

Efektif Kendiliğinden Yerleşen Hafif Beton Dayanımı Tahmini için Farklı Makine Öğrenmesi Algoritmalarının Karşılıklı Değerlendirilmesi

Hakan GÜLER¹, Mustafa ULAŞ^{2*}, Merve AÇIKGENÇ ULAŞ³

¹ Dijital Dönüşüm ve Yazılım Ofisi, , Bilgi İşlem Daire Başkanlığı, Fırat Üniversitesi, Elazığ, Türkiye

² Yapay Zeka ve Veri Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

³ Mimarlık Bölümü, Mimarlık Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

*¹ hakanguler@firat.edu.tr, ² mustafaulas@firat.edu.tr, ³ mervecacikgenc@firat.edu.tr

(Geliş/Received: 18/09/2024;

Kabul/Accepted: 19/02/2025)

Öz: İnşaat mühendisliği literatüründe, özel beton türlerinin karışım tasarımını modellemek ve bu amaçla betonun bazı özelliklerini tahmin etmek için makine öğrenmesi yöntemleri sıklıkla kullanılmaktadır. Geleneksel karışım tasarımı hesapları, istenilen özellikte betonun üretilmesi için bir deneme yanılma süreci gerektirmektedir. Bu süreçte zaman, işgücü ve malzeme kayıpları yaşanır. Makine öğrenmesi yöntemleri kullanılarak deneme yanılma karışımlarının sayısı azaltılabileceğinden, gerek duyulan özelliklere sahip betonun üretilmesi kolaylaşabilir. Burada söz konusu malzeme Kendiliğinden Yerleşen Hafif Beton (KYHB) gibi özel bir tür beton ise karışım tasarımının pratik hale getirilmesi ile üretim sürecinin hızlandırılması daha büyük önem kazanır. Hem kendiliğinden yerleşen özellikte hem de hafif agrega içeren bu beton türünün istenilen özelliklerde üretilmesi süreci geleneksel betona göre daha zordur. Bu çalışmada, KYHB'nin basınç dayanımını tahmin etmek için dört farklı makine öğrenmesi algoritması karşılaştırılmalı değerlendirilmiştir. Çalışmanın amacı, KYHB bileşiminden basınç dayanımının tahmin edilmesidir. Ek olarak makine öğrenmesi algoritmalarının beton performansını tahmin etmedeki başarısını kanıtlamak ve böylece yöntemin öncelikle beton karışım hesabı için kullanımını artırmaktır. Bu amaçla, KYHB karışımının bazı deneysel özelliklerini ve bileşimini içeren bir veri seti ile Lineer Regresyon, Gauss Süreç Regresyonu, Quadratik ve Kernel Destek Vektör Makinası yöntemleri kullanılarak 4 farklı tahmin modeli geliştirilmiştir. Geliştirilen modellerin performansı, deneysel sonuçlar ile model çıktısı arasındaki doğrusal korelasyon oranı ve hata miktarları açısından değerlendirilmiştir. Gauss Süreç Regresyonu modeli ise bu çalışmada en başarılı makine öğrenmesi metodu olmuştur.

Anahtar kelimeler: Kendiliğinden Yerleşen Hafif Beton, Lineer Regresyon, Gauss Süreç Regresyonu, Destek Vektör Makineleri.

Mutual Evaluation of Different Machine Learning Algorithms for Effective Self-Compacting Lightweight Concrete Strength Prediction

Abstract: Machine Learning (ML) methods are frequently used to model the mix design and to predict some properties of concrete. Traditional mix design calculations require a trial-and-error process to produce concrete with the desired properties. In this process, time, labor, and material losses are experienced. By using ML methods, the number of trial-and-error mixtures can be reduced, making it easier to produce concrete with the required properties. As a special type of concrete, Self-Compacting Lightweight Concrete (SCLWC), it becomes more important to speed up the production process by making the mix design practical. SCLWC, which contains both self-compactibility and lightweight aggregates, is more difficult to produce with the desired properties than conventional concrete. In this study, four different ML algorithms were comparatively evaluated to predict the compressive strength of SCLWC. The aim of the study is to predict the compressive strength from the composition of SCLWC. In addition, to prove the success of ML in predicting concrete performance and thus increase the use of the method primarily for concrete mix calculation. For this purpose, 4 different prediction models were developed using Linear Regression, Gaussian Process Regression, Quadratik and Kernel Support Vector Machine methods with a data set containing some experimental properties and composition of SCLWC mix. The performance of the developed models was evaluated in terms of the linear correlation ratio between the experimental results and the model output and the amount of error. The Gaussian Process Regression model was the most successful ML method in this study.

Key words: Self-compacting Lightweight Concrete, Linear Regression, Gaussian Process Regression, Support Vector Machines.

* Sorumlu yazar: mustafaulas@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-7599-5431, ² 0000-0002-0096-9693, ³ 0000-0001-8986-7791

1. Giriş

Modern beton teknolojisindeki ilerlemelerin bir sonucu olarak ortaya çıkan özel beton türlerinden biri de Kendiliğinden Yerleşen Hafif Betondur (KYHB). Hem kendiliğinden yerleşebilirlik özelliğine sahip hem de birim hacim ağırlığı bakımından geleneksel betona göre daha hafif olan bu beton türü, Hafif Beton (HB) ve Kendiliğinden Yerleşen Betonun (KYB) olarak bilinen iki tür betonun özelliklerini bir araya getirir. Literatürde hem HB hem de KYB'nin karışım tasarımlarına ilişkin ayrı ayrı standartlar olmasına rağmen, KYHB'ye özel bir karışım tasarımı, uygulamasına ilişkin herhangi bir teknik şartname veya referans standart bulunmamaktadır. KYHB tasarımı için HB ve KYB için yazılmış standart ve yönetmeliklerden faydalanılır [1–3]. Örneğin üretilmiş bir betonun KYHB olarak anılabilmesi için taze özelliklerinin KYB için yazılmış EFNARC şartnamelerine uygun olması gerekirken, aynı zamanda TS EN 206-1'e göre fırın kurusu yoğunluğunun 800 ila 2000 kg/m³ olması gerekmektedir [1, 4].

Hedeflenen özelliklere ulaşılabilmesi için çok sayıda deneme yanılma karışımı oluşturarak uygun özellikleri testler sonucunda doğrulanmış betonu üretme sürecine karışım tasarımı denir [5]. Karışım tasarımı yaklaşımının geleneksel beton için geçerli olan deneme-yanılma prosedürü yukarıda bahsedilen özel betonlar için daha uzun sürebilir. Bu sürecin uzaması ise işgücü ve malzeme tüketiminde de artışa neden olur. KYHB ise iki beton türünün birleşimi olduğu için bahsedilen karışım tasarımı süreci daha da uzun sürer ve işgücü ile malzeme sarfı doğal olarak artar. Çünkü KYHB, bileşim özellikleri ve oranlarındaki değişikliklere karşı oldukça hassastır, bu nedenle daha fazla kalite kontrolü gerektirir [3, 6]. KYHB gibi özel betonların karışım tasarım sürecini hızlandırabilecek bir tahmin modeli oluşturmak için makine öğrenme algoritmalarının kullanımı literatürde oldukça yaygındır. Hu vd., çalışmalarında yapay zeka teknolojisinin beton performansının tahminindeki kullanımını incelemişlerdir. Çeşitli algoritmaların kullanımı ve örnek veri miktarının yanı sıra model oluşturma etkileri de değerlendirilerek, yapay zeka tabanlı beton basınç tahmini sistemlerinin performansını analiz etmişlerdir [7]. Ziolkowski vd., yaptıkları çalışmada makina öğrenimi modellerini kullanarak beton karışım sürecini kolaylaştırmayı hedeflemişlerdir. Derin sinir ağı mimarisi ile eğitilen bir makine öğrenimi modeli, geniş bir beton tarifi veritabanı üzerinde geliştirilmiş ve betonun basınç dayanımını tahmin etmek için matematiksel bir formüle dönüştürmüşlerdir. Yaptıkları testlerde, adaptif özelliklere sahip yeni algoritmanın, geleneksel yöntemlere kıyasla önemli ölçüde daha iyi performans gösterdiğini söylemişlerdir [8]. Golafshani vd., çalışmalarında ekstra çimento içeren katkı maddeleri ile üretilmiş geri dönüştürülmüş agregalı beton sıkıştırma dayanımının kapsamlı bir analizini yapmışlardır. Elastic Net regresyonu, K-En Yakın Komşu, Yapay Sinir Ağı, Destek Vektör Makinesi, Karar Ağacı, Rastgele Orman, eXtreme Gradient Boosting, Light Gradient Boosting, Kategori Boosting ve yığılmış yöntemler de dahil olmak üzere çeşitli makine öğrenimi teknikleri kullanmışlardır. En iyi performans gösteren yığma modeli, test sırasında diğerlerine kıyasla %4,2 oranında kök ortalama kare hatasında bir azalma göstermiştir [9]. Başka bir çalışmada ise, ultra-yüksek performanslı beton basınç dayanımını tahmin etmek için güncel makine öğrenimi teknikleri kullanılmıştır. Elde ettikleri sonuçlar ile geliştirilen modellerin beklenen başarılı tahmin performansı sergilemiştir [10]. Farooq vd., yaptıkları çalışmada atık malzemelerle hazırlanan yüksek performanslı betonun dayanımını tahmin etmek için makine öğrenimi yöntemlerini kullanan bir yaklaşımı sunmuşlardır. Bagging, boosting ve ensemble modellerini kullanılarak güçlü modeller oluşturulmuş ve bu modellerin performansı $R^2=0,92$ 'ye kadar çıkarmışlardır. Bu çalışmanın sonuçları, atık malzemelerle hazırlanan yüksek performanslı betonun dayanımını tahmin etmek için etkili bir yaklaşım sunmaktadır [11]. Dao ve ekip arkadaşları, yüksek performanslı betonun basınç dayanımını tahmin etmek için iki yapay zeka tekniğinin, Gaussian Süreç Regresyonu (GPR) ve Yapay Sinir Ağı (ANN), hassasiyetini ve sağlamlığını analiz etmeyi amaçlamışlardır. Matern32 çekirdek fonksiyonunu kullanan GPR, diğerlerini geride bırakarak en iyi performansı sergilediğini göstermişlerdir [12]. Ultra-Yüksek Performanslı Betonun hassas tasarımı ve özelliklerinin tahmini için ise Modifiye Andreasen ve Andersen (MAA) modeli ile Genetik Algoritma tabanlı Yapay Sinir Ağı (GA-ANN) tekniğinin ele alındığı bir çalışmada model, diğer klasik tahmin modellerine kıyasla önemli üstünlükler göstermiştir [13]. Moein vd., çalışmalarında beton mekanik özelliklerini tahmin etmek için başarılı makina öğrenimi ve derin öğrenme model uygulamalarının bir derlemesini sunmuşlardır. Birkaç modelleme algoritması incelemiş, uygulamaları, performansları, mevcut bilgi boşlukları ve gelecekteki araştırmalar için önerileri vurgulamışlardır. İnşaat mühendislerine ve araştırmacılara, uygulamalarına uygun ve doğru teknikleri seçmelerinde yardımcı olacağını söylemişlerdir [14]. Ahmad vd., betonun mekanik özelliklerini tahmin etmek için geniş bir kullanım alanına sahip olan makine öğrenimi tekniklerini değerlendirmişlerdir. Bagging gibi ensemble yöntemlerinin, bireysel algoritmalarla karşılaştırıldığında daha iyi bir tahmin performansı gösterdiğini bulmuşlardır. Özellikle, ensemble modelin karar ağacı ve gen ifade programlama yöntemlerine kıyasla daha yüksek bir R^2 değeri olan 0,911 elde ettiği görülmüştür [15]. Başka bir özel beton türü olan Ultra-Yüksek Performanslı Betonun basınç dayanımını tahmin etmek için akıllı algoritmaların kullanılmasının önemini işleyen

bir araştırmada ise Sıralı Özellik Seçimi (SFS) ve Sinir Açıklama Diyagramı (NID) gibi derin makine öğrenme tekniklerinin yapay sinir ağlarına katkısı incelenmiş ve kritik malzeme bileşenlerini tanımlamaya yönelik bir yöntem sunulmuştur. 110 adet basınç dayanımı testi verisi kullanılarak yapılan bu çalışma, dört ana malzeme bileşeninin (çimento, uçucu kül, silis dumanı ve su) tahmin doğruluğunu önemli ölçüde artırdığını göstermişlerdir [16]. Kaloop vd., betonun basınç dayanımını tahmin etmek için çok değişkenli Adaptif Regresyon Eğri Modeli (MARS) bir özellik çıkarma yöntemi olarak kullanmanın ve ardından Gradyan Ağaç Artırma Makinesi (GBM) öğrenme tekniği ile tahmin etmenin etkinliğini incelemişlerdir. Çimento, yüksek fırın cürufu, su, kimyasal katkı, ince agrega, kür süresi gibi sekiz giriş değişkeninin toplam 1030 veri seti kullanılarak yapılan analiz sonuçları, betonun basınç dayanımını farklı yaşlar için tahmin etmenin mümkün olduğunu göstermiştir [17]. Son olarak, Zheng vd., beton karışım oranlarını optimize etmek için Çok Amaçlı Optimizasyon (MOO) çerçevesi önermişlerdir ve bu amaçla gelişmiş makine öğrenimi yöntemleri kullanmışlardır. Elde ettikleri sonuçlar, 5-katlamalı çapraz doğrulama, hiperparametre optimizasyonu ve regresyon özellik eleme gibi tekniklerin basınç dayanımı ve bağlayıcı yoğunluğu gibi önemli beton performans göstergelerinin tahmin doğruluğunu önemli ölçüde artırdığını ortaya koymuşlardır [18].

Bu çalışmada KYHB'nin basınç dayanımını tahmin etmek için uluslararası deneysel araştırmalardan bir veri seti toplanmıştır. Veri seti, çeşitli KYHB bileşimlerinin oranlarına (çimento, su, mineral tozu, kimyasal katkı, hafif agrega ve normal agrega miktarları) ek olarak KYHB'nin taze hal birim hacim ağırlığı, çökme-yayılma test sonuçları ve basınç dayanımı değerlerini içermektedir. Çalışmanın amacı, KYHB'nin basınç dayanımını en doğru şekilde tahmin etmek için hedef birim hacim ağırlık ve hedef işlenebilirlik ile beton bileşimini kullanan bir makine öğrenmesi modeli oluşturmaktır. Bu amaçla çalışmada dört farklı makine öğrenmesi algoritması kullanılmıştır. Ek olarak bu modellerin birbirleri ile karşılaştırılması ile KYHB dayanımının tahmininde en başarılı modelin ortaya çıkarılması da amaçlanmaktadır. KYHB'nin ön karışım tasarımı için basınç dayanımını tahmin etme ihtiyacını ortadan kaldıracabilecek modeller geliştirmek için Lineer Regresyon (LR), Gauss Süreç Regresyonu (GSR), Quadratik Destek Vektör Makinası (Q-DVM) ve Kernel Destek Vektör Makinası (K-DVM) olarak bilinen makine öğrenmesi algoritmaları seçilmiştir. Sonuç olarak, bu modeller içerisinde en başarılı olan Gauss Süreç Regresyonu (GSR) modeli, en doğru tahmin sonuçlarını üretme kabiliyetini göstermiş ve bu yaklaşımın KYHB'nin ön karışım tasarımında kullanım için en uygun makine öğrenmesi metodu olduğu belirlenmiştir. Basınç dayanımının belirlenen girdilere göre tahmin edilebilmesi ile KYHB için karışım tasarımı sürecinin önemli bir bölümü model üstünde yapılabileceğinden hedeflenen karışımı üretme süreci oldukça kısalabilecektir. Böylece karışım tasarımı sürecindeki zaman, malzeme ve işgücünden önemli bir tasarruf sağlanabilecektir. Son olarak, çalışmada sunulan metod ile KYHB kullanımının artırılmasına katkı sağlanması beklenmektedir.

2. Materyal ve Metot

Çalışmada kullanılan veri seti ile makine öğrenmesi metotları bu bölümde açıklanmıştır.

2.1 Veri setinin toplanması ve düzenlenmesi


Bu çalışmada, literatürdeki deneysel çalışmalardan [19–32] elde edilen deneysel bir veri seti, LWSCC'nin basınç dayanımını tahmin eden modeller geliştirmek için kullanılmıştır. Toplam 116 farklı LWSCC karışımını içeren veri setinin özellikleri Tablo 1'de verilmiştir. KYHB bileşimini oluşturan kg/m^3 cinsinden çimento (Ç), su (S), mineral toz (MT), kimyasal katkı (KK), hafif agrega (HA) ve normal agrega (NA) miktarları ile KYHB'nin taze birim hacim ağırlığı (γ)'nın yanında işlenebilirliği ifade eden çökme-yayılma (ÇY) (mm) değeri makine öğrenmesi modellerinin girişlerini oluşturmaktadır. Bu girişlere karşılık olarak modellerin üreteceği çıkış ise MPa cinsinden KYHB'nin 28 günlük basınç dayanımıdır (f_c) (Tablo 1).

Tablo 1. Veri setinin istatistiksel özellikleri.

	GİRİŞLER							ÇIKIŞ	
	Ç	S	MT	KK	HA	NA	γ	ÇY	f_c
Minimum	180,00	93,80	0,00	0,40	0,00	0,00	1459,00	485,00	14,50
Maksimum	591,00	332,50	270,00	17,90	932,00	1753,00	2343,00	860,00	64,30
Ortalama	419,08	212,03	95,97	6,57	465,29	699,10	1890,26	693,66	34,18
Std. Sapma	92,33	62,68	80,49	4,27	290,55	522,87	211,00	81,44	11,63

Bu çalışmada, beton karışım tasarımı için kullanılan giriş özellikleri ve çıkış özellikleri için histogram grafikleri çizdirilmiştir (Şekil 1a-1i). Modellerin girişleri, çimento miktarı (kg/m^3), su miktarı (kg/m^3), mineral toz miktarı (kg/m^3), kimyasal katkı miktarı (kg/m^3), hafif agrega miktarı (kg/m^3) ve normal agrega miktarı (kg/m^3)

gibi KYHB bileşenlerini içermektedir. Öte yandan girişlere, taze KYHB'nin birim hacim ağırlığı (kg/m^3) ve çökme-yayılma test sonuçları (mm) da dahil edilmiştir. Modellerin çıkışı ise 28 günlük basınç dayanımı (MPa)'dır. Şekil 1'de tüm bu parametreler için frekans histogramları verilmiştir. Bu histogramlar, çalışmada kullanılan veri setinin giriş ve çıkış parametreleri için bir parametrenin farklı aralıklarda hangi sıklıkla dağıldığını göstermektedir. Bu histogramlar, KYHB veri setinin özelliklerinin daha iyi anlaşılmasına ve optimize edilmesine katkı sağlar.



Şekil 1. Tüm giriş ve çıkış verileri için frekans histogramları: a) çimento, b) su, c) mineral toz, d) kimyasal katkı, e) hafif agregat, f) normal agregat, g) taze birim hacim ağırlık, h) çökme-yayılma, i) basınç dayanımı.

Histogramlar incelendiğinde veri setinin hangi aralıklarda yoğunlaşmış olduğu görülmektedir. Şekil 1a, 1b, 1c ve 1d’de sırasıyla çimento su, mineral toz ve kimyasal katkı malzemelerinin literatürden toplanan veri setinde belirli aralıklarda yoğun olarak kullanıldığı görülmektedir. Şekil 1e ve 1f’de verilen hafif ve normal agreganın ise geniş bir aralığa yayılmış olduğu anlaşılmaktadır. Betonların taze birim hacim ağırlıkları (Şekil 1g) ve çökme-yayılma test sonuçlarının (Şekil 1h) ise belirli değerler aralığında yoğunlaşmasının sebebi ise çalışmaya konu olan KYHB’un özel bir beton türü olmasından kaynaklıdır. Son olarak, Şekil 1i’de histogram grafiği görülen basınç dayanımı ise genellikle 30 MPa civarında yoğunlaşmıştır. Bu durum veri setinde mümkün olduğunca normal dayanımlı betonlara yer verilmesinden kaynaklanmaktadır.

2.2 Makine öğrenmesi ve performans ölçümleri

Bu çalışmada, Kendiliğinden Yerleşen Hafif Betonun (KYHB) basınç dayanımını tahmin etmek için dört farklı makine öğrenimi algoritması kullanılmıştır. Çalışmanın bu bölümünde kullanılan makine öğrenmesi algoritmaları tanıtılmıştır.

2.2.1 Lineer regresyon (LR)

LR, iki değişken arasındaki ilişkiyi belirlemek için kullanılan istatistiksel bir model veya yaklaşımdır. Bu modelde, bir değişken Bağımlı Değişken olarak hareket ederken, diğeri Bağımsız Değişken olarak hareket eder. Regresyon çizgisi, bu iki değişken arasındaki ilişkiyi temsil eder [33].

Temelde, basit doğrusal regresyon kullanılarak tek bir değişkenin tahminlerinin yapıldığı görülmektedir. Bu durumda, regresyon denklemi Deklem 1’deki gibidir.

$$Y = a + bX + \varepsilon \quad (1)$$

Burada Y , yanıt veya çıktı veya bağımlı değişken; a , ara kesit; b , doğrusal regresyon çizgisinin eğimi; X , Bağımsız Değişken; ve ε , modelin hatası veya artığıdır. Daha sonra, Çoklu Doğrusal Regresyon kullanılarak birden fazla değişkenin tahminlerinin yapıldığı görülmektedir. Bu durumda, regresyon Denklem 2’deki hale gelir.

$$Y = a + bX_1 + cX_2 + dX_3 + \dots + \varepsilon \quad (2)$$

Burada, Y , yanıt; X_1, X_2, X_3 , bağımsız değişkenler; a , ara kesit; b, c, d , bağımsız değişkenlerin eğimleri; ve ε , tüm regresyon çizgileri için hesaplanan artık hataların toplamıdır.

İki tür regresyon analizinde de amaç, ortak bir faktör olan hatayı (ε) en aza indirmektir. Bu hata, çeşitli matematiksel yöntemler kullanılarak azaltılır. Bazı yaygın yöntemler arasında Kök Ortalama Kare Hatası (RMSE), Ortalama Kare Hatası (MSE), Ortalama Mutlak Hata (MAE), R^2 , En Küçük Kareler Yöntemi, Mutlak hataların toplamı ve Gradyan İniş Yöntemi bulunmaktadır. Bu yöntemler arasında, en yaygın ve rahat olanı RMSE yöntemidir. Bu yöntem, tahmin edilen ve gerçek değerler arasındaki farkın karelerinin köküdür [33].

Uyum performansını değerlendirmek için yaygın olarak kullanılan bir metrik olan RMSE (Kare Kök Ortalama Kare Hata), tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasının karekökünü ifade eder. Formül olarak, RMSE, tahmin edilen değerler (Y_{pred}) ile gerçek veya gözlemlenen değerler (Y) arasındaki farkların karelerinin toplamının gözlem sayısına (N) bölünmesi ve sonrasında karekökünün alınmasıyla hesaplanır. RMSE, bir modelin doğruluğunu değerlendirirken, farkların büyüklüğünün katkısını vurgular ve bu sayede daha büyük farklar daha fazla ağırlığa sahip olur. RMSE’nin Denklem 3’te verilmiştir.

$$RMSE = \sqrt{\frac{\sum (Y_{pred} - Y)^2}{N}} \quad (3)$$

Burada, Y_{pred} tahmin edilen değerler, Y gerçek veya gözlemlenen değerler ve N gözlem sayısını temsil eder. RMSE, genellikle bir modelin performansını değerlendirirken kullanılır ve daha küçük bir RMSE değeri, daha iyi bir model uyumu olarak kabul edilir [34].

Ortalama Kare Hatası (MSE), modelin tahmin hatalarının ortalama büyüklüğünün karesidir. MSE, her bir gözlem için tahmin edilen değer ile gerçek değer arasındaki farkın karesinin ortalaması olarak hesaplanır. Büyük hataların daha büyük bir etkisi olması durumunda MSE’nin değeri büyür, çünkü hataların kareleri alınır (Denklem 4).

$$MSE = \frac{1}{N} \sum_{i=1}^m (X_i - Y_i)^2 \quad (4)$$

Burada, N gözlem sayısını, X_i tahmin edilen değerleri ve Y_i gerçek değerleri temsil eder. MSE'nin en iyi değeri 0'dır, bu durumda model tahminleri gerçek değerlere mükemmel şekilde uyar. En kötü değer ise $+\infty$ 'dir, bu durumda modelin tahminleri gerçek değerlerden çok uzak olur [35].

Başka bir hata metriği olan Ortalama Mutlak Hata (MAE), modelin tahmin hatalarının ortalama büyüklüğünü ifade eder. Model tahminleri ile gerçek gözlemler arasındaki farkların mutlak değerlerinin ortalaması olarak hesaplanır. Büyük hataların ortalama hata üzerinde daha büyük bir etkisi olduğundan, MAE'nin hesaplanmasında farkların mutlak değerleri kullanılır. Bu, her gözlem için hata büyüklüğünün aynı öneme sahip olduğu anlamına gelir. MAE ve RMSE, her ikisi de ilgi değişkeninin birimleri cinsinden ortalama model tahmin hatasını ifade eder. Ancak, RMSE'de hatalar kare alındığından büyük hatalar daha yüksek bir ağırlık kazanır. MAE, mutlak değer kullanarak hata büyüklüklerini hesapladığı için, matematiksel hesaplamalarda istenmeyen mutlak değeri içermez (Denklem 5).

$$MAE = \frac{\sum |Y_{pred} - Y|}{N} \quad (5)$$

Burada, Y_{pred} tahmin edilen değerler, Y gerçek veya gözlemlenen değerler ve N gözlem sayısını temsil eder [36].

R^2 , her endojen değişkenin açıklanan varyansını ölçer ve bu nedenle modelin açıklama gücünün bir ölçüsüdür. R^2 ayrıca, örnekleme içindeki tahmin gücü olarak da adlandırılır. R^2 değeri 0 ile 1 arasında değişir ve daha yüksek değerler, modelin daha fazla açıklama gücüne sahip olduğunu gösterir. Genel bir kılavuz olarak, 0.75, 0.50 ve 0.25 R^2 değerleri sırasıyla sağlam, orta ve zayıf olarak kabul edilebilir. Ancak, kabul edilebilir R^2 değerleri bağlama bağlı olarak değişebilir. Örneğin, hisse senedi getirilerini tahmin etmek gibi bazı alanlarda düşük R^2 değerleri kabul edilebilir olarak görülebilir [37].

2.2.2 Gauss süreç regresyonu (GSR)

Gauss Süreci Regresyonu (GSR) yöntemi, bir probabilistik non-parametrik öğrenme yöntemidir ve genellikle regresyon ve sınıflandırma problemleri için kullanılır. Bu yöntem, çekirdek fonksiyonları nedeniyle non-lineer verilerin modellenmesi için oldukça etkilidir. GSR'nin ana avantajlarından biri, girdi verileri için güvenilir bir yanıt sağlamasıdır [38]. Öncelikle, GSR'nin temel varsayımı, çıktının Denklem 6'daki gibi hesaplanabileceğidir:

$$f(x) = y + e \quad (6)$$

Burada $f(x)$ bağımsız değişkenleri temsil ederken, y hedef değişkenleri (beklenen çıktı) ve e gözlem gürültüsünü simgeler. Bu denklemde, e örnekleme için eşit bir gürültü varyansına sahiptir. GSR regresyonu aşağıdaki genel Denklem 7 ile başlar:

$$f(x) = K_*(K + a_n^2 I)^{-1} y \quad (7)$$

Burada K_* test veri noktalarının eğitim veri noktalarına olan çekirdek fonksiyonlarından oluşan matris, K eğitim veri noktalarının çekirdek fonksiyonlarından oluşan matris, a_n^2 gözlem gürültüsünün varyansı ve I birim matristir. Eğitim adımında, modelin hiper-parametreleri ayarlanır. Bu aşamada genellikle gürültü varsayılmaz. Ardından, test veri setinin çıktıları, eğitim veri setinin çıktıları ve verilen bağımsız değişken kullanılarak tahmin edilir. Yukarıdaki denklemler, modelin tahminlerini açıklar ve gauss sürecinin belirli bir dağılıma sahip olduğunu gösterir. Son olarak, GSR modeli bir tahminin doğruluğunu artırmak için, belirli bir hiper-parametre ayarı yapmak önemlidir. Bu ayarlamalar, genellikle veriye özgüdür ve veri setinin özelliklerine bağlıdır [39].

2.2.3 Quadratik destek vektör makinası (Q-DVM)


Quadratik Destek Vektör Makinası (Q-DVM), Dagher tarafından, ilk kez bir kernel-bağımsız non-lineer sınıflandırıcı olarak önerilmiştir. Bu yöntem, maksimum geometrik marj fikrine dayanır ve eğitim örneklerini 2 boyutlu bir hiper-yüzey ile böler. Q-DVM'nin temel avantajı, uygun çekirdek fonksiyonlarını bulma ve hiper-parametrelerini ayarlama zorluğundan kaçınmasıdır [40, 41].

2.2.4 Kernel destek vektör makinesi (K-DVM)


Kernel Destek Vektör Makinesi (K-DVM) doğrusal olmayan veri kümelerini sınıflandırmak için kullanılan güçlü bir makine öğrenmesi algoritmasıdır. Bu yöntem, veri noktalarını daha yüksek boyutlu bir uzaya eşlemek suretiyle bu uzayda doğrusal olarak ayrılabilir hale getirir. Özellikle, doğrusal bir hiperdüzlemle ayrılamayan veri kümelerini sınıflandırmak için K-DVM oldukça etkilidir. Çeşitli çekirdek fonksiyonları aracılığıyla veri noktalarını yüksek boyutlu uzaylara eşleme esasına dayanır ve bu sayede doğrusal olmayan veri kümelerini başarıyla sınıflandırabilir. Bu yöntem, karmaşık yapıya sahip veri kümeleri üzerinde de etkilidir ve problem bağlamına göre en uygun çekirdek fonksiyonunun seçilmesi önemlidir [42].

3. Bulgular ve Tartışma

Bir özel beton türü olan Kendiliğinden Yerleşen Hafif Beton (KYHB)'nin bileşim parametreleri, çökme-yayılma hedefi ve taze birim hacim ağırlık özelliklerinden, 28 günlük basınç dayanımını tahmin etmeyi amaçlayan bu çalışmada ulaşılan sonuçlar bu bölümde açıklanmıştır. Çalışmada kullanılan 4 farklı makine öğrenmesi algoritmasından ilki, LR modelidir. LR modeli, doğrulama veri setine göre 0,358 RMSE değeri ile en düşük ortalama kare hatayı elde etmiştir. Bu, modelin doğruluk açısından kabul edilebilir bir performans sergilediğini göstermektedir. Ayrıca, $R^2=0,871$ değeri, modelin verilere iyi uyum sağladığını gösterir. Ancak, MAE değeri 0,246'dır, bu da bazı tahminlerin hala iyileştirilebileceğini göstermektedir. LR, basitliği ve yorumlana bilirliliği nedeniyle tercih edilir, ancak daha karmaşık ilişkileri yakalamak için yetersiz olabilir (Şekil 2).




Şekil 2. LR modelinin çıkışları ile deneysel basınç dayanımı verilerin karşılaştırılması.



Şekil 3. Q-DVM modelinin çıkışları ile deneysel basınç dayanımı verilerin karşılaştırılması.


Q-DVM modeli, $RMSE=0,322$ değeri ve $R^2=0,896$ değeri ile oldukça iyi bir performans sergilemektedir. Q-DVM, sınıflandırma problemlerindeki başarısıyla bilinse de, bu sonuçlar, metodun regresyon problemleri için de etkili olduğunu göstermektedir. Ancak, MSE ve MAE değerleri biraz yüksektir, bu da modelin bazı tahminlerde geliştirilebileceğini göstermektedir (Şekil 3).

GSR modeli, $RMSE=0,289$ değeri ve $R^2=0,916$ değeri ile en iyi performansı sergilemektedir. Bu, GSR'nin verilere oldukça iyi uyan ve karmaşık olmayan non-lineer ilişkileri yakalayabilen güçlü bir regresyon modeli olduğunu göstermektedir. Ayrıca, MAE değeri diğer modellere kıyasla daha düşüktür ($MAE=0,211$), bu da GSR'nin tahminlerinin daha kesin olduğunu göstermektedir (Şekil 4).



Şekil 4. GSR modelinin çıkışları ile deneysel basınç dayanımı verilerin karşılaştırılması.


K-DVM modeli, $RMSE=0,394$ değeri ile en düşük performansı sergilemektedir. Ayrıca, R^2 değeri diğer modellere kıyasla daha düşüktür ($R^2=0,844$). Bu, modelin verilere daha az uyum sağladığını ve tahminlerin daha az doğru olduğunu gösterebilir. Ancak, $MAE=0,288$ ile diğer modellere benzerdir, bu da bazı tahminlerin doğruluğunun diğer modellerinkinden düşük olduğunu göstermektedir (Şekil 5).



Şekil 5. K-DVM modelinin çıkışları ile deneysel basınç dayanımı verilerin karşılaştırılması.

Çalışmada, dört farklı regresyon modelinin performansı incelenmiş ve karşılaştırılmıştır. LR, Q-DVM, GSR ve K-DVM, gerçek ve tahmin edilen yanıtlar arasındaki ilişkiyi değerlendiren modeller olmuşlardır. Şekil 6'da tüm modellerin tahminleri grafik olarak görülmektedir. Ayrıca Tablo 2'de modellerin performans ölçüm parametreleri verilmiştir. LR modeli genellikle doğrusal bir ilişki sergilerken, Q-DVM modelinin bazı durumlarda düşük doğrulukla tahmin yaptığı gözlenmiştir. Öte yandan, GSR modeli en düşük RMSE değeri ve en yüksek R^2

değeri ile en iyi performansı gösterirken gerçek ve tahmin edilen yanıtlar arasında neredeyse mükemmel bir uyum göstermiştir. Bu da modelin verilere en iyi uyum sağladığını ve doğru tahminlerde bulunduğunu işaret etmektedir. K-DVM modeli, diğer modellere kıyasla daha yüksek hata oranlarına sahip olmasına rağmen, genel olarak doğrusal bir ilişki sergilemiştir. Çalışmada tercih edilen tüm modellerin tahmin doğrulukları (R^2) %80'in üzerindedir. Bu sonuçlar, farklı regresyon modellerinin performansını değerlendirerek, gelecekteki tahminler için en uygun modelin seçilmesine yardımcı olabilir. Ancak, her bir modelin belirli bir veri setine ve probleme bağlı olarak avantajları ve dezavantajları olduğu unutulmamalıdır.



Şekil 6. Kullanılan regresyon modelleri için doğrulama tahminlerinin görselleştirilmesi.

Tablo 2. KYHB dayanım tahmini için makine öğrenmesi algoritmalarının performans ölçümleri.

Model	RMSE	MSE	R^2	MAE
LR	0,3582	0,1283	0,87100	0,2457
GSR	0,2888	0,08345	0,91614	0,2107
Q-DVM	0,3216	0,1034	0,89605	0,2365
K-DVM	0,3940	0,1553	0,84394	0,2883

Sonuç olarak, KYHB tasarımında GSR gibi bir makine öğrenmesi algoritmasından yararlanılması, beton karışım tasarımı sürecini kısaltacaktır. Bu sayede süreçte meydana gelen malzeme ve işgücü sarfiyatı da azaltılabilecektir. Bu çalışma, farklı regresyon modellerinin karşılaştırılmasıyla, verilerin doğru şekilde analiz edilmesi, gelecekteki tahminlerin geliştirilmesi için de değerli bir rehber sağlayacaktır.

4. Sonuçlar

Bu çalışma, özel bir beton türü olan KYHB'nin bileşim parametreleri, çökme-yayılma hedefi ve taze birim hacim ağırlık özelliklerinden, 28 günlük basınç dayanımını tahmin etmeyi amaçlamıştır. Bu amaçla, dört farklı makine öğrenmesi algoritması kullanan regresyon modelinin performansı detaylı bir şekilde incelenmiştir. Çalışma sonuçları şu şekilde özetlenebilir:

- Öncelikle, LR modelinin performansı gözden geçirilmiştir. Bulgular, LR modelinin doğruluk açısından kabul edilebilir bir performans gösterdiğini ortaya koymaktadır. Ancak, diğer modellerle karşılaştırıldığında, LR daha düşük bir doğruluk seviyesine sahip olduğu gözlemlenmiştir.
- Hata ve korelasyon değerleri karşılaştırıldığında Q-DVM modelinin performansının ise LR modeline göre daha iyi olduğu görülmüştür. Bu sonuçlar, Q-DVM modelinin LR modeline göre daha iyi bir performans sergilediğini göstermektedir.
- Hata değerleri ve korelasyon katsayıları açısından en iyi performansı GSR modeli sergilerken, K-DVM modeli ise bu çalışmadaki en düşük performanslı model olmuştur. Yine de bütün modellerin tahminleri ve deneysel gerçek veriler arasındaki korelasyonlarının %80'in üstünde olması çalışmada geliştirilen tüm

modellerin kullanılabilir olduğunu göstermektedir. GSR modelinin performansı bu açıdan bakıldığında %90'ın üstüne çıkmıştır. Dolayısıyla GSR çalışmada en doğru tahminleri üreten model olmuştur.

- Son olarak, bu çalışma, GSR metodunun KYHB'nin karışım tasarımında kullanılabileceğini göstermiş ve amacına ulaşmıştır. Ek olarak çalışma, farklı regresyon modellerinin karşılaştırmalı bir analizini sunarak, araştırmacılara doğru modeli seçmelerine yardımcı olabilir. Ancak, her bir modelin kendi avantajları ve dezavantajları bulunmaktadır ve hangi modelin tercih edileceği, belirli bir veri setinin özelliklerine ve analiz gereksinimlerine bağlı olacaktır. Bu sonuçlar, gelecekteki farklı beton türlerinin karışım tasarımlarını konu edinen çalışmalar için de değerli bir temel oluşturabilir.

Teşekkür

Yazar katkıları şu şekilde açıklanmıştır: H.G., analizleri gerçekleştirmiştir ve kavramsallaştırma, metodoloji/çalışma, doğrulama, analiz ve yorumlama, araştırma, veri iyileştirme, yazma/orijinal taslak, görselleştirme, metodoloji işlerini gerçekleştirmiştir. M.U. sonuçları yorumlamıştır ve kavramsallaştırma, metodoloji/çalışma, analiz ve yorumlama, yazma/orijinal taslak, görselleştirme, metodoloji işlerini gerçekleştirmiştir. M.A.U., fikir sahibidir ve kavramsallaştırma, doğrulama, analiz ve yorumlama, araştırma, Yazma/inceleme ve düzenleme işlerini gerçekleştirmiştir.

Kaynaklar

- [1] Bibm C, Ermco, EFNARC E. European Guidelines for Self-Compacting Concrete: Specification, Production and Use. SCC European Project Group; 2005.
- [2] Sağlam RN, Açikgenç Ulaş M, Alyamaç KE. Hafif Beton Üretimi İçin Gerekli Olan Hafif Agregası Miktarının Yapay Sinir Ağı ile Tahmin Edilmesi. Fırat Üniversitesi Mühendislik Bilim Derg. 2022;34(2):889-898.
- [3] Vakhshouri B, Nejadi S. Mix design of light-weight self-compacting concrete. Case Stud Constr Mater. 2016;4:1-14.
- [4] TS EN 206 Beton- Özellik, Performans, İmalat ve Uygunluk. Published online 2013.
- [5] TS 802 Beton Karışım Tasarımı Hesap Esasları. Published online 2016.
- [6] Agrawal Y, Gupta T, Sharma R, Panwar NL, Siddique S. A Comprehensive Review on the Performance of Structural Lightweight Aggregate Concrete for Sustainable Construction. Constr Mater. 2021;1(1):39-62.
- [7] Hu X, Li B, Mo Y, Alselwi O. Progress in Artificial Intelligence-based Prediction of Concrete Performance. J Adv Concr Technol. 2021;19(8):924-936.
- [8] Ziolkowski P, Niedostatkiwicz M, Kang SB. Model-Based Adaptive Machine Learning Approach in Concrete Mix Design. Materials (Basel). 2021;14(7).
- [9] Golafshani EM, Kim T, Behnood A, Ngo T, Kashani A. Sustainable mix design of recycled aggregate concrete using artificial intelligence. J Clean Prod. 2024;442:140994.
- [10] Marani A, Jamali A, Nehdi ML. Predicting Ultra-High-Performance Concrete Compressive Strength Using Tabular Generative Adversarial Networks. Mater (Basel, Switzerland). 2020;13(21).
- [11] Farooq F, Ahmed W, Akbar A, Aslam F, Alyousef R. Predictive modeling for sustainable high-performance concrete from industrial wastes: A comparison and optimization of models using ensemble learners. J Clean Prod. 2021;292:126032.
- [12] Dao D Van, Adeli H, Ly HB, et al. A Sensitivity and Robustness Analysis of GPR and ANN for High-Performance Concrete Compressive Strength Prediction Using a Monte Carlo Simulation. Sustainability. 2020;12(3).
- [13] Fan D, Yu R, Fu S, et al. Precise design and characteristics prediction of Ultra-High Performance Concrete (UHPC) based on artificial intelligence techniques. Cem Concr Compos. 2021;122:104171.
- [14] Moein MM, Saradar A, Rahmati K, et al. Predictive models for concrete properties using machine learning and deep learning approaches: A review. J Build Eng. 2023;63:105444.
- [15] Ahmad A, Farooq F, Niewiadomski P, et al. Prediction of Compressive Strength of Fly Ash Based Concrete Using Individual and Ensemble Algorithm. Materials (Basel). 2021;14(4).
- [16] Abuodeh OR, Abdalla JA, Hawileh RA. Assessment of compressive strength of Ultra-high Performance Concrete using deep machine learning techniques. Appl Soft Comput. 2020;95:106552.
- [17] Kaloop MR, Kumar D, Samui P, Hu JW, Kim D. Compressive strength prediction of high-performance concrete using gradient tree boosting machine. Constr Build Mater. 2020;264:120198.
- [18] Zheng W, Shui Z, Xu Z, Gao X, Zhang S. Multi-objective optimization of concrete mix design based on machine learning. J Build Eng. 2023;76:107396.
- [19] Andıç-Çakır Ö, Hızal S. Influence of elevated temperatures on the mechanical properties and microstructure of self consolidating lightweight aggregate concrete. Constr Build Mater. 2012;34:575-583.
- [20] Kaffetzakis M, Papanicolaou C. Mix Proportioning Method for Lightweight Aggregate SCC (LWASCC) Based on the Optimum Packing Point Concept BT - Innovative Materials and Techniques in Concrete Construction. In: Fardis MN, ed. Springer Netherlands; 2012:131-151.
- [21] Ofuyatan OM, Olutoge F, Omole D, Babafemi A. Influence of palm ash on properties of light weight self-compacting

- concrete. *Clean Eng Technol.* 2021;4:100233.
- [22] Aslani F, Ma G, Yim Wan DL, Muselin G. Development of high-performance self-compacting concrete using waste recycled concrete aggregates and rubber granules. *J Clean Prod.* 2018;182:553-566.
- [23] Mazloom M, Mahboubi F. Evaluating the settlement of lightweight coarse aggregate in self-compacting lightweight concrete. *Comput Concr.* 2017;19(2):203-210.
- [24] Ghanbari M, Kohnehpooshi O, Tohidi M. Experimental Study of the Combined Use of Fiber and Nano Silica Particles on the Properties of Lightweight Self Compacting Concrete. *Int J Eng.* 2020;33(8):1499-1511.
- [25] Andiç-Çakır Ö, Yoğurtçu E, Yazici S, Ramyar K. Self-compacting lightweight aggregate concrete: design and experimental study. *Mag Concr Res.* 2009;61(7):519-527.
- [26] Mazaheripour H, Ghanbarpour S, Mirmoradi SH, Hosseinpour I. The effect of polypropylene fibers on the properties of fresh and hardened lightweight self-compacting concrete. *Constr Build Mater.* 2011;25(1):351-358.
- [27] Maghsoudi AA, Mohamadpour S, Maghsoudi M. Mix design and mechanical properties of self compacting light weight concrete. *Int J Civ Eng.* 2011;9(3):230-236. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-80052764281&partnerID=40&md5=fbdde60f5121d637865440a4b9e9a0fa>
- [28] Güneysi E, Gesoğlu M, Booya E. Fresh properties of self-compacting cold bonded fly ash lightweight aggregate concrete with different mineral admixtures. *Mater Struct.* 2012;45(12):1849-1859.
- [29] Papanicolaou CG, Kaffetzakis MI. Lightweight Aggregate Self-Compacting Concrete: State-of-the-Art & Pumice Application. *J Adv Concr Technol.* 2011;9(1):15-29.
- [30] Zarnaghi VN, Fouroghi-Asl A, Nourani V, Ma H. On the pore structures of lightweight self-compacting concrete containing silica fume. *Constr Build Mater.* 2018;193:557-564.
- [31] Hilal NN, Sahab MF, Mohammed Ali TK. Fresh and hardened properties of lightweight self-compacting concrete containing walnut shells as coarse aggregate. *J King Saud Univ - Eng Sci.* 2021;33(5):364-372.
- [32] Li J, Chen Y, Wan C. A mix-design method for lightweight aggregate self-compacting concrete based on packing and mortar film thickness theories. *Constr Build Mater.* 2017;157:621-634.
- [33] Priya KS. Linear regression algorithm in machine learning through MATLAB. *Int J Res Appl Sci Eng Technol.* 2021;9(12):989-995.
- [34] Liemohn MW, Shane AD, Azari AR, Petersen AK, Swiger BM, Mukhopadhyay A. RMSE is not enough: Guidelines to robust data-model comparisons for magnetospheric physics. *J Atmos Solar-Terrestrial Phys.* 2021;218:105624.
- [35] Chicco D, Warrens MJ, Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Comput Sci.* 2021;7:e623.
- [36] Kumar A, Verma A, Shinde G, Sukhdeve Y, Lal N. Crime Prediction Using K-Nearest Neighboring Algorithm. In: 2020 International Conference on Emerging Trends in Information Technology and Engineering (Ic-ETITE). ; 2020:1-4.
- [37] Purwanto A. Partial Least Squares Structural Equation Modeling (PLS-SEM) Analysis for Social and Management Research: A Literature Review. *Journal Ind Eng Manag Res.* 2021;2(4):114-123.
- [38] Açikgenç Ulaş M. Gauss Süreç Regresyonu ve Destek Vektör Makineleri Kullanılarak Değerlendirilen Kendiliğinden Yerleşen Beton Davranışının Deneysel Veri İle Doğrulanması. *Fırat Üniversitesi Mühendislik Bilim Derg.* 2023;35(1):379-388.
- [39] Mahdaviara M, Rostami A, Keivanimehr F, Shahbazi K. Accurate determination of permeability in carbonate reservoirs using Gaussian Process Regression. *J Pet Sci Eng.* 2021;196:107807.
- [40] Dagher I. Quadratic kernel-free non-linear support vector machine. *J Glob Optim.* 2008;41(1):15-30.
- [41] Ye J, Yang Z, Ma M, Wang Y, Yang X. ϵ -Kernel-free soft quadratic surface support vector regression. *Inf Sci (Ny).* 2022;594:177-199.
- [42] Jun Z. The Development and Application of Support Vector Machine. *J Phys Conf Ser.* 2021;1748(5):52006.