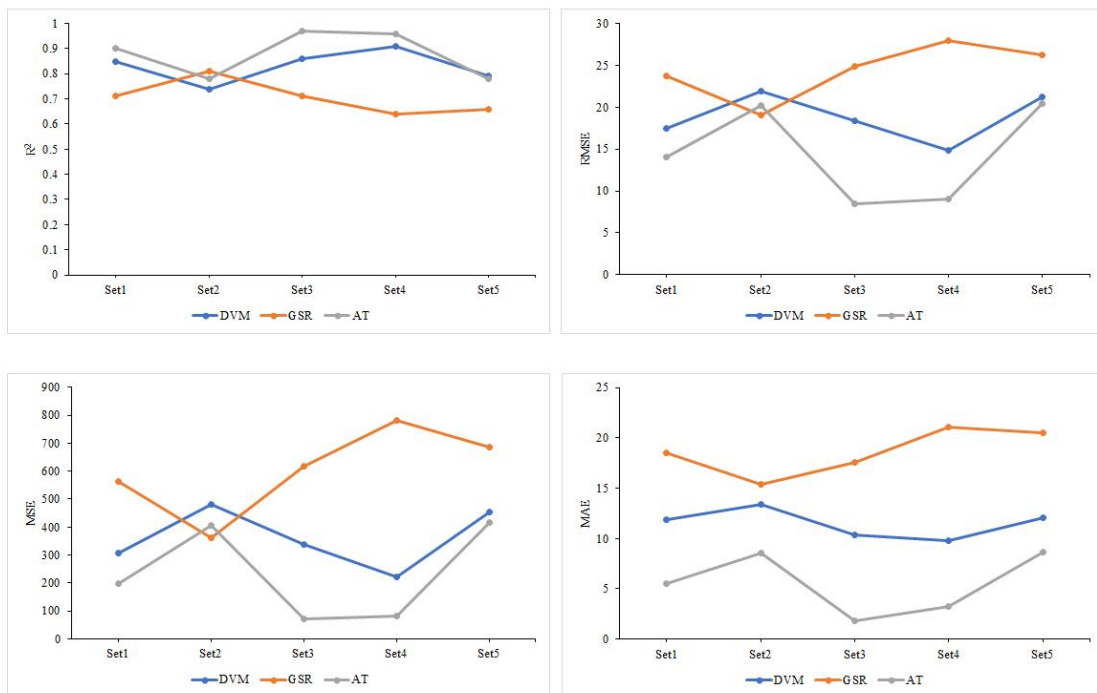
$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - y'_i| \quad (8)$$

Burada, y_i ölçülen değeri, y'_i tahmin edilen değeri, N ise veri sayısını ifade etmektedir. Tablo 4'te analizler sonucunda her iki model için belirlenmiş R^2 , RMSE, MSE ve MAE değerleri yer almaktadır. Her iki model için belirlenen performans indisleri Şekil 3'te grafiksel olarak sunulmuştur. Birden fazla değerlendirme indisinin ve tahmin yönteminin bir arada kullanıldığı çalışmalarda sadece performans indislerine bakarak kullanılan analiz yöntemlerini ya da veri setinin başarısını değerlendirmek oldukça güçleşmektedir. Bu nedenle çalışmada, daha kolay ve daha sağlıklı bir karşılaştırma için Zorlu vd. [69] ve Yagiz vd. [70] tarafından önerilen puanlama esaslı yöntem kullanılmıştır. Buna göre her iki model ve tüm makine öğrenimi için tüm performans indis değerleri 1-5 arasında puanlanmıştır. R^2 'nin en iyi performans değeri için 5, en kötü değeri için 1, diğer performans indisleri için ise; en düşük hata değeri için 5, en yüksek hata değeri için ise; 1 değeri verilmiştir (Tablo 5). Her bir model ve yöneme ait puanlamalar için ayrıca kolon grafikler hazırlanmıştır (Şekil 4). Öncelikle her bir modelde uygulanan 3 ayrı makine öğrenimi yöntemi için hangi veri setinin daha başarılı olduğu değerlendirilmiştir. Bu amaçla her bir makine öğrenimi yönteminde her bir veri seti için tüm performans indis puanlarına bakılarak değerlendirme yapılmıştır (Tablo 5). İkinci aşamada rastgele seçilmiş beş ayrı veri setinden hangisinin modellerde en başarılı veri setini oluşturduğu tespit edilmeye çalışılmıştır. Bu amaçla, her bir veri setinde yer alan tüm yöntemlere ait performans indis puanları toplanmış ve en yüksek puanı veren veri seti o model için en başarılı veri seti olarak belirlenmiştir (Tablo 5). Tablo 5'te her iki model için seçilmiş veri setleri koyu renkte verilmiştir. Karşılaştırmanın son aşamasında en başarılı veri setleri içinde en iyi tahmin performansını veren makine öğrenimi yöntemi belirlenmeye çalışılmıştır. Burada her bir model için belirlenmiş en başarılı veri setleri içinde her bir makine öğrenimi yöntemine ait performans indisleri olan R^2 , RMSE, MSE ve MAE puanları toplanmış en yüksek puanı veren makine öğrenimi yöntemi belirlenmiştir (Tablo 6). Ayrıca belirlenen bu puanlar grafiksel olarak sunulmuştur (Şekil 5). Buna göre; Model 1 için Set 3 ve Model 2 için ise Set 4 çalışmanın en başarılı veri setleri olarak belirlenmiştir. Ayrıca genel olarak; çalışma kapsamında AT yöntemi en başarılı tahmin performansı gösteren yöntem çıkmıştır.

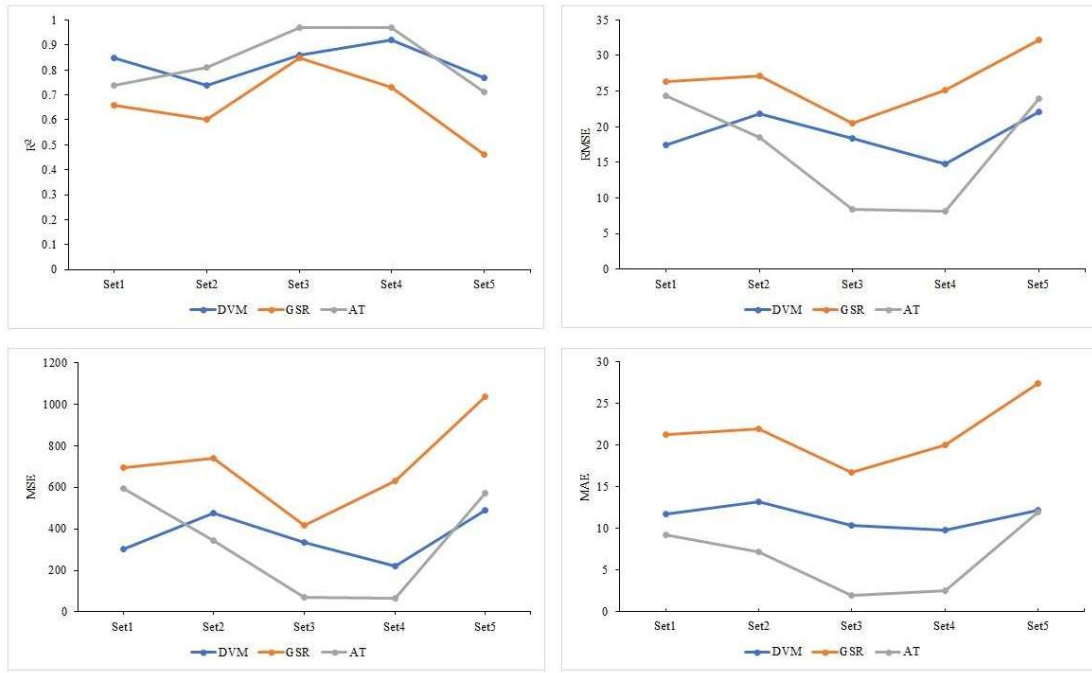
Tablo 4. Modellere ait tahmin performansları

Setler	Yöntemler	Model 1 (V_p, γ_n)				Model 2 (V_p, n)			
		Test				Test			
		R^2	RMSE	MSE	MAE	R^2	RMSE	MSE	MAE
Set 1	DVM	0.85	17.48	305.71	11.86	0.85	17.45	304.6	11.73
	GSR	0.71	23.69	561.45	18.52	0.66	26.31	692.44	21.33

	AT	0.9	14.05	197.35	5.47	0.74	24.39	594.8	9.24
Set 2	DVM	0.74	21.9	479.71	13.37	0.74	21.86	477.8	13.2
	GSR	0.81	19.05	362.78	15.37	0.6	27.19	739.08	21.9
	AT	0.78	20.19	407.51	8.58	0.81	18.56	344.54	7.13
Set 3	DVM	0.86	18.4	338.57	10.34	0.86	18.33	335.95	10.29
	GSR	0.71	24.87	618.54	17.6	0.85	20.46	418.6	16.77
	AT	0.97	8.45	71.36	1.79	0.97	8.42	70.85	1.9
Set 4	DVM	0.91	14.87	221.06	9.81	0.92	14.83	219.91	9.78
	GSR	0.64	27.95	781.15	21.03	0.73	25.1	629.9	20.05
	AT	0.96	9.01	81.17	3.2	0.97	8.14	66.23	2.45
Set 5	DVM	0.79	21.27	452.48	12.03	0.77	22.09	488.16	12.2
	GSR	0.66	26.21	687.16	20.49	0.46	32.19	1,035.96	27.41
	AT	0.78	20.4	416.34	8.63	0.71	23.92	572.3	11.9



(a)




(b)


Şekil 3. Modellere ait tahmin performansları için oluşturulmuş çizgi grafikler (a) Model 1 (b) Model 2

Tablo 5. Her bir model ve yöntemle ait puanlamalar

Setler	Yöntemler	Model 1 (Vp, BHA)				Model 2 (Vp, n)			
		Test				Test			
		R2	RMSE	MSE	MAE	R2	RMSE	MSE	MAE
Set 1	DVM	3	4	4	3	3	4	4	3
	GSR	3	4	4	3	3	3	3	3
	AT	3	3	3	3	2	1	1	2
Set 2	DVM	1	1	1	1	1	2	2	1
	GSR	5	5	5	5	2	2	2	2
	AT	2	2	2	2	3	3	3	3
Set 3	DVM	4	3	3	4	4	3	3	4
	GSR	4	3	3	4	5	5	5	5
	AT	5	5	5	5	4	4	4	5
Set 4	DVM	5	5	5	5	5	5	5	5
	GSR	1	1	1	1	4	4	4	4
	AT	4	4	4	4	5	5	5	4
Set 5	DVM	2	2	2	2	2	1	1	2
	GSR	2	2	2	2	1	1	1	1
	AT	1	1	1	1	1	2	2	1



(a)

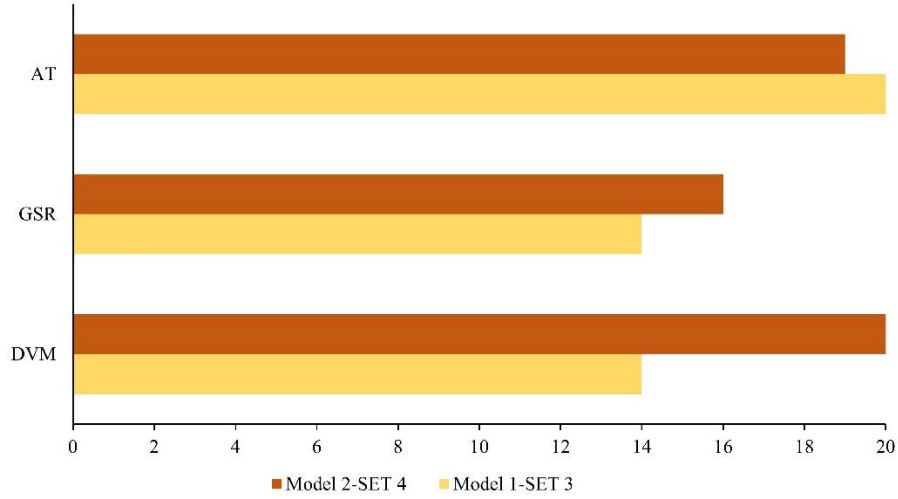


(b)

Şekil 4. Her bir model ve yõteme ait puanlamalar için oluşturulmuş kolon grafikler (a) Model 1 (b) Model 2

Tablo 6. Model 1'e ve Model 2'ye ait en başarılı veri setlerinin her bir makine öğrenimine ait puanları

Setler	Puan		
	DVM	GSR	AT
Model 1-SET 3	14	14	20
Model 2-SET 4	20	16	19



Şekil 5. Model 1'e ve Model 2'ye ait en başarılı veri setlerinin her bir makine öğrenimine ait puanlarının grafiksel gösterimi

VI. SONUÇLAR VE TARTIŞMA

Bir çok alanda kullanılan bazaltların tek eksenli sıkışma dayanımının belirlenmesi mühendislik çalışmaları için önemli olup; bu parametrenin elde edilmesinde karşılaşılabilecek güçlüklerden dolayı kolay elde edilebilir başka parametreler kullanılarak tahmin edilmeye çalışılmaktadır. Bu amaçla çalışma kapsamında 137 karot örneği için gerçekleştirilmiş olan n , V_p , γ_n laboratuvar deney sonuçları kullanılarak UCS değerleri tahmin edilmeye çalışılmıştır. Çalışmada DVM, GSR ve AT olmak üzere üç makine öğrenimi yöntemi kullanılmıştır. Bu yöntemlerin başarısı rastgele seçilmiş beş ayrı veri seti için iki ayrı modelde uygulanmış ve toplam veri seti %80 eğitim ve %20 test verisi olarak ayrılmıştır. Uygulanan üç farklı makine öğrenimi yönteminin değerlendirilmesi için farklı performans indisleri (R^2 , RMSE, MSE ve MAE) kullanılmıştır. Birden fazla performans indisinin kullanıldığı durumlarda daha kolay bir değerlendirme sağlayabilmek için puanlama esaslı bir yöntem uygulanmıştır.

Buna göre, yapılan değerlendirmeler ve puanlamalara göre;

- Model 1'de; DVM için SET 4, GSR için SET 2, AT için ise; SET 3 en başarılı veri seti olarak belirlenmiştir. Model 2'de; DVM için SET 4, GSR için SET 3, AT için ise; SET 4 en başarılı veri seti olarak belirlenmiştir.

- Model 1 için SET 3, Model 2 için ise SET 4 çalışmanın en başarılı veri setleri olarak belirlenmiştir.

- Tablo 6'da verilen puanlamaya göre; her bir model için seçilen en iyi veri setlerine göre değerlendirme yapılmıştır. Buna göre; Model 1-SET 3 için en başarılı tahmin performansı sunan makine öğrenimi yöntemi AT'dir. Model 2-SET4 için ise; AT ve DVM birbirine çok yakın sonuçlar vermekle birlikte DVM daha yüksek performans göstermiştir. Ancak o veri seti için bakıldığında AT yönteminin genel olarak başarılı bir tahmin performansı sunduğu söylenebilmektedir.

Bu çalışma kapsamında değerlendirilen üç makine öğrenimi yöntemi de yüksek tahmin performansına sahip yöntemlerdir. Ancak veri tabanlı çalışmaların başarısı veri sayısı ve veri kalitesine bağlıdır. Çalışmada yeni bir veri seti mevcut olduğunda ileride yapılacak çalışmalarda analiz edilerek daha doğru sonuçların elde edilmesi mümkündür. Bu çalışmanın bir sınırlayıcı durumu kaya türüdür. Çalışma bazaltlarda uygulanmıştır. Başka kayalarla ve daha geniş veri seti ile çalışıldığında çalışmanın hem doğruluğu hem de genelleştirme kapasitesi artmış olacaktır. Bu tür çalışmaların bir diğer sınırlayıcısı ise; analiz sonuçlarının çalışmada kullanılan veri aralığı ile sınırlı olmasıdır. Bu çalışmada elde edilen sonuçlar burada kullanılan veri aralığı için başarılıdır.

Çalışmada elde edilen sonuçlara bakıldığında; bazaltlar için uygulanan 3 ayrı makine öğrenimi yöntemi de genel olarak UCS'nin tahmin edilmesinde başarılı tahmin sonuçları vermektedir. Bazaltlarda UCS'nin tahmininde bu yöntemler çok yaygın kullanılmamakla birlikte; çalışma bu anlamda literatüre katkı sağlayacak niteliktedir.

TEŞEKKÜR: Yazarlar arazi ve laboratuvar çalışmalarındaki katkılarından dolayı Jeoloji Mühendisi H. Serkan Tezer'e, laboratuvar çalışmalarındaki katkılarından dolayı Jeoloji Mühendisi Zeynel Abidin Gök ve Jeoloji Mühendisi Serkan Pişmiş'e teşekkürlerini sunarlar.

VII. KAYNAKLAR

- [1] S. Kahraman, "Evaluation of simple methods for assessing the uniaxial compressive strength of rock," *Int. J. Rock Mech. Min. Sci.*, vol. 38, no. 7, pp. 981–994, 2001.
- [2] İ. Çobanoğlu and S. B. Çelik, "Estimation of uniaxial compressive strength from point load strength, Schmidt hardness and P-wave velocity," *Bull. Eng. Geol. Environ.*, vol. 67, no. 4, pp. 491–498, 2008.
- [3] H. A. Nefeslioglu, "Evaluation of geo-mechanical properties of very weak and weak rock materials by using non-destructive techniques: Ultrasonic pulse velocity measurements and reflectance spectroscopy," *Eng. Geol.*, vol. 160, pp. 8–20, 2013.
- [4] A. E. Aladejare, "Evaluation of empirical estimation of uniaxial compressive strength of rock using measurements from index and physical tests," *J. Rock Mech. Geotech. Eng.*, vol. 12, no. 2, pp. 256–268, 2020.
- [5] C. Gokceoglu and K. Zorlu, "A fuzzy model to predict the uniaxial compressive strength and the modulus of elasticity of a problematic rock," *Eng. Appl. Artif. Intell.*, vol. 17, no. 1, pp. 61–72, 2004.
- [6] K. Zorlu, C. Gokceoglu, F. Ocakoglu, H. A. Nefeslioglu, and S. Acikalin, "Prediction of uniaxial compressive strength of sandstones using petrography-based models," *Eng. Geol.*, vol. 96, no. 3–4, pp. 141–158, 2008.
- [7] I. Yilmaz and G. Yuksek, "Prediction of the strength and elasticity modulus of gypsum using multiple regression, ANN, and ANFIS models," *Int. J. rock Mech. Min. Sci.*, vol. 46, no. 4, pp. 803–810, 2009.
- [8] S. Dehghan, G. H. Sattari, S. C. Chelgani, and M. A. Aliabadi, "Prediction of uniaxial compressive strength and modulus of elasticity for Travertine samples using regression and artificial neural networks," *Min. Sci. Technol.*, vol. 20, no. 1, pp. 41–46, 2010.
- [9] M. Monjezi, H. A. Khoshalan, and M. Razifard, "A neuro-genetic network for predicting uniaxial compressive strength of rocks," *Geotech. Geol. Eng.*, vol. 30, no. 4, pp. 1053–1062, 2012.
- [10] S. Yagiz, E. A. Sezer, and C. Gokceoglu, "Artificial neural networks and nonlinear regression techniques to assess the influence of slake durability cycles on the prediction of uniaxial compressive strength and modulus of elasticity for carbonate rocks," *Int. J. Numer. Anal. Methods Geomech.*, vol. 36, no. 14, pp. 1636–1650, 2012.
- [11] N. Yesiloglu-Gultekin, C. Gokceoglu, and E. A. Sezer, "Prediction of uniaxial compressive strength of granitic rocks by various nonlinear tools and comparison of their performances," *Int. J. Rock Mech. Min. Sci.*, vol. 62, pp. 113–122, 2013.

- [12] N. Yesiloglu-Gultekin, E. A. Sezer, C. Gokceoglu, and H. Bayhan, "An application of adaptive neuro fuzzy inference system for estimating the uniaxial compressive strength of certain granitic rocks from their mineral contents," *Expert Syst. Appl.*, vol. 40, no. 3, pp. 921–928, 2013.
- [13] D. Armaghani, E. Tonnizam Mohamad, E. Momeni, M. Monjezi, and M. S. Narayanasamy, "Prediction of the strength and elasticity modulus of granite through an expert artificial neural network. Arab J Geosci 9: 48." 2016.
- [14] A. Cevik, E. A. Sezer, A. F. Cabalar, and C. Gokceoglu, "Modeling of the uniaxial compressive strength of some clay-bearing rocks using neural network," *Appl. Soft Comput.*, vol. 11, no. 2, pp. 2587–2594, 2011.
- [15] R. Singh, A. Kainthola, and T. N. Singh, "Estimation of elastic constant of rocks using an ANFIS approach," *Appl. Soft Comput.*, vol. 12, no. 1, pp. 40–45, 2012.
- [16] D. J. Armaghani, E. T. Mohamad, E. Momeni, and M. S. Narayanasamy, "An adaptive neuro-fuzzy inference system for predicting unconfined compressive strength and Young's modulus: a study on Main Range granite," *Bull. Eng. Geol. Environ.*, vol. 74, no. 4, pp. 1301–1319, 2015.
- [17] R. K. Umrao, L. K. Sharma, R. Singh, and T. N. Singh, "Determination of strength and modulus of elasticity of heterogenous sedimentary rocks: An ANFIS predictive technique," *Measurement*, vol. 126, pp. 194–201, 2018.
- [18] D. J. Armaghani *et al.*, "Predicting the unconfined compressive strength of granite using only two non-destructive test indexes," *Geomech. Eng.*, vol. 25, pp. 317–330, 2021.
- [19] Q. Fang, B. Yazdani Bejarbaneh, M. Vatandoust, D. Jahed Armaghani, B. Ramesh Murlidhar, and E. Tonnizam Mohamad, "Strength evaluation of granite block samples with different predictive models," *Eng. Comput.*, vol. 37, no. 2, pp. 891–908, 2021.
- [20] R. Barzegar, M. Sattarpour, R. Deo, E. Fijani, and J. Adamowski, "An ensemble tree-based machine learning model for predicting the uniaxial compressive strength of travertine rocks," *Neural Comput. Appl.*, vol. 32, no. 13, pp. 9065–9080, 2020, doi: 10.1007/s00521-019-04418-z.
- [21] N. M. Shahani, X. Zheng, X. Guo, and X. Wei, "Machine Learning-Based Intelligent Prediction of Elastic Modulus of Rocks at Thar Coalfield," *Sustainability*, vol. 14, no. 6, p. 3689, 2022.
- [22] N. M. Khan *et al.*, "Application of Machine Learning and Multivariate Statistics to Predict Uniaxial Compressive Strength and Static Young's Modulus Using Physical Properties under Different Thermal Conditions," *Sustainability*, vol. 14, no. 16, p. 9901, 2022.
- [23] A. Karakuş and M. Akatay, "Determination of basic physical and mechanical properties of basaltic rocks from P-wave velocity," *Nondestruct. Test. Eval.*, vol. 28, no. 4, pp. 342–353, 2013.
- [24] F. Dursun and T. Topal, "Durability assessment of the basalts used in the Diyarbakır City Walls, Turkey," *Environ. Earth Sci.*, vol. 78, no. 15, pp. 1–24, 2019.
- [25] H. Aldeeky, O. Al Hattamleh, and S. Rababah, "Assessing the uniaxial compressive strength and tangent Young's modulus of basalt rock using the Leeb rebound hardness test," *Mater. Construcción*, vol. 70, no. 340, p. 230, 2020.
- [26] M. Korkanç and A. Tuğrul, "Evaluation of selected basalts from Niğde, Turkey, as source of concrete aggregate," *Eng. Geol.*, vol. 75, no. 3–4, pp. 291–307, 2004.
- [27] T. A. Engidasew and G. Barbieri, "Geo-engineering evaluation of Termaber basalt rock mass

for crushed stone aggregate and building stone from Central Ethiopia,” *J. African Earth Sci.*, vol. 99, pp. 581–594, 2014.

[28] E. Kolay and T. Baser, “The effect of the textural characteristics on the engineering properties of the basalts from Yozgat region, Turkey,” *J. Geol. Soc. India*, vol. 90, no. 1, pp. 102–110, 2017.

[29] H. Çanakcı, A. Baykasoğlu, and H. Güllü, “Prediction of compressive and tensile strength of Gaziantep basalts via neural networks and gene expression programming,” *Neural Comput. Appl.*, vol. 18, no. 8, pp. 1031–1041, 2009.

[30] M. Endait and A. Juneja, “New correlations between uniaxial compressive strength and point load strength of basalt,” *Int. J. Geotech. Eng.*, vol. 9, no. 4, pp. 348–353, 2015.

[31] A. Teymen and E. C. Mengüç, “Comparative evaluation of different statistical tools for the prediction of uniaxial compressive strength of rocks,” *Int. J. Min. Sci. Technol.*, vol. 30, no. 6, pp. 785–797, 2020.

[32] E. Gül, E. Ozdemir, and D. E. Sarıcı, “Modeling uniaxial compressive strength of some rocks from turkey using soft computing techniques,” *Measurement*, vol. 171, p. 108781, 2021.

[33] Google Earth. (2022, August, 23). [Online]. Available: <http://www.google.com/intl/tr/earth/index.html>

[34] F. Innocenti, R. Mazzuoli, G. Pasquare, F. Radicati, and L. Villari, “Tertiary and Quaternary volcanism of the Erzurum-Kars area (Eastern Turkey), Geochronological data and geodynamic evolution,” *J. Volconogy Geoth. Res.*, 1982.

[35] H. Aktimur et al., “Kars, Arpaçay ve Çıldır dolayının jeolojisi. MTA Rapor No:9257,” Ankara, 1991.

[36] 2021 SPSS, “IBM SPSS Statistics v23.0. <https://www.ibm.com/support/pages/downloading-ibm-spss-statistics-2>.” [Online]. Available: <https://www.ibm.com/support/pages/downloading-ibm-spss-statistics-23>

[37] M. M. Nelson and W. T. Illingworth, “A practical guide to neural nets,” 1991.

[38] K. Swingler, *Applying neural networks: a practical guide*. Morgan Kaufmann, 1996.

[39] C. G. Looney, “Advances in feedforward neural networks: demystifying knowledge acquiring black boxes,” *IEEE Trans. Knowl. Data Eng.*, vol. 8, no. 2, pp. 211–226, 1996.

[40] V. Vapnik, “The nature of statistical learning theory,” *NY: Springer-Verlag*, 1995.

[41] K. Soman, R. Loganathan, and V. Ajay, *Machine learning with SVM and other kernel methods*. PHI Learning Pvt. Ltd., 2009.

[42] S. Ayhan and Ş. Erdoğan, “Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi,” *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, vol. 9, no. 1, pp. 175–201, 2014.

[43] S. Haykin, “Neural Networks, a comprehensive foundation, Prentice-Hall Inc,” *Upper Saddle River, New Jersey*, vol. 7458, pp. 161–175, 1999.

- [44] S. Tolun, "Destek vektör makineleri: Banka başarısızlığının tahmini üzerine bir uygulama," Doktora Tezi Doktora Tezi, İşletme Anabilim Dalı, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 2008.
- [45] N. Cristianini and J. Shawe-Taylor, *An introduction to support vector machines and other kernel-based learning methods*. Cambridge university press, 2000.
- [46] B. Schölkopf, J. C. B. Christopher, and J. A. Smola, *Advances in kernel methods (Support Vector Learning)*. Cambridge, England: The MIT Press, 1999.
- [47] T. Kavzoğlu and İ. Çölkesen, "Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi," *Harita Dergisi*, vol. 144, no. 7, pp. 73-82, 2010.
- [48] S. Huang, N. Cai, P. P. Pacheco, S. Narrandes, Y. Wang, and W. Xu, "Applications of support vector machine (SVM) learning in cancer genomics," *Cancer genomics & proteomics*, vol. 15, no. 1, pp. 41-51, 2018.
- [49] E. E. Osuna, "Support vector machines: Training and applications," Massachusetts Institute of Technology, USA, 1998.
- [50] K. Liu, X. Hu, Z. Wei, Y. Li, and Y. Jiang, "Modified Gaussian process regression models for cyclic capacity prediction of lithium-ion batteries," *IEEE Transactions on Transportation Electrification*, vol. 5, no. 4, pp. 1225-1236, 2019.
- [51] M. Acı and A. G. Doğansoy, "Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak e-perakende sektörüne yönelik talep tahmini," *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 37, no. 3, pp. 1325-1340, 2022.
- [52] B. Ateş, "Gemi yapılarında gerilme yığılması öngörülerinin kaba ağ yapısı ve makine öğrenmesi ile gerçekleştirilmesi," Yüksek Lisans Tezi Yüksek Lisans Tezi, Gemi ve Deniz Teknolojileri Mühendisliği Ana Bilim Dalı, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2020.
- [53] Y. Heo and V. M. Zavala, "Gaussian process modeling for measurement and verification of building energy savings," *Energy and Buildings*, vol. 53, pp. 7-18, 2012.
- [54] C. Rasmussen and C. Williams, *Gaussian processes for machine learning*. USA: MIT Press, 2006.
- [55] C. K. Arthur, V. A. Temeng, and Y. Y. Ziggah, "Novel approach to predicting blast-induced ground vibration using Gaussian process regression," *Engineering with Computers*, vol. 36, no. 1, pp. 29-42, 2020.
- [56] K. Yazıcı, "Makine öğrenmesi yöntemleri kullanılarak kısa dönem rüzgar gücü tahmini," Yüksek Lisans Tezi Yüksek Lisans Tezi, Endüstri Mühendisliği, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, 2021.
- [57] F. Schiltz, C. Masci, T. Agastisi, and D. Horn, "Using regression tree ensembles to model interaction effects: a graphical approach," *Applied Economics*, vol. 50, no. 58, pp. 6341-6354, 2018.
- [58] L. Rokach, "Ensemble-based classifiers," *Artificial Intelligence Review*, vol. 33, no. 1, pp. 1-39, 2010/02/01 2010, doi: 10.1007/s10462-009-9124-7.
- [59] T. G. Dietterich, "Ensemble methods in machine learning," in *International workshop on multiple classifier systems*, 2000: Springer, pp. 1-15.

- [60] G. Valentini and F. Masulli, "Ensembles of learning machines," in *Italian workshop on neural nets*, 2002: Springer, pp. 3-20.
- [61] D. Opitz and R. Maclin, "Popular ensemble methods: An empirical study," *Journal of artificial intelligence research*, vol. 11, pp. 169-198, 1999.
- [62] L. Breiman, "Bias, variance, and arcing classifiers," Tech. Rep. 460, Statistics Department, University of California, Berkeley, 1996.
- [63] T. G. Dietterich, "An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization," *Machine learning*, vol. 40, no. 2, pp. 139-157, 2000.
- [64] Z.-H. Zhou, J. Wu, and W. Tang, "Ensembling neural networks: Many could be better than all," *Artificial Intelligence*, vol. 137, no. 1, pp. 239-263, 2002/05/01/ 2002, doi: [https://doi.org/10.1016/S0004-3702\(02\)00190-X](https://doi.org/10.1016/S0004-3702(02)00190-X).
- [65] D. Opitz and J. Shavlik, "Generating accurate and diverse members of a neural-network ensemble," *Advances in neural information processing systems*, vol. 8, 1995.
- [66] L. Breiman, "Random forests," *Machine learning*, vol. 45, no. 1, pp. 5-32, 2001.
- [67] R. Katuwal, P. N. Suganthan, and L. Zhang, "An ensemble of decision trees with random vector functional link networks for multi-class classification," *Applied Soft Computing*, vol. 70, pp. 1146-1153, 2018.
- [68] M. Shoaran, B. A. Haghi, M. Taghavi, M. Farivar, and A. Emami-Neyestanak, "Energy-efficient classification for resource-constrained biomedical applications," *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, vol. 8, no. 4, pp. 693-707, 2018.
- [69] K. Zorlu, C. Gokceoglu, F. Ocakoglu, H. A. Nefeslioglu, and S. Acikalin, "Prediction of uniaxial compressive strength of sandstones using petrography-based models," *Eng. Geol.*, vol. 96, no. 3-4, pp. 141-158, 2008.
- [70] S. Yagiz, C. Gokceoglu, E. Sezer, and S. Iplikci, "Application of two non-linear prediction tools to the estimation of tunnel boring machine performance," *Eng. Appl. Artif. Intell.*, vol. 22, no. 4, pp. 808-814, 2009, doi: <https://doi.org/10.1016/j.engappai.2009.03.007>.