

## Gauss Süreç Regresyonu ve Destek Vektör Makineleri Kullanılarak Değerlendirilen Kendiliğinden Yerleşen Beton Davranışının Deneysel Veri İle Doğrulaması

Merve AÇIKGENÇ ULAŞ<sup>1\*</sup>

<sup>1</sup> Fırat Üniversitesi, Mimarlık Fakültesi, Mimarlık Bölümü, Elazığ, Türkiye  
<sup>1</sup> merveacikgenc@firat.edu.tr

(Geliş/Received: 24/01/2023;

Kabul/Accepted: 28/02/2023)

**Öz:** İnşaat Mühendisliği alanında yapı malzemelerinin özellikle betonun karışım tasarımını anlamak ve bazı özelliklerini tahmin edebilmek için makine öğrenmesi metotları sıkça kullanılmaya başlanmıştır. Bu bağlamda oldukça faydalı olan makine öğrenmesi metotları sayısız denilebilecek çeşitliliktedir. Bu çalışmada makine öğrenmesi metotlarından Gauss Süreç Regresyonu (GSR) ve Destek Vektör Makineleri (DVM), Kendiliğinden Yerleşen Beton (KYB)'nin basınç dayanımını tahmin etmek için tercih edilmiştir. Çalışmanın amacı, farklı makine öğrenmesi metotlarının beton performansını tahmin etmekteki başarılarının ispat edilmesi ve böylece bu metotların özellikle beton karışım tasarımı alanında kullanımının artırılmasıdır. Bu amaçla, KYB bileşimini ve özelliklerini içeren deneysel veri seti ile GSR ve DVM modelleri geliştirilmiştir. Geliştirilen modellerin performansları hem birbirleri ile hem de bu alanda başarısını literatürdeki birçok çalışma ile ispat etmiş olan başka bir makine öğrenmesi metodu, Yapay Sinir Ağı ile karşılaştırılmıştır. Sonuçta, deneysel veri ile eğitilen ve doğrulanan GSR ve DVM modellerinin KYB'nin basınç dayanım performansını tahmin etmekte başarılı oldukları ortaya çıkmıştır. Çalışma sonuçlarına göre GSR bu problemdeki en başarılı metot olmuştur. GSR için deneysel veri ile modelin çıkışı arasındaki korelasyon katsayıları eğitim aşamasında 0.9888 ve test aşamasında 0.8648 olarak hesaplanmıştır.

**Anahtar kelimeler:** Destek Vektör Makineleri, Gauss Süreç Regresyonu, Yapay Sinir Ağları, Kendiliğinden Yerleşen Beton, Makine Öğrenmesi.

### Evaluation of Self-Compacting Concrete Behavior by Using Gaussian Process Regression and Support Vector Machines via Experimental Data Validation

**Abstract:** In the field of Civil Engineering, machine learning methods have been used frequently in order to understand the mixture design and to predict some properties of building materials, especially concrete. Machine learning methods, which are very useful in this context, can be said to be innumerable. In this study, Gaussian Process Regression (GPR) and Support Vector Machines (SVM), which are two types of machine learning methods, were preferred to estimate the compressive strength of Self Compacting Concrete (SCC). The aim of the study is to prove the success of different machine learning methods in predicting concrete performance and thus to redound the usage of the methods, especially for concrete mix design. For this purpose, GPR and SVM models were developed with the experimental data set containing the SCC mix composition and properties. The performances of the developed models were compared both with each other and with another machine learning method, Artificial Neural Network, which has proven its success with numerous studies in the literature. As a result, it was revealed that the GPR and SVM models, trained and validated with an experimental dataset, were successful in predicting the compressive strength of SCC. In addition, GSR has been the most successful method in this problem. The correlation coefficients between the experimental data and the output of the GSR model were calculated as 0.9888 in the training state and 0.8648 in the testing state.

**Key words:** Support Vector Machines, Gaussian Process Regression, Artificial Neural Network, Self-Compacting Concrete, Machine Learning.

#### 1. Giriş

Makine öğrenmesi yöntemleri, genellikle insan deneyiminin ve zekasının problem çözme yeteneğinin taklitleri olarak bilinirler. Bu yöntemler karmaşık sorunları, hızlı ve doğru çözüme yeteneğine sahiptir. Karmaşık verilerin analizi ve tahmin yürütme gibi çeşitli uygulamalarda yaygın olarak kullanılırlar. Gerçek hayattan gelen veri setlerinin kullanılması yoluyla, makine öğrenmesi yöntemleri doğruluklarını ve performanslarını sürekli olarak geliştirebilir [1]. Veri setleri ile ilgili olan mühendislik problemleri için genellikle regresyon analizi kullanılarak, iki veya daha çok değişken arasındaki ilişki bulunabilir ve bu ilişki kullanarak sonuç üzerine tahminler yürütülebilir. Makine öğrenmesi yöntemleri ise mühendislik problemleri için regresyon analizine alternatif bir yöntem olarak karşımıza çıkmaktadır [2]. Matematiksel modeller ile çözülemeyecek boyutta karmaşık veri setlerinin değerlendirilmesinde makine öğrenmesi yöntemleri daha kullanışlıdır. Literatürde eğri uydurma veya diğer yöntemlerle çözüm için bir denklem elde edilmesi, sonucun sınırlı bir çözüm uzayında kalmasına neden olmaktadır. Ancak sınırlı verilerle, makine öğrenmesi yöntemleri sayesinde daha geniş bir alanda

\* Sorumlu yazar: [merveacikgenc@firat.edu.tr](mailto:merveacikgenc@firat.edu.tr). Yazarın ORCID Numarası: <sup>1</sup> 0000-0001-8986-7791

yüksek doğrulukta sonuçlar elde etmek mümkündür [3], [4]. Ayrıca makine öğrenmesi yöntemleri kullanılarak herhangi bir hesaplama yapmadan giriş değerleri verilerek sonuçlara çok hızlı bir şekilde ulaşılabilmektedir. Böylece karmaşık matematiksel modelleri çözmeye çalışmak yerine zaman, işçilik, maliyet gibi birçok parametreden kazanç elde etmek için de makine öğrenmesi yöntemleri tercih edilebilir [1], [5], [6].

İnşaat mühendisliği alanında ise makine öğrenmesi yöntemlerinin sıkça kullanıldığı problemlerden biri de beton karışım tasarımıdır. Geleneksel beton karışım tasarımı hesabında yaklaşık matematiksel hesaplamalara ek olarak, hedef işlenebilirlik ve dayanım özelliklerine sahip betonun üretilmesi için bir takım deneysel ispatlara da ihtiyaç vardır. Karışım tasarımı hesabı sonuçlarına göre üretilen betonun gerekli işlenebilirlik ve dayanım özelliklerine uygun olmaması halinde ise hesabın yenilenmesinden yeni beton karışımının üretilip testlere tabi tutulmasına kadar bütün süreç baştan başlatılır. İstenilen özelliklere sahip beton elde edilene kadar tasarım süreci devam eder [7]. Bu durum, üretim süresini uzattığı gibi, üretilen deneme-yanılma karışımları ile maliyet ve işçilik kaybına da yol açmaktadır. Burada, hedef özelliklerin belirlenmesi ve deneme-yanılma karışımlarının sonuçlarına göre bileşenlerin nasıl değişeceği kararları mühendis veya teknisyene aittir. Mühendis veya teknisyenin bilgi ve tecrübesi doğrultusunda sürecin seyri olumlu şekilde değişebilir [1], [5], [6].

Makine öğrenmesi yöntemlerinin devreye girmesi ile hakkında kesin bir matematiksel hesap bulunmayan beton karışım tasarımı kullanıcı için destekleyici olabilir. Hatta makine öğrenmesi ile oluşturulan modele geleneksel beton karışım tasarımında ele alınmayan girdiler bile eklenebilir. Bu şekilde ihtiyaç duyulan parametreler, makine öğrenmesi tarafından önceden tahmin edilerek beton üretim süreci daha verimli hale getirilebilir. Makine öğrenmesi sayesinde üretim aşamasında deneme-yanılma karışımlarının sayısı azaltılabilirse, tasarım süreci kısalar, işçilik ve maliyet düşer [5].

Bu bağlamda, literatürde en çok karşılaşılan makine öğrenmesi yöntemi Yapay Sinir Ağları (YSA)'dır. Birçok farklı beton türünde, beton bileşenlerinden işlenebilirlik testlerinin sonuçlarını ya da basınç dayanımını tahmin eden YSA modelleri bu alanda oldukça başarılıdır [8]–[16]. Ek olarak, hedef dayanım ve/veya işlenebilirlik özelliklerinin girişlere dahil edildiği ve beton bileşiminin tahmin edildiği başarılı YSA modelleri de literatürde mevcuttur [5], [6], [17].

Bu çalışmada, iki farklı makine öğrenmesi yöntemi kullanılmıştır: Gauss Süreç Regresyonu (GSR) ve Destek Vektör Makineleri (DVM). GSR ve DVM modellerinin başarıları hem birbirleri ile hem de aynı problem üstünde çalıştırılan YSA modeli ile karşılaştırılmıştır. GSR ve DVM, literatürde YSA kadar sık karşılaşılan makine öğrenmesi yöntemlerinden olmasalar da, beton özelliklerinin tahmini konusunda bazı çalışmalarda kullanılmışlardır. Örneğin beton bileşimi, beton kür koşulları ve beton yoğunluğundan beton basınç dayanımını tahmin edebilen başarılı DVM modeli geliştirilmiştir [18]. Ayrıca Ling vd. (2019) [19] çalışmalarında DVM ve YSA modellerini beton basınç dayanımını tahmin etmek için kullanmışlar ve DVM modelinin daha başarılı tahmin sonuçları ürettiğini söylemişlerdir. Fan vd. (2020) [20] ise iki farklı çeşit DVM kullanarak oluşturdukları modeller ile beton bileşimini tahmin etmeyi başarmışlardır. Altay vd. (2020) [1] bir ön karışım tasarımı oluşturmak amacıyla, çelik lif donatılı kendiliğinden yerleşen betonun iki farklı işlenebilirlik özelliğini tahmin etmek için bir DVM modeli geliştirmişlerdir. Bunlara ek olarak beton bileşiminde ihtiyaç duyulacak biokatkı miktarının [21], epoksi cam tozunun [22] ve betonda karbonatlaşma derinliğinin [23] tahmin edilmesi problemlerinde de DVM başarılı bir şekilde kullanılmıştır.

GSR ile ilgili çalışmalar ise literatürde oldukça sınırlıdır. Başaran vd. (2021) [24] çalışmalarında birkaç parametreyi göz önünde bulundurarak betona gömülü FRP çubukların bağ kuvvetlerini tahmin eden altı farklı model oluşturmuşlardır. Bu modeller içinde DVM ve YSA'nın yanında GSR modeli de mevcuttur. Çalışma sonuçlarına göre, beton ile FRP çubukların arasında oluşan bağ kuvvetini tahmin etmekte altı model içerisinde en başarılı olanların GSR ve YSA modelleri olduğu ortaya koyulmuştur [24]. Liu vd. (2022) [25] ise geri dönüştürülmüş agrega ile üretilmiş betonun sülfata dayanıklılığının tahmin edilmesi için geliştirdikleri sekiz farklı model içerisinde GSR'nin, YSA'dan sonra en başarılı model olduğunu söylemişlerdir.

Bu çalışmada ise GSR ve DVM, özel bir beton türü olan Kendiliğinden Yerleşen Beton (KYB)'nin basınç dayanımını tahmin etmek için kullanılmışlardır. Geleneksel betondan daha karmaşık bir karışım tasarımı sürecine sahip olan KYB şöyle tanımlanabilir: vibrasyona ihtiyaç duymaksızın, yoğun donatılı, derin veya dar kesitlere kendiliğinden yerleşebilen ve bu sırada ayrışmadan veya su kusmadan stabilitesini koruyabilen, taze özellikleri geliştirilmiş özel bir beton türüdür [26], [27]. KYB'nin basınç dayanımının tahmin edilebilmesi için kapsamlı bir veri seti elde edilmiştir. Bu veri seti, 269 farklı KYB bileşim oranını (çimento, su, iri ve ince agrega miktarları, en büyük agrega tane boyutu, kimyasal katkı ve toz malzeme miktarları) ile taze betonun çökme-yayıma deneyi sonucu ve beton basınç dayanımı değerini içermektedir. Çalışmanın amacı, KYB için beton bileşiminden ve hedef işlenebilirlik özelliğinden yararlanarak basınç dayanımını tahmin eden modeller geliştirilmesidir. Ek olarak literatürde KYB'nin basınç dayanımını tahmin etmekte sıkça kullanılan YSA modellerinin yanı sıra GSR ve DVM gibi modellerin de başarılarını ortaya çıkarmak amaçlanmıştır. Çalışma kapsamında KYB'nin ön karışım tasarımı

için basınç dayanımının tahmin edilmesi probleminde başarılı GSR ve DVM modelleri geliştirilebilmiştir. Bu modellerin performansları, aynı veri seti ile eğitilmiş YSA modeli ile karşılaştırılmıştır. Sonuçta, GSR ve DVM modellerinin, YSA'dan daha başarılı tahmin sonuçları üretebildiği gösterilmiş ve böylece bu yöntemlerin beton karışım tasarımında kullanımının yaygınlaştırılması hedeflenmiştir.


## 2. Veri Seti ve Çalışmada Kullanılan Yöntemler

Bu çalışmada, makine öğrenmesi yöntemleri kullanılarak KYB'nin basınç dayanımını tahmin eden modeller oluşturmak için literatürde yer almış [28]–[40] referans numaralı deneysel çalışmalardan elde edilen kapsamlı bir deneysel veri seti kullanılmıştır. Toplamda 269 farklı KYB karışımı içeren veri setinin istatistik özellikleri Tablo 1'de verilmiştir.

Şekil 1'de ise çalışmada kullanılan makine öğrenmesi modellerinin giriş ve çıkışları şematik olarak gösterilmiştir. Kendiliğinden yerleşen beton bileşimini oluşturan çimento, su, iri ve ince agrega miktarları, en büyük agrega tane boyutu ( $D_{max}$ ), kimyasal katkı ve toz malzeme miktarları ile taze KYB'nin çökme-yayılma değeri modellerin girişlerini oluşturmaktadır. Bu girişlere karşılık, GSR, DVM ve YSA modellerinin üreteceği çıkış ise KYB'nin 28 günlük basınç dayanımı ( $f_c$ )'dir.

**Tablo 1.** Veri setinin istatistiksel özellikleri

	Girişler								Çıkış
	Çimento (kg/m <sup>3</sup> )	Su (kg/m <sup>3</sup> )	İri Agrega (kg/m <sup>3</sup> )	İnce Agrega (kg/m <sup>3</sup> )	$D_{max}$ (mm)	Kimyasal Katkı (kg/m <sup>3</sup> )	Toz Malzeme (kg/m <sup>3</sup> )	Çökme Yayılma (mm)	$f_c$ (MPa)
Maksimum	670.00	508.40	953.00	1095.16	19.00	24.44	465.00	825.00	86.80
Minimum	180.00	140.00	523.71	640.00	9.50	0.46	0.00	500.00	16.30
Ortalama	392.82	191.76	759.57	819.40	15.11	8.89	164.04	666.89	51.55
Standart Sapma	83.04	54.68	108.99	107.85	1.84	5.06	90.21	59.87	14.76



**Şekil 1.** KYB performansını tahmin etmek için tasarlanan modeller.

Girişler belirlenirken KYB'nin basınç dayanımını en çok etkileyen iki parametre göz önünde bulundurulmuştur: KYB bileşimi ve KYB'nin işlenebilirliği. Bileşimi oluşturan çimento dozajı, su miktarı, varsa toz malzeme miktarı, iri agrega ve ince agrega miktarları, kimyasal katkı miktarının KYB'nin hem işlenebilirlik hem de mekanik dayanım performanslarını doğrudan etkilediği bilinmektedir [31], [41], [42]. Ayrıca bileşime giren su ve kimyasal katkı miktarının yanı sıra  $D_{max}$  da işlenebilirlik ve basınç dayanımı üzerinde oldukça etkilidir [9], [42], [43]. KYB'de en sık kullanılan işlenebilirlik testinin, çökme yayılma testi olduğu bilinmektedir [6]. Bu nedenle, model girişlerine, KYB'nin işlenebilirlik özelliğini temsil etmek için bu testin sonuçları da dahil edilmiştir. Böylece, seçilen tüm bu girişler ile talep edilen işlenebilirliğe sahip KYB'nin basınç dayanımı için bir tahmin modeli geliştirmek mümkün olabilecektir.

GSR, DVM ve YSA modellerinin problemi öğrenme ve sonuç üretebilme performanslarının karşılaştırılabilmesi için ilk olarak 269 veri, eğitim verisi ve test verisi olarak iki ayrı grupta toplanmıştır. Literatürde verilerin bu şekilde ayrılması ile YSA modelleri sıkça geliştirilirken, GSR ve DVM modellerinin

geliştirilmesi sürecinde bu şekilde bir ayrıma pek rastlanılmamaktadır. Bu çalışmada geliştirilen modellerin tamamının test verisine üretebildikleri sonuçlar da bir performans ölçütü olarak değerlendirilmiştir. Bu amaçla, toplam veri seti, %80'i eğitim aşamasında ve %20'si ise test aşamasında kullanılmak üzere rastgele iki gruba ayrılmıştır. 215 veri içeren eğitim veri seti, üç makine öğrenmesi yönteminde de öncelikle modellerin problemi öğrenmesi için kullanılmıştır. Ardından kalan 54 adet veriden oluşan test veri seti ile modeller test edilmişlerdir.

Çalışmada geliştirilen tahmin modelleri için kullanılan makine öğrenmesi metotları aşağıda açıklanmıştır.

## 2.1. Destek vektör makineleri (DVM)

İlk olarak Cortes ve Vapnik [44] tarafından geliştirilen DVM, temelde istatistiksel bir öğrenme teorisi ve yapısal risk minimizasyonu yöntemidir. DVM, esasen giriş değerlerini (vektörlerini) sınıflara ayırarak bu sınıflar arasındaki sınırı öğrenmeyi amaçlar. Bu sınır, problemin giriş sayısına bağlı olarak doğrusal bir eğri, iki boyutlu bir düzlem ya da çok boyutlu bir hiperdüzlem olabilir. Bu çalışmadaki gibi çoklu değişkenlere sahip doğrusal olmayan problemlerin çözümü için, doğrusal olmayan DVM, n boyutlu hiperdüzlemi girişleri sınıflara ayıran optimum karar yüzeyi olarak tanımlar ve girişleri bu hiperdüzleme olan uzaklıklarına göre sınıflandırır [1], [44]–[46].

Örneğin, ikinci derece bir polinoma karşılık gelen bir karar yüzeyi elde etmek için, Denklemler 1-3'deki gibi  $N = n(n + 3)/2$  koordinata sahip bir özellik uzayı ( $Z$ ) oluşturulursa [44]:

$$Z_1 = x_1, \dots, Z_n = x_n \quad ; n \text{ koordinatlı}, \quad (1)$$

$$Z_{n+1} = x_1^2, \dots, Z_{2n} = x_n^2 \quad ; n \text{ koordinatlı}, \quad (2)$$

$$Z_{2n+1} = x_1 \cdot x_2, \dots, Z_N = x_n \cdot x_{n-1} \quad ; n(n - 1)/2 \text{ koordinatlı}, \quad (3)$$

burada  $x = (x_1, \dots, x_n)$  girişleri olup,  $Z$  özellik uzayında bir hiperdüzlem oluşturulur [44]. DVM'nin amacı optimum ayırıcı hiperdüzlemi elde etmektir [47]. Burada DVM modelinin çekirdek (Kernel) fonksiyonu önemlidir. Bu çalışmada en iyi sonucu veren DVM modelinin çekirdek fonksiyonu Gauss fonksiyonudur.

## 2.2. Gauss süreç regresyonu (GSR)

GSR, genellikle doğrusal olmayan çok değişkenli regresyon ve sınıflandırma problemlerin çözümü için kullanılan başarılı ve esnek bir makine öğrenme yöntemidir. GSR'nin en önemli avantajı, sonuçları üzerinde belirsizlik ölçümleri yapılabilmesi ve böylece parametrik olmayan küçük veri setlerinde bile başarılı tahminler üretebilmesidir [46], [48].

Sonuçları oluşturan temel işlevin, tamamen bir ortalama işlev,  $m(x)$  ve bir kovaryans işlevi,  $k(x, x')$  tarafından belirtilen stokastik bir süreç olan bir Gauss Süreci olduğu varsayımına dayanır. Gauss Sürecinin ortalama işlevi, girdi değişkenlerini çıktı değişkenlerine eşleyen herhangi bir işlev olabilirken kovaryans işlevi, işlevin düzgünlüğünü ve benzerliğini kodlar [49], [50].

Bir dizi giriş-çıkış çifti  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  verildiğinde, verinin olasılığı şu şekildedir:

$$p(y|X, \theta) = N(y|0, K + \sigma^{2n}) \quad (4)$$

burada  $X$  girdi değişkenlerinin matrisidir,  $\theta$  hiperparametrelerin bir vektörüdür,  $K$ ,  $k(x_i, x_j)$  ögelerini içeren kovaryans matrisidir,  $\sigma^2$  gürültü varyansıdır [50], [51].

GSR'nin amacı ise aşağıda verilen  $f(x)$  fonksiyonunu bulmaktır ki; bu fonksiyon  $y$ 'nin  $x$  üzerindeki dağılımıdır [51]:

$$p(f|X, y, \theta) = N(f|m(x), K) \quad (5)$$

burada  $m(x)$ , ortalama işlev ve  $K$ , kovaryans işlevidir. Modelin hiperparametreleri, verilerin marjinal olasılığını maksimize ederek tahmin edilebilir [51].

Farklı ortalama ve kovaryans fonksiyonlarını seçerek, farklı türde veri setleri modellenabilir. GPR'deki en önemli adımlardan biri kovaryans fonksiyonunun seçimidir. Bu çalışmada geliştirilen GSR modeli için yaygın olarak kullanılan kovaryans fonksiyonlarından biri olan üstel (exponential) kernel fonksiyonu [51] kullanılmıştır.

GPR'nin ana dezavantajı ise özellikle büyük veri kümeleri için hesaplama açısından yavaş ve maliyetli bir yöntem olabilmesidir. Bununla birlikte, hesaplamayı hızlandırmak için kullanılabilir birkaç yaklaşım yöntemi mevcuttur [48].

### 2.3. Yapay sinir ağları (YSA)

YSA, insan beyninin öğrenme yeteneğini simüle eden bir makine öğrenmesi yöntemi olarak tanımlanmaktadır. YSA, tıpkı bir insan beyni gibi öğrenme, hatırlama, çözme ve akıl yürütme yetenekleriyle sorunlara yanıtlar üretir, böylece bilinen örneklerin girdi ve çıktılarının ilişkisini modelleyerek problemlerin tahmininde başarılı bir şekilde uygulanır [5], [52].

Bir problemi öğrenmek için, yapay nöronlar YSA'nın katmanlarında bir araya gelirler. Giriş ve çıkış katmanlarındaki nöronlar problemin giriş ve çıkış sayıları ile aynı iken, bu iki katman arasındaki gizli katman sayısı ve her bir gizli katmandaki yapay nöron sayısı YSA mimarisini belirler. Ağın çıktısı ile hedef veri arasındaki hatayı en aza indirmek için farklı YSA mimarileri ile birkaç deneme yapmak gerekir [5], [53], [54]. Bu çalışmada, gizli katmandaki gizli hücrelerin sayısı Kaba Arama (Brute Force) yöntemi ile sabitlenmiştir. Kaba Arama, teorik sınırlar içinde tüm olası mimariler arasından en az hatayı üreten en başarılı YSA mimarisinin seçilmesi olarak bilinir [54], [55].

YSA, özellikle betonun basınç dayanımını tahmin etmekte literatürde çokça kullanılan bir yöntemdir ve başarısı birçok çalışma ile ortaya koyulmuştur [5], [6], [9]–[16]. Bu çalışmada ise bir YSA modeline yer verilmesindeki amaç, GSR ve DVM modellerinin performanslarının çalışma alanında başarısını kanıtlamış bir başka modelle karşılaştırılmasıdır.

### 3. Bulgular ve Tartışma

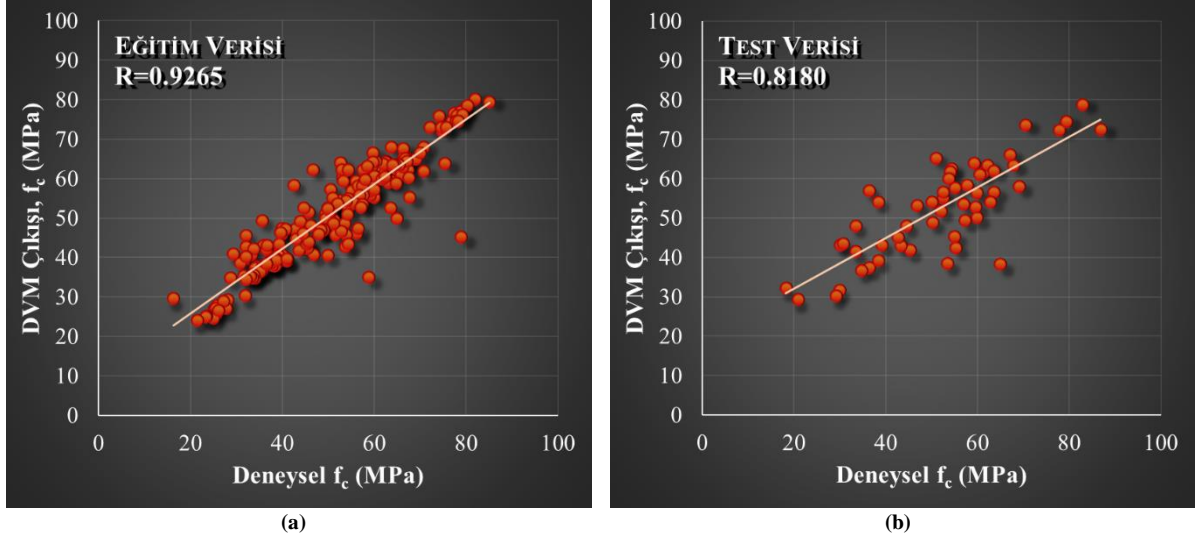
Bu çalışmada, KYB bileşimi ve hedeflenen işlenebilirlikten yola çıkılarak KYB'nin basınç dayanımını tahmin edebilen makine öğrenmesi modelleri geliştirmek ve bu modellerin performanslarını birbirleri ile karşılaştırmak amaçlanmıştır. Bu amaçla geliştirilen GSR, DVM ve YSA modellerinin girişleri, KYB'de yer alan çimento dozajı, su miktarı, iri ve ince agrega miktarları ile  $D_{max}$  değeri, kimyasal katkı miktarı, toz malzeme miktarı ve çökme yayılma testi sonucundan oluşmaktadır. Modellerin bu girişlere karşılık KYB'nin basınç dayanımı ( $f_c$ )'yi tahmin etmesi sağlanmıştır. Toplamda 269 adet deneysel veri den oluşan veri seti, modelleri eğitmek ve doğrulamak için kullanılmıştır. GSR ve DVM modelleri öncelikle 269 verinin, 215'i ile eğitilmiştir. Daha sonra geliştirilen modeller eğitim aşamasına dahil edilmemiş 54 adet veri ile test edilmişlerdir. Çalışmada geliştirilen makine öğrenmesi modellerinin tamamı MATLAB programı kullanılarak tasarlanmıştır.

Eğitim ve test aşamalarında modellerin ürettiği çıkışların doğruluğunu ölçmek amacıyla tahmin edilen beton basınç dayanımı değerleri ile deneysel olarak elde edilmiş beton basınç değerleri arasında bir doğrusal ilişki kurulmuştur. Bu doğrusal ilişkilerin korelasyon katsayıları (R) Denklem (6) kullanılarak hesaplanmıştır.

$$R = \frac{\sum_i \sum_j (f_{c,ij}^{tahmin} - \overline{f_c^{tahmin}}) \cdot (f_{c,ij}^{deneysel} - \overline{f_c^{deneysel}})}{\sqrt{\left(\sum_i \sum_j (f_{c,ij}^{tahmin} - \overline{f_c^{tahmin}})^2\right) \cdot \left(\sum_i \sum_j (f_{c,ij}^{deneysel} - \overline{f_c^{deneysel}})^2\right)}} \quad (6)$$


Denklem (6)'da  $f_{c,ij}^{tahmin}$ , tahmin edilen  $i$ . beton basınç dayanımı değeri;  $f_{c,ij}^{deneysel}$ , deneysel  $i$ . beton basınç dayanımı değeri;  $\overline{f_c^{tahmin}}$ , tahmin edilen beton basınç dayanımı değerlerinin ortalaması;  $\overline{f_c^{deneysel}}$ , deneysel beton basınç dayanımı değerlerinin ortalamasıdır.

Şekil 2a ve 2b'de deneysel  $f_c$  değerlerine karşılık, geliştirilen DVM modelinin tahmin ettiği  $f_c$  değerleri grafik olarak verilmiştir. Deneysel veri ile modelin tahmin ettiği değerler arasında doğrusal bir ilişki mevcuttur. Buna göre bu doğrusal ilişkilerin korelasyon katsayıları (R), DVM modelinin eğitim aşamasında 0.9265 ve test aşamasında ise 0.8180 olarak hesaplanmıştır (Şekil 2a-2b).



Şekil 2. DVM çıkışlarının deneysel veri ile karşılaştırılması, a) eğitim verisi ve b) test verisi.

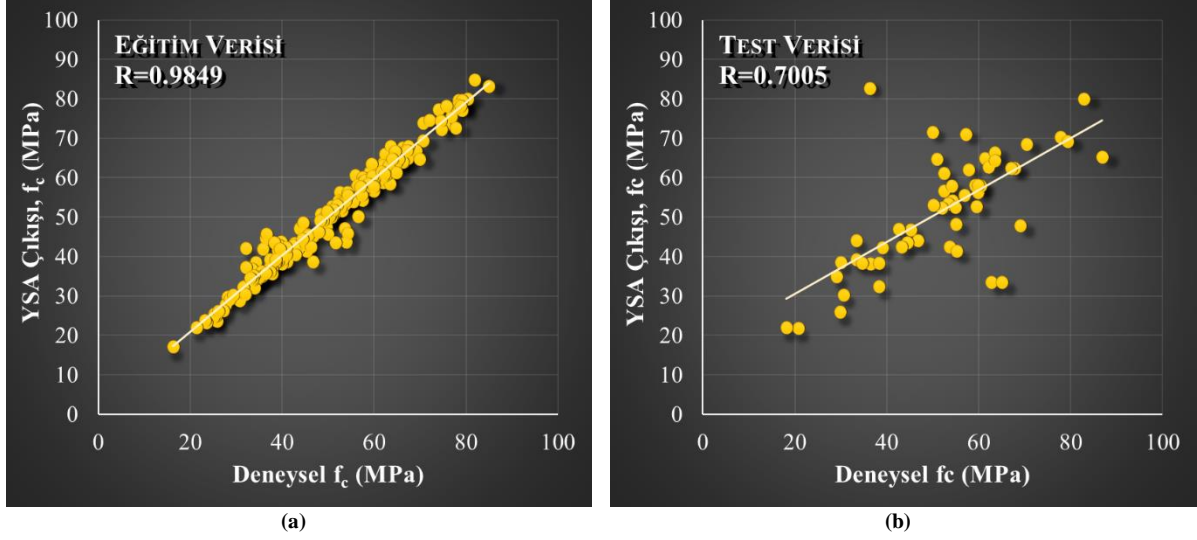
Geliştirilen GSR modelinin, deneysel  $f_c$ 'ye karşılık tahmin ettiği  $f_c$  değerleri ise eğitim ve test aşamaları için sırasıyla Şekil 3a ve 3b'de görülmektedir. GSR modelinin eğitim aşamasında deneysel veri ile modelin çıkışı arasındaki korelasyon katsayısı 0.9888 ve test aşamasında 0.8648'dir. Korelasyon katsayısı değerleri karşılaştırıldığında hem eğitim hem de test aşamalarında GSR modelinin DVM modelinden daha başarılı olduğu görülmektedir. Ayrıca iki model de test veri setini %80'in üzerinde bir doğrulukla tahmin edebilmişlerdir.



Şekil 3. GSR çıkışlarının deneysel veri ile karşılaştırılması, a) eğitim verisi ve b) test verisi.

Literatürde beton bileşiminden basınç dayanımının tahmin edilmesi probleminde üstün başarı sergileyen ve en çok bilinen makine öğrenmesi yöntemi YSA'dır [5], [6], [9]–[16]. Bu sebeple, bu çalışma kapsamında geliştirilen GSR ve DVM modellerinin başarısı, aynı veri seti ile eğitilmiş ve test edilmiş YSA modeli ile de karşılaştırılmıştır. Çalışmada tasarlanan YSA, deneme yanılma yoluyla oluşturularak kullanılan deneysel veri setine en başarılı çıkışları üretebilen YSA modelidir. Şekil 4a ve 4b'de görülen sonuçları üretmiş olan 8 girişli YSA modelinin, bir gizli katmanında 10 adet gizli yapay sinir hücresi ve 1 adet çıkışı bulunmaktadır. Gizli katmandaki hücrelerin aktivasyon fonksiyonu, tanjant sigmoid aktivasyon fonksiyonudur. Şekil 4a'da 215 adet eğitim verisi ile geliştirilen YSA modelinin, deneysel  $f_c$  değerlerine karşılık tahmin edilen  $f_c$  değerleri ile karşılaştırılması görülmektedir. Burada eğitim aşamasındaki korelasyon katsayısı, 0.9849 olarak hesaplanmıştır. Şekil 4b'de ise YSA modelinin deneysel test verisine ürettiği çıkış  $f_c$  değerleri ile deneysel  $f_c$  değerleri arasındaki

doğrusal ilişki verilmiştir. Test verisi için korelasyon katsayısı, 0.7005 olarak hesaplanmıştır. Bu korelasyon değerleri karşılaştırıldığında hem eğitim hem de test aşamalarında GSR ve DVM modellerinin çalışmada kullanılan veri setine YSA'dan daha başarılı sonuçlar üretebildikleri görülmektedir.



Şekil 4. YSA çıktılarının deneysel veri ile karşılaştırılması, a) eğitim verisi ve b) test verisi.

Makine öğrenmesi metotları kullanılarak geliştirilen modellerin, çıktıları tahmin etmekteki başarısını ölçmek için korelasyon katsayılarının yanı sıra deneysel veri ile model çıkışı arasında hesaplanan hata oranları da kullanılmaktadır. Hata oranı, her bir veri için ayrı ayrı basit fark değerleri olarak hesaplanabileceği gibi, bütün veri setinin hatasını tek bir rakamsal değer ile ifade edebilecek şekilde hesaplanabilir. Bu çalışmada eğitim ve test veri setlerinde oluşan, deneysel  $f_c$  ile modellerin tahmin ettiği  $f_c$  değerleri arasında oluşan hata miktarları iki farklı şekilde hesaplanmıştır. Bu hata değerlerinden biri Kök Ortalama Kare Hata (Root Mean Squared Error - RMSE) miktarı, Denklem (7) ve diğeri Ortalama Mutlak Hata (Mean Absolute Error - MAE) miktarı, Denklem (8) kullanılarak hesaplanmıştır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (f_{c,i}^{tahmin} - f_{c,i}^{deneysel})^2}{N}} \quad (7)$$

$$MAE = \frac{\sum_{i=1}^N |f_{c,i}^{tahmin} - f_{c,i}^{deneysel}|}{N} \quad (8)$$

Denklem (7) ve (8)'de  $N$ , veri sayısı;  $f_{c,i}^{tahmin}$ , tahmin edilen  $i$ . beton basınç dayanımı değeri;  $f_{c,i}^{deneysel}$ , deneysel  $i$ . beton basınç dayanımı değeridir.

Tablo 2'de geliştirilen DVM, GSR ve YSA modellerinin tahmin ettiği sonuçların doğruluk ve hata değerleri verilmiştir. Gerek korelasyon katsayıları (R) gerekse RMSE ve MAE hata oranları karşılaştırıldığında DVM ve GSR metotlarının YSA'dan daha başarılı olduğu görülmektedir. Ayrıca üç makine öğrenmesi metodu arasında en başarılı olanı GSR'dir. GSR modelinin hem eğitim hem de test veri setleri için en yüksek korelasyon katsayısı değerlerine ve en düşük hata oranlarına sahip olan model olduğu ortaya konulmuştur (Tablo 2).

Tablo 2. Makine öğrenmesi yöntemleri kullanılarak elde edilen tahmin modellerinin performans ölçümleri

	GSR		DVM		YSA	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
Korelasyon Katsayısı (R)	0.9888	0.8648	0.9265	0.8180	0.9849	0.7005
Kök Ortalama Kare Hata (RMSE)	2.2768	7.5684	5.5411	8.6937	2.5364	11.3507
Ortalama Mutlak Hata (MAE)	1.6468	5.4645	3.7392	6.5747	1.6934	7.0424



#### 4. Sonuçlar

KYB'nin basınç dayanımını tahmin eden makine öğrenmesi modelinin geliştirilmesini amaçlayan bu çalışmada aşağıda sıralanan sonuçlara ulaşılmıştır:

- Çalışmada kullanılan üç farklı makine öğrenmesi metodu GSR, DVM ve YSA'dır. Bu metotlar kullanılarak KYB bileşiminden ve taze KYB'nin çökme yayılma değerinden, KYB'nin basınç dayanımını tahmin edebilen modeller geliştirilmiştir.
- Modellerin üçü de problemi eğitim aşamasında %90'ın üzerinde bir doğrulukla öğrenebilmişleridir. Özellikle test aşamasında GSR ve DVM modelleri, daha başarılı sonuçlar üreterek %80'in üzerinde doğruluk oranı yakalamışlardır.
- Literatürde birçok farklı özel beton türünün basınç dayanımının tahmin edilmesinde kullanılan YSA metodu, bu çalışmada kullanılan veri setini öğrenmede GSR ve DVM modelleri kadar başarılı olamamıştır.
- Bu çalışmada gerek korelasyon katsayıları ile gerekse hata oranları ile ölçülen uygunluk hesaplamalarına değerlere göre, en başarılı makine öğrenmesi modeli ise GSR olmuştur.
- Gelecek çalışmalar için GSR ve DVM metotlarının farklı beton türlerine ait veri setleri ile çalıştırılarak, beton karışım tasarımı alanındaki kullanımının ve başarısının artırılabilceği söylenebilir.

#### Kaynaklar

- [1] O. Altay, M. Ulas, and K. E. Alyamac, "Prediction of the Fresh Performance of Steel Fiber Reinforced Self-Compacting Concrete Using Quadratic SVM and Weighted KNN Models," IEEE Access, vol. 8, pp. 92647–92658, 2020, doi: 10.1109/ACCESS.2020.2994562.
- [2] O. Altay, T. Gurgenc, M. Ulas, and C. Özel, "Prediction of wear loss quantities of ferro-alloy coating using different machine learning algorithms," Friction, vol. 8, no. 1, pp. 107–114, 2020, doi: 10.1007/s40544-018-0249-z.
- [3] T. Gurgenc, O. Altay, M. Ulas, and C. Ozel, "Extreme learning machine and support vector regression wear loss predictions for magnesium alloys coated using various spray coating methods," J. Appl. Phys., vol. 127, no. 18, p. 185103, May 2020, doi: 10.1063/5.0004562.
- [4] O. Altay, M. Ulas, and K. E. Alyamac, "DCS-ELM: a novel method for extreme learning machine for regression problems and a new approach for the SFRSCC.," PeerJ. Comput. Sci., vol. 7, p. e411, 2021, doi: 10.7717/peerj-cs.411.
- [5] M. Açıkgeç, M. Ulaş, and K. E. Alyamac, "Using an Artificial Neural Network to Predict Mix Compositions of Steel Fiber-Reinforced Concrete," Arab. J. Sci. Eng., vol. 40, no. 2, pp. 407–419, 2015, doi: 10.1007/s13369-014-1549-x.
- [6] M. Acikgeç Ulas, "Development of an artificial neural network model to predict waste marble powder demand in eco-efficient self-compacting concrete," Struct. Concr., no. January, pp. 1–14, May 2022, doi: 10.1002/suco.202200043.
- [7] T. Standard, "TS 802 Beton karışım tasarımı hesap esasları." Turkish Standards Institutions, Ankara, 2016.
- [8] V. Chandwani, V. Agrawal, and R. Nagar, "Modeling slump of ready mix concrete using genetic algorithms assisted training of Artificial Neural Networks," Expert Syst. Appl., vol. 42, no. 2, pp. 885–893, 2015, doi: 10.1016/j.eswa.2014.08.048.
- [9] M. T. Uddin, A. H. Mahmood, M. R. I. Kamal, S. M. Yashin, and Z. U. A. Zihan, "Effects of maximum size of brick aggregate on properties of concrete," Constr. Build. Mater., vol. 134, pp. 713–726, Mar. 2017, doi: 10.1016/J.CONBUILDMAT.2016.12.164.
- [10] U. Atici, "Prediction of the strength of mineral admixture concrete using multivariable regression analysis and an artificial neural network," Expert Syst. Appl., vol. 38, no. 8, pp. 9609–9618, Aug. 2011, doi: 10.1016/J.ESWA.2011.01.156.
- [11] A. Behnood and E. M. Golafshani, "Predicting the compressive strength of silica fume concrete using hybrid artificial neural network with multi-objective grey wolves," J. Clean. Prod., vol. 202, pp. 54–64, 2018, doi: 10.1016/j.jclepro.2018.08.065.
- [12] C. Bilim, C. D. Atiş, H. Tanyildizi, and O. Karahan, "Predicting the compressive strength of ground granulated blast furnace slag concrete using artificial neural network," Adv. Eng. Softw., vol. 40, no. 5, pp. 334–340, May 2009, doi: 10.1016/J.ADVENGSOFT.2008.05.005.
- [13] H. Naderpour, A. H. Rafiean, and P. Fakharian, "Compressive strength prediction of environmentally friendly concrete using artificial neural networks," J. Build. Eng., vol. 16, pp. 213–219, Mar. 2018, doi: 10.1016/J.JOBE.2018.01.007.
- [14] B. K. R. Prasad, H. Eskandari, and B. V. V. Reddy, "Prediction of compressive strength of SCC and HPC with high volume fly ash using ANN," Constr. Build. Mater., vol. 23, no. 1, pp. 117–128, Jan. 2009, doi: 10.1016/J.CONBUILDMAT.2008.01.014.
- [15] İ. B. Topçu and M. Saridemir, "Prediction of compressive strength of concrete containing fly ash using artificial neural



- networks and fuzzy logic,” *Comput. Mater. Sci.*, vol. 41, no. 3, pp. 305–311, Jan. 2008, doi: 10.1016/J.COMMATSCI.2007.04.009.
- [16] G. Pazouki, E. M. Golafshani, and A. Behnood, “Predicting the compressive strength of self-compacting concrete containing Class F fly ash using metaheuristic radial basis function neural network,” *Struct. Concr.*, no. January, pp. 1–23, 2021, doi: 10.1002/suco.202000047.
- [17] R. N. Sağlam, M. Açikgenç Ulaş, and K. E. Alyamaç, “Hafif Beton Üretimi İçin Gerekli Olan Hafif Agreganın Yapay Sinir Ağı ile Tahmin Edilmesi,” *Fırat Üniversitesi Mühendislik Bilim. Derg.*, vol. 34, no. 2, pp. 889–898, 2022, doi: 10.35234/fumbd.1133877.
- [18] A. M. Abd and S. M. Abd, “Modelling the strength of lightweight foamed concrete using support vector machine (SVM),” *Case Stud. Constr. Mater.*, vol. 6, pp. 8–15, 2017, doi: <https://doi.org/10.1016/j.cscm.2016.11.002>.
- [19] H. Ling, C. Qian, W. Kang, C. Liang, and H. Chen, “Combination of Support Vector Machine and K-Fold cross validation to predict compressive strength of concrete in marine environment,” *Constr. Build. Mater.*, vol. 206, pp. 355–363, 2019, doi: <https://doi.org/10.1016/j.conbuildmat.2019.02.071>.
- [20] Z. Fan, R. Chiong, Z. Hu, and Y. Lin, “A fuzzy weighted relative error support vector machine for reverse prediction of concrete components,” *Comput. Struct.*, vol. 230, p. 106171, 2020, doi: <https://doi.org/10.1016/j.compstruc.2019.106171>.
- [21] J. Dhanpat, A. Higginson, and K. Brooks, “Estimation of the Effect of Bio-Admixtures on Concrete Workability Using Linear Regression and Support Vector Machines,” *IFAC-PapersOnLine*, vol. 54, no. 21, pp. 133–138, 2021, doi: <https://doi.org/10.1016/j.ifacol.2021.12.023>.
- [22] N. Harish and P. Janardhan, “Support vector machine in predicting epoxy glass powder mixed cement concrete,” *Mater. Today Proc.*, vol. 46, pp. 9042–9046, 2021, doi: <https://doi.org/10.1016/j.matpr.2021.05.385>.
- [23] K. Zhang, K. Zhang, R. Bao, and X. Liu, “A framework for predicting the carbonation depth of concrete incorporating fly ash based on a least squares support vector machine and metaheuristic algorithms,” *J. Build. Eng.*, vol. 65, p. 105772, 2023, doi: <https://doi.org/10.1016/j.jobe.2022.105772>.
- [24] B. Basaran, I. Kalkan, E. Bergil, and E. Erdal, “Estimation of the FRP-concrete bond strength with code formulations and machine learning algorithms,” *Compos. Struct.*, vol. 268, p. 113972, 2021, doi: <https://doi.org/10.1016/j.compstruct.2021.113972>.
- [25] K. Liu, Z. Dai, R. Zhang, J. Zheng, J. Zhu, and X. Yang, “Prediction of the sulfate resistance for recycled aggregate concrete based on ensemble learning algorithms,” *Constr. Build. Mater.*, vol. 317, p. 125917, 2022, doi: <https://doi.org/10.1016/j.conbuildmat.2021.125917>.
- [26] K. Ozawa, K. Maekawa, M. Kunishima, and H. Okamura, “High-performance concrete based on the durability of concrete structures,” 1989.
- [27] H. Okamura, K. Ozawa, K. Maekawa, and S. Tangtermsinikul, “High-performance concrete mechanism of super-fluidized concrete,” in *EIT-JSCE-AIT joint seminar on solution to urban infrastructure problems through civil engineering technology*, 1992, p. 16.
- [28] X. Wang, K. Wang, P. Taylor, and G. Morcous, “Assessing particle packing based self-consolidating concrete mix design method,” *Constr. Build. Mater.*, vol. 70, pp. 439–452, 2014, doi: 10.1016/j.conbuildmat.2014.08.002.
- [29] H. Yazici, “The effect of silica fume and high-volume Class C fly ash on mechanical properties, chloride penetration and freeze-thaw resistance of self-compacting concrete,” *Constr. Build. Mater.*, vol. 22, no. 4, pp. 456–462, 2008, doi: 10.1016/j.conbuildmat.2007.01.002.
- [30] B. Felekoğlu, S. Türkel, and B. Baradan, “Effect of water/cement ratio on the fresh and hardened properties of self-compacting concrete,” *Build. Environ.*, vol. 42, no. 4, pp. 1795–1802, 2007, doi: 10.1016/j.buildenv.2006.01.012.
- [31] K. E. Alyamaç and R. Ince, “A preliminary concrete mix design for SCC with marble powders,” *Constr. Build. Mater.*, vol. 23, no. 3, pp. 1201–1210, Mar. 2009, doi: 10.1016/j.conbuildmat.2008.08.012.
- [32] M. C. S. Nepomuceno, L. A. Pereira-de-Oliveira, and S. M. R. Lopes, “Methodology for the mix design of self-compacting concrete using different mineral additions in binary blends of powders,” *Constr. Build. Mater.*, vol. 64, pp. 82–94, 2014, doi: 10.1016/j.conbuildmat.2014.04.021.
- [33] H. J. H. Brouwers and H. J. Radix, “Self-compacting concrete: Theoretical and experimental study,” *Cem. Concr. Res.*, vol. 35, no. 11, pp. 2116–2136, 2005, doi: 10.1016/j.cemconres.2005.06.002.
- [34] H. W. Reinhardt and M. Stegmaier, “Influence of heat curing on the pore structure and compressive strength of self-compacting concrete (SCC),” *Cem. Concr. Res.*, vol. 36, no. 5, pp. 879–885, 2006, doi: 10.1016/j.cemconres.2005.12.004.
- [35] R. Siddique, P. Aggarwal, and Y. Aggarwal, “Influence of water/powder ratio on strength properties of self-compacting concrete containing coal fly ash and bottom ash,” *Constr. Build. Mater.*, vol. 29, pp. 73–81, 2012, doi: 10.1016/j.conbuildmat.2011.10.035.
- [36] S. Nunes, H. Figueiras, P. Milheiro Oliveira, J. S. Coutinho, and J. Figueiras, “A methodology to assess robustness of SCC mixtures,” *Cem. Concr. Res.*, vol. 36, no. 12, pp. 2115–2122, 2006, doi: 10.1016/j.cemconres.2006.10.003.
- [37] V. B. Bosiljkov, “SCC mixes with poorly graded aggregate and high volume of limestone filler,” *Cem. Concr. Res.*, vol. 33, no. 9, pp. 1279–1286, 2003, doi: 10.1016/S0008-8846(03)00013-9.
- [38] E. Güneysi, M. Gesoğlu, Z. Algin, and H. Yazici, “Effect of surface treatment methods on the properties of self-compacting concrete with recycled aggregates,” *Constr. Build. Mater.*, vol. 64, pp. 172–183, 2014, doi: 10.1016/j.conbuildmat.2014.04.090.

- [39] M. Gesoğlu, E. Güneyisi, M. E. Kocabağ, V. Bayram, and K. Mermerdaş, “Fresh and hardened characteristics of self compacting concretes made with combined use of marble powder, limestone filler, and fly ash,” *Constr. Build. Mater.*, vol. 37, pp. 160–170, 2012, doi: 10.1016/j.conbuildmat.2012.07.092.
- [40] E. Güneyisi, M. Gesoğlu, S. Al-Rawi, and K. Mermerdaş, “Effect of volcanic pumice powder on the fresh properties of self-compacting concretes with and without silica fume,” *Mater. Struct. Constr.*, vol. 47, no. 11, pp. 1857–1865, 2014, doi: 10.1617/s11527-013-0155-9.
- [41] K. E. Alyamac, E. Ghafari, and R. Ince, “Development of eco-efficient self-compacting concrete with waste marble powder using the response surface method,” *J. Clean. Prod.*, vol. 144, pp. 192–202, 2017, doi: 10.1016/j.jclepro.2016.12.156.
- [42] P. K. Mehta and P. J. M. Monteiro, *Concrete: Microstructure, Properties and Materials*. New York: McGraw-Hill, 2006.
- [43] M. A. Ulas, K. E. Alyamac, and Z. C. Ulucan, “Effects of aggregate grading on the properties of steel fibre-reinforced concrete,” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 246, p. 12015, 2017, doi: 10.1088/1757-899x/246/1/012015.
- [44] C. Cortes and V. Vapnik, “Support-vector networks,” *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, 1995, doi: 10.1007/BF00994018.
- [45] T. Kavzoğlu and İ. Çölkesen, “Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi,” *Harit. Derg.*, vol. 76, no. 144, pp. 73–82, 2010, [Online]. Available: <http://search/yayin/detay/102501>.
- [46] M. Korkmaz, A. Dogan, and V. Kirmaci, “Performance Analysis of Counterflow Ranque – Hilsch Vortex Tube with Linear Regression, Support Vector Machines and Gaussian Process Regression Method,” *Gazi J. Eng. Sci.*, vol. 8, no. 2, pp. 361–370, 2022, doi: 10.30855/gmbd.0705015.
- [47] O. Chapelle, P. Haffner, and V. N. Vapnik, “Support vector machines for histogram-based image classification,” *IEEE Trans. Neural Networks*, vol. 10, no. 5, pp. 1055–1064, 1999, doi: 10.1109/72.788646.
- [48] E. Snelson and Z. Ghahramani, “Local and global sparse Gaussian process approximations,” in the Eleventh International Conference on Artificial Intelligence and Statistics, 2007, vol. 2, pp. 524–531, [Online]. Available: <http://proceedings.mlr.press/v2/snelson07a/snelson07a.pdf>.
- [49] J. Vanhatalo, V. Pietiläinen, and A. Vehtari, “Approximate inference for disease mapping with sparse Gaussian processes,” *Stat. Med.*, vol. 29, no. 15, pp. 1580–1607, Jul. 2010, doi: <https://doi.org/10.1002/sim.3895>.
- [50] M. N. Mohd Aris, H. Daud, S. C. Dass, and K. A. Mohd Noh, “Gaussian Process Methodology for Multi-Frequency Marine Controlled-Source Electromagnetic Profile Estimation in Isotropic Medium,” *Processes*, vol. 7, no. 10, 2019, doi: 10.3390/pr7100661.
- [51] J. Liang, Z. Shi, F. Zhu, W. Chen, X. Chen, and Y. Li, “Gaussian Process Autoregression for Joint Angle Prediction Based on sEMG Signals,” *Front. Public Heal.*, vol. 9, 2021, doi: 10.3389/fpubh.2021.685596.
- [52] Ç. Elmas, *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayıncılık, 2007.
- [53] M. Sarıdemir, “Prediction of compressive strength of concretes containing metakaolin and silica fume by artificial neural networks,” *Adv. Eng. Softw.*, vol. 40, no. 5, pp. 350–355, May 2009, doi: 10.1016/J.ADVENGSOFT.2008.05.002.
- [54] A. S. Pandya and R. B. Macy, *Pattern Recognition with Neural Networks in C++*. Boca Raton, Florida: CRC Press, 1996.
- [55] A. J. Thomas, M. Petridis, S. D. Walters, S. M. Gheytsi, and R. E. Morgan, “On Predicting the Optimal Number of Hidden Nodes,” in 2015 International Conference on Computational Science and Computational Intelligence (CSCI), 2015, pp. 565–570, doi: 10.1109/CSCI.2015.33.