

En Küçük Kareler Destek Vektör Makineleri (LS-SVM) Kullanarak Kaya Malzemesi Tanjant Elastisite Modülünün Tahmini

Prediction of Tangent Elasticity Modulus of Rock Material Using Least Square Support Vector Machine

NURÇİHAN CERYAN^{1*}

¹Balıkesir Üniversitesi Balıkesir Meslek Yüksekokulu Madencilik ve Maden Çıkarma Bölümü

Geliş (received) : 18 Şubat (February) 2016

Kabul (accepted) : 01 Ağustos (August) 2016

ÖZ

Kaya malzemesi tanjant elastisite modülü kaya mühendisliği tasarım problemlerinin çözümünde önemli bir parametredir. Elastisite modülünün standart laboratuvar deneyleriyle belirlenmesi zor, pahalı ve zaman alıcı bir işittir. Bu durum özellikle ince tabakalı, ileri derecede kırıklı, foliasyonlu, yüksek poroziteli ve zayıf kayalar için geçerlidir. Bu nedenle, araştırmacılar tarafından tanjant elastisite modülünün tahmini için bazı istatistiksel modeller geliştirilmiştir. Bu modeldeki korelasyonlar indeks özellikler, petrografik özellikler, Schmidt çekici geri tepme sayısı ve Nokta yük indeksi gibi basit mekanik deneylerle ilgilidir. Ancak, bu korelasyonlar genel amaçlı kullanıma uygun değildir ve basit mekanik deneyler bazı zorluklara ve kısıtlamalara sahiptir. Son birkaç yıl içinde, bu geleneksel yönteme ek olarak, tanjant elastisite modülünün tahmini için yeni teknikler büyük ilgi toplamıştır. Bu yeni teknikler yapay sinir ağları (ANN), genetik algoritma (GA), ilgililik vektör makineleri (RVM) ve destek vektör makineleri (SVM) gibi esnek hesaplama yöntemleridir. Bu çalışmada, kaya malzemesi tanjant elastisite modülünün (E_t) tahmininde En Küçük Kareler Destek Vektör Makinesi (LS-SVM) yönteminin uygulanabilirliği ve yeteneği incelenmiştir ve yöntemin performansı yapay sinir ağları (ANN) modeli ile karşılaştırılmıştır. İncelenen örnekler Gümüşhane, Giresun ve Rize'de (KD Türkiye) yüzeylenen volkanik kayalardan alınmıştır. Bu modellerin girdi parametreleri efektif porozite ve P-kararlılık indeksidir. ANN ve LS-SVM modellerinin performanslarını belirlemek için Performans İndeksi (PI) kullanılmıştır. Bu iki yöntem güçlü esnek hesaplama teknikleri olmasına rağmen, LS-SVM daha yüksek doğruluk ve daha hızlı sonuçlar üretmektedir. Bu çalışma sonuçlarına göre, incelenen volkanik kayaç örnekleri için, LS-SVM modelinin ANN modeline göre daha iyi genelleme yeteneğine sahip olduğu söylenebilir.

Anahtar Kelimeler: En küçük kareler destek vektör makinesi (LS-SVM), KD Türkiye, tanjant elastisite modülü, volkanik kayaç, yapay sinir ağı (ANN).

ABSTRACT

The tangent elasticity modulus is an important parameter in designing solutions to rock engineering problems. Determining the parameter using standard laboratory tests is a difficult, expensive and time-consuming task. This is particularly true for thinly bedded, highly fractured, foliated, highly porous and weak rocks. Therefore, the researchers developed some statistical models for prediction of the tangent elasticity modulus. The correlations in these models often relate to some index properties, petrographic characteristics and basic mechanical test such as Schmidt hammer rebound number, point load index. However, these correlations are not open to the general purpose use and basic mechanical tests have some limitation and difficulties. In addition to these conventional methods, new techniques for prediction of the tangent elasticity modulus have also garnered considerable attention in the last several years. These new methods are soft computing methods such as Artificial Neural Network (ANN), Genetic algorithm (GA), Relevance vector machines (RVM) and Support vector machines (SVM). In this study, the applicability and capability of least squares support vector machines (LS-SVM) for predicting the tangent elasticity modulus of the rock materials was examined and its performance was compared with the artificial neural networks (ANN) model. The samples investigated were taken from volcanic rocks exposed in Gümüşhane, Giresun and Rize (NE Turkey). The input parameters of LS-SVM and ANN developed in this study models are the effective porosity, and P-durability index. The performance index (PI) was used to determine the performance of the LS-SVM and ANN models. Although these two methods are powerful soft computing techniques,

*N. Ceryan

e-posta: nceryan@balikesir.edu.tr

LS-SVM makes the running time considerably faster, in terms of accuracy. As a result of the study, it can be concluded that the generalization ability of the LS-SVM model produces better results than those of the ANN model for the volcanic rock samples investigated..

Keywords: Artificial neural network (ANN), least squares support vector machines (LS-SVM), NE Turkey, tangent elasticity modulus, volcanic rock.

GİRİŞ

Kaya malzemesi elastisite modülü kaya malzemesinin deformasyon özelliklerinin tanımlanmasındaki temel parametre olup kaya kütlesi deformasyon modülünün tahmininde ve kaya kütlesinin gerilme-deformasyon ilişkisinin sayısal modellenmesinde de kullanılmaktadır. Bu nedenle, kaya mühendisliğinin birçok uygulamasında söz konusu parametreye ihtiyaç duyulmaktadır. Elastisite modülünü laboratuvar deneyleriyle elde etmek için ilgili standartlarda tanımlanmış, düzgün geometriye sahip karot örnekleri ihtiyaç duyulmaktadır. Ancak, zayıf, ileri derecede kırıklı, ince tabakalı, foliasyonlu ve/veya zayıf matris içinde blok içeren kayalardan bu standart karot örneklerini elde etmek çoğu kez mümkün olmamaktadır (Gökçeoğlu ve Zorlu, 2004; Sönmez vd., 2006; Yılmaz ve Yüksel, 2008). Ayrıca, elastisite modülünü bulmak için yapılan tek eksenli sıkışma deneyi; zaman alıcıdır, hassasiyeti fazladır (dikkat gerektirir), ucuz değildir ve aynı örnek için tekrarlanamamaktadır (Gökçeoğlu ve Zorlu, 2004; Sönmez vd., 2006). Bu zorlukları aşmak için, araştırmacılar tarafından farklı tahmin modelleri geliştirilmiştir. Söz konusu bu modellerde en çok kullanılan araçlar; istatistiksel (korelasyon) analize dayalı görgül ilişkiler ve esnek hesaplama yöntemleridir.

Kaya malzemesi elastisite modülünü tahmin etmek için geliştirilen görgül ilişkilerde bazen tek bağımsız değişken kullanılırken (Sachpazis, 1990; Leitev ve Ferland, 2001; Yılmaz ve Sendir, 2002; Lashkaripour, 2002; Yaşar ve Erdoğan, 2004; Dinçer vd., 2004; Moradian ve Behnia, 2009; Armaghani vd., 2015) bazen de birden fazla değişken kullanılmaktadır (Christasaras vd., 1994; Karakus vd., 2005; Dehghan vd., 2010; Yılmaz ve Yüksel, 2009; Beiki vd., 2013; Torabi-Kaveh vd., 2015). Bu görgül bağıntılar belirli bir kaya türü için geliştirilmiş olup (Fener vd., 2005; Sönmez vd., 2006; Maji ve Sitharam, 2008; Rezaei vd., 2012) güncelleştirilmek istendiğinde de yeni verilere ihtiyaç duyulmaktadır (Rezaei vd., 2012).

Son on beş yılda, kaya malzemesi ve kaya kütlesinin dayanım ve deformasyon özelliklerinin tahmininde

esnek hesaplama yöntemlerinin kullanımına sıklıkla rastlanmaktadır (Ceryan, 2015). Kaya malzemesi elastisite modülünü tahmin etmek için geleneksel görgül bağıntılara alternatif olarak kullanılan başlıca esnek hesaplama yöntemleri; yapay sinir ağlarının (ANN) farklı modelleri (Meulenkamp ve Grima, 1999; Sönmez vd., 2006; Yılmaz ve Yüksel, 2008; Tiryaki, 2008; Yılmaz ve Yüksel, 2009; Heidari vd., 2010; Dehghan vd., 2010; Torabi-Kaveh vd., 2015), bulanık çıkarım sistemleri (FIS) (Gökçeoğlu ve Zorlu, 2004; Sönmez vd., 2004; Ranjbar-Karami vd., 2014) ve Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemidir (ANFIS) (Yılmaz ve Yüksel, 2009; Singh vd., 2012, Armaghani vd., 2015). Son on yıldır, sıklıkla kullanılan söz konusu yöntemlerin yan sıra, genetik algoritma (GA) (Amin vd., 2013; Beiki vd., 2013), genetik algoritma ile geliştirilmiş ANN (GA-ANN) (Majdi ve Beki, 2010), regresyon ağacı (Tiryaki, 2008), Gauss süreci regresyonu (Gaussian Process Regression) (Kumar vd., 2013) ve mini-maksimum olasılık makineleri regresyonu (Minimax Probability Machine Regression) (Kumar vd., 2013), ilgililik vektör makineleri (RVM) (Liu vd., 2014) ve destek vektör makineleri (SVM) (Liu vd., 2013; 2014; Ceryan, 2015; Al-Anazi ve Gates 2015) modellerinin de E_t 'yi tahmin için kullanıldığı görülmektedir.

ANN algoritmaları birçok avantaja sahip olmasına rağmen, çok katmanlı yapısındaki karmaşıklık, yerel minimum noktalarına takılma ve aşırı öğrenme olasılığı, parametrelerindeki hassasiyet analizindeki güçlük ve ağırlıklarının rastgele atanmasından dolayı modelin her koşuturulmasında farklı çıktılar elde edilmesi gibi olumsuz özellikler de içermektedir (ASCE, 2000). ANN'nin bu olumsuzluklarını en aza indirmek amacıyla Vapnik (1995) makine öğrenme teorisine ve karesel (kuadratik) programlamayla çözüm esasına dayanan destek vektör makineleri (SVM) yöntemini geliştirmiştir. Bu yöntem güçlü öğrenme ve tahmin yetenekleri olan, etkin ve doğru bir araç olarak kabul edilmektedir (Ceryan vd., 2012; Ceryan, 2014). SVM modeli yapay sinir ağları (ANN ile yakından ilişkilidir. Aslında sigmoid bir kernel fonksiyonu kullanan SVM

modeli; iki katmanlı, ileri beslemeli bir sinir ağına karşılık gelmektedir (Tolun, 2008). Standart sinir ağı eğitimi gibi konveks olmayan kısıtlayıcı koşullar içermeyen minimizasyon (hataları en az indirme) problemini çözmek yerine kısıtlayıcı koşullar içeren bir karesel programlama problemini çözen SVM modelleri bir kernel fonksiyonu kullanan radyal tabanlı fonksiyon ve çok katmanlı algılayıcı (perception) sınıflandırıcılar için alternatif bir eğitim yöntemidir (Tolun 2008).

Bu çalışmanın amacı; kaya malzemesi tanjant elastisite modülünün (E_t) tahmininde LS-SVM yönteminin uygulanabilirliğinin araştırılmasıdır. Bu amacı gerçekleştirmek için, Giresun-Gümüşhane-Rize (KD Türkiye) yöresinde yüzeylenen volkanik kayalardan örnekler alınmış ve bu örneklerin fiziksel özellikleri, P-dalgı hızı, suda kararlılık indeksi ve tanjant elastisite modülü belirlenmiştir. Bu çalışmada, LS-SVM modelinin yansira bu modelin performansını karşılaştırmak amacıyla, Levenberg-Marquardt algoritmasına sahip ileri beslemeli geriye yayımlı ANN modeli de oluşturulmuştur. Söz konusu bu modellerin tahmin parametreleri olarak efektif porozite (görünür gözeneklilik) ve P-kararlılık indeksi (Ceryan, 2014) kullanılmıştır. ANN ve LS-SVM modellerinin genelleme yeteneğini değerlendirebilmek amacıyla verilerin yansı eğitim, diğer yansı da test için kullanılmış olup hem eğitim hem de testteki performansları da ilgili kriterler ile değerlendirilmiştir. Söz konusu modellerin oluşturulması ve çalıştırılmasında MATLAB R2010a yazılımından yararlanılmıştır.

YAPAY SİNİR AĞI MODELİ (ANN)


Yapay sinir ağı (Artificial Neural Network, ANN) insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır (Haykin, 1994; Skapura, 1996). Genel olarak yapay sinir ağı mimarisi üç katman halinde tanımlanmaktadır (Şekil 1). Bir ağda birden fazla gizli katman olabilmektedir. Bir yapay sinir ağında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç sinir hücresi olacağı ise bugüne kadar belirlenememiş; probleme göre değişen, bazı sezgisel yaklaşımlar geliştirilmiştir (Sönmez vd., 2015). Bu çalışmada, iki girdi parametresi ve bir çıktı parametresi ile yapılandırılan ANN modelinde 3 sinir hücresi bulunan 1 gizli katman kullanılmıştır (Şekil 1).

Şekil 1'de bir ANN modelinin katmanlı yapısının ölçülen parametre değerleri (girdiler) (x), ağırlıklar (W), net fonksiyonu, aktivasyon fonksiyonu (f) ve çıktılar (y) olmak üzere 5 temel elemanı vardır. Parametrelerin (bağımsız değişkenlerin) sistem içindeki etkinlikleri ağırlıklarla sağlanmakta ve dolayısıyla modelin performansı ağırlıklara bağlı olmaktadır. Parametre değerlerinin hücreler üzerindeki etkilerini ifade etmek için parametre değerlerinin ağırlıklı toplamı olarak bulunan net fonksiyonu (Şekil 1) kullanılır. Hücrelere gelen ağırlıklı toplamı olarak parametre değerleri de aktivasyon fonksiyonları (f) yardımıyla çıktılara dönüştürülmektedir (Haykin, 1994; Skapura, 1996). Aktivasyon fonksiyonu olarak; doğrusal, logaritmik sigmoid, hiperbolik tanjant sigmoid, gauss gibi fonksiyonlar bulunmakla birlikte, bu çalışmada da olduğu gibi, çoğunlukla logaritmik sigmoid fonksiyonu kullanılmaktadır (Ham ve Kostanic, 2001).

ANN'nin yapısı kadar ağı kurulması da; yani ağı tahmin parametrelerinin değerlerine karşılık beklenen çıktıları öğrenmesini (ağın eğitimi) sağlayacak algoritma da çok önemlidir. Araştırmacılar tarafından ANN ağının eğitiminde kullanılacak birçok algoritma geliştirilmiş olmasına karşın, uygulamalarda sıklıkla kullanılan algoritmalar; ileri beslemeli geri yayımlı algoritmalar (Skapura, 1996; Ham ve Kostanic, 2001). İleri doğru hesaplamaya, ölçülen parametre değerlerinin ağa sunulmasıyla başlanmaktadır. Gizli katmandaki her hücre girdi katmanından gelen parametre değerlerini ağırlıklarıyla birlikte alarak net girdiler hesaplanmakta, bu aşamanın son adımında ise bu net girdi değerlerinin belirlenen bir aktivasyon fonksiyonundan geçirilmesiyle gizli katman elemanlarının çıktıları hesaplanmaktadır (Ham ve Kostanic, 2001; Okkan ve Mollamahmutoğlu, 2010; Ceryan vd., 2013). Bu işlemler tüm gizli katman ve çıktı katmanı arasında da tekrarlanmaktadır. ANN modelinde verilen ölçülen parametre değerlerini çıktılara dönüştüren yukarıda verilen süreç aşağıdaki bağıntıyla ifade edilmektedir (Eşitlik 1, Ham ve Kostanic, 2001);

$$y_m = f^{(2)} \left\{ \sum_{j=1}^m \left[f^{(1)} \left(\sum_{i=1}^n x_i W_{ij} + b_j \right) \right] W_{jm} + b_m \right\} \quad (1)$$

Yukarıdaki denklemde; x_i ağı arasındaki girdileri, W_{ij} girdi katmanı ile gizli katman arasındaki ağırlıkları, b_j girdi katmanı ile gizli katman arasındaki sabit terimleri (bias değeri), $f^{(1)}$ girdi katmanı ile gizli katman arasındaki aktivasyon fonksiyonunu, $f^{(2)}$ çıktı katmanı ile gizli katman arasındaki aktivasyon fonksiyonunu, j



Şekil 1. İncelenen örneklerin tanjant elastisite modülünü tahmin etmek için kurulan yapay sinir ağı yapısı (Huang ve Wandstedt, 1998'den değiştirilerek) (n_e^* : normalize edilmiş efektif porozite, V_{md}^* : normalize edilmiş P-kararlılık indeksi, E_t^* : normalize edilmiş tanjant elastisite modülü).

Figure 1. The Artificial neural network structure to predict the tangent elasticity modulus of the sample investigated (modified from Huang and Wandstedt, 1998) (n_e^* : effective porosity normalized, V_{md}^* : P-durability index normalized, E_t^* : tangent elasticity modulus normalized).

gizli katmana ait hücre sayısını, n girdi katmanındaki hücre sayısını, W_{jm} çıktı katmanı ile gizli katman arasındaki ağırlıkları, b_m ise çıktı katmanı ile gizli katman arasındaki sabit terimdir..

Geriye doğru hesaplama aşamasında ise ağın çıktı değerleri ölçülen değerler (beklenen çıktı değerleri) ile karşılaştırılmakta, geriye yayılım aşamasında bu ikisi arasındaki farkın (hatanın, e_p) azaltılması amaçlanmaktadır. Bu amacı gerçekleştirmek için başlangıçta rastgele atanan ağın ağırlıkları, hata istenen sınırlara azaltılıncaya kadar iteratif olarak değiştirilmektedir (Ham ve Kostanic, 2001).

Önceki çalışmalarda, kaya malzemesinin deformasyon özelliklerin kestirilmesinde kullanılan ANN için değişik ileri beslemeli geriye yayımlı algoritmalarından yararlanılmıştır (Yılmaz ve Yüksek, 2008; Yılmaz ve Yüksek, 2009; Sarkar vd., 2010; Beiki vd., 2013). Zaman ihtiyacı ve eğitimde yavaş yakınsama gibi olumsuzluklar içeren bu standart algoritmaların yerine daha hassas ve sayısal optimizasyon tabanlı Newton ve Levenberg-Marquardt algoritmaları da kullanılmaktadır (Meulenkamp ve Alvarez Grima, 1999; Ham ve Kostanic, 2001; Tiryaki, 2008; Ceryan vd., 2013). Bu çalışma da ileri beslemeli geri yayımlı eğitim algoritmasının gelişmiş bir türü olan Levenberg-Marquardt algoritması kullanılmıştır.

Levenberg-Marquardt algoritması Newton algoritmasının bir versiyonu olarak geliştirilmiş (Marquardt, 1963) ve ANN' ya eklenerek ileri beslemeli geriye yayılım algoritmaları arasında kullanılmaya başlanmıştır (Hagan ve Menhaj, 1994; Meulenkamp ve Alvarez Grima, 1999; Tiryaki, 2008; Ceryan vd., 2013). Newton algoritmasında, performans fonksiyonunu minimize eden en uygun ağ ağırlıkları aşağıdaki denklem yardımıyla bulunabilmektedir (Eşitlik 2, Hagan ve Menhaj, 1994).

$$W_{k+1} = W_k - H_k^{-1} g_k \quad (2)$$

Burada H_k performans (amaç) fonksiyonun ağırlıklara göre ikinci derecede türevlerinden oluşan Hessian matrisi, g_k ise ağın gradyanı olup performans fonksiyonunun birinci dereceden türevlerinden oluşan matristir.

Çok katmanlı yapay sinir ağı modellerinde genellikle en küçük kareler yöntemine dayalı performans fonksiyonu (Eşitlik 3) kullanılmaktadır.

$$E(w) = \frac{1}{2} \sum_{i=1}^P e_i^2(w), \quad P = nQ \quad (3)$$

Burada, $E(w)$ performans fonksiyonunu, w ağın ağırlıklarını n çıktı katmanındaki hücre sayısını, Q ağın ku-

rumundaki (eğitiminde) kullanılan örneklem büyüklüğünü, $e(w)$ ise çıktı ile beklenen değerler arasındaki farkı göstermektedir.

Ağın gradyanı aşağıdaki bağıntıyla (Eşitlik 4) ifade edilebilmektedir (Hagan ve Menhaj, 1994);

$$g_k = J^T e \quad (4)$$

Burada $J \in R^{P \times N}$ Jakobiyen matrisi olarak adlandırılmakta ve ağ hatalarının (e) ağırlıklarına (W) göre birinci türevinden oluşmaktadır (Eşitlik 5);

$$J(w) = \frac{\partial e}{\partial W} \quad (5)$$

Jakobiyen matrisi kullanılarak Hessian matrisinin yaklaşık değeri Eşitlik 6 ile bulunmaktadır;

$$H = J^T J \quad (6)$$

Bu aşamada, 2 nolu bağıntı aşağıdaki gibi (Eşitlik 7) yeniden yazılarak belirli bir k iterasyon adımında ağın ağırlıkları hesaplanabilmektedir.

$$W_{k+1} = W_k - H_k^{-1} J^T e_k \quad (7)$$

Yukarıdaki denklemin çözümünde Hessian matrisinin tersine ihtiyaç duyması sorun oluşturmaktadır. Levenberg-Marquardt algoritması Hessian matrisini tanımlamak için aşağıdaki denklemi (Eşitlik 8) kullanarak bu sorunu çözmüştür (Okkan ve Mollamahmutoğlu, 2010; Ceryan vd., 2013).

$$H = J^T J + \mu I \quad (8)$$

Burada J Jakobien matrisi, I birim matrisi μ ise Marquard parametresini ifade etmektedir.

Ağın hatasının geri yayılması aşamasında, ilk önce Jakobien matrisinin transpozesi ve ağ hataları kullanılarak 4 nolu bağıntıdan ağın gradyanı (g_k) hesaplanmakta, sonra 7 nolu bağıntı kullanılarak ağın ağırlıkları (W_{k+1}) yeniden hesaplanarak güncellenmektedir (Okkan ve Mollamahmutoğlu, 2010; Ceryan vd., 2013). Levenberg-Marquardt algoritmasında en önemli parametre, μ olup skaler bir sayı olarak tanımlanmaktadır. Eğer μ sifıra yakınsarsa, yöntem Newton algoritması gibi işleyişini sürdürmekte; μ büyük bir sayıyı temsil ettiğinde ise yöntem küçük adımlı gradyan azalması yöntemi haline gelmektedir (Hagan ve Menhaj, 1994). Marquard parametresi (μ) belirli bir k adımında ağın gradyanı azaldığında belirli bir bo-

zulma oranı (β , $0 < \beta < 1$) ile çarpılmakta, gradyan yeni bir aşamada arttığında ise beta değerine bölünerek ağın performansı her adımda iyileşmektedir (Ham ve Kostanic, 2001).

EN KÜÇÜK KARALAR DESTEK VEKTÖR MAKİNELERİ MODELİ (LS-SVM)

ANN'nin olumsuzluklarını en aza indirme amacıyla Vapnik (1995), makine öğrenme teorisine ve karesel programlamayla çözüm esasına dayanan destek vektör makineleri (SVM) yöntemini önermiştir. Bir destek vektör makinesi, en uygun olarak verileri iki kategoriye ayıran bir hiper düzlem oluşturur (Şekil 2a, c). SVM regresyonunda en uygun bir ayırıcı hiper düzlem ve destek vektörleri arasındaki marj yerine "bir yaklaşım hatası" kullanılmaktadır (Şekil 2b, d). Vapnik (1995), Tripathi vd. (2006), Tolun (2008) ve Ceryan vd. (2012) çalışmalarında SVM ve LS-SVM hakkında ayrıntılı bilgi vermişlerdir. Bu çalışmada; tanjant elastisite modülü tahmininde kullanılan En Küçük Kareler Destek Vektör Makinesi (LS-SVM) yöntemi anlatılırken söz konusu çalışmalardan geniş ölçüde yararlanılmıştır.

Suykens vd. (2001) tarafından geliştirilen LS-SVM modelinin tipik mimarisi Şekil 3'te verilmiştir.


Bu yöntemde $y_k = W^T \Phi(x_k) + b + e_k$ olmak üzere modele sunulan $\{x_k, y_k\}$ eğitim veri seti ($k=1, \dots, N$) kullanılarak hata optimizasyonu problemi aşağıdaki kısıtlayıcı denklem (Eşitlik 9) ile sağlanmaktadır (Suykens vd., 2001; Tolun, 2008).

$$\min. J(W, e) = \frac{1}{2} W^T W + \frac{\gamma}{2} \sum_{k=1}^N e_k^2 \quad y_k - \hat{y}_k = e_k \quad (9)$$

Burada, e_k hata terimini, W ağırlıkları, $\Phi(x_k)$ girdi uzayının doğrusal olmayan bir şekilde çok boyutlu özellik uzayına haritalanmasını sağlayan (çekirdek) fonksiyonu, b sabit (bias) terimi ve γ düzenleme faktörünü ifade etmektedir.

$\Phi(\cdot)$ doğrusal olmayan fonksiyonu kullanılarak orijinal düşük boyutlu girdi uzayındaki doğrusal olmayan problem yapısının çok boyutlu özellik uzayındaki doğrusal problem yapısına dönüştürülmesi işlemi Şekil 4'te özetlenmiştir.

LS-SVM'deki optimizasyon problemi çözümü ise, Lagrange çarpanları dikkate alınarak gerçekleştirilmektedir (Eşitlik 10) (Suykens vd., 2001; Tolun, 2008).



Şekil 2 a) En geniş marjlı en uygun kanonik ayırıcı hiperdüzlem (Tolun, 2008), b) tek boyutlu bir doğrusal regresyon modeli için duyarsız bant (Tolun, 2008), c) SVM'nin duyarsız bant için kayıp fonksiyonu (Ceryan vd., 2012), d) LS-SVM'nin kuadratik kayıp fonksiyonu (Ceryan vd., 2012). (b: bias terimi, y_k : ölçülen değer; \hat{y}_k : SVM/LS-SVM modeli çıktı değeri, w : ağırlık vektörü, M : marj).

Figure 2. a) The optimal separator canonical hyperplane having the most margin (Tolun 2008), b) insensitive band for a one-dimensional linear regression model (Tolun, 2008), c) insensitive loss function of SVM (Ceryan et al., 2012) and d) quadratic loss function of LS-SVM (Ceryan et al., 2012 (b: the bias term, y_k : the parameter value measured, \hat{y}_k : the output of SVM/LS-SVM models, w : weight vector, M : margin).

$$L(W, b, e, \alpha) = J(W, e) - \sum_{k=1}^N \alpha_k \{W^T \phi(x_k) + b + e_k - y_k\} \quad (10)$$


Burada α_k Lagrange çarpanlarını ifade etmektedir. Bu çarpanlar standart SVM yönteminde pozitif olması gerekirken LS-SVM yönteminde negatif değerler de alabilmektedir.

Eşitlik 10'daki birinci dereceden kısmi türevler uygulanıp W ve hata teriminin elenmesiyle, LS-SVM modeli için fonksiyon tahmini Eşitlik 11 gibi düzenlenmektedir. Bu işleyiş Şekil 3 üzerinde görülebilmektedir.

$$\hat{y}_k = \sum_{k=1}^N \alpha_k K(x_k, x) + b \quad (11)$$


Burada $K(x_k, x)$ fonksiyonu kernel (çekirdek) fonksiyonunu ifade etmektedir.

Mercer (1909) tarafından önerilen teoriden hareketle haritalama fonksiyonu, transpozunu ile çarpılarak kernel (çekirdek) fonksiyonu hesaplanabilmektedir. Kernel fonksiyonu olarak farklı fonksiyonlar kullanılmasıyla beraber çalışma kapsamında Radyal Tabanlı Fonksiyon (RBF) tercih edilmiştir (Eşitlik 12).



Şekil 3. a) SVM ve b) LS-SVM'nin mimarisi (Ceryan vd., 2012).

Figure 3. a) Structures of SVM and b) LS-SVM (Ceryan et al., 2012).



Şekil 4. $\Phi(\cdot)$ kernel fonksiyonunun işlevi (Tripathi vd., 2006).

Figure 4. The mission of $\Phi(\cdot)$ kernel function (Tripathi et al., 2006).

$$K(x_k, x) = \exp\left(-\frac{\|x - x_k\|^2}{2\sigma^2}\right) \quad (12)$$

Burada σ radyal tabanlı fonksiyonun genişliğidir.

LS-SVM modellemesinde düzenleme faktörü (γ) ve RBF'nin genişlik parametresi (σ) olmak üzere iki adet kalibre edilmesi gereken parametreye ihtiyaç duyulmaktadır. Bu çalışmada en uygun LS-SVM parametreleri hata kareler ortalamasını minimum yapacak şekilde k-kat çapraz-doğrulama tekniği (Kalra vd., 2013) ile belirlenmiştir. SVM ve LS-SVM yöntemleri

ile ilgili detaylar bu çalışmada da geniş ölçüde yararlanılan Tripathi vd. (2006) tarafından verilmiştir.

MALZEME VE LABORATUVAR DENEYLERİ

İncelenen örnekler Gümüşhane-Giresun karayolu şevlerinde yüzeylenen Üst Kretase yaşlı dasit ve andezitlerden, Karadeniz Teknik Üniversitesi (KTÜ) merkez yerleşkesindeki (Trabzon) çevre düzenlemesi için yapılan duvarlarda kullanılan bloklardan ve bu blokların kaynağı olan İyidere'de (Rize) Üst Kretase yaşlı bazaltik volkanitlerden alınmıştır (Şekil 5 ve 6).

Araziden alınan yaklaşık 30x30x30 cm³ boyutunda 47 kaya bloğundan elde edilen 50 mm çaplı karotların boy/çap oranı 2.5 olacak şekilde hazırlanmıştır.

KTÜ Mühendislik-Mimarlık Fakültesi Maden Mühendisliği Bölümü, Jeoloji Mühendisliği Bölümü ve İnşaat Mühendisliği Bölümü'ndeki Kaya Mekaniği Laboratuvarları ve Malzeme Laboratuvarı'nda gerçekleştirilen deneylerle (Şekil 7) bu karot örneklerinin fiziksel özellikleri, kuru ve doymun durumda boyuna dalga hızı ve tanjant elastisite modülü belirlenmiştir (Çizelge 1). Söz konusu deneylerde ISRM (2007) esas alınmıştır.

Suda dağılmaya karşı kararlılık deneyi ilk kez Franklin ve Chandra (1972) tarafından, çamurtaşlarının kısa süreli ıslanma-kuruma şeklindeki fiziksel etkilerle parçalanma durumunu belirlemek için geliştirilmiş olup, ISRM (1979) tarafından önerilmiş, Lee ve Freitas (1988) tarafından yeniden düzenlenmiş ve ASTM (1990) 'ye göre standart hale getirilmiştir. Örneklerin suda dağılmaya karşı gösterdiği kararlılık indeksi tamburda en son kalan malzemenin kuru kütlelerinin başlangıçtaki malzemenin kuru kütlelerine oranı olarak hesaplanmaktadır. Bu çalışmada örnekler dört stan-


dart ıslanma-kuruma devrine tabi tutulmuştur.

Karot örneklerin efektif porozitesi (görünür gözenekliliği) aşağıdaki bağıntılardan bulunmuştur.

$$n_e = \frac{(Mk - Md) / \rho_w}{V_T} \quad (13)$$

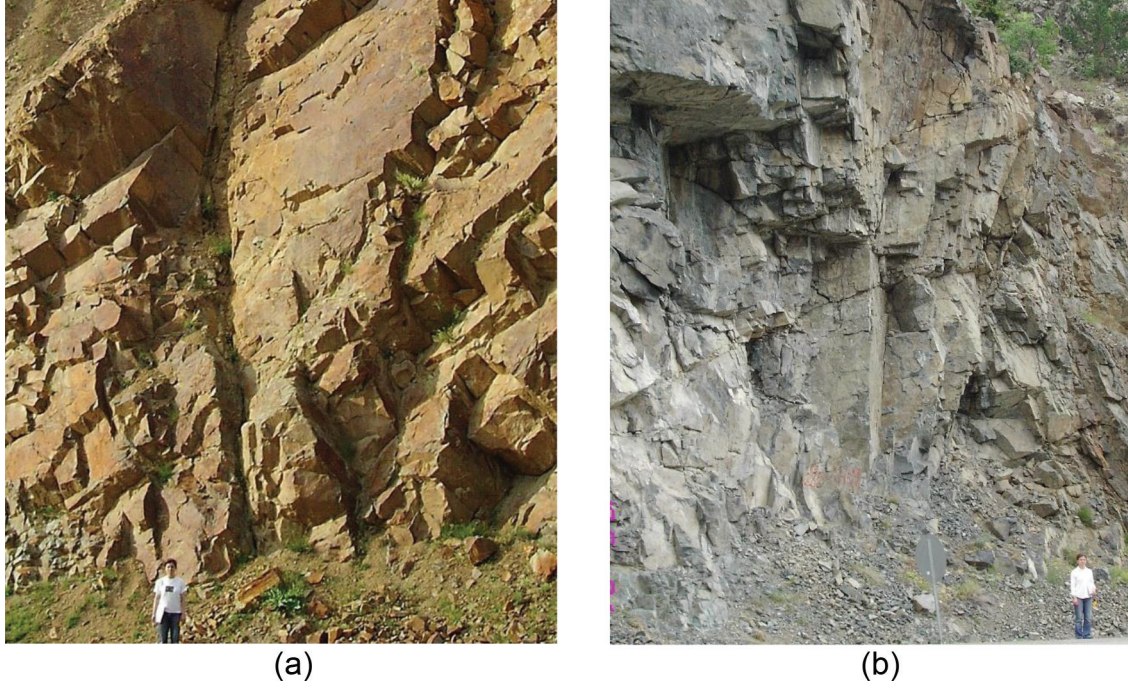
Burada M: Örneklerin 105° C de 12 saat kurutulduktan sonraki kütlesi, Md: Su dolu kaptan en az 1 saat süreyle vakum altında tutularak doymun hale getirilen örneklerin (doymun) kütlesi (Wd), ρ_s tane yoğunluğu, ρ_w ise suyun yoğunluğudur.

Ultrasonik dalga hızı (UPV) ölçümleri örneklerin hem kuru ve hem de doymun durumu için gerçekleştirilmiştir. Karot yüzeyleri ile alıcı ve gönderici jeofonların arasındaki temasın artırılarak boşluk kalmaması için örneğin alt ve üst yüzeylerine gres yağı sürülmüş, örnekten geçen P dalgası 0.1 mikro saniye (μ s) hassasiyetle okunmuştur. P dalga hızı gönderici ve alıcı arasındaki mesafenin (örnek boyunun) geçiş süresine bölünmesi ile elde edilmiştir.




Şekil 5. Çalışma alanının konumu (1: Paleozoyik metamorfik taban, 2: Paleozoyik granitler, 3: Manto peridotitleri, 4: Genellikle Mesozoyik ve Senozoyik kayalar, 5: Karbonatlar, 6: Başlıca Mesozoyik ve Senozoyik sedimanter kayalar, 7: Geç Kretase ve Eosen yaşlı yay volkanitleri, 8: Eosen granitleri, 9: Kaldera veya dom, 10: Kıvrım eksenleri, 11: Doğrultu atımlı fay, 12: Bindirme fayı, 13: Tanımlanmamış fay, 14: Çalışma alanı) (Eyüboğlu vd., 2006'dan alınmıştır).

Figure 5. Location of study area (1: Paleozoic Metamorphic Basement; 2: Paleozoic Granites; 3: Serpentine; 4: Undifferentiated Mesozoic and Cenozoic Rocks; 5: Platform Carbonate Rocks; 6: Mesozoic Sedimentary Rocks; 7: Cretaceous and Eocene Arc Volcanic Rocks; 8: Late Cretaceous and Eocene Arc Granites; 9: Caldera or dome; 10: drag folds; 11: Strike-slip Fault; 12: Thrust fault; 13: Undefined Fault; 14: Study area; (from Eyüboğlu et al., 2006).



Şekil 6. a) Gümüşhane-Giresun karayolu boyunca yüzeylenen dasitik ve b) andezitik kayalar.
Figure 6. a) The dacitic and b) andesitic rock exposed throughout the Gümüşhane-Giresun road.



Şekil 7. Deney örnekleri (D1 ve D2: dasit, A2: andezit, A5: tüf).
Figure 7. Test samples (D1 and D4: dacite, A2: andesite, A5: tuff).

Kaya malzemesinin katı kısımdaki P dalgası hızını bulmak için "zaman ortalama eşitliği olarak" anılan ve aşağıda verilen bağıntıdan (Eşitlik 14) (Barton, 2007) yararlanılmıştır.

$$\frac{1}{V_p} = \frac{n}{V_{fl}} + \frac{1-n}{V_m} \quad (14)$$

Burada V_p örnekteki P-dalga hızı, V_{fl} : boşluklardaki suda P-dalga hızı, n porozite ve V_m ise P-dalgasının örneğin katı kısmındaki hızıdır.

İncelenen örneklerin tanjant elastisite modülünü bulmak için tek eksenli basınç aletinde prese yerleştirilen örneklere yapılan yükleme sırasında yük ile birlikte boyuna deformasyon ölçümlerinden de yararlanılmıştır. Yükleme hızı örneğin yaklaşık 10 dakikada kırılmasını sağlayacak şekilde seçilmiş, örnekler kırılıncaya kadar yükleme yapılmıştır. Deneylerde elde edilen gerilme-birim deformasyon eğrisine örneğin tek eksenli basınç dayanımının % 50'sine karşılık gelen gerilme değeri için teğet çizilmiş ve bu teğetin eğiminden tanjant elastisite modülü bulunmuştur (Çizelge 1).

TAHMİN PARAMETRELERİ VE NORMALİZASYONU

Kaya malzemesinin iki fazdan; katı faz ve boşluktan oluştuğu dikkate alındığında, dayanım ve deformasyon özelliklerin etkileyen kaya parametrelerini iki başlık altında toplanabilir (Ceryan, 2014). Bunlardan ilki içerdiği boşlukların karakteristikleri olup diğeri ise mineralojik ve petrografik özelliklerdir (Ceryan, 2014). Liu vd., (2014) çalışmasında, kaya malzemesinin fiziksel ve mekanik özelliklerinin çok büyük ölçüde mineralojik karakteristikleri ve boşluk özelliklerine bağlı olduğunu belirtmiştir.

Kaya malzemesinin boşluk yapısı özellikleri, onun fiziksel, mekanik özelliklerini ve hidrolik iletkenliğini belirleyen en önemli kaya parametrelerden biridir (Tuğrul, 2004; Palchik ve Hatzor, 2004; Liu vd., 2014). Bundan dolayı; kaya malzemesinin deformasyon özelliklerinin tahmini için kurulan modellerin çoğunda porozite ve efektif porozite yer almaktadır (Leite ve Ferland, 2001; Lashkaripour, 2002; Yılmaz ve Yüksek, 2008; Dehghan vd., 2010; Majdi ve Beiki, 2010; Singh vd., 2012; Beiki vd., 2013; Liu vd., 2013; Diamantis vd., 2014; Liu vd., 2014; Torabi-Kaveh vd., 2015; Armaghani vd., 2016). Bu çalışmada, tanjant elastisite modülünün tahmininde efektif porozite kullanılmıştır.

Kaya malzemesinin mekanik özellikleri, boşluk karakteristikleriyle birlikte mineralojik bileşimine ve petrografik özelliklerine de (tane büyüklüğü, minerallerin düzenlenmesi, tane-tane dokunağı özellikleri, tanelerin kenetlenme şekli ve derecesine) bağlıdır (Hartley, 1974; Tuğrul ve Zarif, 1999; Pomonis vd., 2007;

Tamrakar vd., 2007; Ceryan vd., 2008, Rigopoulos vd., 2010, Liu vd., 2013; Diamantis vd., 2014, Ceryan, 2014, Liu vd., 2014). Ceryan (2014) çalışmasında, kaya malzemesinin katı kısmın özelliklerinin serbest basınç dayanımı üzerindeki etkisini ifade etmek için P dalga hızı ve suda dağılmaya karşı kararlılık indeksinden yararlanılarak oluşturduğu P-kararlılık indeksini (V_{md}) önermiştir (Eşitlik 15).

$$V_{md} = V_m I_d \quad (15)$$

Burada; V_m kaya malzemesinin katı kısmındaki P-dalga hızı, I_d ise suda dağılmaya karşı kararlılık indeksidir.

P-dalga hızı (V_p) ölçümü kolay ve tekrarlanabilir olup aynı zamanda kaya malzemesinde örselenme oluşturmamaktadır. Bu özellikleri nedeniyle deformasyon özelliklerinin tahmininde en sık kullanılan parametrelerden biri V_p ' dir (Yaşar ve Erdoğan, 2004; Gökçeoğlu ve Zorlu 2004; Ceryan vd., 2008; Moradian ve Behnia 2009; Yılmaz ve Yüksek, 2009; Dehghan vd., 2010; Ceryan vd., 2012; Manoj, 2013; Armaghani vd., 2015; Armaghani vd., 2016). Ancak, söz konusu kestirim modellerinde P-dalga hızının kullanılmasında bazı sınırlamaların olduğunu belirten çalışmalar da vardır (Martinez-Martinez vd., 2011; Tandon ve Gupta, 2013). Suda dağılmaya karşı kararlılık indeksi (I_d) kaya örneklerinin ıslanma-kuruma süreçlerindeki dağılmaya karşı kararlılığını ifade etmekle birlikte aynı zamanda, mineralojik bileşime de bağlıdır (Sharma ve Singh, 2008; Yağız vd., 2012). V_p ve I_d ile ilgili yukarıda verilen söz konusu sınırlamalar ve avantajlar dikkate alınarak, bu çalışmadaki ANN ve LS-SVM modellerinde de efektif porozite ile birlikte P-kararlılık indeksi (V_{md}) (Ceryan, 2014) kullanılmıştır.

LS-SVM ve ANN modellerinde kullanılan söz konusu bu tahmin parametrelerinin (n_e ve V_{md}) ve çıktıların (E_v) standart hale getirilmesinde aşağıdaki denklem kullanılmıştır.

$$z_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (16)$$

Burada z_i is ölçeklendirilmiş (standart) değer, x_i ölçeklendirilmemiş (orjinal) veriyi göstermektedir. x_{\min} ve x_{\max} ise orijinal verinin en küçük ve en büyük değerleridir

Çizelge 1. İncelenen örneklerin efektif porozitesi (n_e), kuru durumda P dalgası hızı (V_p), suda dağılmaya karşı kararlılık indeksi (I_p), örneğin katı kısmında P dalgası hızı (V_m), P-kararlılık indeksi (V_{md}) ve tanjant elastisite modülü (indeks özellikler Ceryan ve Usturbelli (2011)'den alınmıştır).

Table 1. The effective porosity (n_e), P-wave velocity in dried condition (V_p), slake durability index (I_p), P-wave velocity in the solid part of rock sample (V_m), P-durability index (V_{md}) and tangent elasticity modulus (E_t) of the samples investigated (index properties were taken from Ceryan and Usturbelli (2011)).

No	ne %	Vp m/sn	Id %	Vm m/sn	Vmd	Et (GPa)	No	ne (%)	Vp m/sn	Id %	Vm m/sn	Vmd	Et (GPa)
1	4.8	3352	80.5	3930	3164	12.946	25	6	3400	87.6	3884	3402	15.306
2	5.2	3246	81.9	3804	3115	12.072	26	5.7	3517	89.7	4029	3614	15.747
3	6.4	3228	74.9	3886	2911	9.829	27	7.7	3265	78.9	4001	3157	13.937
4	5.6	3285	77.8	3883	3021	12.408	28	5.6	2674	78.5	3326	2611	11.347
5	5.2	3246	81.6	3993	3259	13.327	29	4.8	3404	88.3	3815	3369	19.875
6	1.7	4202	98.1	4332	4250	26.752	30	4.8	3471	93.4	3908	3650	12.636
7	4.1	3575	94.7	3985	3774	22.435	31	1.6	4124	99.2	4468	4432	31.802
8	7.6	2578	72.1	3105	2239	11.240	32	4.1	3550	91.8	3957	3633	18.024
9	2.4	3757	97.8	4089	3999	29.572	33	4.3	3057	88.7	3682	3266	17.120
10	2.4	3886	94.6	4253	4024	27.237	34	2.8	3883	97.4	4248	4138	28.616
11	1.5	3700	96.2	4078	3923	30.787	35	1.4	3857	98.8	4108	4059	2.1781
12	1.6	4090	98.8	4214	4163	30.109	36	9.8	2876	68.4	3381	2313	7.025
13	5.1	3173	89.7	3534	3170	12.232	37	5.1	3144	79.3	3756	2979	13.150
14	3.5	3691	95.4	4096	3908	25.891	38	3.4	3836	93.7	4274	4005	24.035
15	7.9	3288	85.6	4047	3464	11.871	39	0.9	4559	96.3	4624	4453	33.786
16	2.7	3538	94.2	3955	3726	17.104	40	1.4	3571	96.5	4237	4089	26.988
17	4.5	3417	91.1	3817	3477	14.145	41	2.5	3661	90.4	4106	3712	25.203
18	1.1	4625	98.6	4747	4681	36.458	42	2.2	4043	96.2	4430	4262	26.646
19	4.2	3479	94.5	3876	3663	16.783	43	2.3	4100	96.3	4160	4006	28.374
20	4.3	3332	79.2	3873	3067	13.069	44	3.6	3629	93.8	4019	3770	22.143
21	6.5	3046	66.3	3934	2608	10.478	45	3.5	3722	94.9	4351	4129	23.063
22	2.3	3896	93.8	4239	3976	24.835	46	4	3730	89.1	4185	3729	17.140
23	7.9	3178	74.5	3689	2748	10.745	47	1.5	3841	97.3	4129	4018	29.974
24	1.5	4048	99.5	4375	4353	32.143							

MODELLERİN PERFORMANSININ DEĞERLENDİRİLMESİ

Bu çalışmada kurulan ANN modelinde üç katman kullanılmış olup gizli katmanda 3 adet sinir hücresi (nöron) yer almıştır. Bu modelde aktivasyon fonksiyonu

olarak sigmoid fonksiyonu kullanılmıştır. 30 eğitim dönemi (iterasyonu) kullanılan ANN modelinde Marquard parametresi (μ) 0.001, bozulma oranı (β) 0.1 olarak alınmıştır. LS-SVM modelinde ise, düzenleme parametresi $\gamma=265.97$ ve radyal tabanlı fonksiyonun genişliğini ifade eden değer $\sigma=5.37$ olarak alınmıştır.

ANN ve LS-SVM modellerinin eğitim ve test sonuçlarının laboratuvar deneyleriyle elde edilen (E_t) değerleriyle karşılaştırılması ve aralarındaki ilişki Şekil 8 ve Şekil 9'da verilmiştir.

Bu çalışmada, tanjant elastisite modülünü tahmin etmek amacıyla kurulan LS-SVM ve ANN modellerinin performansını değerlendirmek için hata kareler ortalamasının karekökü (RMSE) (Gökçeoğlu, 2002), varyansın nedeni (VAF) (Gökçeoğlu, 2002) determinasyon (belirlilik) katsayısı (R^2), düzeltilmiş determinasyon katsayısı ($Adj.R^2$) ve bu parametreler bağlı olarak tanımlanan performans indeksi (PI) (Yağız vd., 2012), kullanılmıştır (Eşitlikler 17-21, Çizelge 2). RMSE ölçülen ve çıkış verileri arasındaki farkın ortalamasını, VAF ise ölçülmüş verinin varyansı ile hata varyansının oranını temsil etmektedir. R^2 ve $adj.R^2$ ise ölçülmüş değer ile tahmin edilmiş değer arasındaki doğrusal ilişkiyi değerlendirmede kullanılmaktadır.

Eşitlikler 17-21 de verilen performans kriterlerinin tanımları dikkate alındığında; kurulan modellerin kestirim performansı yükseldikçe, RMSE değerleri 0'a, R^2 ve $adj.R^2$ değerleri 1'e, VAF değeri %100'e, PI değeri ise 2'ye yaklaşması beklenir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (d_t - y_t)^2} \quad (17)$$

$$VAF = 1 - (var(d_t - y_t) / vard_t) \quad (18)$$

$$R^2 = \frac{\sum_{t=1}^n (d_t - d_{mean})^2 - \sum_{t=1}^n (d_t - y_t)^2}{\sum_{t=1}^n (d_t - d_{mean})^2} \quad (19)$$

$$AdjR^2 = 1 - \frac{(n-1)}{(n-p-1)} (1 - R^2) \quad (20)$$

$$PI = AdjR^2 + 0.01VAF - RMSE \quad (21)$$

Yukarıda verilen bağıntılarda d_t ölçülen değeri, d_{mean} ölçülen değerlerin aritmetik ortalamasını, y_t modellerin çıktı (kestirim) değerlerini, n örnek sayısını ve $var d_t$ ise ölçülen değerlerin varyans değerini göstermektedir.

Çizelge 2'de ANN ve LS-SVM modellerinin performansının hem eğitim hem de test çıktıları açısından genel olarak iyi olduğu görülmektedir. ANN modeli için R^2

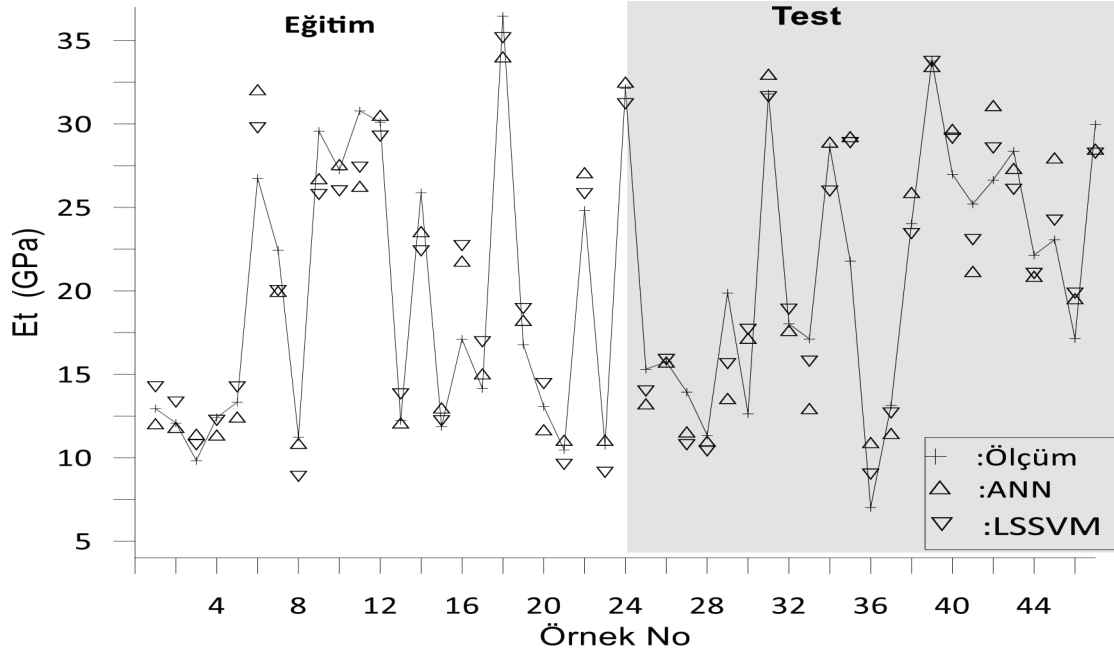
değerleri eğitim döneminde 0.9325, test döneminde 0.8259 iken, bu değerler LS-SVM modeli için 0.9291 ve 0.873 olarak elde edilmiştir. RMSE değerleri ANN modeli eğitim dönemi için 0.0746, test dönemi için 0.1106 olarak bulunurken, bu değerler LS-SVM modelinin eğitim döneminde 0.0762, test döneminde ise 0.0871 olmuştur. VAF değerleri ANN eğitim dönemi %93.25, test dönemi %78.84 iken LS-SVM modelinin eğitim ve test dönemleri için sırasıyla %92.78 ve %86.74'tür. R^2 , $Adj. R^2$, RMSE ve VAF'in eğitim dönemi ile test döneminde elde edilen değerleri arasındaki farklar incelendiğinde; LS-SVM modeli için bu farkın, ANN modeline göre daha az olduğu görülmektedir.

Modellerin eğitimi için ayrılan E_t değerlerinin en büyük değeri 36.458 GPa en küçük değeri 9.829 GPa iken, test dönemi için ayrılanların en büyük değeri 33.76 GPa en küçük değeri 7.025 GPa dır. LS-SVM modelinin söz konusu bu ölçülmüş değerlerin tahmini açısından performansı ANN modelinden daha başarılıdır (Çizelge 2).

SONUÇ VE ÖNERİLER


Bu çalışmada, kaya malzemesi tanjant elastisite modülünün (E_t) tahmininde LS-SVM yönteminin kullanılabilirliği araştırılmış olup bu yöntem çıktıları ile Levenberg-Marquardt algoritmasına dayanan ileri beslemeli geriye yayımlı ANN modeli çıktıları karşılaştırılmıştır. Çalışmada kullanılan örnekler Giresun, Gümüşhane ve Rize'de (KD Türkiye) yüzeylenen volkanik kayalardan alınmıştır.

İncelenen volkanik kayaç örneklerine ait tanjant elastisite modülünün ölçülen değerleri ile ANN ve LS-SVM modelleriyle tahmin edilen değerleri birbiriyle karşılaştırılarak (Şekil 8, Çizelge 2), söz konusu modellerin E_t 'yi tahmin etmedeki performanslarının yeterli olduğu görülmüştür. PI değerleri; ANN modeli için eğitim döneminde 1.79 test döneminde 1.504 iken, bu değerler LS-SVM modeli için sırasıyla 1.781 ve 1.653'tür (Çizelge 2). Eğitim dönemi dikkate alındığında; söz konusu modellerin performansının birbirine çok yakın olduğu, ancak performansları arasındaki fark anlamlı olmasa da ANN modelinin LS-SVM modelinden daha başarılı olduğu görülmektedir. Bununla birlikte, test dönemi dikkate alındığında LS-SVM modelinin, ANN modeline göre performansı daha yüksektir. Bu nedenle, incelenen volkanik kaya örnekleri (ve kullanılan girdi parametreleri) açısından, LS-SVM modelinin genelleme özelliğinin ANN modelinden iyi olduğu söylenebilir.



Şekli 8. ANN ve LS-SVM model sonuçları.

Figure 8. The results of ANN and SVM models.



Şekil 9. Eğitim ve test dönemleri için bu çalışmada geliştirilen ANN ve LS-SVM modellerinin dağılım grafiği.

Figure 9. The scatter plots of ANN and LS-SVM model developed in this study during the training and testing periods.

ANN eğitimde hatayı en aza indirmek için görgül riski en küçüğe indirgeme (ERM) ilkesini uygularken, SVM yaklaşımı yapısal riski en küçüğe indirgeme (SRM) prensibine dayanmaktadır (Tolun, 2008). SVM modelleri, genellikle birden fazla yerel minimuma uğrayan ANN modellerine kıyasla, genel çözümde

çok daha fazla kolaylık sağlamaktadır (Ceryan, 2014; Anazi ve Gates, 2015). Regresyon problemlerinde, genellikle, klasik SVM yerine en küçük kareler destek vektör makineleri (LS-SVM) tercih edilmektedir (Ceryan vd., 2012) Bu durumun ana nedeni; LS-SVM yönteminin karesel optimizasyon problemini doğrusal

Çizelge 2. Önerilen tahmin modellerinin performans indeks değerleri.

Table 2. The values of performance indices of the predictive models proposed.

	RMSE	R ²	adj. R ²	En küçük (GPa)	En büyük (GPa)	VAF (%)	PI
ANN							
Eğitim	0.0746	0.9325	0.9261	10.88	34.037	93.25	1.79
Test	0.1106	0.8259	0.8086	10.92	33.453	78.84	1.504
LS-SVM							
Eğitim	0.0762	0.9291	0.9224	8.88	35.17	92.78	1.781
Test	0.0871	0.873	0.8601	9.025	33.749	86.74	1.653

denklem sistemine dönüştürmesi ve klasik SVM'ye göre daha az kalibre edilmesi gereken parametre içermesidir (Ceryan vd., 2012). ANN yöntemine göre SVM ve LS-SVM yöntemlerinin dezavantajı ise yaygın olarak kullanılmamasıdır.

Mühendislik projelerinde, kaya malzemesi tanjant elastisite modülüne (E) ihtiyaç duyulduğunda izlenecek doğru yaklaşım; söz konusu parametrenin deneysel imkânlar olduğunda laboratuvarında tek eksenli basınç (yükleme) deneyi ile bulunması, aksi durumda değişik kestirim yöntemleri ile tahmin edilmesidir. Bu çalışmada verilen LS-SVM ve ANN modellerinin karşılaştırılması için incelenen örnekler ve bu modellerde kullanılan parametreler açısından geçerlidir. ANN ile SVM ve SVM ile LS-SVM yöntemlerinin yukarıda verilen karşılaştırmaları ve ANN modellerinin genel olarak olumsuzlukları (ASCE, 2000) dikkate alındığında, incelenen örneklerin tanjant elastisite modülünün tahmininde iyi performans gösteren LS-SVM modelinin farklı kaya türlerinin elastisite modülünün tahmininde kullanılabilirliğinin araştırılmalıdır. Ayrıca, bu çalışmada elastisite modülü tahmininde kullanılan P-kararlılık indeksinin de farklı kaya türleri için dayanım ve deformasyon özelliklerinin tahmininde kullanılabilirliğinin test edilmesi yararlı olacaktır.

TEŞEKKÜR

Bu çalışmada MATLAB programını kullanmak için imkân sunan ve ilgili programların yazılmasında yardımcı olan Arş.Gör. Nuray KORKMAZ'a (İstanbul Üniversitesi Makine Mühendisliği Bölümü) ve Dr. Umut OKKAN'a (Balıkesir Üniversitesi İnşaat Mühendisliği Bölümü) teşekkür ederim.

KAYNAKÇA

- Al-Anazi, A.F. and Gates, L.D., 2015. On Support Vector Regression to Predict Poisson's Ratio and Young's Modulus of Reservoir Rock (Artificial Intelligent Approaches in Petroleum Geosciences (Editor C. Cranganu, H. Luchian, M.Elena Breaban) ISBN 978-3-319-16530-1, Springer International Publishing Switzerland)
- Amin, M., Mostafa, S., Rasoul, H.M. and Tohid, N., 2013. Selection of regression models for predicting strength and deformability properties of rocks using GA, International Journal of Mining Science and Technology, 23 (4), 495-501.
- Armaghani, D.J., Mohamad, E.T., Momeni, E., Narayanasamy, M. S. and Amin, M.F.M., 2015. An adaptive neuro-fuzzy inference system for predicting unconfined compressive strength and Young's modulus: a study on Main Range granite. Bulletin of Engineering Geology and the Environment, 7 (4), 1301-1309.
- Armaghani, D.J., Mohamad, E.T., Momeni, E., Monjezi, and Narayanasam, M.S. 2016. Prediction of the strength and elasticity modulus of granite through an expert artificial neural network. Arabian Journal of Geosciences, 9 (48), 2-16.
- ASCE (Task Committee on Application of Artificial Neural Networks in Hydrology), 2000. Artificial Neural Networks in Hydrology. I: Preliminary Concepts. Journal of Hydrologic Engineering, 5 (2), 115-123.

- ASTM (American Society for Testing and Materials), 1990. Standard Test Method for Slake Durability of Shales and Similar Weak Rocks (D4644). Annual Book of ASTM Standards 4.08, 863-865.
- Barton, N., 2007. Fracture-induced seismic anisotropy when shoring is induced in production from fractured reservoirs. *Journal of Seismic Exploration* 16, 115-143.
- Beiki, M., Majdi, A. and Givshad, A.D., 2013. Application of genetic programming to predict the uniaxial compressive strength and elastic modulus of carbonate rocks. *International Journal of Rock Mechanics and Mining Sciences*, 63, 159-169.
- Ceryan, N., 2014. Application of support vector machines and relevance vector machines in predicting uniaxial compressive strength of volcanic rocks. *Journal of African Earth Sciences* 100, 634-644.
- Ceryan, N., 2015. A Review of Soft Computing Methods Application in Rock Mechanic Engineering. (Handbook of Research on Advanced Computational Techniques for Simulation-Based Engineering, Editor: P. Samui, ISBN13: 9781466694798, Chapter 1, 1-70).
- Ceryan, N., Okkan, U., Samui, P. and Ceryan, S., 2012. Modeling of tensile strength of rocks materials based on support vector machines approaches", *International Journal for Numerical and Analytical Methods in Geomechanics*, 37 (16), 2655-2670.
- Ceryan, N., Okkan, U. and Kesimal, A., 2013. Prediction of unconfined compressive strength of carbonate rocks using artificial neural networks. *Environmental Earth Sciences*, 68 (3), 807-819.
- Ceryan, S., Tudes, S. and Ceryan, N., 2008. A new quantitative weathering classification for igneous rocks. *Environmental Geology*, 55, 1319-1336.
- Ceryan, N., and Usturbelli, Z.H., 2011. The estimating of durability and weathering state of tuff using rock durability indicators: a case study. In: *SGEM2011 Conference Proceedings/ISSN 1314-2704*, June 20-25, 1, 623-630.
- Christasaras, B., Auger, F. and Mosse E., 1994. Determination of moduli of elasticity of rocks, Comparison the ultrasonic velocity and mechanical resonance frequency methods with direct static methods. *Materials and Structure*, 27, 222-2228.
- Dehghan, S., Sattar, G.H., Chehreh, C.S. and Aliabadi, M.A., 2010. Prediction of unconfined compressive strength and modulus of elasticity for Travertine samples using regression and artificial neural. *Mining Science and Technology (China)*, 20 (1), 41-46.
- Diamantis, K., Gartzos, E., and Migiros, G. 2014 Influence of petrographic characteristics on physico-mechanical properties of ultrabasic rocks from central Greece. *Bulletin of Engineering Geology and the Environment*, 73, 1273-1292.
- Dinçer, I, Acar, A., Çobanoğlu. I. and Uras, Y., 2004. Correlation between Schmidt hardness, uniaxial compressive strength and Young's modulus for andesites, basalts and tuffs. *Bulletin of Engineering Geology and the Environment*, 63, 141-148.
- Eyüboğlu, Y., Bektaş, O., Seren, A., Nafiz, M., Jacoby, W.R. and Özer, R., 2006. Three directional Extensional Deformation and Formation of the Liassic Rift Basins in the Eastern Pontides (NE Turkey), *Geologica Carpathica*, 57 (5), 337-346,
- Fener, M., Kahraman, S., Bilgil, A. and Günaydın, O., 2005. A Comparative Evaluation of Indirect Methods to Estimate the Compressive Strength of Rocks, *Rock Mechanics and Rock Engineering*, 38 (4), 329-343.
- Franklin, J. A. and Chandra, R., 1972. The slake-durability test. *International Journal of Rock Mechanics and Mining Sciences*, 9, 325-341.
- Gökçeoğlu, C. and Zorlu, K., 2004. A fuzzy model to predict the unconfined compressive strength and modulus of elasticity of a problematic rock. *Engineering Applications of Artificial Intelligence*, 17, 61-72.
- Gökçeoğlu, C., 2002. A fuzzy triangular chart to predict the uniaxial compressive strength of the agglomerates from their petrographic composition. *Engineering Geology*, 66 (1-2), 39-51.
- Hagan, M. T. and Menhaj, M. B., 1994. Training feed forward networks with the Marquardt algo-

- rihm." IEEE Transactions on Neural Networks, 5 (6), 989-993.
- Ham, F. M. and Kostanic, I., 2001. Principles of Neuro computing for Science and Engineering. McGraw Hill.
- Hartley, A., 1974. A review of the geological factors influencing the mechanical properties of road surface aggregates. The Quarterly Journal of Engineering Geology, 7, 69-100.
- Haykin, S., 1994. Neural Networks: A Comprehensive Foundation, MacMillan. New York.
- Heidari, M., Khanlari, G.R. and Momeni, A.A., 2010. Prediction of Elastic Modulus of Intact Rocks Using Artificial Neural Networks and non-Linear Regression Methods. Australian Journal of Basic and Applied Sciences, 4 (12), 5869-5879.
- Huang, Y. and Wanstedt, S., 1998. Application of Kalman learning algorithm multilayer neural network to estimates of ore grades, International Journal of Mining, Reclamation and Environment, 12, 19-27.
- ISRM (International Society for Rock Mechanics), 1979. Suggested Methods for Determining Water Content, Porosity, Density, Absorption and Related Properties and Swelling and Slake Durability Index Properties. International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts, 16 (2) 141-156.
- ISRM (International Society for Rock Mechanics), 2007. The Complete ISRM Suggested Methods for Rock Characterization, Testing and Monitoring; 1974-2006, Suggested Methods prepared by the Commission on testing Methods. ISRM. R. Ulusay and J.A. Hudson (eds). Kozan Ofset. Ankara.
- Kalra, A., Li, L., Li, X. and Ahmad, S., 2013. Improving Streamflow Forecast Lead Time Using Oceanic-Atmospheric Oscillations for Kaidu River Basin, Xinjiang, China. Journal of Hydrologic Engineering, 18 (8), 1031-1040.
- Karakuş, M., Kumral, M. and Kılıç, O. 2005. Predicting elastic properties of intact rocks from index tests using multiple regression modeling. International Journal of Rock Mechanics and Mining Sciences, 42 (2), 323-330.
- Kumar, M., Samui, P. and Naithani, A.K., 2013. Determination of Uniaxial Compressive Strength and Modulus of Elasticity of Travertine using Machine learning Techniques. International Journal of Advances in Soft Computing and Application, 5 (3), 1-15.
- Lashkaripour, G. R., 2002. Predicting mechanical properties of mudrock from index parameters. Bulletin of Engineering Geology and the Environment, 61, 73-77.
- Lee, S., G. and De Freitas, M., H., 1988. Quantitative Definition of Highly Weathered Granite Using the Slake Durability test. Geotechnique, 38, 123-128.
- Leite, M. H. and Ferland, F., 2001. Determination of unconfined compressive strength and Young's modulus of porous materials by indentation tests. Engineering. Geology, 59, 267-280.
- Liu, Z., Shao, J., Xu, W., Zhang, Y. and Chen, H. 2014. Prediction of elastic compressibility of rock material with soft computing techniques. Applied Soft Computing, 22, 118-125.
- Liu, Z., Shao, J., Xu, W. and Shi, C., 2013. Estimation of elasticity of porous rock based on mineral composition and microstructure. Advances in Materials Science and Engineering, Doi: 10.1155/2013/512727.
- Majdi, A. and Beiki, M., 2010. Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses. International Journal of Rock Mechanics and Mining Sciences, 47 (2), 246-253.
- Maji, V.B. and Sitharam, T.G., 2008. Prediction of elastic modulus of jointed rock mass using Artificial Neural Networks. Geotechnical and Geological Engineering, 26 (4), 443-452.
- Manoj, K. 2013. Correlating P-wave Velocity with the Physico-Mechanical Properties of Different Rocks. Pure and Applied Geophysics, 170 (4), 507-514.
- Marquardt, D. W., 1963. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. Journal of the Society for Industrial and Applied Mathematics, 11 (2), 431-442.
- Martinez-Martinez, J., Benavente, D. and García-del-Cura, M.A., 2011. Spatial attenuation: the most sensitive ultrasonic parameter for detecting petrographic features and decay processes in carbonate rocks. Engineering Geology, 119 (3-4), 84-95.

- Mercer, J., 1909. Functions of Positive and Negative Type, and their Connection with the Theory of Integral Equations. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences.
- Meulenkamp, F. and Alvarez Grima, M., 1999. Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness. International Journal of Rock Mechanics and Mining Sciences 36 (1), 29-39.
- Moradian, Z.A. and Behnia, M., 2009. Predicting the uniaxial compressive strength and static Young's modulus of intact sedimentary rocks using the ultrasonic test. International Journal of Geomechanics, 9 (1), 14-19.
- Okkan, U. ve Mollamahmutođlu, A., 2010. Yiđitler ayı gnlk akımlarının yapay sinir ađları ve regresyon analizi ile modellenmesi. Dmlnar niversitesi Fen Bilimleri Enstits Dergisi, 23, 33-48.
- Palchik, V. and Hatzor, Y.H., 2004. The Influence of Porosity on Tensile and Compressive Strength of Porous Chalks. Rock Mechanics and Rock Engineering, 37 (4), 331-341.
- Pomonis, P., Rigopoulos, I., Tsikouras, B. and Hatzipanagiotou, K., 2007. Relationships between petrographic and physico-mechanical properties of basic igneous rocks from the Pindos ophiolitic complex, NW Greece. Bulletin of Geological Society of Greece, 2, 947-958.
- Ranjbar-Karami, R., Kadkhodaie-Ilkhchi, A. and Shiri, M., 2014. A modified fuzzy inference system for estimation of the static rock elastic properties: A case study from the Kangan and Dalan gas reservoirs, South Pars gas field, the Persian Gulf. Journal of Natural Gas Science and Engineering, 21, 962-976.
- Rezaei, M., Majdi, A. and Monjezi, M., 2012. An intelligent approach to predict unconfined compressive strength of rock surrounding access tunnels in longwall coal mining. Neural Computing and Applications, 24 (1), 233-241.
- Rigopoulos, I., Tsikouras, B., Pomonis, P. and Hatzipanagiotou, K., 2010. The influence of alteration on the engineering properties of dolerites: the examples from the Pindos and Vourinos ophiolites (northern Greece). International Journal of Rock Mechanics and Mining Sciences, 47, 69-80.
- Sachpazis, C.I., 1990. Correlating Schmidt hardness with compressive strength and Young's modulus of carbonate rocks. Bulletin of the International Association of Engineering Geology, 42, 75-84.
- Sarkar, K., Tivary, A. and Singh, T.N., 2010. Estimation of strength parameters of rock using artificial neural networks. Bulletin of Engineering Geology and the Environment, 69 (4), 559-606.
- Sharma, P.K. and Singh, T.N., 2008. A correlation between P-wave velocity, impact strength index, slake durability index and uniaxial compressive strength. Bulletin of Engineering Geology and the Environment, 67, 17-22.
- Singh, R., Kainthola, A. and Singh, T.N., 2012. Estimation of elastic constant of rocks using an ANFIS approach. Applied Soft Computing, 12 (1), 40-45.
- Skapura, D. M., 1996. Building Neural Networks, Addison-Wesley, New York.
- Snmez, H., Gokeođlu, C., Nefesliođlu, H. A. and Kayabaşı, A. 2006. Estimation of rock modulus for intact rocks with an artificial neural network and for rock masses with a new empirical equation. International Journal of Rock Mechanics and Mining Sciences, 43 (2), 224-235.
- Snmez, H., Tuncay, E. and Gokeođlu, C., 2004. Models to predict the uniaxial compressive strength and the modulus of elasticity for Ankara agglomerate. International Journal of Rock Mechanics and Mining Sciences, 41, 717-729.
- Snmez, B., Dađdelen, G., Tunar zcan, N., Ercanođlu, M. ve Snmez, H., 2015. Yapay Sinir Ađı Kullanılarak CPT Tabanlı Sıvılařma Deđerlendirme Abađının Geliřtirilmesi, Yerbilimleri, 36 (2), 45-60.
- Suykens, J. A., Vandewalle, J. and De Moor, B., 2001. Optimal control by least squares support vector machines. Neural Networks, 14 (1), 23-35.
- Tamrakar, N.K., Yokota, S. and Shrestha, S.D., 2007. Relationships among mechanical, physical and petrographic properties of Siwalik

- sandstones, Central Nepal Sub-Himalayas. *Engineering Geology*, 90, 105-123.
- Tandon, R.S. and Gupta, V., 2013. The control of mineral constituents and textural characteristics on the petrophysical & and mechanical (PM) properties of different rocks of the Himalaya, *Engineering Geology*, 153, 125-143.
- Tiryaki, B., 2008. Predicting intact rock strength for mechanical excavation using multivariate statistics, artificial neural networks and regression trees. *Engineering Geology*, 99, 51-60.
- Tolun, S., 2008. Destek Vektör Makineleri: Banka Başarısızlığının Tahmini Üzerine Bir Uygulama (Doktora Tezi, İÜ Sosyal Bilimler Enstitüsü İktisadi Araştırmalar Vakfı Tez Değerlendirme Yarışma Dizisi, İstanbul, s252.
- Torabi-Kaveh, M., Naseri, F., Saneie, S. and Sarshari, B., 2015. Application of artificial neural networks and multivariate statistics to predict UCS and E using physical properties of Asmari limestone. *Arabian Journal of Geosciences*, 8, 2889-2897.
- Tripathi, S., Srinivas, V. V. and Nanjundiah, R.S., 2006. Downscaling of precipitation for climate change scenarios: A support vector machine approach. *Journal of Hydrology*, 330 (3-4), 621-640.
- Tuğrul, A. and Zarif, I.H., 1999. Correlation of mineralogical and textural characteristics with engineering properties of selected granitic rocks from Turkey. *Engineering Geology*, 51, 303-317.
- Tuğrul, A., 2004. The effect of weathering on pore geometry and compressive strength of selected rock types from Turkey. *Engineering Geology*, 75, 215-227.
- Vapnik, V.N., 1995. *The Nature of Statistical Learning Theory*. Springer.
- Yağız, S., Sezer, E.A. and Gökçeoğlu, C., 2012. 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. *International Journal for Numerical and Analytical Methods in Geomechanics* 36, 1636-1650.
- Yaşar, E. and Erdoğan, Y., 2004. Correlating sound velocity with the density, compressive strength and Young's modulus of carbonate rocks. *International Journal of Rock Mechanics and Mining Sciences*, 41 (5), 871-875.
- Yılmaz, I. and Sendir, H., 2002. Correlation of Schmidt hardness with unconfined compressive strength and Young's modulus in gypsum from Sivas (Turkey). *Engineering Geology*, 66 (3), 211-219.
- Yılmaz, I. and Yüksek, A. G., 2008. An example of artificial neural network (ANN) application for indirect estimation of rock parameters. *Rock Mechanics and Rock Engineering*, 41 (5), 781-795.
- Yılmaz, I. and Yüksek A. G., 2009. Prediction of the strength and elasticity modulus of gypsum using multiple regression, ANN, and ANFIS models. *International Journal of Rock Mechanics and Mining Sciences*, 46 (4), 803-810.