

MAKİNE ÖĞRENMESİ YÖNTEMLERİNİN İNŞAAT SEKTÖRÜNE KATKISI: BASINÇ DAYANIMI TAHMİNLEMESİ

CONTRIBUTION OF MACHINE LEARNING METHODS TO THE CONSTRUCTION INDUSTRY: PREDICTION OF COMPRESSIVE STRENGTH

Hamit ERDAL^{1*}

¹Savunma Bilimleri Enstitüsü, Kara Harp Okulu, Ankara, Türkiye.
hamit_erdal@hotmail.com

Geliş Tarihi/Received: 21.04.2014, Kabul Tarihi/Accepted: 07.07.2014
* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2014.26121
Araştırma Makalesi/Research Article

Öz

Yüksek performanslı beton (high performance concrete, HPC)'un eksenel basınç dayanımının yüksek doğrulukla tahmini son derece önemli bir konudur. Geçtiğimiz yıllarda, çeşitli gelişmiş modelleme yaklaşımları ve metodolojileri kullanılarak farklı başarı oranları ile HPC basınç dayanımı tahminlemeleri uygulanmıştır. Bu çalışmada farklı karışım oranları kullanılarak HPC'lerin eksenel basınç dayanımının tahmininde uygun bir makine öğrenmesi yöntemi araştırılmıştır. Son yıllarda makine öğrenmesinde oldukça gelişmekte olan Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM)'nin bu tahminde uygulanabilirliği incelenmiş ve son derece yüksek tahmin sonuçları elde edilmiştir. Bu çalışmada DVM'lerin tahmin başarısının YSA'lara oranla daha tatmin edici sonuçlar verdiği görülmüştür. DVM yönteminin araştırma laboratuvarları ve beton firmaları tarafından dayanım tahmininde alternatif bir yöntem olarak etkin bir şekilde kullanılabilceği sonucuna varılmıştır.

Anahtar kelimeler: Yüksek performanslı beton, Yapay sinir ağları, Destek vektör makineleri

Abstract

Highly accurate prediction of high performance concrete (HPC) compressive strength is very important issue. In recent years, a variety of modeling approaches and methodologies have been applied to predict HPC's compressive strength from a wide range of variables, with different ratios of success. In this study, an appropriate machine learning method, using different mixing ratios for the prediction of compressive strength of HPC, is investigated. In recent years, rather developing machine learning methods; Artificial Neural Networks (ANN) and Support Vector Machines (SVM)'s applicabilities for the prediction, handled in this study, are being investigated and extremely high results were obtained. In this paper, it's obtained that prediction success of SVM has been found more satisfactory than ANN's. It is concluded that the SVM's can be used effectively as an alternative method by research labs and the concrete firms for predicting the strength.

Keywords: High performance concrete, Artificial neural networks, Support vector machines

1 Giriş

Yüksek performanslı beton (high performance concrete, HPC) stratejik öneme haiz yapıların (nükleer santraller, barajlar, askeri tesisler vb.) imarında kullanılmaktadır. Günümüzde kullanılan modern inşaat ve kimya altyapısıyla bu yapı malzemesinin dayanımını artırıcı çalışmalar artarak devam etmektedir. Normalde beton; çimento, agrega ve suyun; uygun oranlarda bir araya getirilmesinden meydana gelir. HPC'ler ise dayanımını artırmak ve normal betonun zafiyetlerini azaltmak için bir takım ilavelere ihtiyaç duyarlar. Bu ilavelerin karışım oranları değiştirilerek malzemenin dayanım değerleri artırılıp/azaltılabilir. Maksimum dayanımı sağlayacak karışım oranının elde edilmesi için pek çok deney yapılması gerekmektedir. Bu deneylerin laboratuvar ortamında yapılması durumunda yüklü miktarda ekipman, işgücü ve finansal kaynak gerekeceğinden, daha önce elde edilen veriler ile başarısı test edilmiş makine öğrenmesi yöntemleri kullanılarak tüm bu maliyet ve iş gücü kayıpları engellenebilir.

Bu çalışmada; istatistik, makine öğrenmesi ve sinir ağlarından çeşitli teknikleri kombine eden Destek Vektör Makineleri (DVM) ile insan beyninin biyolojik sinir sisteminin çalışma şeklinin simüle edilmesiyle bilgi işleme fonksiyonundan esinlenerek geliştirilen Yapay Sinir Ağları (YSA)'nın, yüksek performanslı betonun eksenel basınç dayanımının tahmin edilmesinde kullanılabilirliği araştırılmış ve bu iki yöntemle elde edilen sonuçlar karşılaştırılmıştır.

Çalışmada, 17 farklı laboratuvar da yapılan 1030 örneklilik beton dayanım veri setinin [1], DVM ve YSA yöntemleriyle analizi yapılmış ve bu iki yöntemle yapılan tahminler sonucunda; tutarlılık ve tahmin gücü açısından DVM'lerin daha tatmin edici sonuçlar verdiği görülmüştür.

Son yıllarda farklı yöntem ve veri setleri kullanılarak beton dayanımı tahminlemesine yönelik çalışmalar hız kazanmıştır.

Literatürde beton basınç dayanımı tahmini için yaygın olarak YSA'ların kullanıldığı gözlenmiştir [2]-[8]. Yeh [2] beton dayanımı tahmininde YSA'ların etkin bir yöntem olarak kullanılabilceğini ortaya koyduğu çalışmasında, YSA'lar ile regresyon analizi (regression analysis)'ne göre çok daha yüksek tahmin başarısı elde edilebildiğini ortaya koymuştur. Benzer bir çalışma Atıcı [9] tarafından yapılmıştır. Yazar, YSA ile çoklu regresyon analizi (multiple regression analysis) tahmin sonuçlarını karşılaştırdığı çalışmasında, YSA'ların üstünlüğünü rapor etmiştir. Çoklu regresyon analizi ile bir YSA modeli olan özdüzenleyici haritalar (self organization feature map, SOFM)'ın tahmin başarısını karşılaştıran Nikoo ve diğ. [10] SOFM'un üstünlüğünü raporlamıştır. Fazel-Zarandi ve diğ. [11] beton dayanımı tahmini için bulanık sinir ağları (fuzzy neural networks) ve polinomial sinir ağları (polynomial neural networks)'nın birleşiminden oluşan bulanık polinomial sinir ağı modeli önermiştir. Yeh ve Lien [12] HPC basınç dayanımı tahmini için karar ağacı (decision tree; operation tree) ve genetik algoritmaların

(genetic algorithm) birleştirildiği bir genetik karar ağacı (genetic operation tree) modeli önermiştir.

DVM'lerin inşaat mühendisliği alanında gerçekleştirilen, proje maliyeti [13] ve proje tamamlanma süresinin tahmini [14] gibi birçok çalışmada yaygın olarak kullanılmasına rağmen beton dayanımı tahmininde uygulanması sınırlıdır. Cheng ve diğ. [15] bulanık mantık (fuzzy logic, FL), ağırlıklı DVM (wSVM) ve hızlı dağıntık genetik algoritmalar (fast messy genetik algorithms, fmGA)'ın birleştirilmesinden oluşan melez bir sistem olan zaman serileri verisi için evrimsel bulanık destek vektör makinası çıkarımsal modeli (evolutionary fuzzy support vector machine inference model for time series data, EFSIMT) önermiştir. Yazarlar EFSIMT ile elde ettikleri tahmin sonuçlarının DVM'den yüksek olduğunu ve geri yayılım sinir ağları (back-propagation neural network, BPN) ile karşılaştırılabilir olduğunu belirtmişlerdir. Cheng ve diğ. [16]'de genetik algoritma, ağırlıklı karar yapısı (weighted operation structure) ve piramit karar ağacı (pyramid operation tree)'ndan oluşan bir genetik karar ağacı olan genetik ağırlıklı piramit karar ağacı (genetic weighted pyramid operation tree, GWPOT) ile HPC basıncı dayanımı tahminlemesi gerçekleştirmiştir. Geliştirilen modelin başarısı YSA, DVM ve evrimsel destek vektör makinası çıkarımsal modeli (evolutionary support vector machine inference model, ESIM) ile karşılaştırmış ve daha iyi sonuçlar elde edildiği belirtilmiştir.

Literatürde beton dayanımı tahmini konusunda tespit edilen en kapsamlı çalışma Chou ve diğ. [17]'nin çalışmasıdır. Yazarlar 5 farklı makine öğrenmesi yöntemini; YSA, DVM, çoklu regresyon analizi ve 2 farklı birleşik öğrenme modeli (çok katlı regresyon ağaçları (multiple additive regression trees, MART) ve torbalama regresyon ağaçları (bagging regression trees, BRT))'ni HPC'lerin basıncı dayanımının tahmininde uygulamış ve elde edilen tahmin sonuçlarının karşılaştırmışlardır. Çalışmanın sonucunda birleşik öğrenme modellerinin tahmin başarısının üstünlüğü vurgulanmıştır.

Son yıllarda DVM ile tahminleme konusunda gerçekleştirilen çalışmaların bir çoğunda, DVM'lerin YSA'lara üstünlüğü rapor edilmiştir [18],[19].

Literatürde bu çalışmada kullanılan yöntemler ve veri seti ile gerçekleştirilen diğer tahminleme çalışmaları incelendiğinde; YSA yöntemiyle aynı veri setinin 727 örneklemini kullanarak tahmin yapan Yeh [2], $r=0.914$ (Korelasyon Katsayısı (r)) sonucunu elde etmiştir. Yine aynı veri setinin 1030 örneklemini kullanarak tahmin eden Chou ve diğ. [17] çalışmalarında ise YSA yöntemi ile $r = 0.909$ ve DVM yöntemi ile $r = 0.886$ sonucunu elde etmişlerdir.

Bu çalışmada, önceki çalışmalardan farklı olarak DVM'lerin tahmin başarısındaki üstünlük; farklı çekirdek (kernel) fonksiyonunun uygulanması sonucu elde edilmiştir.

2 Yöntem ve Prosedürler

Bu bölümde öncelikle, çalışmada kullanılan YSA ve DVM'ler tanıtılacak daha sonra tahminleme için uygulanan prosedürler açıklanacaktır.

2.1 Yapay Sinir Ağları

Yapay sinir ağları (YSA) insan beyninin biyolojik sinir sisteminin çalışma şeklinin simüle edilmesiyle bilgiyi işleme fonksiyonundan esinlenerek geliştirilmiştir. İlk YSA modeli 1943'de, W. McCulloch ve W. Pitts tarafından önerilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, basit bir sinir ağı modeli geliştirmiştir [20].

1948'de Wiener "Cybernetics" adlı eserinde, sinirlerin çalışması ve davranış özelliklerini ele almış, 1949 yılında ise Hebb, "Organization of Behavior" adlı eserinde öğrenme ile ilgili temel teoriye değinmiştir. Hebb kitabında, öğrenebilen ve adapte olabilen sinir ağları modeli için temel oluşturacak, yapay sinir ağının bağlantı sayısının değiştirilmesiyle öğrenme arasında ilişki kuran "Hebb Kuralı"na ortaya koymuştur [21].

1957'de F. Rosenblatt'ın Perceptron'u geliştirmesinden sonra, YSA çalışmaları artış göstermiştir. "Perceptron"; insan beyninin fonksiyonlarını modelleyebilmek amacıyla yapılan çalışmalar neticesinde geliştirilen tek katmanlı, eğitilebilen ve tek çıkışlı bir ağ modelidir [22].

Dünya çapında bilinen birçok şirket, iş hayatına ilişkin problemlerin çözümünde profesyonel YSA programlarından yararlanmaktadır. Bu şirketlerden bazıları; American Airlines, AT&T, Bank of America, Bankers Trust, Boeing, BP, Coopers & Lybrand, Dell Computer, NASA, Phillip Morris, Pfizer, Xerox ve Volvo'dur [23].

YSA'da girdi değerleri ile çıktı değerleri arasındaki fark aşağıdaki hata fonksiyonu ile elde edilir [20],[21] (d_j : hedeflenen sonuç, o_j : gerçekleşen sonuç).

$$E_p = \frac{1}{2} \sum_j (d_j^p - o_j^p)^2 \quad (1)$$

Ağırlıkları yeniden düzenlemek için hata fonksiyonunun farkı kullanılır.

$$\Delta^p w_{ji} = -n \left(\frac{\partial E^p}{\partial w_{ji}} \right) \quad (2)$$

Burada, "öğrenme oranı" n sabiti herhangi bir değer seçilebilir. Ağırlıkların yeniden revizesi

$$w_{ij}(t+1) \cong w_{ij}(t) + n \delta_j i_i \quad (3)$$

şeklinde yapılır. Burada, $w_{ij}(t)$ ağırlık, i_i : i düğümünün sonuç değeri olabileceği gibi bir giriş, δ_j : j düğümünün hata terimi de olabilir. Bir çıkış düğümü için hata terimi (δ_j);

$$\delta_j \cong o_j(1 - o_j)(d_j - o_j) \quad (4)$$

olarak elde edilir. j düğümü bir gizli düğüm olmak üzere hata terimi (δ_j);

$$\delta_j \cong o_j(1 - o_j) \sum_k \delta_k w_{jk} \quad (5)$$

olarak düzenlenir. Bir "moment" teriminin (α) eklenmesi ile ağırlık değişimleri üzerine etki yapılabilir.

$$w_{ij}(t+1) \cong w_{ij}(t) + n(d_j - o_j)i_i + \alpha(w_{ij}(t) - w_{ij}(t-1)) \quad (6)$$


Örnek olarak ileri beslemeli YSA modelinin temel yapısı Şekil 1'de sunulmuştur.

2.2 Destek Vektör Makineleri

1960'lı yılların sonlarında Vapnik tarafından teorik temelleri atılan [23]-[25] DVM'ler, 1995 yılında ilk defa bir sınıflandırma probleminin çözümünde kullanılmıştır [26]. DVM'ler sınıflandırma (classification) ve regresyon (regression) problemlerinin analizinde kullanılan bir öğrenme makinesidir.

DVM temelde, iki grup örnek arası mesafeyi maksimize eden optimum ayıraç hiperdüzlem (hyperplane) ile ikili (binary) sınıflandırma yapan bir yöntemdir. Hiperdüzlemin sınırlarına (margins) en yakın sınıf elemanlarına destek vektörleri (support vectors) denir. DVM diğer öğrenme makinelerinin de

kullanmakta olduğu, örnekler arasındaki hata oranını azaltmaya çalışan ampirik risk minimizasyonu da (empirical risk minimization) kullanır. DVM iki sınıfı sınıra en yakın iki örnek arasındaki mesafeyi maksimize edecek hiperdüzlem ile ayırmaya çalışırken ampirik sınıflandırma hatasını (empirical classification error) minimize eder. Burada gözden kaçırılmaması gereken olgu, ampirik risk minimizasyonu tek bir çözüm garantisi etmemesine karşın iyi bir çözüm için gerekli olduğudur [27].



Şekil 1: İleri beslemeli YSA modeli [22].

Bunun yanında DVM’de sınıflandırmada öğrenmeyi istatistiksel bir bakış açısıyla ele alan VC boyutu (Vapnik-Chervonenkis dimension) temelli yapısal risk minimizasyonu kullanılır. Böylece örnekler üzerinde oluşabilecek hata oranı üst sınırının en küçük olması sağlanır [28].

Hiperdüzlem sınırlarının bulunması bir optimizasyon problemi ve bu problem lagrange çarpanları (lagrange multipliers) yönteminin, eşitsizlik durumlarında kullanılan özel bir hali olan Karush-Kuhn-Tucker koşulları (KKT conditions) yöntemi ile çözülür.

Doğrusal olmayan problemler giriş uzayından problemlerin doğrusal analiz edilebileceği yüksek boyutlu öznitelik uzayına haritalanarak çözümlenir. İşlem yükünü azaltmak için haritalamada çekirdek fonksiyonları (kernel functions) kullanılır [29]. DVM harf tanımadan [30] sel tahminine [31] kadar birçok farklı alanda etkin olarak kullanılmaktadır.

İki ayrı sınıfa ait toplam “n” adet elemanı olan bir eğitim kümesi Denklem (7)’de gösterilmiştir [25].

$$(x_1, y_1), \dots, (x_n, y_n), \quad x_i \in R^d, \quad y_i \in \{-1, +1\} \quad (7)$$

Eğitim kümesini ikili sınıflandırabilecek hiperdüzlem formülü

$$wx + b = 0 \quad (8)$$

şeklinde gösterilebilir. Hiperdüzlemin sınırları ise Denklem (9)’da belirtildiği gibidir.

$$\begin{aligned} wx_i + b &\geq 0 & y_i &= 1 \\ wx_i + b &\leq -1 & y_i &= -1 \end{aligned} \quad (9)$$

Denklem (9) aşağıdaki gibi genelleştirilebilir.

$$y_i(wx_i + b) \geq 1 \quad i, \dots, I \quad (10)$$

Burada, w ağırlık vektörü ve b eşik değeri ifade eder.

Optimum ayırıcı hiperdüzlemin bulunması için hiperdüzlem sınırlarının (d) maksimize edilmesi gerekir. Bunun için w ağırlık vektörünün normu olan $\|w\|$ ’i minimize etmek için lagrange çarpanları yöntemi kullanılır.

$$d = \frac{2}{\|w\|} \quad (11)$$

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^I \alpha_i [y_i(wx + b) - 1] \quad (12)$$

Lagrange çarpanları yöntemi gereği $L(w, b, \alpha)$ fonksiyonunun ekstremum noktaları, fonksiyonun w ve b değerlerine göre türevlerinin sıfıra eşitlenmesi ile bulunur.

$$\sum_{i=1}^I \alpha_i y_i \quad \alpha_i \geq 0, \quad i = 1, \dots, I \quad (13)$$

$$w = \sum_{i=1}^I \alpha_i y_i x_i \quad \alpha_i \geq 0, \quad i = 1, \dots, I \quad (14)$$

$\alpha \neq 0$ olduğu noktalar destek vektörleridir. KKT koşulları teoremi kullanılarak Denklem (10) eşitsizliğinin $\alpha \neq 0$ farklı olduğu noktalarda aşağıdaki eşitliğe dönüştüğü bulunur.

$$\alpha_i [y_i(wx + b) - 1], \quad i = 1, \dots, I \quad (15)$$

$$L(\alpha) = \sum_{i=1}^I \alpha_i - \frac{1}{2} \sum_{i=1}^I \sum_{j=1}^J \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (16)$$

Denklem (14) ve (15), Denklem (12)’de yerine konulup tekrar düzenlenirse, Denklem (16) elde edilir. $L(\alpha)$ fonksiyonu Denklem (13) kısıtına bağlı olarak maksimize edilerek çözüm bulunur.

Çekirdek fonksiyonu iki parametreye sahiptir. Bunlar; karmaşıklık parametresi (the complexity parameter) “C” ve çekirdeğin üstellik değeri (the exponent value) “p”dir. C ve p DVM’lerin doğruluk oranına etki eden iki parametredir, aldıkları değerlere bağlı olarak sınıflandırma performanslarına etki ederler. Bu nedenle en iyi doğruluk oranını veren C ve p parametrelerinin bulunması için çapraz-geçerlilik (cross-validation) uygulaması yapılır.

2.3 Prosedürler

Bu çalışmanın nüvesi olan veri setini 17 farklı laboratuvarında yapılan 1030 örneklik beton dayanım değerleri oluşturmaktadır. Gayet kapsamlı oluşu ve daha önce üzerinde çeşitli makine öğrenmesi yöntemleriyle analiz yapılması bu veri setinin kullanılmasının ana sebebidir. Veri setindeki değerler oluşturulurken 8 farklı değişken kullanılmıştır. Bu değişkenler Tablo 1’de görüldüğü gibidir.

Tablo 1: Beton bileşenleri tablosu.

Girdiler	Birim	Min.	Maks.	Ort.	Varyans
Çimento	kg/m ³	102.0	540.0	281.2	10921.5
Yüksek Fırın Cürufu	kg/m ³	11.0	359.4	107.3	3829.6
Uçucu Kül	kg/m ³	24.5	200.1	83.9	1599.1
Su	kg/m ³	121.8	247.0	181.6	593.1
Süperplastikleştirici	kg/m ³	1.7	32.2	8.5	16.3
Kaba Agregası	kg/m ³	801.0	1.145.0	972.9	6045.7
İnce Agregası	kg/m ³	594.0	992.6	773.6	6428.2
Numune Bekleme Süresi	gün	1.0	365.0	45.7	3990.5
Beton Basınç Dayanımı	MPa	2.3	82.6	35.8	279.1

Açık kaynak kodlu WEKA 3.7.7. programıyla önce DVM yöntemiyle en iyi sonucu ortaya çıkaracak parametreler (çekirdek fonksiyonu, C ve p) seçilmiştir.

Ardından YSA yöntemiyle en iyi sonucu ortaya çıkaracak parametreler (h , α ve n) seçilmiştir.

DVM'nin çekirdek fonksiyonu için doğrusal, polynomial, radyal tabanlı ve sigmoid fonksiyonları sırasıyla denenmiştir. Her bir model için birçok farklı denemeden sonra, DVM için polynomial kernel seçilmiş ve parametrelerin optimizasyonu için rassal ayırma (random split) yöntemi uygulanmıştır. p için 1, karmaşıklık katsayısı C için de 1 değeri en iyi sonucu sağlamıştır. YSA yönteminde n ve α için 0.2, 0.3 ve 0.4; h için 2, 3, 4, 5, 10 ve 15 denemiş ve sırasıyla $n=0.3$, $\alpha=0.2$ ve $h=2$ seçilmiştir.

Yapılan tahminlerin başarı kriteri olarak korelasyon katsayısı (r), ortalama mutlak hata (mean absolute error, MAE) ve ortalama hata karesinin kökü (root mean square error, RMSE) alınmıştır. Grafik gösterim için literatürde yapılan önceki çalışmalar ile karşılaştırma yapabilmek amacıyla r tercih edilmiştir. Bulgular karşılaştırmalı olarak analiz edilmiş, müteakiben daha önce yapılan çalışmalarla karşılaştırılmıştır.

Çalışmanın yöntemini oluşturan YSA ve DVM'ler el yazısı tanıma, ses tanıma, yüz tanıma, obje tanıma, bioinformatik, finansal tahmin gibi pek çok alanda başarıyla kullanılmaktadır.

3 Bulgular

Kullanılan yöntemlerin performansları farklı istatistiksel ölçütler kullanılarak karşılaştırılabilmektedir. MAE, RMSE ve r ortalama hata kavramını temel alan, yaygın şekilde kullanılan ölçütlerdendir.

Korelasyon analizi iki değişken arasındaki ilişkinin düzeyini ve yönünü belirlemek amacı ile yapılır. r , -1 ile +1 arasında bir değer alır. Burada değişkenler arasındaki ilişkinin düzeyini, rakamların mutlak büyüklüğü, yönünü ise rakamların işareti (pozitif veya negatif) belirler. r 'nin pozitif olması, bir değişkene ilişkin verilerin artması durumunda, diğer değişkenin de artması veya bir değişkene ilişkin verilerin azalması durumunda, diğer değişkenin de azalması anlamına gelir.

$$r = 1 - \frac{\sum_{i=1}^N (o_i - t_i)^2}{\sum_{i=1}^N (o_i - \bar{o}_i)^2} \quad (17)$$

Değişkenler arasındaki ilişkinin düzeyi olan r 'nin, 0-0.25 arasında olması durumunda ilişki düzeyi çok zayıf, 0.26-0.49 olması durumunda zayıf, 0.50-0.69 olması durumunda orta, 0.70-0.89 olması durumunda yüksek, 0.90-1.00 olması durumunda çok yüksek şeklinde yorumlanabilmektedir.

RMSE, ölçüm değerleri ile model tahminleri arasındaki hata oranını belirlemek amacıyla kullanılmaktadır. RMSE değerinin sifıra yaklaşması modelin tahmin kabiliyetinin artması anlamına gelmektedir. Ele alınan problem için aşağıda verilen RMSE denkleminde ifade edilen o_i ve t_i sırasıyla yöntemin tahmin sonuçlarını ve gerçekleşen değerleri göstermektedir. N ise gözlem değerini ifade etmektedir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (o_i - t_i)^2}{N}} \quad (18)$$

MAE, ölçüm değerleri ile model tahminleri arasındaki mutlak hatayı sorgular. MAE değeri ne kadar sifıra yaklaşırsa, modelinin tahmin yeteneğinin o kadar iyi olduğu sonucu çıkar. Aşağıda verilen denklemde o_i ve t_i sırasıyla gözlemlenen tahmin sonuçlarını ve gerçekleşen değerleri göstermektedir.


$$MAE = \frac{1}{N} \sum_{i=1}^N |o_i - t_i| \quad (19)$$

Bu çalışmada r , RMSE ve MAE ölçütleri dikkate alınarak DVM ve YSA yöntemlerinin başarıları karşılaştırılmıştır.

Çalışmada gerek DVM, gerekse YSA yöntemlerinde eğitim ve test aşamaları için rassal ayırma (random split) yöntemi kullanılmıştır. Rassal ayırma yöntemi gereği veri kümesi eğitim ve test kümeleri olarak ikiye ayrılmakta, tahmin yöntemi ilk önce eğitim verisi ile eğitilmekte ardından model başarısının test edilmesi için test verisi kullanılarak tahmin başarısı hesaplanmaktadır. Bu çalışmada rassal ayırma yöntemi kullanarak 2 model oluşturulmuştur (model-1: %90 eğitim %10 test; model-2: %80 eğitim %20 test). İstatistiksel ölçütlerin hesaplanan değerleri Tablo 2'de, grafik olarak tahmin sonuçlarının karşılaştırması Şekil 2 ve 3'te sunulmuştur.

Tablo 2: Yöntemlerin HPC basınç dayanımı tahmin kabiliyeti.

Yöntem	Model	(r)	RMSA (MPa)	MAE (MPa)
DVM	Model-1	0.942	4.54	3.30
YSA	Model-1	0.859	5.57	4.18
DVM	Model-2	0.921	5.24	4.09
YSA	Model-2	0.834	6.07	4.65

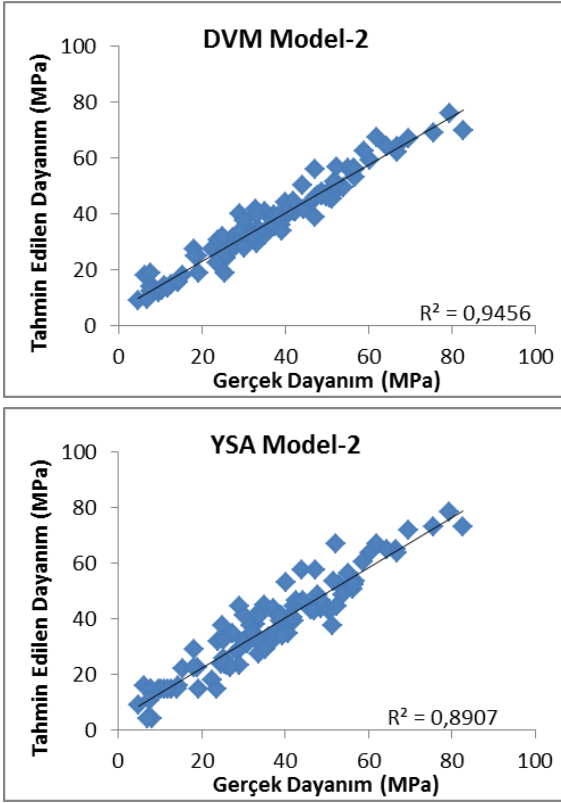


Şekil 2: DVM ve YSA'nın gözlenen Model-1 tahminlerinin karşılaştırılması.

Model-1 ve Model-2 sonuçlarına göre DVM ile YSA'dan daha iyi sonuçlar elde edilmiştir. Yine iki farklı tahmin yöntemi içinde Model-1 ile (%90 eğitim-%10 test) daha iyi sonuçlar elde edilmiştir.

Elde edilen sonuçlar daha önceki çalışmalarla karşılaştırıldığında önceki çalışmalardan farklı olarak DVM'ler ile daha yüksek tahmin başarısı elde edilmiştir. Bu üstünlük,

farklı çekirdek fonksiyonunun kullanılması sonucu elde edilmiştir.



Şekil 3: DVM ve YSA'ların gözlenen Model-2 tahminlerinin karşılaştırılması.

Literatürde, aynı veri seti kullanılarak yapılan çalışmaların bulguları Tablo 3'te sunulmuştur.

Tablo 3: Önceki çalışmaların bulguları.

Önceki Çalışmalar	Yöntemler	Veri seti büyüklüğü	(r)
Yeh [2].	YSA	727	0.914
Chou ve diğ. [17].	YSA DVM	1030	0.909 0.886

4 Sonuç

Destek Vektör Makineleri Vapnik tarafından 1960'lı yılların sonlarında teorik temelleri atılan, sınıflandırma ve regresyon problemlerinin analizinde kullanılan bir öğrenen makine yöntemidir.

Bu çalışmada yüksek performanslı betonun eksenel basınç dayanımının tahmin edilmesi için 17 farklı laboratuvarda yapılan 1030 örneklilik beton dayanım değerleri kullanılmıştır.

Bu değerlerin tahmininde 8 farklı değişken ve verinin eğitim ile test verisi olarak ayrılması için 2 farklı model kullanılmıştır. 2 tahmin modelinde de DVM ile YSA'dan daha iyi sonuçlar elde edilmiştir. Yine iki farklı tahmin yöntemi içinde Model-1 ile (%90 eğitim-%10 test) daha iyi sonuçlar elde edilmiştir.

Sonuç olarak; DVM'lerin genelde çok boyutlu doğrusal olmayan tahmin problemlerinde, özelden ise yüksek performanslı betonun eksenel basınç dayanımının tahmin edilmesinde

başarılı bir yöntem olduğu tespit edilerek, DVM yönteminin araştırma laboratuvarları ve beton firmaları tarafından dayanım tahmininde alternatif bir yöntem olarak etkin bir şekilde kullanılabileceği sonucuna varılmıştır.

5 Kaynaklar

- [1] Yeh IC. "UCI Machine Learning Repository: Concrete Compressive Strength Data Set" <http://archive.ics.uci.edu/ml/datasets/Concrete+Compressive+Strength> (20.03.2014).
- [2] Yeh IC. "Modeling of Strength of High-Performance Concrete Using Artificial Neural Networks". *Cement and Concrete Research*, 28(12), 1797-1808, 1998.
- [3] Hong-Guang N, Ji-Zong W. "Prediction of Compressive Strength of Concrete by Neural Networks". *Cement and Concrete Research*, 30(8), 1245-1250, 2000.
- [4] Seyhan AT, Tayfur G, Karakurt M, Tanoğlu M. "Artificial Neural Network (ANN) Prediction of Compressive Strength of VARTM Processed Polymer Composites". *Computational Materials Science*, 34(1), 99-105, 2005.
- [5] Gupta R, Kewalramani MA, Goel A. "Prediction of Concrete Strength Using Neural-Expert System". *Journal of Materials in Civil Engineering*, 18(3), 462-466, 2006.
- [6] Topcu IB, Sarıdemir M. "Prediction of Compressive Strength of Concrete Containing Fly Ash Using Artificial Neural Networks and Fuzzy Logic". *Computational Materials Science*, 41(3), 305-311, 2008.
- [7] Raghu Prasad BK, Eskandari H, Venkatarama Reddy BV. "Prediction of Compressive Strength of SCC and HPC with High Volume fly ash Using ANN". *Construction and Building Materials*, 23(1), 117-128, 2009.
- [8] Khan MI. "Predicting Properties of High Performance Concrete Containing Composite Cementitious Materials Using Artificial Neural Networks". *Automation in Construction*, 22, 516-524, 2012.
- [9] Atıcı U. "Prediction of the Strength of Mineral Admixture Concrete Using Multivariable Regression Analysis and an Artificial Neural Network". *Expert Systems with Applications*, 38(8), 9609-9618, 2011.
- [10] Nikoo M, Zarfam P, Sayahpour H. "Determination of Compressive Strength of Concrete Using Self Organization Feature Map (SOFM)". *Engineering with Computers*, 31(1), 113-121, 2015.
- [11] Fazel-Zarandi MH, Türksen IB, Sobhani J, Ramezaniyanpour AA. "Fuzzy Polynomial Neural Networks for Approximation of the Compressive Strength of Concrete". *Applied Soft Computing*, 8(1), 488-498, 2008.
- [12] Yeh IC, Lien LC. "Knowledge Discovery of Concrete Material Using Genetic Operation Trees". *Expert Systems with Applications*, 36(3), 5807-5812, 2009.
- [13] Cheng MY, Peng HS, Wu YW, Chen TL. "Estimate at Completion for Construction Projects Using Evolutionary Support Vector Machine Inference Model". *Automation in Construction*, 19(5), 619-629, 2010.
- [14] Wang YR, Yu CY, Chan HH. "Predicting Construction Cost and Schedule Success Using Artificial Neural Networks Ensemble and Support Vector Machines Classification Models". *International Journal of Project Management*, 30(4), 470-478, 2012.
- [15] Cheng MY, Chou JS, Roy AFV, Wu YW. "High-performance Concrete Compressive Strength Prediction using Time-Weighted Evolutionary Fuzzy Support Vector Machines Inference Model". *Automation in Construction*, 28, 106-115, 2012.

- [16] Cheng MY, Firdausi PM, Prayogo D. "High-performance Concrete Compressive Strength Prediction using Genetic Weighted Pyramid Operation Tree (GWPOT)". *Engineering Applications of Artificial Intelligence*, 29, 104-113, 2014.
- [17] Chou JS, Chiu CK, Farfoura M, Al-Taharwa I. "Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on A Comparison of Data-mining Techniques". *Journal of Computing in Civil Engineering*, 25(3), 242-253, 2011.
- [18] Abraham A, Philip NS, Saratchandran P. "Modeling Chaotic Behavior of Stock Indices Using Intelligent Paradigms". *Neural, Parallel & Scientific Computations*, 11(1-2), 143-160, 2003.
- [19] Huang S, Wu T. "Integrating GA-based Time-scale Feature Extractions with SVMs for Stock Index Forecasting". *Expert Systems with Applications*, 35(4), 2080-2088, 2008.
- [20] Öztemel E. *Yapay Sinir Ağları*. İstanbul, Türkiye, Papatya Yayıncılık, 2003.
- [21] Elmas Ç. *Yapay Sinir Ağları Kuram, Mimari, Eğitim, Uygulama*. 1. Baskı, Ankara, Türkiye, Seçkin Yayıncılık, 2003.
- [22] Bayramoğlu MF. Finansal Endekslerin Öngörüsünde Yapay Sinir Ağı Modellerinin Kullanılması: İMKB Ulusal 100 Endeksinin Gün İçi En Yüksek ve En Düşük Değerlerinin Öngörüsü Üzerine Bir Uygulama. Yayımlanmamış Yüksek Lisans Tezi. Karaelmas Üniversitesi, Zonguldak, Türkiye, 2007.
- [23] Vapnik VN, Lerner A. "Pattern Recognition Using Generalized Portrait Method". *Automation and Remote Control*, 24(6), 774-780, 1963.
- [24] Vapnik VN, Chervonenkis A. "A Note on One Class of Perceptrons". *Automation and Remote Control*, 25, 838-845, 1964.
- [25] Vapnik VN. *The Nature of Statistical Learning Theory*. New York, USA, Springer-Verlag, 1995.
- [26] Vapnik VN. "An Overview of Statistical Learning Theory". *IEEE Transactions on Neural Networks*, 10(5), 988-999, 1999.
- [27] Schölkopf B. "Support Vector Machine". *Intelligent System*, 13(4), 18-21, 1998.
- [28] Schölkopf B, Simard P, Smola AJ, Vapnik V. "Prior Knowledge in Support Vector Kernels". *Advances in Neural Information Processing Systems*, 10, 640-646, 1998.
- [29] Kılıç N, Gorgel P, Uçan ON, Kala A. "Multifont Ottoman Character Recognition Using Support Vector Machine". *3rd International Symposium on Control Communication and Signal Processing (ISCCSP2008)*, St. Julians, Malta, 12-14 March 2008.
- [30] Chen ST, Yu PS. "Pruning of Support Vector Networks on Flood Forecasting". *Journal of Hydrology*, 347(2), 67-78, 2007.
- [31] Lute V, Upadhyay A, Singh KK. "Support Vector Machine Based Aerodynamic Analysis of Cable Stayed Bridges". *Advances in Engineering Software*, 40(9), 830-835, 2009.