

## PAPER DETAILS

TITLE: Gradyan Güçlendirme Kullanarak Çelik Fiberli Geopolimerin Basınç Dayanımının Tahmini

AUTHORS: Necip Altay Eren

PAGES: 745-753

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/4048122>



## Araştırma Makalesi / Research Article

## Gradyan Güçlendirme Kullanarak Çelik Fiberli Geopolimerin Basınç Dayanımının Tahmini

*Prediction of Compressive Strength of Geopolymers Reinforced with Steel Fiber Using Gradient Boosting*Necip Altay Eren<sup>1\*</sup><sup>1</sup> Gaziantep Üniversitesi, İslahiye MYO, İnşaat Bölümü, [altayeren@gantep.edu.tr](mailto:altayeren@gantep.edu.tr)ORCID: <https://orcid.org/0000-0003-1421-4619>

## MAKALE BİLGİLERİ

## ÖZ

## Makale Geçmişi:

Geliş 5 Temmuz 2024  
 Revizyon 26 Ağustos 2024  
 Kabul 12 Eylül 2024  
 Online 30 Eylül 2024

## Anahtar Kelimeler:

Geopolimer, Basınç dayanımı,  
 Makina öğrenme, Çelik fiber

Bu makalenin amacı, çelik fiberli Geopolimer Betonların veya Harçların basınç dayanımını daha hızlı, doğru, ucuz ve zahmetsız bir şekilde belirlemektir. Geleneksel laboratuvar testlerinin maliyetli olduğu ve zaman aldığı göz önüne alındığında, yapay zekâ uygulamalarının betonun basınç değerinin belirlenmesinde önemli alternatif yöntemlerinden birisi olabilir. Günümüzde yapay zekâ teknolojilerinin hızla gelişmesi, hassas ve hızlı sonuçlar elde edilmesine imkân tanımaktadır. Bu çalışmada, Makine Öğrenimi kullanılarak belirli bir veri seti üzerinden çelik fiberli geopolimer betonun basınç dayanımının tahmin edilmesi hedeflenmiştir. Literatürde bu konuda yapılan önceki çalışmalar incelenerek 105 veriden oluşan bir veri seti hazırlanmış ve analiz için uygun hale getirilmiştir. Veri seti, Gradyan Güçlendirme yöntemi kullanılarak Python programlama diliyle modellenmiş ve analiz edilmiştir. Yapılan çalışma sonucunda  $R^2$  değeri 0,971 olarak elde edilmiştir. Bu sonuçlar, Gradyan Güçlendirme modelinin çelik fiberli geopolimer betonun basınç dayanımını tahmin etmede oldukça başarılı olduğunu göstermektedir. Sonuç olarak, yapay zekâ teknikleri basınç dayanım sonuçlarının daha hızlı tahmin edebilecek ve maliyetleri ölçüde azaltacak imkânlar sunmaktadır. Bu çalışmanın bulguları, inşaat sektöründe gelecekteki araştırma ve uygulamalar için umut verici bir yöntem sunmaktadır.

## ARTICLE INFO

## ABSTRACT

## Article history:

Received 5 July 2024  
 Received in revised form 26 August 2024  
 Accepted 12 September 2024  
 Available online 30 September 2024

## Keywords:

Geopolymer, Compressive strength,  
 Machine learning, Steel fiber

The aim of this article is to determine the compressive strength of Geopolymer Concrete or Mortar with steel fiber in a faster, accurate, cheaper and effortless way. Considering that traditional laboratory tests are costly and time-consuming, artificial intelligence applications can be one of the important alternative methods in determining the compressive strength of concrete. Today, the rapid development of artificial intelligence technologies allows obtaining precise and fast results. In this study, it is aimed to estimate the compressive strength of geopolymers concrete with steel fiber using a specific database using Machine Learning. By examining previous studies on this subject in the literature, a data set consisting of 105 data was prepared and made suitable for analysis. The data set was modeled and analyzed with the Python programming language using the Gradient Boosting method. As a result of the study, the  $R^2$  value was obtained as 0.971. These results show that the Gradient Boosting model is quite successful in predicting the compressive strength of geopolymers concrete with steel fiber. As a result, artificial intelligence techniques offer opportunities to predict compressive strength results faster and significantly reduce costs. The findings of this study provide a promising method for future research and applications in the construction industry.

Doi: 10.24012/dumf.1511100

\* Sorumlu Yazar

## Giriş

Günümüzde çevre kirliliği sorunları, özellikle sera gazı salınımı gibi konular, ciddi endişelere neden olmaktadır. Çimento üretimi sürecindeki kireçtaşının dekarburizasyonu, atmosfere önemli miktarda sera gazı emisyonuna sebep olmaktadır. Bu durum, çimento üretimi ile ilgili CO<sub>2</sub> salınımının yüksek olduğunu ve çevresel etkilerinin önemli olduğunu göstermektedir (%54 kalsinasyon ve %46 yakıt yakımı yoluyla) [1]. Dünya genelinde en fazla kullanılan malzemelerden biri betondur ve inşaat sektöründe kullanımını giderek artmaktadır [2]. Ancak beton üretimi de çimento kullanımıyla doğrudan ilişkilidir ve dolayısıyla CO<sub>2</sub> salınımının artmasına sebep olmaktadır. Bu nedenle, inşaat sektöründe çevresel etkileri azaltmak için alternatif malzemelere yönelik arayışlar devam etmektedir. Geopolimer Beton (GB), bu bağlamda önemli bir alternatif olarak öne çıkmaktadır. GB, geleneksel çimentoya kıyasla daha az CO<sub>2</sub> salınımına neden olur. Alkali çözelti ile zenginleştirilmiş alümina silikat içeren metakaolin, cüruf, uçucu kül gibi malzemeler kullanılarak üretilen bir beton türüdür. Bu özelliklerile hem çevre dostu hem de sürdürülebilir bir yapı malzemesi olarak dikkat çeker [3]-[5]. GB'nun kullanımını, inşaat ve beton endüstrisinde CO<sub>2</sub> salınımını %80 oranında azaltabileceği göz önünde bulundurulmaktadır [4]. Fiberli geopolimerler, dayanıklılık ve çevresel sürdürülebilirlik avantajları nedeniyle inşaat sektöründe artarak ilgi görmektedir. Bu malzemeler, doğal liflerin (cam, karbon, polipropilen gibi) geopolimer matrisine eklenmesiyle oluşturulurlar. Fiberler, malzemenin mekanik özelliklerini geliştirmek için çatlak oluşumunu azaltır ve genellikle basınç dayanıklılığı artırır. Bu bağlamda, fiberli GB'ların basınç dayanımının doğru bir şekilde tahmin edilmesi, mühendislik uygulamalarında önem arz etmektedir. Betonun temel mekanik özelliklerinden biri olan basınç dayanımı, yapıların güvenliği için kritik öneme sahiptir ve bu özellik laboratuvar testleri ile belirlenir. Ancak, laboratuvar testleri zaman alıcı ve maliyetlidir. Bu nedenle, yapay zekâ teknikleri, betonun mekanik özelliklerini belirlemeye alternatif bir yaklaşım sunabilir. Makine öğrenimi algoritmaları kullanılarak geliştirilen tahmin modelleri, basınç dayanımını hızlı ve doğru bir şekilde tahmin etmede etkili olabilir [6]. Bu makalede, fiberli GB'un basınç dayanımını tahmin etmek için Gradyan Güçlendirme (GG) modeli kullanılarak belirlenmeye çalışılmıştır. Bu yaklaşım, GB'nun mühendislik uygulamalarında daha geniş bir kabul görmesine ve çevresel sürdürülebilirlik açısından olumlu katkılar sağlaymasına yardımcı olabilir.

İnşaat mühendisliği alanında yapay zekâ teknikleri, özellikle beton gibi malzemelerin davranışını ve performansını tahmin etmede önemli bir rol oynamaktadır. Bu alanda birçok makine öğrenimi tekniği, istenilen çıktıları tahmin etmek için kullanılmaktadır. Örneğin, Karar Ağacı (KA), Yapay Sinir Ağrı (YSA), Gen Ekspresyonu Programlama (GEP), Destek Vektör Makinesi (DVM) ve Rastgele Orman (RO) gibi yöntemler literatürde sıkça karşılaşılan teknikler arasındadır [7]-[10]. Ahmed ve ark. [11], geri dönüştürülmüş kaba agregal betonun basınç dayanımını tahmin etmek için GEP algoritmasını kullanarak başarılı sonuçlar elde etmiştir. Song ve ark. [12] ise seramik atık bazlı beton için YSA modelinin yüksek performans gösterdiğini ve diğer Karar Ağacı

modellerine kıyasla daha iyi tahminler yaptığıni belirtmiştir. Khan ve ark. [13] uçucu kül bazlı GB'un basınç dayanımını GEP modeli ile başarılı bir şekilde tahmin etmişlerdir. Aslam ve ark. [14] yüksek dayanıklı betonun basınç dayanımını tahmin etmek için GEP modelinin doğruluğunu göstermiş ve makine öğrenimi yöntemlerinin yüksek performans sergilediğini vurgulamışlardır. Chu ve ark. [15] ise GB'un mukavemet özelliklerini tahmin etmek için GEP ve Çoklu İfade Programlamayı (ÇİP) kullanmışlar ve GEP modelinin daha doğru tahminler sağladığını bulmuşlardır. Ancak, literatürde fiberli GB'un basınç dayanımını tahmin etmek için çok az çalışma bulunmaktadır. Kumar ve ark. [16] yaptıkları çalışmada, YSA ve Destek Vektör Regresyonu (DVR) modelleri kullanarak fiber takviyeli GB'un basınç dayanımını tahmin etmişlerdir. Bu çalışma DVR modelinin, YSA modeline göre daha doğru tahminler yaptığıni göstermiştir. Öte yandan, literatürde Gradyan Güçlendirme (GG) algoritması kullanılarak çelik fiberli (ÇF) GB'un basınç dayanımını tahmin etmek için yapılmış bir çalışma bulunmamaktadır. GG algoritması özellikle büyük ve karmaşık veri kümelerinde tahmin hızı ve doğruluğuyla öne çıkan ve başarılı sonuçlar veren bir yöntem olarak öne çıkmaktadır. Bu bağlamda, ÇF'li GB'un basınç dayanımını tahmin etmek için GG algoritması'nın potansiyelini araştıran yeni çalışmaların yapılması önem arz etmektedir. Bu tür çalışmalar, GB'un inşaat sektöründeki kullanımını daha sürdürülebilir hale getirme potansiyeline sahiptir.

GB'un basınç dayanımının doğru bir şekilde tahmin edilmesi zorlu bir süreçtir, ancak yapay zekâ ve makine öğrenimi bu alanda umut verici çözümler sunmaktadır. GG, Friedman [17] tarafından önerilen bir algoritmadır. GG algoritması, zayıf öğrenenlerin yinelemeli bir dizi yoluyla daha iyi öğrenenlerle birleştirilmesiyle oluşturulmuştur [18]. Sonuç olarak, GG performansı güçlendirilebilir, bu da toplam hatanın azalmasına ve model kaybinin azalmasına yol açabilir [19]. Önceki çalışmalar, GG algoritması aşırı uyum sorunlarını önlemede temel bir avantaja sahip olduğunu ve bu algoritmanın daha az hesaplama kaynağı kullandığını belirtmiştir [19]-[20]. Betonun basınç dayanımını tahmin etmek için birçok çalışmada GG algoritması kullanılmıştır [21]-[22]. Genomik üreme değerlerinin tahmin edilmesinde GG algoritması, DVR ve rastgele orman modelleri arasındaki tahmin performansını karşılaştırmak için daha önce bir çalışma yapılmış ve GG algoritmasının diğer algoritmalarдан daha iyi performans gösterdiği sonucuna varılmıştır [23]. Bu özelliklerini sayesinde, GG gibi karmaşık yapı malzemelerinin mekanik özelliklerini tahmin etme konusunda potansiyel göstermektedir. Sonuç olarak, yapay zekâ ve makine öğrenimi tekniklerinin, GG'nin basınç dayanımının doğru tahmin edilmesinde önemli bir rol oynayabileceğini ve inşaat sektöründe sürdürülebilir malzeme kullanımını teşvik edebileceğini görmektedir. Bu teknolojilerin kullanımı, laboratuvar testlerine olan bağımlılığı azaltabilir ve maliyetleri düşürebilirken, aynı zamanda doğru ve güvenilir sonuçlar elde edilmesine yardımcı olabilir.

Makine öğrenimi, yapay zekânın önemli bir alt dalıdır ve insan etkileşimi olmadan veri kalıplarını analiz eder ve yorumlar. ÇF'li GB'un basınç dayanımını daha hızlı bir şekilde tahmin etmek için yapay zekâ yöntemleri oldukça etkili olabilir. Bu yöntemler, GB'nin bileşimi (molaritesi), kullanılan ÇF miktarı, geometrik ve mekanik özellikler ile numunenin geometrisi gibi faktörleri analiz ederek basınç dayanımını tahmin etmeyi mümkün kılar. Bu çalışmada, GG kullanılarak ÇF'li GB'un basınç dayanımını tahmin etmenin

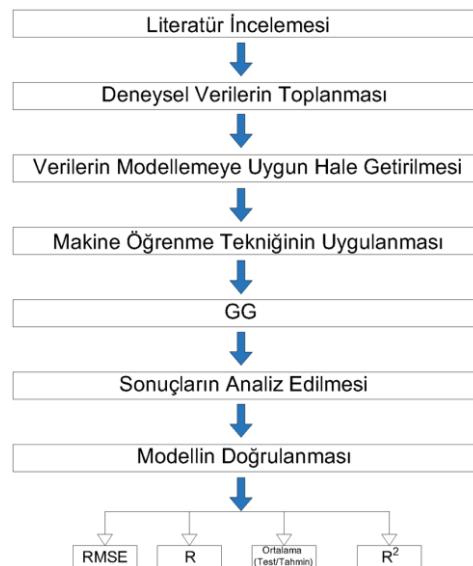
uygulanabilirliği araştırılmaktadır. GG, sınıflandırma, regresyon ve sıralama gibi çeşitli görevler için kullanılabilen bir makine öğrenimi algoritmasıdır. Son yıllarda yapay zekâ çalışmalarında gösterdiği yüksek performansı ve hızlı yakınsama yeteneğiyle dikkat çekmektedir. Araştırmada GG modeli, Python programlama dili kullanılarak geliştirilmiştir. Python, açık kaynaklı olması, kolay okunabilir olması ve yüksek performansıyla tercih edilen bir programlama dilidir [24]. Bu özellikleri sayesinde, makine öğrenimi modellerinin oluşturulması, veri analizi ve sonuçların değerlendirilmesi Python ile etkili bir şekilde gerçekleştirilebilir. Sonuç olarak, yapay zekâ ve özellikle GG kullanılması, ÇF'li GB'un basınç dayanımının tahmin edilmesinde önemli bir potansiyele sahiptir. Bu çalışma, inşaat sektöründe daha sürdürülebilir ve verimli malzemelerin kullanımını teşvik etmeyi hedeflemektedir.

Literatürde fiberli GB'un basınç dayanımının tahmin edilmesine yönelik yapılan çalışmaların azlığına rağmen, Kumar ve ark. [16] tarafından yapılan çalışma önemli bir adım olarak öne çıkmaktadır. Bu çalışmada, fiber takviyeli GB'un (ÇF ve PVA ile takviyeli) basınç dayanımının tahmin edilmesi için Yapay Sinir Ağı (YSA) ve Destek Vektör Regresyonu (DVR) modelleri ile Olağanüstü Gradyan Güçlendirme (OGG) algoritması kullanılmıştır. Çalışmada, farklı özelliklerin (kimyasal bileşim, aktivatör türü vb.) OGG modeli için kullanılarak başarılı bir şekilde eğitildiği ve elde edilen tahminlerin deneysel verilerle uyumlu olduğu gözlemlenmiştir. YSA ve DVR gibi geleneksel makine öğrenimi modellerinin yanı sıra OGG algoritmasının da kullanılması, basınç dayanımı tahmininde doğruluğun artırılması açısından önemli bir adımdır. Bu çalışma, fiber takviyeli GB'un mekanik özelliklerinin tahmin edilmesinde yapay zekâ tekniklerinin potansiyelini göstermesi açısından değerlidir. Ancak, literatürde direkt GG'nın kullanımıyla çelik fiberli GB'un basınç dayanımının tahmin edilmesiyle ilgili yapılan bir çalışma bulunamamıştır. Literatürde yapılan çalışmalardan elde edilen başarılı sonuçlar, GB gibi yenilikçi ve sürdürülebilir yapı malzemelerinin geliştirilmesinde önemli bir katkı sağlayabilir.

Bu çalışmada, ÇF takviyeli GB'un basınç dayanımını GG kullanarak tahmin etmek amaçlanmaktadır. Literatürde bu konuda yapılan çalışmaların azlığına rağmen, özellikle ÇF takviyeli GB üzerine yapılan çalışmalar incelenmiş ve bu çalışmalardan elde edilen veriler kullanılarak 105 veriden oluşan bir veri seti oluşturulmuştur. Oluşturulan veri seti üzerinde GG eğitilmiş ve bu model kullanılarak ÇF takviyeli GB'nun basınç dayanımı tahmin edilmeye çalışılmıştır. Elde edilen tahmin sonuçları, veri setindeki deneyel sonuçlar ile karşılaştırılmış ve bu karşılaştırma sonuçları değerlendirilmiştir. Çalışmanın amacı, ÇF'li GB'nun basınç dayanımını tahmin etmede makine öğrenimi algoritmalarının kullanımının potansiyelini göstermektir. Yapılan analizler ve karşılaştırmalar, makine öğrenimi algoritmalarının GB'nun basınç dayanımını doğru bir şekilde tahmin edebileceğini ortaya koymaktadır. Bu bulgular, gelecekte standartların belirlenmesi ve GB kullanımının yaygınlaşması açısından önemli bir katkı sağlayabilir. Sonuç olarak, bu çalışma, sürdürülebilir inşaat malzemeleri geliştirilmesinde yapay zekâ ve makine öğrenimi tekniklerinin potansiyelini göstermek ve inşaat sektöründe doğru, ekonomik ve çevre dostu çözümler sunma yolunda bir adım olarak değerlendirilebilir.

## Materiyal ve Yöntem

Bu bölümde çalışmada kullanılan materyal ve yöntemler açıklanmıştır. İlk olarak, bu çalışmada kullanılan makine öğrenimi algoritması anlatılmıştır. Daha sonra verilerin nasıl elde edildiği ve modellemeye hazır hale getirmek için kullanılan yöntemle ilgili bilgi verilmiştir. Son olarak, modelin nasıl oluşturulduğu ve elde edilen sonuçlar aktarılmıştır. Çalışmanın stratejisini gösteren grafik Şekil 1.'de aşağıda sunulmuştur.



Şekil 1. Çalışma yönteminin akış şeması

## Değerlendirme yöntemi

Makine öğrenmesi algoritmasının doğruluğunun değerlendirilmesinde ortalama hata (ortalama test/tahmin), kök ortalama kare hatası (RMSE), korelasyon katsayısı (R) ve belirleme katsayısı ( $R^2$ ) dikkate alındı.

### Ortalama Hata (Ortalama Test/Tahmin)

Ortalama Hata modelleme ve tahmin süreçlerinde modelin tahminlerinin ne kadar doğru olduğunu ölçmek için kullanılan bir değerlendirme metriğidir. Bir modelin tahmin ettiği değerlerle (tahmin) gerçek değerler (test) arasındaki oranı ifade eder. Bu oran tahminlerin gerçek değerlere ne kadar yakın olduğunu belirtir. 1'e ne kadar yakınsa, modelin performansının o kadar iyi olduğu anlamına gelir [25].

### Kök Ortalama Kare Hatası (RMSE)

Regresyonda genellikle kullanılan kayıp fonksiyonu, aşağıdaki Deklem (1)'de tanımlanan RMSE'dir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y' - y)^2} \quad (1)$$

burada  $y'$  tahmin edilen değer,  $y$  gerçek değer ve  $n$  veri örneklerinin sayısıdır. Hata ne kadar büyükse RMSE de o kadar büyütür; böylece tahminlerin doğruluğu tahmin edilebilir. RMSE, model tarafından tahmin edilen değerler gerçek değerlerden farklı olduğunda yaygın olarak kullanılır. Ayrıca, RMSE değeri daha küçük olduğunda modelin performansı iyileştirilir [26].

## Korelasyon Katsayısı (R)

Korelasyon katsayısı, iki değişken arasındaki doğrusal ilişkisinin yönünü ve kuvvetini ölçen bir istatistiksel değerdir. Korelasyon katsayısı, -1 ile 1 arasında bir değer alır. R değeri 1 ise; mükemmel pozitif korelasyon ve iki değişken arasında tam bir doğrusal pozitif ilişki vardır. Eğer R değeri -1 ise; mükemmel negatif korelasyon ve iki değişken arasında tam bir doğrusal negatif ilişki vardır. Eğer R değeri 0 ise; iki değişken arasında doğrusal bir ilişki yoktur [27].

## Belirleme Katsayısı ( $R^2$ )

Belirleme katsayısı, genellikle  $R^2$  olarak ifade edilir ve bir regresyon modelinin bağımlı değişkenin Deklem (2)'de ki gibi toplam varyansını ne kadar açıkladığını gösteren bir istatistiksel ölçütür. Başka bir deyişle,  $R^2$ , modelin veri noktalarının ne kadarını doğru bir şekilde tahmin edebildiğini gösterir.  $R^2$  1'e eşit ise; model, bağımlı değişkendeki varyansın tamamını açıklar. Bu, modelin mükemmel bir uyum sağladığını gösterir. Eğer  $R^2$  0'a eşit ise; model, bağımlı değişkendeki varyansı hiç açıklamaz. Yani, modelin tahmin etiği değerler ile gerçek değerler arasında hiçbir ilişki yoktur. Eğer  $R^2$  değeri 0 ile 1 arasında ise; 1'e yaklaşıkça modelin açıklayıcılığı artar, 0'a yaklaşıkça azalır ve  $R^2$  değeri genellikle 0 ile 1 arasında yer alır [28].

$$R^2 = 1 - \frac{KKT}{TKT} \quad (2)$$

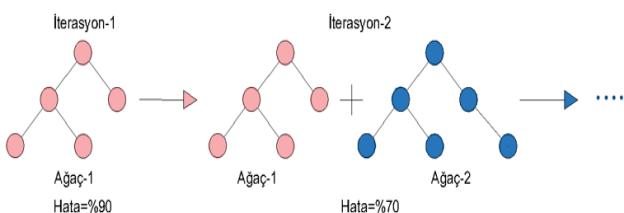
Burada;

TSS : Toplam kareler toplamı

RSS : Kalan kareler toplamı

## Gradyan Güçlendirme (GG)

GG algoritması, boosting teknigine dayanır ve zayıf öğrenicileri yinelemeli bir şekilde birleştirerek daha güçlü bir öğrenici oluşturur [18]. Her bir iterasyonda yeni tahlimciler eklenmesi, modelin performansını artırabilir. Ayrıca, GG algoritması toplam hata ve model kaybını azaltmaya odaklanır [19], bu da aşırı uyum sorununu önemli ölçüde azaltır. GG teknigiden, zayıf öğrenici olarak regresyon ağaçları kullanılır ve her iterasyonda model, hata azaltmak için yinelemeli gradyan tabanlı öğrenme algoritması kullanılarak eğitilir. İlk iterasyonda, genel eğitim hatasını azaltmak amacıyla ilk zayıf öğrenici (ilk ağaç) eğitenir. Daha sonra Şekil 2.'de ki gibi her bir sonraki iterasyonda, önceki ağaçların yetersiz kaldığı alanlarda hataları düzeltmek için bir sonraki zayıf öğrenici eğitilir. Bu süreç, istenilen hata seviyesine ulaşılınca kadar devam eder. Sonuç olarak, GG algoritması, zayıf öğrenicilerin kademeli olarak birleştirilmesi ve her adımda modelin performansının artırılmasıyla güçlü bir tahminci oluşturur. Bu yöntem, özellikle karmaşık ilişkileri ve örüntüleri yakalamak için etkili bir makine öğrenimi tekniğidir.



Şekil 2. Gboost ağaçları

Ayrıca, GG modelinde başlangıçta model  $F_0(x)$  tahmin yapar. Ardından, Deklem (3)'de ki gibi her yeni adımda şu şekilde bir iyileştirme yapılır:

$$F_m(x) = F_{m-1}(x) + \alpha \cdot h_m(x) \quad (3)$$

Burada;

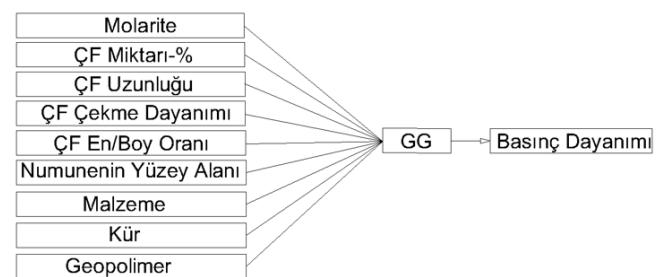
$F_{m-1}(x)$  : önceki modelin tahmini

$\alpha$  : öğrenme oranı

$h_m(x)$  : yeni zayıf öğrenci (genellikle bir karar ağıacı)

$F_m(x)$  : güncellenmiş modelin tahmini

Ayrıca, GG algoritmaları için giriş ve çıkış yol haritası Şekil 3.'te gösterilmiştir.



Şekil 3. OGG algoritması için giriş ve çıkış yol haritası

## Veri Hazırlanması

Makine öğrenimi modelleri için veri setinin kalitesi kritik önem taşır; bu nedenle veri toplama ve hazırlama süreçleri doğru ve titizlikle yapılmalıdır. Bu amaçla literatürde yapılan araştırmalar incelendikten sonra ÇF takviyeli GB numunelerinin basınç dayanımıyla ilgili 105 adet veriyi içeren bir veri seti oluşturulmuş ve bu veri setinde kullanılan basınç değerleri Tablo 1.'de verilmiştir.

Modelleme yapılmadan önce regresyon analizlerinde yanlış sonuçlar elde etmemek için veri setindeki kategorik değişkenlerin sayısal hale dönüştürülmesi gereklidir. Bunun için veri setindeki kategorik değişkenlerin 1 ya da 0, var veya yok olarak kukla değişkenlere (dummy variable) dönüştürülecek kategorik değişkenler regresyon analizine dahil edilmiştir. İlk başta veri setinde toplam 9 tane değişken var iken, Python yardımı ile kategorik değişkenlerin kukla değişkenlere dönüşümü yapıldıktan sonra değişken sayısı 14 olmuştur. Kür çeşidi parametresi 2 adette, bağlayıcı Malzeme çeşidi parametresi 4 adette ve Geopolimer çeşidi parametresi 2 adette dönüştürülmüştür.

Veri setine ait frekans grafikleri Şekil 4.'te sunulmuştur. Ayrıca, veri setinde yer alan sayısal parametrelerin istatistiksel özellikleri Tablo 2.'de sunulmuştur. Veri setindeki eksik değerler, daha iyi sonuçlar elde etmek için eksik verilerin ortalamalarıyla doldurulmuştur. Buna ek olarak, veri setindeki bağımsız değişkenler arasındaki korelasyonlar Şekil 5.'te gösterilmiştir. Korelasyon katsayıları, değişkenler arasındaki ilişkileri analiz etmemize yardımcı olur. Pozitif korelasyon katsayıları değişkenler arasında doğrusal bir ilişki olduğunu gösterirken, negatif korelasyon katsayıları ters ilişkiye işaret eder. Korelasyon katsayısı 1 ise değişkenler arasında mükemmel bir ilişki olduğunu, katsayı 0 ise değişkenlerin bağımsız olduğunu gösterir. Sonuç olarak, doğru toplanmış ve hazırlanmış bir veri seti, makine öğrenimi modellerinin doğruluğunu ve güvenilirliğini artırmada temel bir rol oynar. Bu süreçlerin titizlikle yönetilmesi, modelin kalitesini önemli ölçüde etkiler.

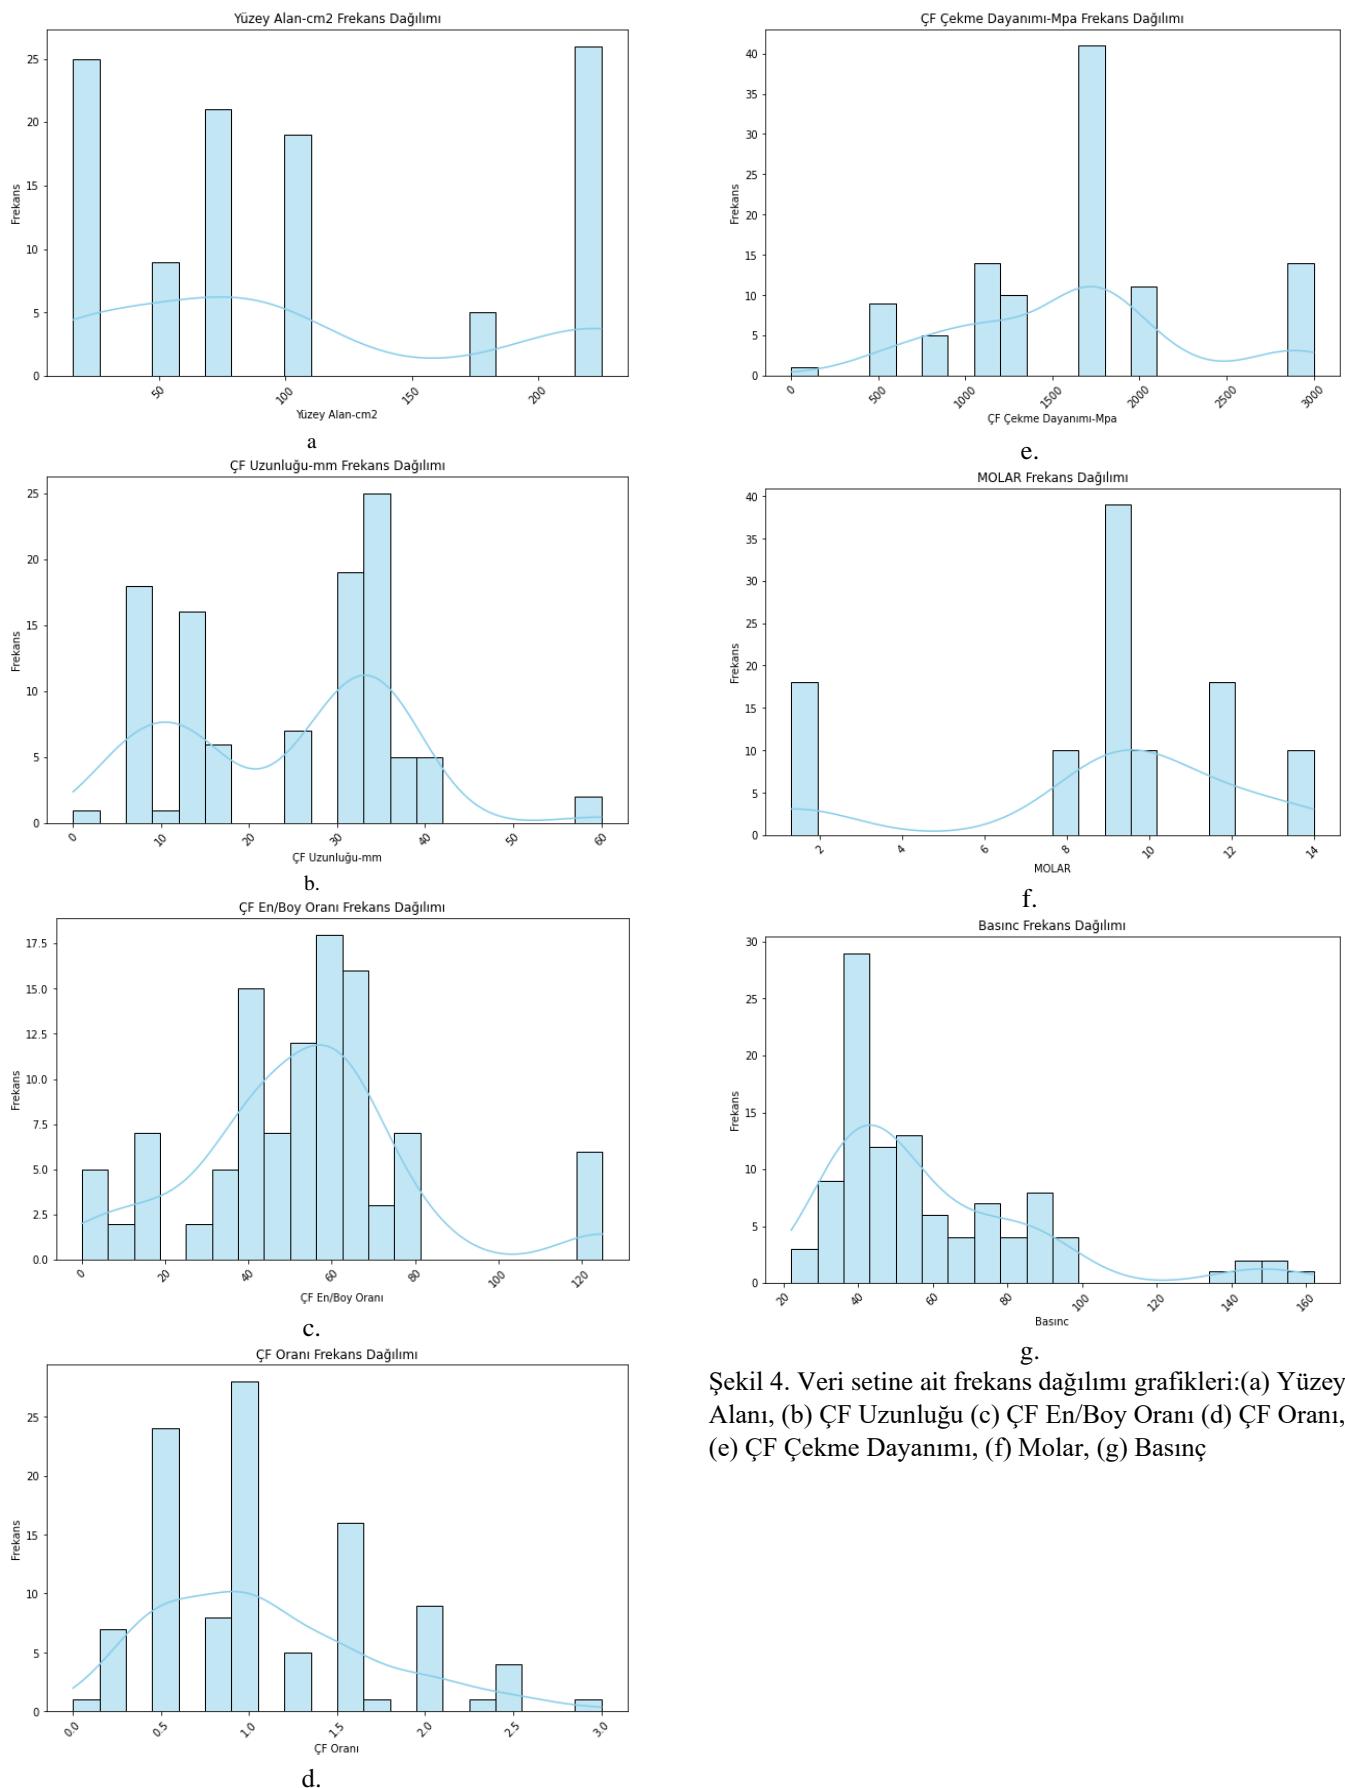
Tablo 1. Veri Seti'ni Oluşturulurken Kullanılan Basınç Dayanım Değerleri

Kaynaklar	Basınç Dayanımı - MPa
[29]	43.3
	47.14
	48.3
	51.21
	54.9
	53
[30]	78
	78.2
	84.6
	81.1
	85.6
	78.9
[31]	140
	147
	144
	152
	150
	162
[32]	42.44
	43.09
	47.46
[33]	32
	32.5
	28.5
	28.5
[34]	55.2
	56.47
	57.7
	59.64
[35]	61.5
	67.02
	73.56
	67.93
[36]	74.97
	74.5
	77.8
	70.5
[37]	72
	38.59
	40.98
	43.04
[38]	40.41
	41.32
	44.25
	53.45
[39]	54.41
	33.6
	35.1
[40]	36.2
	86.5
	99
	89
[41]	78
	35.92
	37.6
	34.73
	33.5
	31.5

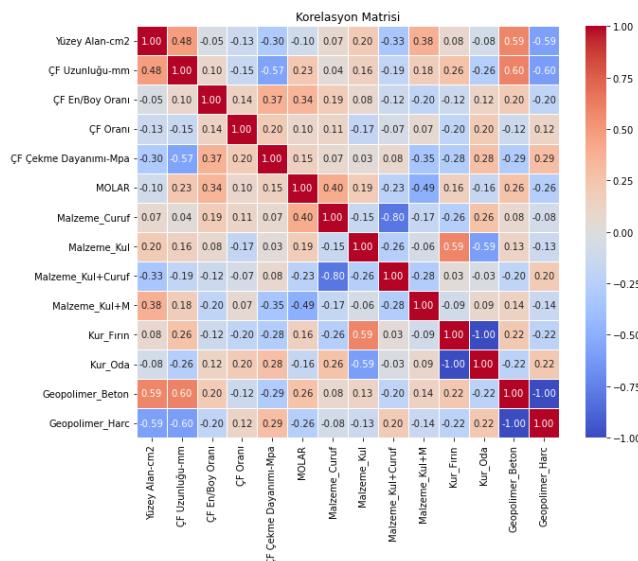
[42]	38.1
	39.8
	37.8
[43]	44.69
	45.45
	48.12
	52.65
	56.06
	58.41
[44]	61.68
	62.15
	67.76
	37
	37.46
	37.94
[45]	38.46
	42
	47
	30.93
	22.13
	50.1
[46]	52.4
	42.3
	37.4
	36.6
	38.46
	39.74
[47]	40.77
	39.49
	45.62
	51.24
	53.21
	54.32
[48]	89.5
	93
	96
	95
	86
	88
[49]	90
	90.1
	50
	51.24
	53.21
	54.32
[50]	89.5
	93
	96
	95
	86
	88

Tablo 2. Veri setinin istatistiksel değerleri

Değişkenler	Veri Sayısı	Min. Değer	Mak. Değer	Ortalama	Standard Sapma
ÇF Uzunluğu (mm)	105	6	60	24.38	12.66
ÇF En/Boy Oranı	105	1.25	125	53.25	26.12
ÇF Oranı (%)	105	0.25	3	1	0.61
ÇF Çekme Dayanımı (MPa)	105	577	3000	1580.4	651.75
Numunenin Yüzey Alanı (cm <sup>2</sup> )	105	16	225	106.77	77.63
Molarite	105	1.3	14	9.45	3.78



Şekil 4. Veri setine ait frekans dağılımı grafikleri:(a) Yüzey Alanı, (b) ÇF Uzunluğu (c) ÇF En/Boy Oranı (d) ÇF Oranı, (e) ÇF Çekme Dayanımı, (f) Molar, (g) Basınç



Şekil 5. Veri setinin korelasyon katsayıları Isı Haritası

## Bulgular ve Sonuçlar

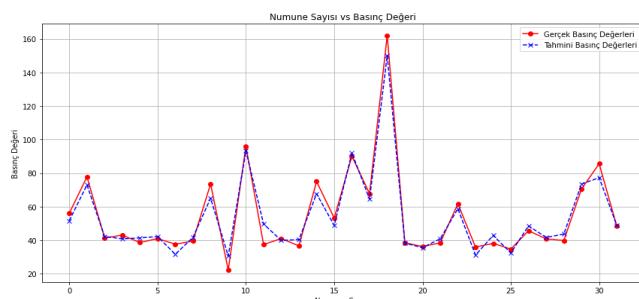
### Bulgular

Bu bölümde, çalışmada kullanılan 105 veriden oluşan veri seti GG modeli kullanılarak ÇF'li kül, metakaolin veya cüruf tabanlı geopolimer beton ya da harçların basınç dayanım tahmin edilmeye çalışılmıştır. Bu çalışmanın performansını değerlendirmek için ortalama hata (ortalama test/tahmin), kök ortalama kare hatası (RMSE), korelasyon katsayısı (R) ve belirleme katsayısı ( $R^2$ ) metrikleri kullanılmıştır. Bu metrikler, modelin tahminlerinin gerçek değerlerden ne kadar farklı olduğunu, doğruluğunu ve tahminler ile gerçek değerler arasındaki ilişkiyi gösterir. Tablo 3.'te, eğitilen GG modeli için kullanılan metrik verilmektedir. Bu sonuçlara göre, GG modelinin performansı oldukça yüksektir. Düşük RMSE, yüksek R ve  $R^2$  değerleri, modelin tahminlerinin genellikle doğru olduğunu ve gerçek değerlerle güçlü bir şekilde ilişkili olduğunu gösterir. Bu durum, modelin veriyi iyi öğrendiğini ve yeni veriler üzerinde iyi sonuçlar verebileceğini işaret eder.

Tablo 3. GG Model değerlendirme metriklerine ait değerler

Model	Ortalama (Test/Tahmin)	RMSE	R	$R^2$
GG	0,99602	4,5428	0,9903	0,971

Ayrıca, GG tarafından yapılan tahminlerin ayrıntıları Şekil 6.'da gösterilmektedir. Bu grafikte mavi çizgi gerçek değerleri, kırmızı çizgi ise tahmin edilen değerleri gösterir. İki çizgi birbirine yakın olduğunda, GG modelinin doğru tahminler yaptığı ve güvenilir bir şekilde çalıştığı anlaşılmıştır.



Şekil 6. GB'nun Basınç Dayanımı tahmin grafiği

Sonuç olarak, GG modeli, veri setindeki desenleri iyi anlayıp doğru tahminler yapabilen güvenilir bir model olarak değerlendirilebilir. Bu metriklerin sağladığı bilgiler, modelin performansının objektif bir şekilde değerlendirilmesini sağlar ve modelin genelleme yeteneğini doğrular.

### Sonuçlar

Bu çalışma, ÇF takviyeli GB'un basınç dayanımının GG makine öğrenimi algoritması kullanılarak modellenmesi ve bu modellemelerin kullanılarak basınç dayanımının tahmin edilmesini amaçlamaktadır. GB, geleneksel çimentolu betonun yerini alabilecek çevre dostu bir yapı malzemesi olarak önem kazanmaktadır. Bu nedenle, bu çalışma bu yenilikçi malzemenin mukavemet özelliklerini daha hızlı ve etkin bir şekilde değerlendirmeyi hedeflemektedir. Çalışmanın ilk adımı literatürde kapsamlı bir inceleme yapmak ve uygun veri setini oluşturmaktır. GB'un basınç dayanımıyla ilgili mevcut araştırmalar ve veri setleri incelenerek modelleme için gerekli veriler toplanmıştır. Daha sonra, toplanan veri seti üzerinde GG makine öğrenimi algoritması kullanılarak bir model eğitilmiştir. GG algoritması, zayıf tahmincileri (genellikle regresyon ağaçları) birleştirerek güçlü bir tahminci oluşturur ve bu sayede karmaşık ilişkileri modelleyebilir. Elde edilen model çeşitli değerlendirme yöntemleri kullanılarak analiz edilmiştir. Bu değerlendirme sürecinde kullanılan bazı yöntemler ve elde edilen sonuçlar şunlardır:

- Tahmin modelinin performansını değerlendirme yöntemlerinden biri modelin tanımlayıcılık katsayısıdır.  $R^2$  değeri GG modeli için 0,971 olarak elde edilmiştir, yani GG modeli %97,1 doğrulukla tahmin yapmıştır. Buda, GG modelinin basınç dayanımının tahminlerinde başarılı sonuçlar verdiği görülmüş ve kullanılabilirliği test edilmiştir.
- Tahmin modellerinin performansını değerlendirmede kullanılan bir diğer yöntemde ortalama hata (ortalama (test/tahmin)) değerleridir. Ortalama hata değeri GG modeli için 0,99602 olarak elde edilmiştir. Ortalama hata değeri 1 yaklaşıkça modelin daha doğru sonuç verdiği anlaşılmıştır. GG modelinin ortalama hata değeri 1 yakın olduğu için model iyi performans göstermiştir.
- GG için RMSE değeri 4,5428'dır, bu da modelin tahminlerinin gerçek değerlere yakın olduğunu gösterirken, R değeriniz 0,9903'dır, bu da gerçek ve tahmin edilen değerler arasında güçlü bir pozitif ilişki olduğunu gösterir. Son olarak, ortalama (test/tahmin) oranı 0,99602'tür, bu da test değerlerinin tahmin değerlerinden yaklaşık % 0,398 daha büyük olduğunu gösterir.
- GG makine öğrenmesi algoritmasının gerçek değerlere yakın tahminler yaptığı gözlemlenmiştir, böylece GB ile yapılacak yapıların maliyetlerinin önceden tahminin yapılabileceği anlaşılmaktadır.

### Kaynaklar

- [1] A. Karthik, K. Sudalaimani, and C. T. Vijaya Kumar, "Investigation on mechanical properties of fly ash-ground granulated blast furnace slag based self-curing bio-geopolymer concrete," *Construction and Building Materials*, vol. 149, pp. 338–349, Sep. 2017, doi: <https://doi.org/10.1016/j.conbuildmat.2017.05.139>.

- [2] M.A. Javeed, M.V. Kumar, H. Narendra, "Studies on mix design of sustainable geopolymers concrete", *International Journal of Innovative Research in Engineering & Management (IJIREM)*, Volume-2: Issue-4, 2015.
- [3] S. A. Bernal, E. D. Rodríguez, R. Mejía de Gutiérrez, M. Gordillo, and J. L. Provis, "Mechanical and thermal characterisation of geopolymers based on silicate-activated metakaolin/slag blends," *Journal of Materials Science*, vol. 46, no. 16, pp. 5477–5486, Aug. 2011, doi: <https://doi.org/10.1007/s10853-011-5490-z>.
- [4] J. Davidovits, "Geopolymers and geopolymeric materials", *J. Therm. Anal.* 1989; 35: 429–441.
- [5] P. Duxson, J. L. Provis, G. C. Lukey, and J. S. J. van Deventer, "The role of inorganic polymer technology in the development of 'green concrete,'" *Cement and Concrete Research*, vol. 37, no. 12, pp. 1590–1597, Dec. 2007, doi: <https://doi.org/10.1016/j.cemconres.2007.08.018>.
- [6] F. Deng, Y. He, S. Zhou, Y. Yu, H. Cheng, and X. Wu, "Compressive strength prediction of recycled concrete based on deep learning," *Construction and Building Materials*, vol. 175, pp. 562–569, Jun. 2018, doi: <https://doi.org/10.1016/j.conbuildmat.2018.04.169>.
- [7] V.A. Chenarlogh, F. Razzazi, and N. Mohammadyahya, "A Multi-View Human Action Recognition System in Limited Data Case using Multi-Stream CNN," Dec. 2019, doi: <https://doi.org/10.1109/icspis48872.2019.9066079>.
- [8] M. Roshani *et al.*, "Proposing a gamma radiation based intelligent system for simultaneous analyzing and detecting type and amount of petroleum by-products," *Nuclear Engineering and Technology*, vol. 53, no. 4, pp. 1277–1283, Apr. 2021, doi: <https://doi.org/10.1016/j.net.2020.09.015>.
- [9] B. Pourghbleh, A. Aghaei Anvigh, A. R. Ramtin, and B. Mohammadi, "The importance of nature-inspired meta-heuristic algorithms for solving virtual machine consolidation problem in cloud environments," *Cluster Computing*, vol. 24, no. 3, pp. 2673–2696, May 2021, doi: <https://doi.org/10.1007/s10586-021-03294-4>.
- [10] A. Karbassi, B. Mohebi, S. Rezaee, and P. Lestuzzi, "Damage prediction for regular reinforced concrete buildings using the decision tree algorithm," *Computers & Structures*, vol. 130, pp. 46–56, Jan. 2014, doi: <https://doi.org/10.1016/j.compstruc.2013.10.006>.
- [11] A. Ahmad, K. Chaiyasarn, F. Farooq, W. Ahmad, S. Suparp, and F. Aslam, "Compressive Strength Prediction via Gene Expression Programming (GEP) and Artificial Neural Network (ANN) for Concrete Containing RCA," *Buildings*, vol. 11, no. 8, p. 324, Jul. 2021, doi: <https://doi.org/10.3390/buildings11080324>.
- [12] H. Song, A. Ahmad, K. A. Ostrowski, and M. Dudek, "Analyzing the Compressive Strength of Ceramic Waste-Based Concrete Using Experiment and Artificial Neural Network (ANN) Approach," *Materials*, vol. 14, no. 16, p. 4518, Aug. 2021, doi: <https://doi.org/10.3390/ma14164518>.
- [13] M. A. Khan, S. A. Memon, F. Farooq, M. F. Javed, F. Aslam, and R. Alyousef, "Compressive Strength of Fly-Ash-Based Geopolymer Concrete by Gene Expression Programming and Random Forest," *Advances in Civil Engineering*, vol. 2021, pp. 1–17, Jan. 2021, doi: <https://doi.org/10.1155/2021/6618407>.
- [14] F. Aslam *et al.*, "Applications of Gene Expression Programming for Estimating Compressive Strength of High-Strength Concrete," *Advances in Civil Engineering*, vol. 2020, pp. 1–23, Sep. 2020, doi: <https://doi.org/10.1155/2020/8850535>.
- [15] H.-H. Chu, M.A. Khan, M. Javed, A. Zafar, H. Alabduljabbar, S. Qayyum, "Sustainable use of fly-ash: Use of gene-expression programming (GEP) and multi-expression programming (MEP) for forecasting the compressive strength of geopolymers concrete," *Ain Shams Engineering Journal*, May 2021, doi: <https://doi.org/10.1016/j.asej.2021.03.018>.
- [16] P. Kumar, S. Sharma, B. Pratap, "Prediction of Compressive Strength of Geopolymer Fiber Reinforced Concrete Using Machine Learning" *Civil Engineering Infrastructures Journal*, 2024, doi: 10.22059/ceij.2024.364871.1956
- [17] J. H. Friedman, "Greedy function approximation: a gradient boosting machine", *Annals of Statistics*, 2001, 1189–1232
- [18] C. Bentejac, A. Csorgo Ho, G. Martinez-Munoz, "A comparative analysis of gradient boosting algorithms", *Artificial Intelligence Review*. 54, 1937–1967, 2021.
- [19] P. Bühlmann, T. Hothorn, "Boosting algorithms: Regularization, prediction and model fitting", 2007.
- [20] T. Chen and C. Guestrin, "XGBoost: a Scalable Tree Boosting System," *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16*, pp. 785–794, 2016, doi: <https://doi.org/10.1145/2939672.2939785>.
- [21] V.Q. Tran, V.Q. Dang, L.S. Ho, "Evaluating compressive strength of concrete made with recycled concrete aggregates using machine learning approach", *Construction and Building Materials*, 323, 126578, 2022.
- [22] T.B. Redmond, M.H. Allen, "Compressive strength of composite brick and concrete masonry walls, MASONRY: Past and Present. Philadelphia: ASTM", 195–232, 1975.
- [23] J. O. Ogutu, H.-P. Piepho, and T. Schulz-Streeck, "A comparison of random forests, boosting and support vector machines for genomic selection," *BMC Proceedings*, vol. 5, no. S3, May 2011, doi: <https://doi.org/10.1186/1753-6561-5-s3-s11>.
- [24] Y. Huang, Z. Huo, G. Ma, L. Zhang, F. Wang, and J. Zhang, "Multi-objective optimization of fly ash-slag based geopolymer considering strength, cost and CO<sub>2</sub> emission: A new framework based on tree-based ensemble models and NSGA-II," *Journal of Building Engineering*, vol. 68, pp. 106070–106070, Jun. 2023, doi: <https://doi.org/10.1016/j.jobe.2023.106070>.
- [25] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, "Scikit-learn: machine learning in python", *J. Mach. Learn. Res.* 12, 2825–2830, 2011.
- [26] M. C. Kang, D. Y. Yoo, R. Gupta, "Machine learning-based prediction for compressive and flexural strengths of steel fiber-reinforced concrete", *Construction and Building Materials*, 266, 121117, 2021. <https://doi.org/10.1016/j.conbuildmat.2020.121117>
- [27] <https://medium.com/machine-learning-t%C3%BCrkiye/korelasyon-katsay%C4%B1s%C4%B1-pyton-uygulamas%C4%B1-de83ea37ff23>
- [28] T. Hastie, R. Tibshirani, J. Friedman, "The Elements of Statistical Learning", *Springer*, 2009. ISBN : 978-0-387-84857-0
- [29] P. Zhang, J. Wang, Q. Li, J. Wan, and Y. Ling, "Mechanical and fracture properties of steel fiber-reinforced geopolymer concrete," *Science and Engineering of Composite Materials*, vol. 28, no. 1, pp. 299–313, Jan. 2021, doi: <https://doi.org/10.1515/secm-2021-0030>.

- [30] Y. Ding and Y.-L. Bai, "Fracture Properties and Softening Curves of Steel Fiber-Reinforced Slag-Based Geopolymer Mortar and Concrete," *Materials*, vol. 11, no. 8, p. 1445, Aug. 2018, doi: <https://doi.org/10.3390/ma11081445>.
- [31] Y. I. A. Aisheh, D. S. Atrushi, M. H. Akeed, S. Qaidi, and B. A. Tayeh, "Influence of polypropylene and steel fibers on the mechanical properties of ultra-high-performance fiber-reinforced geopolymer concrete," *Case Studies in Construction Materials*, vol. 17, p. e01234, Dec. 2022, doi: <https://doi.org/10.1016/j.cscm.2022.e01234>.
- [32] K. Vijai, R. Kumutha, B.G. Vishnuram, "Effect of inclusion of steel fibres on the properties of geopolymer concrete composites", *Asian Journal of Civil Engineering*, 13(3), 381-389, 2012.
- [33] S. F. A. Shah, B. Chen, S. Y. Oderji, M. Aminul Haque, and M. R. Ahmad, "Comparative study on the effect of fiber type and content on the performance of one-part alkali-activated mortar," *Construction and Building Materials*, vol. 243, p. 118221, May 2020, doi: <https://doi.org/10.1016/j.conbuildmat.2020.118221>.
- [34] R. R. Bellum, "Influence of steel and PP fibers on mechanical and microstructural properties of fly ash-GGBFS based geopolymer composites", *Ceramics International*, 48(5), 6808-6818, 2022.
- [35] N. A. Eren, R. Alzeebaree, A. Çevik, A. Niş, A. Mohammedameen, M. E. Gülsan, "Fresh and hardened state performance of self-compacting slag based alkali activated concrete using nanosilica and steel fiber," *Journal of composite materials*, vol. 55, no. 28, pp. 4125–4139, Aug. 2021, doi: <https://doi.org/10.1177/00219983211032390>.
- [36] K. Z. Farhan, M. A. M. Johari, R. Demirboğa, "Evaluation of properties of steel fiber reinforced GGBFS-based geopolymer composites in aggressive environments," *Construction and Building Materials*, vol. 345, p. 128339, Aug. 2022, doi: <https://doi.org/10.1016/j.conbuildmat.2022.128339>.
- [37] A. Pham, K. T. Nguyen, T. A. Le, K. Lee, "Investigation of impact behavior of innovative non-curing steel fiber geopolymer composites," *Case studies in construction materials*, vol. 16, pp. e01011–e01011, Jun. 2022, doi: <https://doi.org/10.1016/j.cscm.2022.e01011>
- [38] A. C. R. da Silva, B. M. Almedia, M. M. Lucas, V. S. Cândido, K. S. P. da Cruz, M. S. Oliveira, A. R. G. de Azevedo, S. N. Monteiro, "Fatigue behavior of steel fiber reinforced geopolymer concrete," *Case Studies in Construction Materials*, vol. 16, p. e00829, Jun. 2022, doi: <https://doi.org/10.1016/j.cscm.2021.e00829>.
- [39] H. A. Goaiz, H. A. Shamsaldeen, M. A. Abdulrehman, and T. S. Al-Gasham, "Evaluation of Steel Fiber Reinforced Geopolymer Concrete Made of Recycled Materials," *International Journal of Engineering*, vol. 35, no. 10, pp. 2018–2026, 2022, doi: <https://doi.org/10.5829/ije.2022.35.10a.19>.
- [40] W. Chen, J. Pan, B. Zhu, X. Ma, Y. Zhang, Y. Chen, X. Li, L. Meng, J. Cai, "Improving mechanical properties of 3D printable 'one-part' geopolymer concrete with steel fiber reinforcement," *Journal of Building Engineering*, vol. 75, pp. 107077–107077, Sep. 2023, doi: <https://doi.org/10.1016/j.jobr.2023.107077>.
- [41] L. Qin, Z. Xu, Q. Liu, Z. Bai, C. Wang, Q. Luo, Y. Yuan, "Experimental study on mechanical properties of coal gangue base geopolymer recycled aggregate concrete reinforced by steel fiber and nano-Al<sub>2</sub>O<sub>3</sub>," *Reviews on advanced materials science*, vol. 62, no. 1, Jan. 2023, doi: <https://doi.org/10.1515/rams-2023-0343>.
- [42] J. M. Their and M. Özakça, "Developing geopolymer concrete by using cold-bonded fly ash aggregate, nano-silica, and steel fiber," *Construction and Building Materials*, vol. 180, pp. 12–22, Aug. 2018, doi: <https://doi.org/10.1016/j.conbuildmat.2018.05.274>.
- [43] S. A. Elkholly, H. I. El-Hassan, "Mechanical and microstructure characterization of steel fiber-reinforced geopolymer concrete", *InProceedings of the ISEC*, 2019.
- [44] Z. Xu, Q. Liu, H. Long, H. Deng, Z. Chen, and D. Hui, "Influence of nano-SiO<sub>2</sub> and steel fiber on mechanical and microstructural properties of red mud-based geopolymer concrete," *Construction and Building Materials*, vol. 364, p. 129990, Jan. 2023, doi: <https://doi.org/10.1016/j.conbuildmat.2022.129990>
- [45] S. C. Moghaddam, R. Madandoust, M. Jamshidi, I. M. Nikbin, "Mechanical properties of fly ash-based geopolymer concrete with crumb rubber and steel fiber under ambient and sulfuric acid conditions," *Construction and Building Materials*, vol. 281, p. 122571, Apr. 2021, doi: <https://doi.org/10.1016/j.conbuildmat.2021.122571>
- [46] M. Ibraheem, F. Butt, R. M. Waqas, K. Hussain, R. F. Tufail, N. Ahmad, K. Usanova, M. A. Musarat, "Mechanical and Microstructural Characterization of Quarry Rock Dust Incorporated Steel Fiber Reinforced Geopolymer Concrete and Residual Properties after Exposure to Elevated Temperatures," *Materials*, vol. 14, no. 22, pp. 6890–6890, Nov. 2021, doi: <https://doi.org/10.3390/ma14226890>.
- [47] J. Zheng, L. Qi, Y. Zheng, and L. Zheng, "Mechanical properties and compressive constitutive model of steel fiber-reinforced geopolymer concrete," *Journal of Building Engineering*, vol. 80, pp. 108161–108161, Dec. 2023, doi: <https://doi.org/10.1016/j.jobr.2023.108161>.
- [48] A. K. Parashar, A. Kumar, P. Singh, N. Gupta, "Study on the mechanical properties of GGBS-based geopolymer concrete with steel fiber by cluster and regression analysis," *Asian journal of civil engineering*, vol. 25, no. 3, pp. 2679–2686, Dec. 2023, doi: <https://doi.org/10.1007/s42107-023-00937-2>.
- [49] C. P. Devika, R. N. Deepthi, "Study of Flexural Behavior of Hybrid Fibre Reinforced Geopolymer Concrete Beam," *International Journal of Science and Research (IJSR)*, vol. 4, Issue 7, July 2015.
- [50] X. Gao, Q. L. Yu, H. J. H. Brouwers, "Evaluation of hybrid steel fiber reinforcement in high performance geopolymer composites," *Materials and Structures*, vol. 50, 165, 2017. <https://doi.org/10.1617/s11527-017-1030-x>