

Ultras ses dalga hızının tahmininde farklı makine öğrenimi yöntemlerinin karşılaştırılması

Comparison of different machine learning methods for prediction of ultrasonic pulse velocity

Serhat DEMİRHAN^{*1}, Necim KAYA², Selahattin AKALP¹

¹Batman Üniversitesi, Mühendislik ve Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, 72060, Batman

²Batman Üniversitesi, Teknik Bilimler MYO, İnşaat Teknolojisi Programı, 72060, Batman

• Geliş tarihi / Received: 19.09.2023

• Kabul tarihi / Accepted: 07.02.2024

Öz

Deneysel sonuçlardan elde edilen basınç dayanımı sonuçlarına bağlı olarak ultras ses dalgası hızı sonuçlarının tahmin edilmesi amacıyla, farklı oranlarda mineral katkı içeren on iki (12) farklı çimento harcı üretilmiştir. Üretilen harç numunelerinin 1, 3, 7, 28 ve 90 günlük kür yaşları için hem basınç dayanımı hem de ultras ses dalgası hızı sonuçları deneysel olarak elde edilmiştir. Farklı kür koşulları için harç numunelerinden elde edilen basınç dayanımı deneysel verileri Aşırı Öğrenme Makinesi, Destek Vektör Makinesi ve Grup Veri İşleme Yöntemi olmak üzere üç farklı regresyon yöntemi kullanılarak ultras ses dalgası hızı değerlerinin tahmininde kullanılmıştır. Regresyon yöntemlerinin uygulanmasında iki farklı yaklaşım izlenmiştir. İlk yaklaşımda, farklı kür yaşları için ultras ses dalgası hızı sonuçları, basınç dayanımı değerleri göz ardı edilerek tahmin edilmiştir. Diğer yaklaşımda ise ultras ses dalgası hızı sonuçlarının tahmin etmek için basınç dayanımı değerleri dikkate alınmıştır. Böylece hem basınç dayanımı hem de ultras ses dalgası hızı değerleri ile regresyon modelleri ile elde edilen başarı sonuçları arasındaki ilişki belirlenip, karşılaştırılmıştır. Bu çalışmada, Yöntem 1'deki Grup Veri İşleme Yöntemi modeli ile en iyi test performansları (yani R^2 ve MSE için) sırasıyla 0.856 ve 0.037; Yöntem 2'de ise Grup Veri İşleme Yöntemi modeli ile en iyi test performansları sırasıyla 0.977 ve 0.003 olarak bulunmuştur. Elde edilen sonuçlar dikkate alındığında, ultras ses dalgası hızı değerleri seçilen regresyon modelleri ile yüksek başarı oranlarıyla elde edilmiştir.

Anahtar kelimeler: Basınç dayanımı, Regresyon, Ultras ses dalga hızı

Abstract

In order to predict the ultrasonic pulse velocity results based on the compressive strength results obtained from the experimental results, twelve (12) different cement mortars including mineral admixtures with different proportions were cast. Five curing ages of 1, 3, 7, 28, and 90 days were chosen in order to obtain experimental testing results of compressive strength and ultrasonic pulse velocity. Ultrasonic pulse velocity values have been estimated with regression methods developed via the experimental results of Compressive strength by using Extreme Learning Machine, Support Vector Machine and Group Method of Data Handling. Two distinct approaches were employed for each regression method. In Method 1, ultrasonic pulse velocity values were estimated without compressive strength test results. In Method 2, ultrasonic pulse velocity values were estimated using the compressive strength results. Hereby, first experimental test results of compressive strength and ultrasonic pulse velocity were determined and then estimated results of compressive strength and ultrasonic pulse velocity via regression models were compared in terms of success rate of regression models. When evaluating the performance, the Group Method of Data Handling model achieved the highest test performance among the approaches used in Method 1 and the results for R^2 and MSE were 0.856 and 0.037, respectively. In Method 2, the best test performance was achieved with the Group Method of Data Handling model, while the results for R^2 and MSE were 0.977 and 0.003, respectively. It has been revealed that the selected regression models have achieved high success in estimating ultrasonic pulse velocity (with/without considering compressive strength).

Keywords: Compressive strength, Regression, Ultrasonic pulse velocity

*Serhat DEMİRHAN; serhat.demirhan@batman.edu.tr

1. Giriş

1.1. Introduction

Yapısal betonun üretim sonrası dayanım özelliklerinin doğrudan ölçümle belirlenmesi ve test numunelerinin toplanmasındaki zorluklar, zaman alıcı ve tahribatlı gerilmeler içerir. İnşaat mühendisliği alanında pek çok sorunların giderilmesi için pek çok tahribatsız değerlendirme metodu geliştirilmiştir (Çalışkan vd., 2022; Gültekin & Doğan, 2022; Gültekin & Doğan, 2023). Geleneksel olarak, tahribatsız testler, rehabilitasyon işlerinde çimento esaslı malzemenin basınç dayanımını tahmin etmek ve inşaat sırasında ve yapının yaşam döngüsü boyunca beton dayanımını tahmin etmek ve izlemek için kullanılmıştır (Revilla-Cuesta vd., 2021). Bunlar, betonun belirli fiziksel ve mikro yapısal özelliklerinin dayanımla ilişkilendirilebilmesi ve tahribatsız metotlarla ölçülebilmesine bağlıdır. Bu özellik, sertlik, penetrasyon direnci, geri tepme kapasitesi ve ultrases ses dalgası hızı (UPV), X-ışını ve gama ışınlarını iletme kabiliyetini içerir (Ghosh vd., 2018). Mevcut yöntemler arasında, schmidt çekici prensibi ve UPV testi, hem maliyet açısından verimli olmaları hem de uygulamalarının kolaylığı nedeniyle en çok tercih edilen tahribatsız test yöntemleri olarak öne çıkmaktadır. İlk yöntem, yüzey sertliğini ölçer ve ikincisi, test numunesinin bir ucundan diğer ucuna yayılan bir stres dalgasının hızını dolaylı olarak hesaplamaktadır. Her ikisi de yapısal sağlık izleme ve beton yapıların dayanım değerlendirmesi için önerilir (Hamidian vd., 2012). Basınç dayanımıyla aralarında yüksek bir korelasyonun bulunduğu UPV'nin belirlenmesi (Hong vd., 2021), mühendislik yapılarında çimento esaslı malzemenin mikro yapısal karakteristiğinin tahmin edilmesinde tercih edilen en popüler tahribatsız yöntemlerden biridir (Sajid vd., 2016; Zengin vd., 2023). Diğer testlere kıyasen, UPV testi, betonun kalitesini güvence altına almak için nispeten ucuz bir yerde tespit test yöntemidir. Çimento esaslı malzemenin içinden geçen UPV'nin hareket süresini ölçer.

Üretim, zaman ve maliyetten gelen zorlukların azaltılması ve iyileştirilmesi adına deneysel sonuçların makine öğrenmesi yöntemleri ile işlenmesi son dönemlerde popüler olarak tercih edilen bir yöntemdir. Literatürde, makine öğrenmesi yöntemleri (Çalışkan vd., 2022) ve görüntü işleme yöntemlerinin kullanılarak basınç dayanımının ön görüldüğü (Zengin vd., 2023) pek çok araştırma mevcuttur (Li vd., 2023; Lee vd., 2023). Yaprak vd. (2013) tarafından önerilen YSA modelinde çimento esaslı malzemenin basınç dayanımının tahmin edilmesinde eğitim veri seti için regresyon ve MSE değerleri sırasıyla 0.994 ve 1.078 elde edilirken test veri seti için ise sırasıyla 0.987 ve 2.456 olarak tespit edilmiştir. Çimento, kür yaşı ve kür koşulları gibi farklı parametrelerin girdi parametresi olarak değerlendirildiği bu çalışmada YSA kullanılmıştır. Çimento esaslı malzemelerin basınç dayanımlarının tahmin edilmesinde tercih edilen diğer yöntemlere alternatif bir yöntem olduğu belirlenmiştir. Ling vd. (2019), deniz koşullarındaki mukavemet bozulmasını tahmin etmek ve değerlendirmek için k-kat çapraz doğrulama ile optimize edilmiş SVM modelini önermişlerdir. YSA ve karar ağacı algoritmaları SVM modelindeki doğruluk oranını kıyaslamak için kullanılmıştır. Hammoudi vd. (2019), çimento bazlı malzemenin basınç dayanımını tahmin etmek için 7, 28 ve 56 günlük kür sürelerinde hem tepki yüzeyi yöntemini (TYM) hem de yapay sinir ağı (YSA) yaklaşımını kullanmışlardır. Yapılan yöntemler arası karşılaştırmalar, YSA modelinin TYM'e göre daha üstün sonuçlar sunduğunu göstermiştir.

Literatürde, basınç dayanımı esas alınarak UPV değerlerini tahmin etme konusunda herhangi bir araştırmaya rastlanmamıştır. Ayrıca, her bir tahmin metodu farklı düzeyde tahmin oranları ile sonuç verdiği için dolayı farklı tahmin metotlarının kıyaslanması da büyük önem arz etmektedir. Akademik literatürdeki bu eksikliği gidermek hedefiyle, bu çalışmada farklı mineral katkı oranlarına sahip ve çeşitli kür yaşlarına sahip harç numuneleri kullanılmıştır. Bu numunelerin UPV değerlerinin tahmin edilmesi için üretilen harç numunelerinin ilgili kür yaşlarına bağlı olarak basınç dayanımı değerleriyle birlikte kullanılma veya kullanılmama senaryolarına üç farklı tahmin yöntemi uygulanmış ve bu tahmin yöntemleri arasında karşılaştırmalar yapılmıştır. Bu amaç doğrultusunda, farklı tür (uçucu kül ve nano kalsit) ve oranda mineral katkı içeren 12 farklı harç karışımı üretilmiş ve bu numunelerin 1, 3, 7, 28 ve 90 günlük kür yaşlarında elde edilen basınç dayanımı değerlerine göre UPV tahminleri ELM, SVM ve GMDH regresyon modelleriyle tespit edilmiştir. Çimento, uçucu kül, nano kalsit kullanım oranı ve numune kür yaşı olmak üzere dört girdi parametresi ile iki çıktı parametresi olan basınç dayanımı ve UPV sonuçları regresyon modellerinde kullanıldı. Karışımlara ve kür yaşlarına bağlı olarak elde edilen basınç dayanımı ve UPV sonuçları elde edilmiştir.


2. Materyal ve metod

2. Material and method

2.1. Materyal

2.1. Materials

Çimento harçlarının üretiminde bağlayıcı malzeme olarak TS EN 197-1 (2012) minimum standart şartlarını sağlayan Normal Portland Çimentosu (PÇ) (CEM I 42,5 N) ve CaO oranı %1.95 olan F tipi Uçucu kül (UK) kullanılmıştır. Minör ilave bileşen olarak nano boyutlu kalsit (NK) kullanılırken, en büyük tane boyutu 2 mm olan standart CEN referans kumu kullanılmıştır. UK ve PÇ'nin tane boyutu dağılımı Şekil 1'de gösterilmiş, aynı zamanda tüm bağlayıcı malzemelerin (PÇ, UK ve NK) fiziksel ve kimyasal özellikleri Tablo 1'de detaylı bir şekilde sunulmuştur. Ayrıca, bağlayıcı malzemelerin taramalı elektron mikroskopu (SEM) görüntüleri ve NK'nin Termogravimetrik/Diferansiyel Termal Analizleri (TGA/DTA) ve x-ray kırınımı (XRD) diyagramı sırasıyla Şekil 2 ve Şekil 3'te verilmiştir.




Şekil 1. PÇ ve UK tane boyutu dağılımı

Figure 1. Particle size distribution of PC and UK


Tablo 1. Bağlayıcı malzemelerin fiziksel özellikleri ve kimyasal bileşimleri

Table 1. Physical properties and chemical compositions of cementitious materials

Kimyasal Bileşim, %	PÇ	UK	NK
SiO ₂	20.41	61.07	0.24
Al ₂ O ₃	5.34	19.99	0.21
Fe ₂ O ₃	3.10	8.94	0.04
MgO	3.48	1.48	0.55
CaO	61.36	2.95	56.14
SO ₃	2.57	0.43	0.06
Na ₂ O	0.37	0.91	-
K ₂ O	0.94	2.15	-
Kızdırma Kaybı	2.46	2.08	42.76
Fiziksel Özellikleri			
Özgül ağırlık, gr/cm ³	3.24	2.38	2.69
Blaine, cm ² /gr	3092	3560	-
BET yüzey alanı, m ² /kg	-	-	7.4



Şekil 2. Bağlayıcı malzeme SEM görüntüleri
Figure 2. SEM images of cementitious material



Şekil 3. NK için TGA/TDA eğrisi ve XRD diyagramı
Figure 3. TGA/TDA curve and XRD diagram of NK

2.2. Metod

2.2. Method

Karışım oranları TS EN 197-1'e göre belirlenmiş ve basınç dayanımı testi ile UPV değerlerinin ölçümü ise sırasıyla TS EN 196-1 (2002) ve TS EN 12504-4 (2012) standartlarında belirtilen şekilde yapılmıştır. Tasarlanan 12 karışımda standarda uygun olarak su/bağlayıcı oranı 0,5 olarak sabit tutulmuş, UK/PÇ oranı ve NK ikame oranı sırasıyla %0.0, %0.25, %0.54, %1.0 ve %0.0, %2.5 ve %5.0 olarak belirlenmiştir. Deneysel verilerin elde edilmesi için tasarlanmış olan karışımların bileşen oranları Tablo 2'de sunulmuş olup, her bir karışım farklı değişkenlere göre tasarlandığı için tüm karışımlar farklı sayı ve harflerden oluşan bir kodlama ile ifade edilmiştir. Örneğin; NK_2.5_UK/PÇ_1.0 karışımında, NK_2.5 ile toplam bağlayıcı oranının %2.5'i kadar NK kullanılırken, UK/PÇ_1.0 ise UK/PÇ oranının 1.0 olduğunu ifade etmektedir.

Basınç dayanımı ve UPV sonuçlarının değerlendirilmesi için kullanılan ELM, SVM ve GMDH regresyon yöntemlerinden elde edilen tahmin sonuçları kıyas edilerek karşılaştırılmıştır. Farklı kür yaşları için elde edilen hem basınç hem de UPV analiz sonuçları arasındaki ilişki regresyon yöntemleriyle tespit edilmiştir. Deneysel sonuçlardan elde edilen veri setindeki verilerin %70'i eğitim için kullanılırken %30'u ise test için değerlendirilmiştir.

ELM regresyon metodunun uygulanmasında en yüksek başarı performansının elde edilmesi için her farklı uygulamada aktivasyon fonksiyonları (AF) ve gizli nöron sayısı (GNS) belirlenir. Bu amaçla, ELM metodunun kullanıldığı farklı deneylere bağlı olarak en iyi sonucu veren değişkenler Tablo 3'te sunulmuştur.

Tablo 2. Karışım oranları
Table 2. Mixture proportions

Karışım #	Karışım ID	PÇ	UK/PÇ	Su/Bağlayıcı	Kum	NK/Bağlayıcı, %	Blaine, cm ² /gr	Özgül ağırlık, gr/cm ³
1	NK_0.0_UK/PÇ_0.0	1	0	0.5	3	0	3092	1.03
2	NK_2.5_UK/PÇ_0.0	1	0	0.5	3	2.5	3821	3.22
3	NK_5.0_UK/PÇ_0.0	1	0	0.5	3	5	4283	3.18
4	NK_0.0_UK/PÇ_0.25	1	0.25	0.5	3	0	3567	3.08
5	NK_2.5_UK/PÇ_0.25	1	0.25	0.5	3	2.5	3958	3.06
6	NK_5.0_UK/PÇ_0.25	1	0.25	0.5	3	5	4786	3.07
7	NK_0.0_UK/PÇ_0.54	1	0.54	0.5	3	0	3960	2.95
8	NK_2.5_UK/PÇ_0.54	1	0.54	0.5	3	2.5	4396	2.92
9	NK_5.0_UK/PÇ_0.54	1	0.54	0.5	3	5	4982	2.91
10	NK_0.0_UK/PÇ_1.0	1	1	0.5	3	0	4217	2.88
11	NK_2.5_UK/PÇ_1.0	1	1	0.5	3	2.5	4720	2.84
12	NK_5.0_UK/PÇ_1.0	1	1	0.5	3	5	5069	2.83

Tablo 3: ELM sınıflandırma yönteminde basınç dayanımı tahmini uygulamaları için en iyi sonuçları veren AF ve GNS parametreleri

Table 3: AF and GNS parameters giving the best results for compressive strength estimation application in ELM classification method

Metotlar	AF ve GNS parametreleri
Basınç dayanımı test verileri dikkate alınmadan UPV tahmini (Yöntem 1)	AF='sin' and GNS=18
Basınç dayanımı test verileri dikkate alınarak UPV tahmini (Yöntem 2)	AF='radbas' and GNS=20

SVM sınıflandırma yöntemi basınç dayanımı tahmin uygulamasında en iyi sonuçları veren çekirdek fonksiyonu kübik çekirdek olarak belirtilmiştir. Öte yandan, GMDH sınıflandırma yönteminde ise MaxLayerNeurons: 15, MaxLayers:4, alpha:0.6 ve pTrain:0.85 olarak tanımlanmıştır.

ELM, temelde gizli katmana sahip bir YSA olduğundan dolayı ELM, yapay sinir ağlarıyla belirli ölçülerde benzer çalışma prensiplerine sahiptir. Ancak ELM'de gizli katmanda rastgele bir ağırlık ataması vardır ve eğitimin sonraki adımlarında değerler değişmez. Bu bağlamda, gizli ve çıktı katmanları arasındaki ağırlıklar, matematiksel bir model kullanılarak sistematik ve pratik bir yaklaşımla belirlenmektedir (Tang vd., 2015).

Gizli katmanında \tilde{N} nöronlu standart ileri beslemeli YSA ve aktivasyon fonksiyonu denklem (1)'deki gibidir.

$$Y_p = \sum_{i=1}^{\tilde{N}} \beta_i g(w_i x_i + b_{ij}) = o_j, j = 1, 2, \dots, N \quad (1)$$

Bu modelde, β_i ; çıkış ağırlığını, w_i ise giriş ağırlık matrisini ifade ederken, ayrıca b_i ise i nöronundaki eşik değerini simgeler. (Ding vd., 2015).

Hiper düzlemler oluşturarak sınıflandırma işlemlerini gerçekleştiren Destek Vektör Makinesi, SVM, birincil sınıflandırma yöntemi olup, çok boyutlu bir uzayda farklı sınıfları ayıran yöntemidir. Regresyon ve sınıflandırma işlemlerini destekleyen SVM, sürekli ve kategorik olan değişkenleri işleyebilir. (Rodríguez-Pérez vd., 2017). SVM yöntemi, sınıflandırma ve regresyon görevlerini gerçekleştirmek için doğrusal olmayan karar sınırları oluşturabilir. Bu esneklik, öznelik uzayının özelliklerinden kaynaklanır ve SVM'in geniş bir uygulama alanına sahip olmasına olanak tanır. SVM yöntemi, istatistiksel öğrenme teorisine ve ayrıca yapısal risk azaltımına bağlıdır. SVM yönteminde parametreler net değildir. Giriş ve çıkış değerlerinin dağılımı hakkında önceden bilgi mevcut değildir. Eğitim veri setlerinde, giriş ve çıkış değerleri birbirleriyle ilişkilendirilir. Bu ilişkilendirmeler kullanılarak yeni veri setlerini sınıflandırmak için karar fonksiyonları oluşturulur.

SVM ile bulunan düzlem denklemi; denklem (2) ile ifade edilir (Fung & Mangasarian, 2005).

$$f(x) = (w, x) + b \quad (2)$$

Burada w ağırlık vektörü ve b skaler bir sabittir. n boyutlu x vektörleri eğitim verilerini temsil edilir. w ile x vektörlerinin iç çarpımı alınarak b skaleri eklenir ve bu işlem sonucunda fonksiyonun değeri elde edilir. Eğitim verilerinin her biri, bir n -boyutlu vektörle ifade edilir. Veri kümesini oluşturan m sayısı, $y \in \{+1, -1\}$ kümesindeki öğelerden birine etiketlenir. SVM modeli, sınıf örneklerinin uzaydaki nokta temsili olarak kullandığı bir modele sahiptir (Ling vd., 2019).

1, 3, 7, 28 ve 90 günlük kür yaşları dikkate alınarak basınç dayanımı testi ve UPV analizi ile elde edilen çimento harcı verileri on iki farklı karışımdan elde edilmiş olup, karışım oranları Tablo 4'te verilmiştir. Regresyon modelleri için çimento, uçucu kül, nano kalsit kullanım oranı ve numune kür süresi dört giriş değişkeni ve basınç dayanımı ve UPV sonuçları ise iki çıkış değişkeni olarak kullanılmıştır. Karışımlara ve kür yaşlarına bağlı olarak elde edilen basınç dayanımı ve UPV sonuçları Tablo 4'te verilmiştir.

Regresyonda, sistemin çıktısı rastgele bir değişkendir (Sun vd., 2019). Bu rastgele değişken, gerçek değerler kümesinden değerler alır ve kararlı bir fonksiyon toplamı olarak yorumlanabilir.

$$y = g(x) + \varepsilon \quad (3)$$

Kararlı fonksiyon $g(x)$, çıkış koşullu olasılığının ortalamasıdır.

$$g(x) = \int y p(y|x) d_y \quad (4)$$

Regresyonda kayıp fonksiyonu aşağıdaki gibi ifade edilir.

$$L(y, f(x, w)) = (y - f(x, w))^2 \quad (5)$$

Tablo 4. Basınç dayanımı ve UPV test sonuçları
Table 4. Compressive strength and UPV test results

Karışım ID	Kür Yaşı (Gün)	Basınç Dayanımı, MPa	UPV, km/sn.	Karışım ID	Kür Yaşı (Gün)	Basınç Dayanımı, MPa	UPV, km/sn.	Karışım ID	Kür Yaşı (Gün)	Basınç Dayanımı, MPa	UPV, km/sn.
NK_0.0_UK/PÇ_0.0	1	11.50	3.39	NK_5.0_UK/PÇ_0.54	3	21.5	3.83	NK_2.5_UK/PÇ_0.25	28	46.10	4.22
NK_2.5_UK/PÇ_0.0	1	13.40	3.49	NK_0.0_UK/PÇ_1.0	3	9.2	3.4	NK_5.0_UK/PÇ_0.25	28	46.20	4.27
NK_5.0_UK/PÇ_0.0	1	12.45	3.43	NK_2.5_UK/PÇ_1.0	3	13.7	3.61	NK_0.0_UK/PÇ_0.54	28	37.50	4.08
NK_0.0_UK/PÇ_0.25	1	7.10	3.02	NK_5.0_UK/PÇ_1.0	3	13.4	3.64	NK_2.5_UK/PÇ_0.54	28	43.80	4.21
NK_2.5_UK/PÇ_0.25	1	11.50	3.18	NK_0.0_UK/PÇ_0.0	7	33.8	4.1	NK_5.0_UK/PÇ_0.54	28	46.10	4.31
NK_5.0_UK/PÇ_0.25	1	10.90	3.30	NK_2.5_UK/PÇ_0.0	7	37.3	4.2	NK_0.0_UK/PÇ_1.0	28	30.70	4.02
NK_0.0_UK/PÇ_0.54	1	5.10	2.83	NK_5.0_UK/PÇ_0.0	7	37.7	4.11	NK_2.5_UK/PÇ_1.0	28	37.60	4.22
NK_2.5_UK/PÇ_0.54	1	7.30	3.01	NK_0.0_UK/PÇ_0.25	7	28.3	3.98	NK_5.0_UK/PÇ_1.0	28	35.70	4.20
NK_5.0_UK/PÇ_0.54	1	8.20	3.16	NK_2.5_UK/PÇ_0.25	7	35.6	4.17	NK_0.0_UK/PÇ_0.0	90	43.20	4.30
NK_0.0_UK/PÇ_1.0	1	3.00	2.66	NK_5.0_UK/PÇ_0.25	7	34.2	4.22	NK_2.5_UK/PÇ_0.0	90	46.00	4.37
NK_2.5_UK/PÇ_1.0	1	5.10	2.78	NK_0.0_UK/PÇ_0.54	7	21.1	3.84	NK_5.0_UK/PÇ_0.0	90	44.90	4.31
NK_5.0_UK/PÇ_1.0	1	4.90	2.88	NK_2.5_UK/PÇ_0.54	7	26.5	3.95	NK_0.0_UK/PÇ_0.25	90	47.60	4.29
NK_0.0_UK/PÇ_0.0	3	25.30	3.94	NK_5.0_UK/PÇ_0.54	7	27.7	4.01	NK_2.5_UK/PÇ_0.25	90	52.80	4.41
NK_2.5_UK/PÇ_0.0	3	29.70	4.13	NK_0.0_UK/PÇ_1.0	7	13.1	3.7	NK_5.0_UK/PÇ_0.25	90	52.60	4.45
NK_5.0_UK/PÇ_0.0	3	29.20	4.09	NK_2.5_UK/PÇ_1.0	7	20.2	3.86	NK_0.0_UK/PÇ_0.54	90	45.10	4.24
NK_0.0_UK/PÇ_0.25	3	19.20	3.80	NK_5.0_UK/PÇ_1.0	7	18.8	3.85	NK_2.5_UK/PÇ_0.54	90	50.00	4.31
NK_2.5_UK/PÇ_0.25	3	25.60	3.97	NK_0.0_UK/PÇ_0.0	28	42.7	4.19	NK_5.0_UK/PÇ_0.54	90	53.70	4.34
NK_5.0_UK/PÇ_0.25	3	26.30	4.06	NK_2.5_UK/PÇ_0.0	28	43.3	4.26	NK_0.0_UK/PÇ_1.0	90	38.10	4.22
NK_0.0_UK/PÇ_0.54	3	14.70	3.67	NK_5.0_UK/PÇ_0.0	28	43.4	4.2	NK_2.5_UK/PÇ_1.0	90	45.90	4.32
NK_2.5_UK/PÇ_0.54	3	19.00	3.75	NK_0.0_UK/PÇ_0.25	28	43.2	4.1	NK_5.0_UK/PÇ_1.0	90	43.90	4.31

Bu bağlamda, öğrenme süreci, risk fonksiyonunu minimize eden $f(x, w_0)$ formülünü bulmayı içerir. Regresyon için risk, gürültü varyansı ve doğruluk yaklaşımının bir kombinasyonunu ifade eder. En düşük riskli tahmin, yani en kesin $g(x)$ fonksiyonunu bulmakla eşdeğerdir.

Grup Veri İşleme Yöntemi, GMDH, karmaşık sistemleri modellemek ve karakterize etmek için iki veya daha fazla değişken niceliği analiz etmek için geliştirilmiştir (Live vd., 2020). GMDH ağları, ileri beslemeli ve kendi kendini düzenleyen ağlardır. GMDH, bu transfer fonksiyonunun katsayılarının regresyon bazlı bir yöntemle elde edildiği, ikinci dereceden ve üç kuadratik polinom transfer fonksiyonlarına bağlı bir ileri beslemeli ağda analitik olarak oluşturulmuş bir fonksiyon üretir. Bu ağın en önemli özelliklerinden biri kendi kendini organize eden aktif nörondan oluşmasıdır. GMDH, veri madenciliği, tahmin, karmaşık sistem modelleme, optimizasyon ve örüntü tanıma gibi farklı alanlarda kullanılan bir yöntem olup, bu teknik, doğrusal olmayan karmaşık sistemlerin tanımlanmasında kullanılan yaygın yöntemlerden biridir. GMDH, karmaşık sistemler için yüksek dereceli regresyon türü modeller oluşturmaktadır.

GMDH'nin ilk katmanı olan giriş katmanında girdi değişkenleri kullanılarak regresyon denklemleri oluşturulmuştur. Bir sonraki katmanda, girdi değişkenleri bir önceki katmanın regresyon denklemleri kullanılarak oluşturulur. Görüldüğü gibi, mevcut katmandaki regresyon denklemlerinin çıktıları bir sonraki katmana yeni girdiler oluşturur. Bu nedenle çıktı katmanı, ardışık bağımlılıkları ile tüm katmanlardan seçilen regresyon denklemlerinden oluşur ve her katmandaki hata değerinin bir önceki katmandaki hata değerinden daha az olması beklenir. GMDH modellerinin ürettiği tekrarlanabilir ve evrimsel algoritmalar, daha önce kullanılmış modellere ve geleneksel denklemlere kıyasla daha kesin tahminler sunar.

Çok girişli ve tek çıkışlı veriler arasındaki ilişki göz önüne alındığında, denklem aşağıdaki gibi yazılabilir (M adet gözlem için).

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (6)$$

Bu doğrultuda, girdi vektörü olan $X = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{in})$ için \hat{y}_i çıktılarının tahmin edilmesi aşağıdaki şekilde ifade edilebilir:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (7)$$

Gerçek ve tahmin edilen çıktı değerleri arasındaki farkın karesinin mümkün olabilecek en düşük seviyeye indirilmesi, GMDH sinir ağının temel sonuçlarından biridir.

$$\sum_{i=1}^M [\hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) - y_i]^2 \quad (8)$$

GMDH sinir ağlarında, Kolmogorov-Gabor polinomu genellikle girdi değişkenleri ile çıktı değişkenleri arasında genel fonksiyonel ilişkiler kurmak için referans olarak alınır (Madandoust vd., 2010).

$$y = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (9)$$

Bu çalışmada R^2 ve Minimum Square Error (MSE) regresyon metrikleri kullanılmıştır. R^2 , modelin doğruluk derecesini ölçen bir karar katsayısıdır. Ek olarak, regresyon çizgisinin genel değişimi gerçek verilere göre yansıtmaktadır. Belirlenen bu katsayının yüksek olarak elde edilmesi, tahmin oranının yüksek olduğunu göstermekte olup, R^2 için en temel tanım formülü aşağıda verilen şekliyledir (Sharma & Chandra, 2020):

$$R^2 = 1 - \frac{SS_{error}}{SS_{total}} \quad (10)$$

Analizde R^2 değeri bulunur ve bulunan değer 0 - 1 aralığında olmalıdır. MSE, bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu belirler. MSE, tahmin edici olan bir makine öğrenimi modelinin verimini ve verimliliğini değerlendirir. Her zaman pozitif değerlidir ve MSE değeri sıfıra yakın olan tahmin edicilerin daha iyi performans gösterdiği söylenebilir. MSE formülü aşağıdaki gibidir (Hosseinpour vd., 2018):

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (11)$$

3. Bulgular ve tartışma

3. Results and discussion

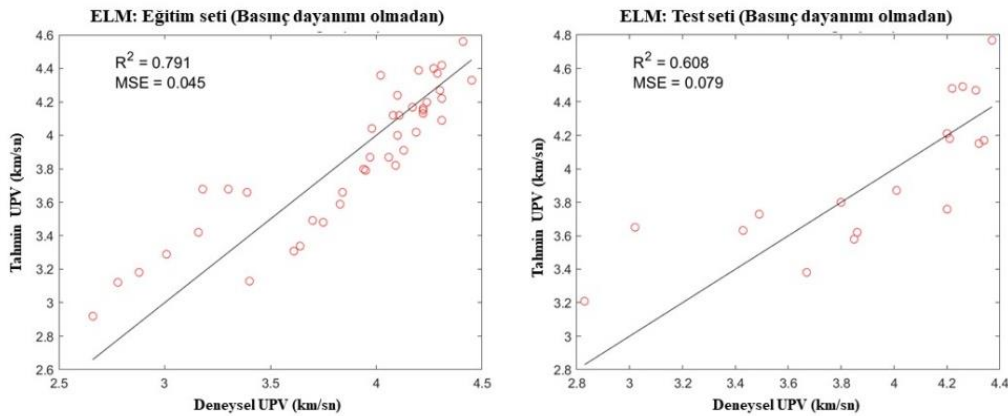
Mevcut çalışmada; 1, 3, 7, 28 ve 90 günlük kür yaşları için üretilen harç numunelerinin hem basınç hem de UPV sonuçları değerlendirilmiş olup, 60 basınç dayanımı ve 60 UPV sonucu ile toplamda 120 veri ile çalışma yapılmıştır. Veri seti kısıtlı olmasına rağmen üretilen numunelerin hem küçük hem de harç numunesi olması ve beton numunelerine kıyasen daha homojen bir mikroyapıya sahip olarak üretilebildiği için veri seti az olmasına rağmen başarı oranları yüksek çıkmıştır.

Çalışma kapsamında hedeflenen sonuçların elde edilmesi amacıyla, R^2 ve MSE parametreleri deneysel ve tahmin edilen sonuçları karşılaştırmak ve performanslarını belirlemek için kullanılmıştır. Her bir regresyon yöntemi için iki farklı yöntem uygulanmıştır. Bunlar; Yöntem 1: Basınç dayanımı test sonuçlarını içermeyen UPV değerlerinin tahmini ve Yöntem 2: Basınç dayanımı sonuçlarını içeren UPV değerlerinin tahminidir. Her regresyon modelinin sonuçları ayrıntılı olarak farklı biçimlerde sunulmuştur (Şekil 4-9).

R^2 , verilerin ideal regresyon çizgisine ne kadar uygun olduğunu istatistiksel olarak değerlendiren bir ölçüdür. Bu nedenle tahmin modellerinin performansının değerlendirilmesi ve ideal modelin atanması için her modelin R^2 yani belirleme katsayısı diğer modellerle karşılaştırılır.

Bütün tabloların gösterdiği gibi, seçilen modeller ve yöntemler, R^2 değerleri bağlamında başarılı sonuçlar elde etmektedir. Ayrıca, uygulanan yöntemlere göre tüm modellerin tahmin sonuçları ile sıkı bir tutarlılığın olduğu ve korelasyon katsayısı değerlerinin 0.608 ile 0.989 arasında değiştiği Tablolardan açıkça ortaya konmuştur. Sonuçların literatürle uyumlu olduğu görülmüştür (Nash't vd., 2005). Ek olarak, basınç dayanımının UPV tahmininde dikkate alındığı Yöntem 2 için UPV tahmini daha üstün bir sonuç göstermiştir. Bunun temel nedeni, UPV değeri ve basınç dayanımını sonuçlarının çimento esaslı malzemelerin mikro yapısal karakteristiği yansıtan sonuçlar olmalarındandır. Bu nedenle, bu değerler arasındaki korelasyon sinerjisi, modellerin tahminlerinin doğruluğunu artırıcı bir etki yapmaktadır.

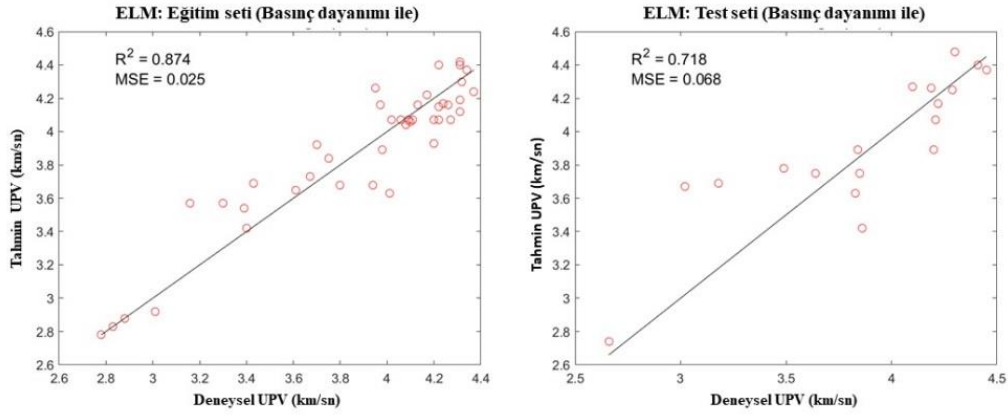
ELM modeli ile basınç dayanımı verileri kullanılmadan elde edilen UPV tahminleri Şekil 4'te verilmiştir. Bu regresyon modeli kullanılarak birinci yöntem için eğitim ölçütleri sırasıyla R^2 değeri 0.791 ve MSE değeri ise 0.045 olarak elde edilirken test performans ölçütleri için ise R^2 değeri 0.608 ve MSE değeri ise 0.079 olarak elde edildi.



Şekil 4. ELM yöntemi ile basınç dayanımı (MPa) değerleri dikkate alınmadan elde edilen deneysel ve tahmin edilen UPV (km/sn.) değerleri

Figure 4. Experimental and estimated UPV (km/s) values obtained by ELM method without considering compressive strength (MPa) values

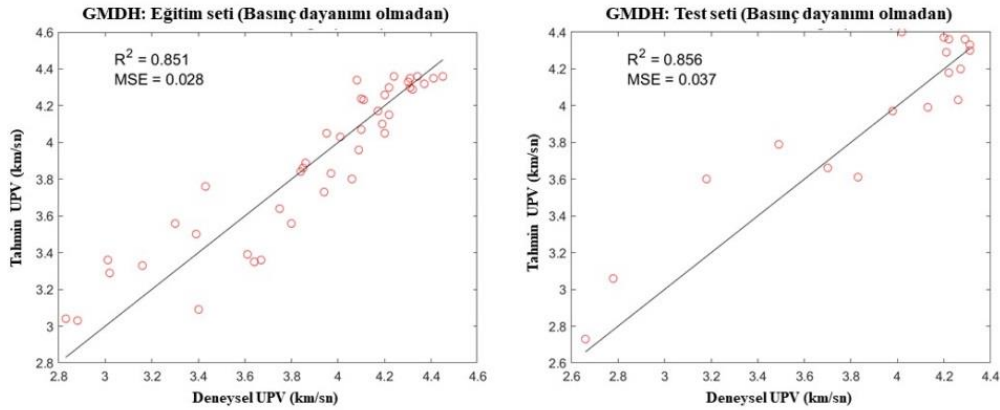
ELM modeli kullanılarak basınç dayanımı verilerinin değerlendirmeye alınarak hesaplanan UPV tahminleri, Şekil 5'te sunulmuştur. Bu regresyon modeli kullanılarak ikinci yöntem için eğitim ölçütleri için R^2 değeri 0.874 ve MSE değeri ise 0.025 olarak gözlemlenirken, test performans ölçütleri için ise R^2 değeri 0.718 ve MSE değeri 0.068 olarak gözlemlendi.



Şekil 5. ELM yöntemi ile basınç dayanımı (MPa) değerleri dikkate alınarak elde edilen deneysel ve tahmin edilen UPV (km/sn.) değerleri

Figure 5. Experimental and estimated UPV (km/s) values obtained by ELM method with considering compressive strength (MPa) values

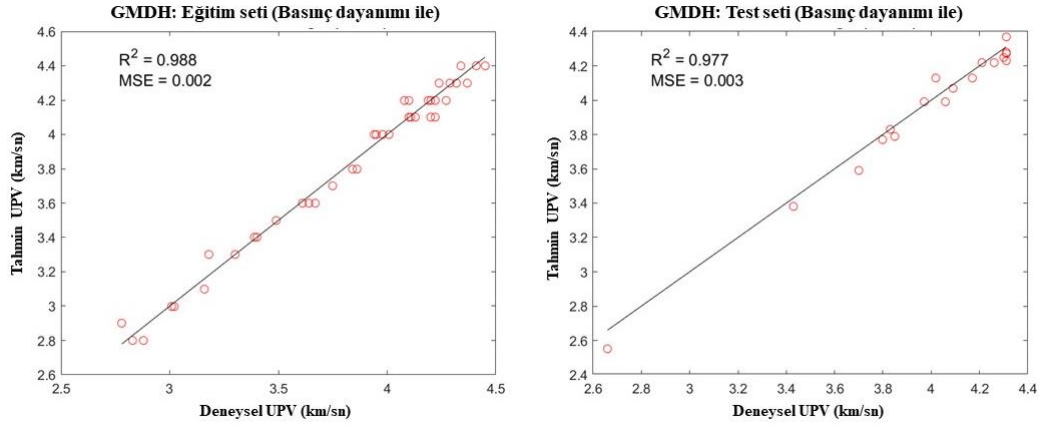
Basınç dayanımı test sonuçlarının tahmin için değerlendirmeye katılmadan GMDH modeli kullanılarak elde edilen UPV değeri tahmin sonuçları Şekil 6'da verilmiş olup, bu regresyon metodunun kullanılmasıyla uygulanan birinci yöntem için eğitim ve test başarı kriterleri sırasıyla; $R^2 = 0.851$, $MSE = 0.028$ ve $R^2 = 0.856$, $MSE = 0.037$ olarak tespit edilmiştir.



Şekil 6. GMDH yöntemi ile basınç dayanımı (MPa) değerleri dikkate alınmadan elde edilen deneysel ve tahmin edilen UPV (km/sn) değerleri

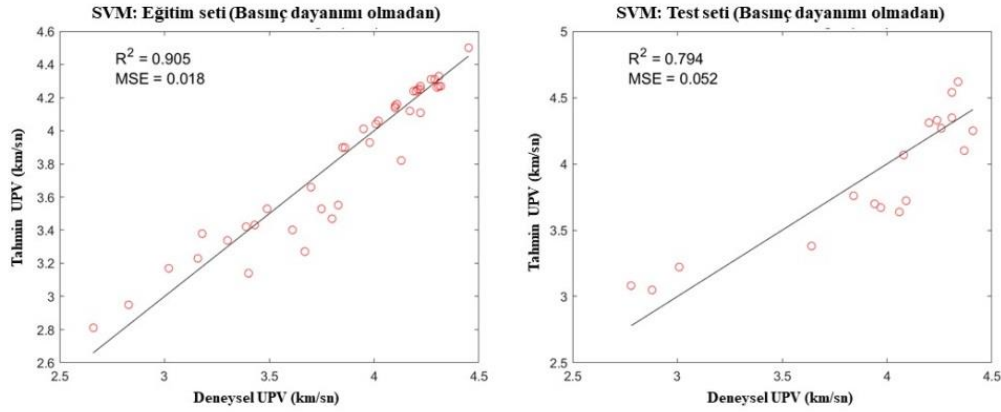
Figure 6. Experimental and estimated UPV (km/s) values obtained by GMDH method without considering compressive strength (MPa) values

Basınç dayanımı verileri kullanılmadan GMDH modeli ile elde edilen UPV tahminleri Şekil 7'de verilmiştir. Bu regresyon modeli kullanılarak ikinci yöntem için eğitim başarı kriterleri için R^2 değerleri 0.988 ve MSE değerleri 0.002 olarak kaydedilirken, test başarı kriterleri için ise R^2 değerleri 0.977 ve MSE değerleri 0.003 olarak belirlenmiştir.



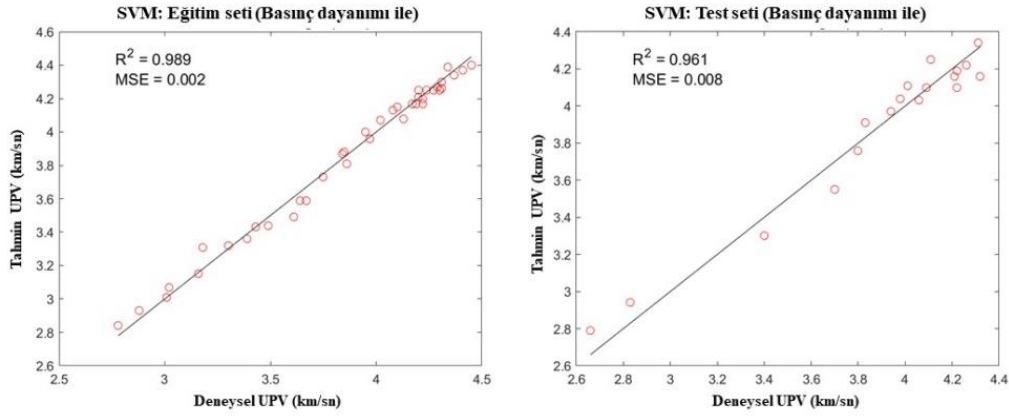
Şekil 7. GMDH yöntemi ile basınç dayanımı (MPa) değerleri dikkate alınarak elde edilen deneysel ve tahmin edilen UPV (km/sn) değerleri
Figure 7. Experimental and estimated UPV (km/s) values obtained by ELM method with considering compressive strength (MPa) values

Basınç dayanımı test sonuçlarının tahmin için değerlendirmeye katılmadan SVM modeli kullanılarak elde edilen UPV değeri tahmin sonuçları Şekil 8'de verilmiş olup, bu regresyon metodunun kullanılmasıyla uygulanan *birinci yöntem* için eğitim ve test başarı kriterleri sırasıyla; $R^2 = 0.905$, $MSE = 0.018$ ve $R^2 = 0.794$, $MSE = 0.052$ olarak tespit edilmiştir.



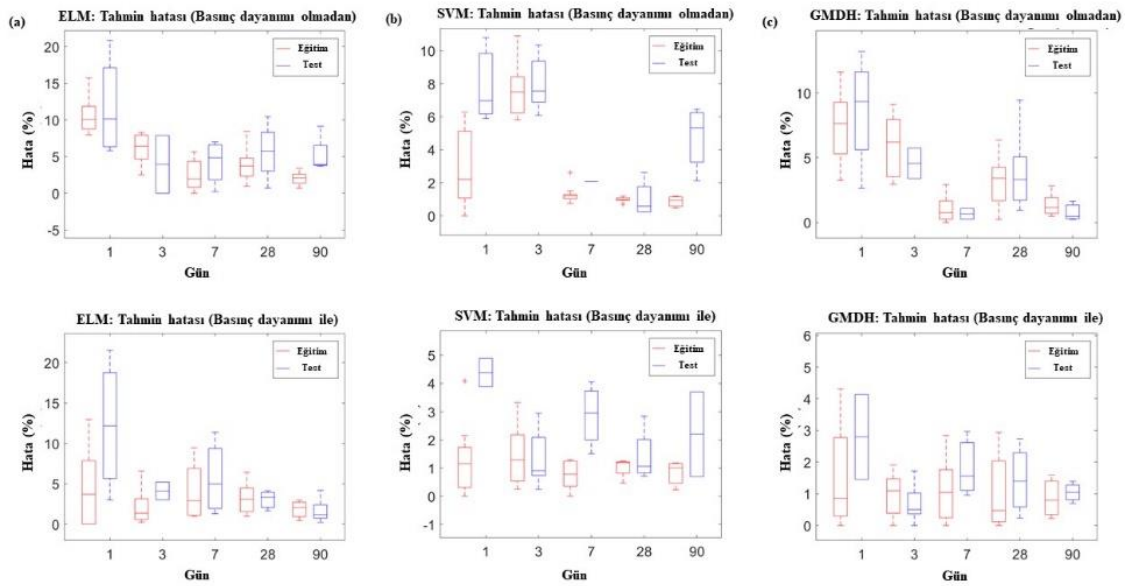
Şekil 8. SVM yöntemi ile basınç dayanımı (MPa) değerleri dikkate alınmadan elde edilen deneysel ve tahmin edilen UPV (km/sn) değerleri
Figure 8. Experimental and estimated UPV (km/s) values obtained by SVM method without considering compressive strength (MPa) values

Basınç dayanımı test sonuçlarının tahmin için değerlendirmeye katılmadan SVM modeli kullanılarak elde edilen UPV değeri tahmin sonuçları Şekil 9'da verilmiş olup, bu regresyon metodunun kullanılmasıyla uygulanan *ikinci yöntem* için eğitim ve test başarı kriterleri sırasıyla; $R^2 = 0.989$, $MSE = 0.002$ ve $R^2 = 0.961$, $MSE = 0.008$ olarak tespit edilmiştir.



Şekil 9. SVM yöntemi ile basınç dayanımı (MPa) değerleri dikkate alınarak elde edilen deneysel ve tahmin edilen UPV (km/sn) değerleri
Figure 9. Experimental and estimated UPV (km/s) values obtained by SVM method with considering compressive strength (MPa) values

ELM, SVM ve GMDH yöntemleriyle elde edilen tahminlerin hata çubukları (% olarak) kür yaşına göre belirlenmiş olup, birinci ve ikinci yöntemler için sırasıyla Şekil 10-a, Şekil 10-b ve Şekil 10-c'de verilmiştir. Hata oranları belirlenirken mutlak yüzde hatası yöntemi kullanılmıştır ($e_j = |a_j - p_j|$, a_j : gerçek değerler, p_j : tahmin edilen değerler).



Şekil 10. Kür yaşına (gün) göre tahmin hatası (%) çubukları
Figure 10. Prediction error bars (%) by cure ages (days).

Şekil 10'da verilen hata çubuklarında ve Tablo 5'te sunulan ayrıntılı istatistiklerde (min, max ve medyan) görüldüğü üzere, birinci ve ikinci yöntemlerde, kür yaşı artışıyla birlikte hata yüzdesinin azaldığı tespit edilmiştir. Mikroyapısal gelişimin erken dönemi olduğundan dolayı en yüksek tahmin hata yüzdesinin genellikle 1 günlük kür yaşlarında elde edildiği tespit edilmiş olup, buna dair istatistik veriler Tablo 5'te verilmiştir. Öte yandan, mikroyapısal gelişimin büyük bir çoğunluğu tamamlandığı için en düşük tahmin hatası yüzdeleri 90 günlük kür yaşı için elde edilmiştir.

Bu sonuçlar, hem (i) çimento hidratasyonları hem de (ii) puzolanik reaksiyonların, Kür yaşına bağlı olarak halen devam eden ve/veya mikroyapısal gelişime katkısı daha yüksek olan nano boyutlu malzemelerin

(Demirhan, 2020; Çiftçi & Demirhan, 2021), özellikle erken yaşlarda kullanılmasının yanı sıra, Buradaki istisnaların rastgele seçilen tarih ve test veri setlerinin dağılımından kaynaklandığı söylenebilir.

Bu çalışmada kullanılan regresyon modellerinin başarı performansları, birinci ve ikinci yöntemler için Tablo 5'te verilmiş olup, tabloya verilen bilgilere göre hem birinci hem de ikinci yöntemler için en başarı ornlarnının elde edildiği model GMDH regresyon modelidir. R^2 ve MSE için değerler sırasıyla 0.859/0.037 ve 0.977/0.003 olarak tespit edilmiştir.

Tablo 5. Tüm uygulamaların tahmin performansı (Metotlar)
Table 5. Prediction performance of all applications (Methods)

Metot	Sınıflandırma Metotları	Eğitim		Test	
		R^2	MSE	R^2	MSE
Metot 1	ELM	0.791	0.045	0.608	0.079
	SVM	0.905	0.018	0.794	0.052
	GMDH	0.851	0.028	0.856	0.037
Metot 2	ELM	0.874	0.025	0.718	0.068
	SVM	0.989	0.002	0.961	0.008
	GMDH	0.988	0.002	0.977	0.003

Çimento esaslı malzemelerin basınç dayanımı tahmini ile ilgili yapılan çalışmalar, yöntemleri ve başarı performansları Tablo 6'da listelenmiştir. Çimento esaslı malzemelerin basınç dayanımını tahmin etmek için bir yapay sinir ağı (YSA) modeli önerenlerden biri de Kostić ve Vasović (2015)'tir. Çalışmalarının YSA modelinde eğitim veri seti için R^2 ve standart hata değerleri sırasıyla 0.948 ve 1.581, test veri seti için 0.951 ve 2.028 olarak bulunmuştur. Yaprak vd. (2013) tarafından önerilen Yapay Sinir Ağı modelinde, eğitim veri seti için R^2 ve MSE değerleri sırasıyla 0.994 ve 1.078, test veri seti için ise 0.987 ve 2.456 olarak tespit edilmiştir. Ling vd. (2019), SVM modelinin tahmin hassasiyetini karşılaştırmak için YSA ve DT algoritmalarını kullanmışlardır. SVM, YSA, DT modelleri için R^2 'yi eğitim veri seti sırasıyla; 0.960, 0.920, 0.810 ve test veri seti için; 0.883, 0.775, 0.764 olarak buldular. Hammoudi vd. (2019), çimento esaslı malzemelerin basınç dayanımını tahmin etmek için RSM ve YSA yöntemlerini kullanmışlardır. Karşılaştırma sonuçlarına göre, YSA modeli ($R^2=0.999$), RSM'den ($R^2=0.987$) daha üstün performans sergilemiştir. Shahmansouri vd. (2021), çimento esaslı malzemelerin basınç dayanımını tahmin etmek için kullandıkları YSA modellerinde, eğitim veri seti için elde edilen R^2 değeri 0.985 ve MSE değeri 3.526 iken, test veri seti için R^2 değeri 0.961 ve MSE değeri 9.288 olarak bulunmuştur.

Mevcut çalışmada, daha önce bahsedilen çalışmaların aksine, GMDH modelinin R^2 ve MSE değerleri eğitim veri seti için sırasıyla 0.988 ve 0.002 ve test veri seti için ise 0.977 ve 0.003 olarak doğruluk ve düşük hata payı ile yüksek değerlerle verdiği görülmüştür.

Tablo 6. Çimento Esaslı Malzemelerde Basınç Dayanımı Tahmin Çalışmalarında Metotsal Karşılaştırma
Table 6. Methodical Comparison of Compressive Strength Estimation Studies in Cement-Based Materials

Ref. No.	Veri seti	Sınıflandırma Metotları	Sonuçlar
Mevcut çalışma	1, 3, 7, 28 ve 90 günlük kür yaşları için 60 harç numunesi, basınç dayanımı ve UPV.	ELM SVM GMDH	$R^2 = 0.970 - 0.994$ MSE = 1.270 - 6.359 $R^2 = 0.982 - 0.982$
Yaprak vd., (2013)	72 beton numunesi, basınç dayanımları: 3, 7, 28 ve 90 gün.	YSA-I ve YSA-II	$R^2 = 0.969 - 0.990$
Hammoudi vd., (2019)	17 farklı karışımda çimento içeriği değişik oranlarda bulunmakta olup, bu karışımlar için kür süreleri 7, 28 ve 56 gündür	RSM YSA	$R^2 = 0.987 - 0.994$ MSE = 1.078 - 2.456
Shahmansouri vd., (2021)	39 farklı karışımdan üretilmiş 117 beton numunesi, basınç dayanımları: 7, 28 ve 90 gün.	YSA	$R^2 = 0.883 - 0.960$

4. Sonuçlar

4. Conclusions

Bu mevcut bilgisayar destekli deney çalışması, çimento harcı numunelerine ait verileri temel alarak regresyon modelleri oluşturulmuştur. Farklı karışım parametrelerine bağlı olarak üretilen çimento harcı numunelerinin UPV sonuçları, basınç dayanımı değerlerini değerlendirmeye katmak veya katmamak şeklinde tahmin edilmiştir. ELM, SVM ve GMDH regresyon yöntemleri gibi makine öğrenmesi teknikleri kullanılmış ve bu yöntemlerin tahmin sonuçları karşılaştırmalı bir şekilde sunulmuştur. Tespit edilmiş olan başarı performanslarına göre, harç numunelerinin basınç dayanımı ve UPV değerlerinin deneysel sonuçları ile eğitilmiş regresyon yöntemlerinin tahminleri arasında hata oranı çok düşük elde edilirken karşılaştırmada başarı oranı ise yüksek çıkmıştır. Ayrıca, mikroyapısal gelişimin devam etmesinden dolayı hem basınç hem de UPV değerleri değişkenlik gösterdiklerinden dolayı kür yaşının tahmin hata yüzdesi üzerinde etkili bir parametre olduğu tespit edilmiştir. Tüm sınıflandırma yöntemleri için Yöntem 1 ve Yöntem 2'nin her ikisinde de, yüksek kür yaşlarının tahmin hatalarının, düşük kür yaşlarının hatalarından genellikle daha düşük olduğu ifade edilebilir. Bu sonuç, daha önce bahsedildiği gibi, karışıma bağlı olarak kullanılan çimento esaslı malzemeye bağlı hidrasyon mekanizmasına dayandırılabilir.

Kullanılan regresyon modellerinin, çimento harçlarının UPV değerlerini tahmin etmede güvenilir yöntemler olduğu ortaya çıkmıştır. Hem Yöntem 1'de hem de Yöntem 2'de GMDH modeli ile en iyi test performansları (yani R^2/MSE için) elde edilmiş olup, sırasıyla 0.856/0.037 ve 0.977/0.003 olarak elde edilmiştir. Daha iyi başarı sonuçları yönteme bağlı olsa da genel olarak GMDH modelinin yüksek doğruluk ve düşük hata payı ile en iyi başarı sonuçlarını verdiği gözlemlenmiştir.

Bu araştırma kapsamında, farklı kürlenme sürelerine sahip çimento harcı numunelerine ait deneysel verileri kullanarak, çimento dayanımı ve UPV değerlerinin yüksek hassasiyet ve düşük hata payıyla tahmin edilmesi mümkün hale getirilmiştir. Bu sayede zaman, malzeme, işgücü ve maliyet unsurları en aza indirgenebilir.

Yazar katkısı

Author contribution

Araştırmacılarından Dr. Demirhan mevcut çalışmada incelenen numunelerin üretimleri ve testlerini yapmış olup, bunların dışında kalan tüm işlemlerde ise Öğr. Gör. Necim KAYA ve Arş. Gör. Dr. Selahattin AKALP ile eşit oradadırlar.

Etik beyanı

Declaration of ethical code

Bu çalışmada, “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması gerekli tüm kurallara uyulduğunu, bahsi geçen yönergenin “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbirinin gerçekleştirilmediğini taahhüt ederiz.

Çıkar çatışması beyanı

Conflicts of interest

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

Kaynaklar

References

- Atici, U. (2011). 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. <https://doi.org/1016/j.eswa.2011.01.156>
- Ciftci, M., & Demirhan, S. (2021). Effect of nano type and slag replacement level on cement mortars. *Gumushane University Journal of Science Institute*, 11(2), 482-496. <https://doi.org/10.17714/gumusfenbil.867858>

- Çalışkan, A., Demirhan, S., & Tekin, R. (2022). Comparison of different machine learning methods for estimating compressive strength of mortars. *Construction and Building Materials*, 335, 127490. <https://doi.org/10.1016/j.conbuildmat.2022.127490>
- Ding, S., Zhao, H., Zhang, Y., Xu, X., & Nie, R. (2015). Extreme learning machine: algorithm, theory and applications. *Artificial Intelligence Review*, 44(1), 103-115. <https://doi.org/10.1007/s10462-013-9405-z>
- Demirhan, S. (2020). Combined Effects of Nano-Sized Calcite and Fly Ash on Hydration and Microstructural Properties of Mortars. *Afyon Kocatepe University Journal of Science and Engineering Sciences*, 20(6), 1051-1067. <https://doi.org/10.35414/akufemubid.825862>
- Fung, G. M., & Mangasarian, O. L. (2005). Multicategory proximal support vector machine classifiers. *Machine learning*, 59(1-2), 77-97. <https://doi.org/10.1007/s10994-005-0463-6>
- Gültekin, N., & Doğan, A. (2023). Makine Öğrenimi Yöntemleriyle Bazaltlarda Tek Eksenli Sıkışma Dayanımının Değerlendirilmesi ve Performanslarının Karşılaştırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(2), 1059-1074. <https://doi.org/10.29130/dubited.1173624>
- Gültekin, N., & Doğan, A. (2022). Kohezyonlu zeminlerde net limit basınç ve deformasyon modülünün makine öğrenimi temelli modeller kullanılarak tahmin edilmesi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 11(4), 1025-1033. <https://doi.org/10.28948/ngumuh.1155568>
- Ghosh, R., Sagar, S. P., Kumar, A., Gupta, S. K., & Kumar, S. (2018). Estimation of geopolymer concrete strength from ultrasonic pulse velocity (UPV) using high power pulser. *Journal of building engineering*, 16, 39-44. <https://doi.org/10.1016/j.jobbe.2017.12.009>
- Hamidian, M., Shariati, A., Khanouki, M. A., Sinaei, H., Toghrolı, A., & Nouri, K. (2012). Application of Schmidt rebound hammer and ultrasonic pulse velocity techniques for structural health monitoring. *Scientific Research and Essays*, 7(21), 1997-2001. <https://doi.org/10.5897/SRE11.1387>
- Hammoudi, A., Moussaceb, K., Belebchouche, C., & Dahmoune, F. (2019). Comparison of artificial neural network (YSA) and response surface methodology (RSM) prediction in compressive strength of recycled concrete aggregates. *Construction and Building Materials*, 209, 425-436. <https://doi.org/10.1016/j.conbuildmat.2019.03.119>
- Hong, G., Oh, S., Choi, S., Chin, W. J., Kim, Y. J., & Song, C. (2021). Correlation between the Compressive Strength and Ultrasonic Pulse Velocity of Cement Mortars Blended with Silica Fume: An Analysis of Microstructure and Hydration Kinetics. *Materials*, 14(10), 2476. <https://doi.org/10.3390/ma14102476>
- Hosseinpour, M., Sharifi, H., & Sharifi, Y. (2018). Stepwise regression modeling for compressive strength assessment of mortar containing metakaolin. *International Journal of Modelling and Simulation*, 38(4), 207-215. <https://doi.org/10.1080/02286203.2017.1422096>
- Kostić, S., & Vasović, D. (2015). Prediction model for compressive strength of basic concrete mixture using artificial neural networks. *Neural Computing and Applications*, 26(5), 1005-1024. <https://doi.org/10.1007/s00521-014-1763-1>
- Lee, S., Nguyen, N. H., Karamanli, A., Lee, J., & Vo, T. P. (2023). Super learner machine-learning algorithms for compressive strength prediction of high performance concrete. *Structural Concrete*, 24(2), 2208-2228.
- Li, D., Tang, Z., Kang, Q., Zhang, X., & Li, Y. (2023). Machine Learning-Based Method for Predicting Compressive Strength of Concrete. *Processes*, 11(2), 390. <https://doi.org/10.3390/pr11020390>
- Ling, H., Qian, C., Kang, W., Liang, C., & Chen, H. (2019). Combination of support vector machine and K-fold cross validation to predict compressive strength of concrete in marine environment. *Construction and Building Materials*, 206, 355-363. <https://doi.org/10.1016/j.conbuildmat.2019.02.071>
- Madandoust, R., Ghavidel, R., & Nariman-Zadeh, N. (2010). Evolutionary design of generalized GMDH-type neural network for prediction of concrete compressive strength using UPV. *Computational Materials Science*, 49(3), 556-567. <https://doi.org/10.1016/j.commatsci.2010.05.050>
- Revilla-Cuesta, V., Skaf, M., Serrano-López, R., & Ortega-López, V. (2021). Models for compressive strength estimation through non-destructive testing of highly self-compacting concrete containing recycled concrete aggregate and

slag-based binder. *Construction and Building Materials*, 280, 122454. <https://doi.org/10.1016/j.conbuildmat.2021.122454>

- Rodríguez-Pérez, R., Vogt, M., & Bajorath, J. (2017). Support vector machine classification and regression prioritize different structural features for binary compound activity and potency value prediction. *ACS omega*, 2(10), 6371-6379. <https://doi.org/10.1021/acsomega.7b01079>
- Sajid, S. H., Ali, S. M., Saeed, S., Sajid, H. U., & Naeem, A. (2016). Non-destructive testing for in-place strength estimation of concrete masonry units. *Insight-Non-Destructive Testing and Condition Monitoring*, 58(3), 152-156. <https://doi.org/10.1784/insi.2016.58.3.152>
- Shahmansouri, A. A., Yazdani, M., Ghanbari, S., Bengar, H. A., Jafari, A., & Ghatte, H. F. (2021). Artificial neural network model to predict the compressive strength of eco-friendly geopolymer concrete incorporating silica fume and natural zeolite. *Journal of Cleaner Production*, 279, 123697. <https://doi.org/10.1016/j.jclepro.2020.123697>
- Sharma, D., & Chandra, P. (2020). Linear regression with factor analysis in fault prediction of software. *Journal of Interdisciplinary Mathematics*, 23(1), 11-19. <https://doi.org/10.1080/09720502.2020.1721641>
- Sun, J., Zhang, J., Gu, Y., Huang, Y., Sun, Y., & Ma, G. (2019). Prediction of permeability and unconfined compressive strength of pervious concrete using evolved support vector regression. *Construction and Building Materials*, 207, 440-449. <https://doi.org/10.1016/j.conbuildmat.2019.02.117>
- Tang, J., Deng, C., & Huang, G. B. (2015). Extreme learning machine for multilayer perceptron. *IEEE transactions on neural networks and learning systems*, 27(4), 809-821. <https://doi.org/10.1109/TNNLS.2015.2424995>
- TS EN 196-1, 2002, Methods of testing cement - Part 1: Determination of strength
- TS EN 197-1, 2012, Cement- Part 1: Compositions and conformity criteria for common cements
- TS EN 12504-4, 2012, Testing concrete - Part 4: Determination of ultrasonic pulse velocity
- Turgut, P. (2004). Research into the correlation between concrete strength and UPV values. *NDT. net*, 12(12), 1-9.
- Yaprak, H., Karacı, A., & Demir, I. (2013). Prediction of the effect of varying cure conditions and w/c ratio on the compressive strength of concrete using artificial neural networks. *Neural Computing and Applications*, 22(1), 133-141. <https://doi.org/10.1007/s00521-011-0671-x>
- Zengin, S., Demirhan, S., Gözkeser, M. Y., Başaran, E., & Çalışkan, A. (2023). Monitoring consumption of calcium hydroxide via a new approach. *Materials Today Communications*, 36, 106672. <https://doi.org/10.1016/j.mtcomm.2023.106672>