

Beton Basınç Dayanımı Tahmini için Özellik Mühendisliği ve Makine Öğrenimi Tabanlı Hibrit Bir Yaklaşım

Mehmet Akif Bülbül*¹

*¹ Kayseri Üniversitesi Mühendislik Mimarlık ve Tasarım Fakültesi Yazılım Mühendisliği, KAYSERİ

(Alınış / Received: 16.04.2024, Kabul / Accepted: 23.04.2024, Online Yayınlanma / Published Online: 30.04.2024)

Anahtar Kelimeler
Özellik Mühendisliği,
Makine Öğrenimi,
Beton Basınç Dayanımı

Öz: Beton basınç dayanımı tahmini, inşaat sektöründe yapıların dayanıklılığı ve güvenliği açısından hayati önem taşır. Doğru bir tahmin, yapıların tasarımında güvenilirlik sağlar ve yapısal mühendislik projelerinin başarılı bir şekilde tamamlanmasına katkıda bulunur. Ayrıca, tahminler, malzeme seçimi ve yapısal güvenlik hesaplamaları gibi kritik kararların alınmasında da önemli bir rol oynar. Bu nedenle, beton basınç dayanımı tahmini, beton endüstrisinde kalite kontrolünün ve güvenliğin sağlanması için temel bir adımdır. Bu sebeple bu çalışmada beton basınç dayanımlarının yüksek doğrulukta tahmin edilmesi amaçlanmıştır. Bu amaç doğrultusunda UCI' den (University of California Irvine) alınan Beton Basınç Dayanımı veri seti üzerinde Karar Ağaçları Regresyonu, Destek Vektör Regresyonu, Lineer Regresyon ve Sinir Ağları ile tahmin işlemleri gerçekleştirilmiştir. Çalışmada veri seti üzerinde özellik mühendisliği tekniği kullanılarak 50 özelliğe sahip yeni bir veri seti daha oluşturulmuştur. Oluşturulan yeni veri seti üzerinde aynı yöntemler yeniden uygulanarak beton basınç dayanım tahminleri yapılmıştır. Özellik mühendisliği uygulanmadan yapılan tahminler ile özellik mühendisliği uygulanarak elde edilen yeni veri seti üzerinde yapılan tahminler tartışmalı ve karşılaştırılmalı bir şekilde sunulmuştur. Elde edilen bulgular Özellik mühendisliğinin çalışmada kullanılan makine öğrenimi yöntemlerinin performanslarını artırdığını gösterirken en başarılı yöntemin makine mühendisliği ve sinir ağları ile kurulan yapıdan elde edildiğini göstermektedir.

A Hybrid Approach Based on Feature Engineering and Machine Learning for Concrete Compressive Strength Prediction

Keywords
Feature Engineering,
Machine Learning,
Concrete Compressive
Strength

Abstract: Concrete compressive strength prediction is vital to the durability and safety of structures in the construction industry. An accurate prediction ensures reliability in the design of structures and contributes to the successful completion of structural engineering projects. Furthermore, predictions play an important role in making critical decisions such as material selection and structural safety calculations. Therefore, concrete compressive strength prediction is a fundamental step to ensure quality control and safety in the concrete industry. Therefore, this study aims to predict concrete compressive strength with high accuracy. For this purpose, prediction processes were performed with Decision Tree Regression, Support Vector Regression, Linear Regression and Neural Networks on the Concrete Compressive Strength data set obtained from UCI (University of California Irvine). In the study, a new dataset with 50 features was created by using feature engineering technique on the dataset. Concrete compressive strength predictions were made by reapplying the same methods on the new data set. The predictions made without applying feature engineering and the predictions made on the new data set obtained by applying feature engineering are presented in a controversial and comparative manner. The findings show that feature engineering improves the performance of the machine learning methods used in the study, while the most

successful method is obtained from the structure established with machine engineering and neural networks.

*İlgili Yazar, email: makifbulbul@kayseri.edu.tr

1. Giriş

Basınç dayanımının değeri beton yapıların güvenilir tasarımı ve güvenlik değerlendirmesinin yanı sıra betonun kalite değerlendirmesinde önemli bir rol oynar [1]. Betonun basınç dayanımı, verilen bileşenlere göre oldukça doğrusal olmayan işlevlere sahiptir [2]. Yüksek performanslı beton üretmek ciddi zaman alan, mali değerleri yüksek ve ciddi bir insan gücü gerektirir [3]. Harcanan bu zaman, maliyetten ve insan gücünden tasarruf sağlanabilmesi ancak yüksek doğruluk oranlarına sahip tahmin modellerinin geliştirilmesi ile mümkündür.

Chengquan ve arkadaşları [4], betonun basınç dayanımını belirlemek için stokastik fraktal arama, çoklu evren optimizasyonu ve girdap arama algoritması olmak üzere üç yapay zeka yöntemi kullanmışlardır. Çalışmada bu üç yöntem çok katmanlı algılayıcı ağlar ile entegre edilmiştir. Yapılan deneysel çalışmalardan elde edilen bulgular beton basınç dayanımı tahmininde stokastik fraktal arama ile entegre edilen çok katmanlı algılayıcı ağların diğer yöntemlere göre daha başarılı sonuçlar elde ettiğini göstermiştir.

Şarkı ve arkadaşları [5], yapmış oldukları çalışmada atık mermer tozu içeren betonun basınç dayanımının tahmininde makine öğreniminin yeteneklerinden yararlanmışlardır. Çalışmada farklı atık mermer tozu bileşimleri ve değişen su bağlayıcı oranları kullanılarak veri seti elde edilmiştir. Çoklu doğrusal regresyon, K-en yakın komşu, destek vektör regresyonu, karar ağacı, rastgele orman, ekstra ağaçlar ve gradyan artırma yöntemlerinin kullanıldığı çalışmada rastgele orman yöntemi ile diğer yöntemlerden daha yüksek R2 değeri ve daha düşük ortalama mutlak hata değeri elde edilmiştir.

Zhang ve arkadaşları [6], hibrit algoritmalar kullanılarak ultra büyük işlenebilirlik betonunun basınç dayanımı tahminini gerçekleştirmişlerdir. Çalışmada basınç dayanımı tahmini için nöro-bulanık çıkarım sistemi kullanılmıştır. Nöro-bulanık çıkarım sistemi balina optimizasyon algoritması ve parçacık sürü optimizasyon algoritması ile hibritleştirilerek iki farklı model öne sürülmüştür. Yapılan deneysel çalışmalar sonucunda balina optimizasyon algoritması ile hibritleştirilen nöro-bulanık çıkarım sistemi hem diğer modelden hem de literatürde aynı veri seti ile yapılan diğer çalışmalardan daha başarılı sonuçlar elde etmiştir.

Maheryan ve arkadaşları [7], yapmış oldukları çalışmada nano silika modifiyeli betonda basınç dayanımını tahmin etmek için farklı makine öğrenimi yöntemleri kullanmışlardır. Yapay Sinir Ağları, Doğrusal Regresyon, Karar Ağaçları, Rastgele Orman, Destek Vektör Makineleri, Stokastik Gradyan İnişi, K-en Yakın Komşu yöntemleri gibi literatürde sıkça kullanılan makine öğrenimi yöntemlerinin kullanıldığı çalışmada Rastgele Orman yöntemi ile diğer yöntemlerden daha başarılı sonuçlar elde edilmiştir.

Mustapha ve arkadaşları [8], kuaterner karışım betonun basınç dayanımının tahmini için dört farklı gradyan artırıcı algoritma kullanmışlardır. Gradyan Artırıcı Regresör, Işık Gradyan Artırma Modeli, Aşırı Gradyan Artırma ve CatBoost makine öğrenme algoritmalarının kullanıldığı çalışmada her algoritmanın hiper parametre optimizasyonu beş katlı çapraz doğrulama kullanarak gerçekleştirmişlerdir. Her gradyan artırma algoritması için beş olmak üzere toplam yirmi optimal model oluşturulan çalışmada CatBoost yöntemi ile daha başarılı sonuçlar elde edilmiştir.

Zhou ve arkadaşları [9], karar ağacı modellerini kullanarak geopolimer beton basınç dayanımının tahmini etmeye çalışmışlardır. Karar ağacı, XGBoost ve Rastgele Orman yöntemlerinin kullanıldığı çalışmada modellerin doğruluğu ortalama mutlak hata, ortalama mutlak yüzde hata gibi yöntemlerle belirlenmiştir. Yapılan deneysel çalışmalar sonucunda XGBoost yöntemi ile geopolimer beton basınç dayanımı tahmininde daha yüksek doğrulukta sonuçlar elde etmişlerdir.

Joshi ve arkadaşları [10], yüksek performanslı beton ve lif takviyeli yüksek dayanımlı kendiliğinden yerleşen betonun basınç dayanımını üç aşamalı bir yöntemle tahmin etmeye çalışmışlardır. Ön işleme, özellik çıkarma ve tahmin aşamalarını içeren bu çalışmada Derin İnanç Ağı ve Uzun Kısa Süreli Bellek yöntemleri hibritleştirilmiştir. Ayrıca, Kaya Sırtlanları Güncellenmiş Serçe Algoritması, önerilen çalışmanın tahmin doğruluğunu artırmak için Derin İnanç Ağı'nda kullanılan ağırlıklarına ince ayar yapmak için kullanılmıştır. Yapılan deneysel çalışmalardan elde edilen bulgular sunulan hibrit yöntemin başarısını ortaya koymuştur.

Beton basınç dayanımı tahmininde literatürde birçok farklı yöntem ve algoritma kullanılmaktadır. Kullanılan yöntemler belirli bir veri seti üzerinde uygulanmış ve belirli sonuçlar elde edilmiştir. Beton basınç dayanımı

tahmininde kullanılan yöntemlerde kullanılan veri seti özellikleri genelde az ve sınırlıdır. Veri setlerinde kullanılan özelliklerin farklı yöntemler kullanılarak artırılması ve bu artırımın tahmin performansında nasıl bir etki yapacağı sorusu bu çalışmalarda eksik kalmaktadır. Bunları ışığında bu çalışmada, beton basınç dayanımı tahmini için literatürde sıkça kullanılan Karar Ağaçları Regresyonu, Destek Vektör Regresyonu, Lineer Regresyon ve Sınır Ağları yöntemleri kullanılmıştır. Bu yöntemler UCI (University of California Irvine) veri deposunda bulunan Beton Basınç Dayanımı (Concrete Compressive Strength) veri seti üzerinde çalıştırılmıştır. Daha sonra kullanılan veri setinden özellik mühendisliği kullanılarak daha fazla özelliğe sahip yeni bir veri seti oluşturulmuştur. Oluşturulan bu yeni veri seti ile aynı makine öğrenimi yöntemleri yeniden kullanılmıştır. Yapılan deneysel çalışmalardan elde edilen bulgular karşılaştırmalı ve tartışmalı bir şekilde sunulmuştur.

2. Materyal ve Metot

Bu bölümde beton basınç dayanımı tahmin işleminde kullanılan yöntemler tanıtılacaktır.


2.1. Veri Seti

Beton basınç dayanımı tahmin işlemi için Yeh tarafından oluşturulan ve UCI' de bulunan Beton Basınç Dayanımı (Concrete Compressive Strength) veri seti kullanılmıştır [11]. Veri seti içerisinde bulunan özellikler Tablo 1'de gösterilmektedir.

Tablo 1. Beton Basınç Dayanımı veri seti özellikleri

Değişken Adları	Çalışmadaki Roller	Özellik No	Birimler
Çimento	Özellik	1	kg/m ³
Yüksek Fırın Cürufu	Özellik	2	kg/m ³
Uçucu Kül	Özellik	3	kg/m ³
Su	Özellik	4	kg/m ³
Süper akışkanlaştırıcı	Özellik	5	kg/m ³
İri Agregası	Özellik	6	kg/m ³
İnce Agregası	Özellik	7	kg/m ³
Yaş	Özellik	8	Gün
Beton basınç dayanımı	Hedef	9	Mpa

Tablo 1' de sunulan veri seti özelliklerinden 8 tanesi ile beton basınç dayanımı tahmin edilecektir. Veri seti içerisinde 1030 tane Tablo 1' de sunulan özelliklere sahip veri bulunmaktadır. Makine öğrenimi yöntemlerinde kullanılmak üzere veri seti %70 eğitim ve %30 test olmak üzere iki bölüme ayrılmıştır. Çalışmada kullanılan veri seti içerisindeki özelliklerin birbirleri ile olan korelasyon grafiği Şekil 1' de gösterilmektedir.



Şekil 1. Veri seti özellikleri arasındaki korelasyon grafiği

Şekil 1' de sunulan korelasyon grafiğine bakıldığında özellikler arasında farklı korelasyonlar durumları bulunmaktadır. Özellik 6 ile özellik 5 arasında negatif yönde bir korelasyon gözlenirken özellik 5 ile özellik 9 arasında pozitif bir korelasyon gözlemlenmektedir.

2.2. Değerlendirme Metrikleri

Beton basınç dayanımı tahmin işleminde modellerin başarısını ölçmek için literatürde makine öğrenmesi yöntemlerinin başarısını ölçen metrikler kullanılacaktır. Bu metrikler Ortalama Karesel Hata (OKH) ve Ortalama Karesel Hatanın Kökü (OKHK) olup bu değerlerin matematiksel formülleri Denklem 1 ve Denklem 2'de gösterilmiştir.

$$OKH = \frac{1}{n} \sum_{i=1}^N (y_i^r - y_i^p)^2 \quad (1)$$

$$OKHK = \sqrt{OKH} = \sqrt{\frac{1}{n} \sum_{i=1}^N (y_i^r - y_i^p)^2} \quad (2)$$

Denklem 1 ve Denklem 2'te, y^r gerçek değerlerin tahmin edilen değerlerini, y^p tahmin edilen değerleri temsil eder. Bu değerlendirme metrikleri makine öğreniminde tahmin edilen değerlerin doğruluğunu ölçmek için kullanılmaktadır [12].

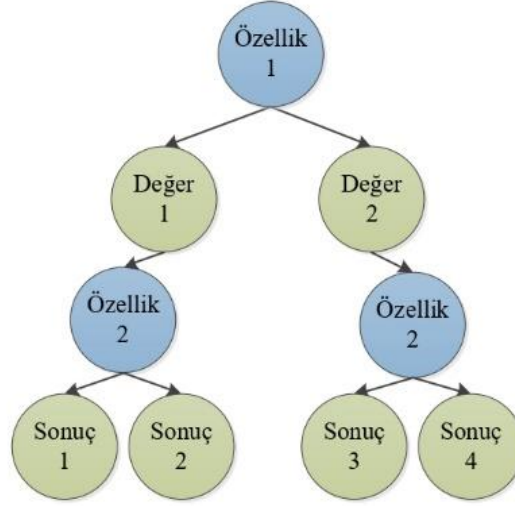
2.3. Özellik Mühendisliği

Özellik mühendisliği, model performansını iyileştirmek için ham verilerden ilgili özelliklerin veya niteliklerin oluşturulmasını ve seçilmesini içeren, makine öğrenimi ve veri biliminin kritik bir yönüdür [13]. Bir modele daha bilgilendirici girdi değişkenleri sağlayarak modelin tahmin gücünü artırmayı amaçlayan özellik çıkarma, dönüştürme ve seçme gibi bir dizi tekniği kapsar. Özellik mühendisliği genellikle veri içindeki temel kalıpları ve ilişkileri yakalayan anlamlı özellikleri tanımlamak için alan bilgisini içerir. Ölçeklendirme, kategorik değişkenleri kodlama, eksik değerleri işleme ve etkileşim terimleri oluşturma gibi teknikler, verileri modellemeye hazırlamak için özellik mühendisliğinde yaygın olarak kullanılır [14]. Sonuçta etkili özellik mühendisliği, makine öğrenimi modellerinin doğruluğunu ve genelleştirilmesini önemli ölçüde etkileyerek gerçek dünya verilerinin karmaşıklığını daha iyi yakalamalarını sağlar.

Çalışmada Tablo 1’de sunulan özelliklere ait veri seti özellik mühendisliği kullanılarak özellik sayısı artırılmıştır. Oluşturulan yeni veri seti üzerinde 50 farklı özellik bulunmaktadır. Bu sayı yapılan deneysel çalışmalar sonucunda belirlenmiştir. Bu özellik artırımı MATLAB platformunda gerçekleştirilmiştir.

2.4. Karar Ağacı Regresyonu

Karar ağacı (KA), her bir düğümde rastgele sayıda alt düğüm ve dallara sahip bir ağaç veri yapısıdır. Bir düğümün çıkışları olan alt düğümlere iç düğüm denir; diğer düğümlere ise yaprak denir. Bu yapı, regresyon veya sınıflandırma gibi işlemlerde kullanılır. Belirli bir fonksiyonla ilgili bir iç düğüm tarafından verilen girdi değişkenlerinin değerlerine göre, veri kümesi iki veya daha fazla gruba bölünür [15]. Basit bir KAR yapısı Şekil 2’de gösterilmektedir.

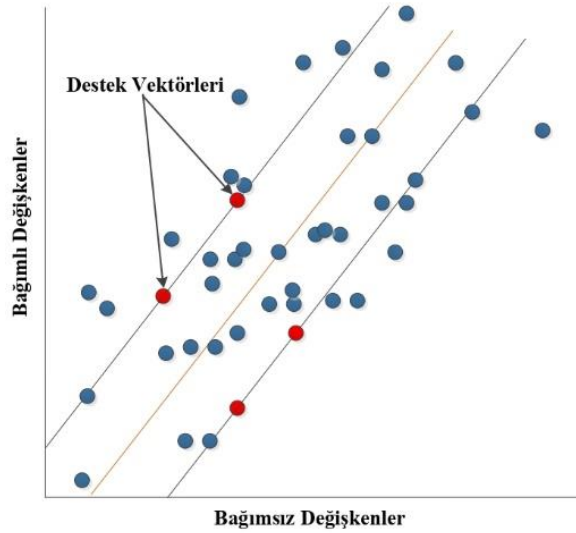


Şekil 2. KAR yapısı

Karar ağacı modeli, ağaçtaki her bölmede her bağımsız değişkenin bağımlı değişken üzerindeki etkisini hesaplamak için tüm girdi özniteliklerini değerlendirir. Bu işlem modelde özyinelemeli olarak gerçekleştirilir ve sonuç olarak bir karar ağacı oluşturulur [16].

2.5. Destek Vektör Regresyonu

Destek Vektör Regresyonu(Support Vector Regression-SVR), istatistiksel öğrenme teorisine ve yapısal risk minimizasyonu ilkesine dayanmaktadır [17]. SVR küçük örneklem büyüklükleri ve yüksek boyutlara sahip doğrusal olmayan problemlerin ele alınmasında benzersiz avantajlara sahiptir. SVR İnşaat mühendisliği problemlerinde daha yüksek doğrulukla etkin bir şekilde kullanılabilen kararlı algoritmalarından biridir [18]. Basit bir SVR yapısı Şekil 3’de gösterilmektedir.

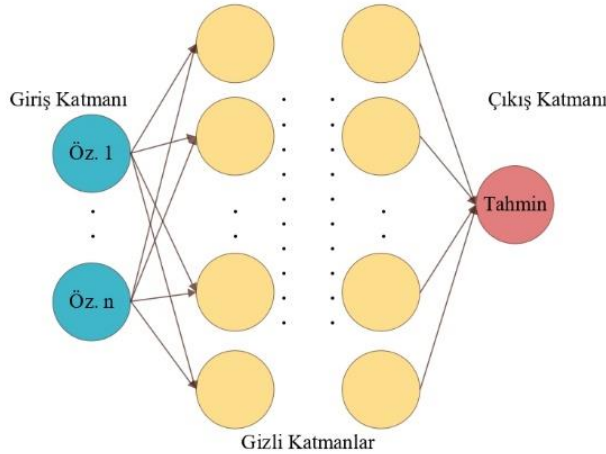


Şekil 3. SVR yapısı

Şekil 3'de görüldüğü gibi SVR veri noktalarının marjinal hatayla çevrelenmesini sağlar. Her bir veri noktasının hiper düzlem ile ne kadar uyduğunu buradaki marjinal hata belirler. Bu hata en aza indirgenerek model tahmin yeteneğini artırır.

2.6. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), regresyon problemlerini çözmek için kullanılan güçlü bir makine öğrenimi tekniğidir [19]. Regresyon modelleri, bir bağımlı değişkenin bir veya daha fazla bağımsız değişkene bağlı olduğu ilişkiyi modellemeyi amaçlar. Yapay sinir ağları, karmaşık veri setlerindeki bu ilişkileri keşfetmek ve öngörmek için kullanılır [20]. Basit bir YSA yapısı Şekil 4' de gösterilmektedir.



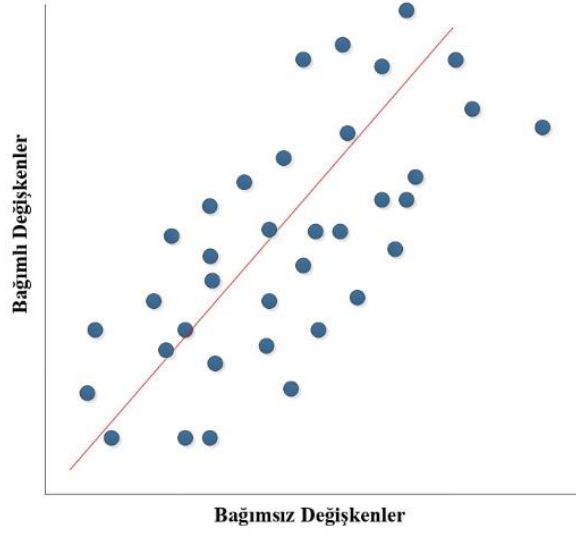
Şekil 4. YSA yapısı

Şekil 4'de görüldüğü gibi YSA yapısı üç ana katmandan oluşmaktadır. Veri akış yönü giriş katmanından çıkış katmanına doğru ilerlemektedir. Ağ, giriş özelliklerinden çıktı tahminini üretmek için katmanlar arasındaki ağırlıkları ayarlar ve veriye uyum sağlar. Eğitim sürecinde, ağ gerçek çıktılar ile tahmin edilen çıktılar arasındaki farkı minimize etmek için optimizasyon algoritmaları kullanır. Bu şekilde, yapay sinir ağları regresyon problemlerini çözer ve veriler arasındaki karmaşık ilişkileri modellemeye yardımcı olur.

2.6. Lineer Regresyon

Lineer Regresyon (LR), değişkenlerin bağımsız ve özdeş olarak dağıldığı varsayımına sahip istatistiksel bir modeldir. Basit ve çok değişkenli doğrusal regresyon, bağımlı ve bağımsız değişkenler arasındaki doğrusal ilişkiyi

ifade eden matematiksel modelleri bulmayı ve bu modelleri kullanarak bağımlı değişken hakkında geleceğe yönelik tahminler yapmayı amaçlar [21]. Yüksek boyutlu veri kümelerinde, birçok değişken veya özellik, hedef veya yanıt değişkeniyle ilgisiz veya gereksiz olabilir [22]. Basit LR grafiği Şekil 5’ de gösterilmektedir.

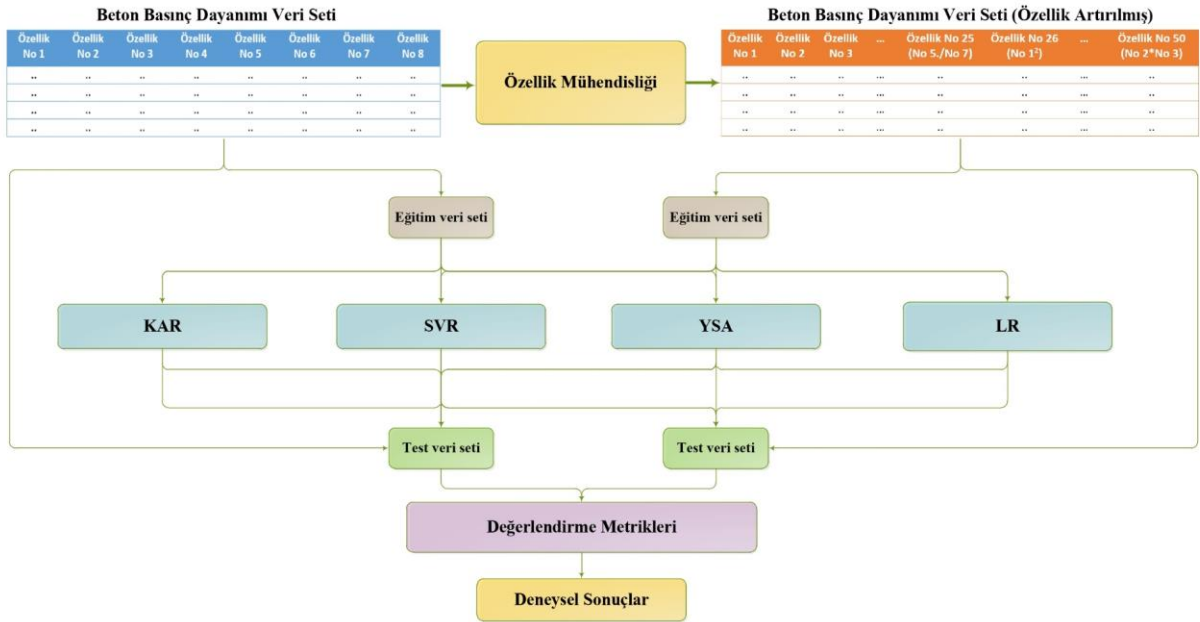


Şekil 5. LR yapısı

Şekil 5’ de sunulan grafik bağımsız bir değişkenin bağımlı bir değişken ile olan ilişkisini göstermektedir.

3. Bulgular

Beton basınç dayanımı tahmini için çalışmada kullanılan metodolojinin diyagramı Şekil 6’da gösterilmektedir.



Şekil 6. Çalışmada kullanılan metodoloji diyagramı

Şekil 6’ da sunulan diyagramda öncelikle beton basınç dayanımı tahmini için kullanılan veri seti üzerinde farklı makine öğrenimi yöntemleri kullanılacaktır. Daha sonra özellik mühendisliği kullanılarak mevcut veri setinden üretilen ve daha fazla özelliğe sahip yeni veri seti üzerinde aynı makine öğrenimi yöntemleri beton basınç dayanımını tahmin edeceklerdir. Şekil 6’ da sunulan mimari çok boyutlu problem çözümlerinde sunmuş olduğu kodlama kolaylığı nedeniyle MATLAB platformunda gerçekleştirilmiştir. Her iki veri seti üzerinde aynı yöntemlerle elde edilen bulgular tartışmalı bir şekilde sunulacaktır.

Şekil 6' da sunulan veri setleri üzerinde her iki veri seti de %70 eğitim ve %30 test olmak üzere iki bölüme ayrılmıştır. Eğitim veri seti ile eğitilen makine öğrenimi yöntemlerinin başarıları daha sonra karşılaştıkları test verileri ile ölçülmektedir. Ham veri seti üzerinde yapılan deneysel çalışmalar ile test veri seti üzerinden modellerin yapmış oldukları tahminlerin performansları Eşitlik 1-4' e göre hesaplanmış ve Tablo 2' de sunulmuştur.

Tablo 2. Veri seti üzerinde makine öğrenimi yöntemlerinin performansları

Modeller	OKH	OKHK
KAR	157,50	12,55
SVR	130,65	11,43
YSA	138,53	11,77
LR	129,96	11,40

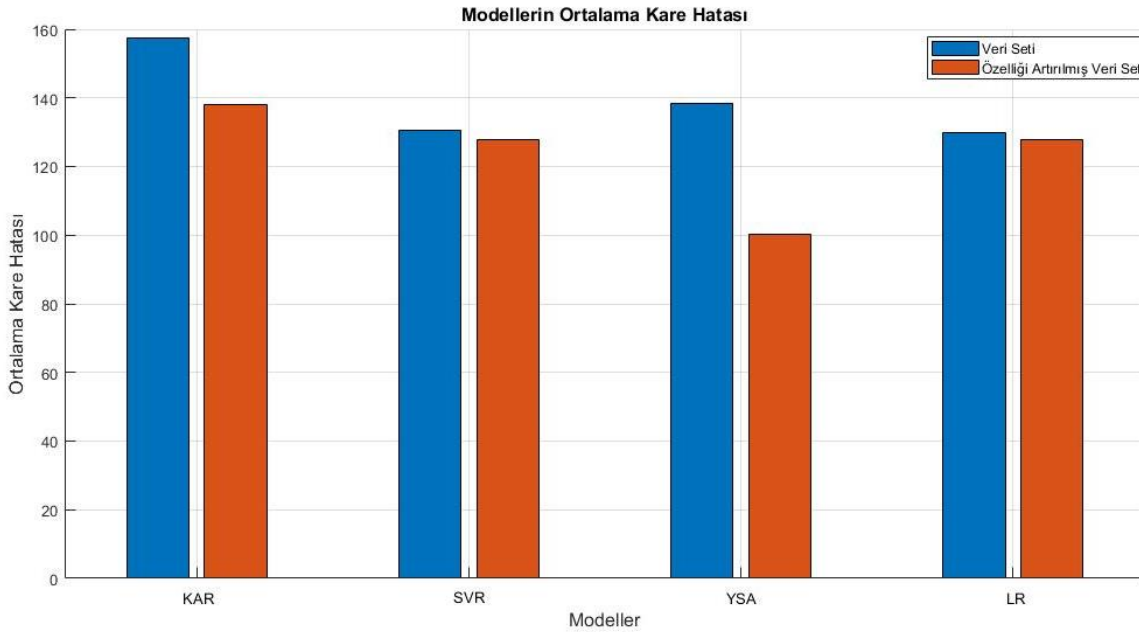
Tablo 2'de görüldüğü üzere özellik mühendisliği uygulanmamış veri seti üzerinde çalıştırılan makine öğrenme yöntemleri üzerinde en başarılı model LR modelidir.

Deneysel çalışmaların ikinci bölümünde özellik mühendisliği ile elde edilen veri seti üzerinde aynı modeller çalıştırılmış ve deneysel sonuçlar Tablo 3' de sunulmuştur.

Tablo 3. Özellik mühendisliği ile genişletilmiş veri seti üzerinde makine öğrenimi yöntemlerinin performansları

Modeller	OKH	OKHK
Özellik Mühendisliği + KAR	138,06	11,75
Özellik Mühendisliği + SVR	127,69	11,30
Özellik Mühendisliği + YSA	100,20	10,01
Özellik Mühendisliği + LR	127,69	11,30

Çalışmada kullanılan veri setleri ve kullanılan bütün modellerin performanslarının karşılaştırılmış hali Şekil 7'de gösterilmektedir.



Şekil 7. Her iki veri setinde uygulanan yöntemlerin OKH performansları

Şekil 7'de görüldüğü üzere veri seti üzerinde uygulanana özellik mühendisliği ile özellik artırılma işlemi sonucunda YSA modelinin performansında ciddi bir artış söz konusu olmuştur. Aynı zamanda özellik mühendisliği uygulanmayan veri seti üzerinde yapılan deneysel çalışmalarda en başarılı model LR iken veri seti üzerinde özellik mühendisliği uygulandıktan sonra en başarılı model YSA olmuştur.

4. Tartışma ve Sonuç

Beton basınç dayanımı tahmini, inşaat mühendisliği ve malzeme bilimi alanlarında temel konulardan bir tanesidir. Beton, yapıların mekanik dayanıklılığını sağlayan kilit bir yapı malzemesidir ve bu nedenle basınç dayanımının doğru bir şekilde tahmin edilmesi önemlidir. Basınç dayanımını belirleyen faktörler arasında birçok faktör vardır ve bu faktörlerin karmaşıklığı ve etkileşimi, tahmin sürecini zorlaştırır. Bu zorluluk beraberinde deneysel ve analitik çalışmaları gerektirir. Betonun basınç dayanımının doğru tahmini, yapısal mühendislik projelerinin başarılı bir şekilde tamamlanması ve yapıların dayanıklılığı ve güvenliği için kritik bir öneme sahiptir. Bu çalışmada beton basınç dayanımını tahmin etmek için literatürde sıkça kullanılan KAR, SVR, YSA ve LR makine öğrenme yöntemleri kullanılmıştır. Bu yöntemler halka açık bir şekilde UCI veri deposunda bulunan Beton Basınç Dayanımı veri seti üzerinde uygulanmıştır. Bununla birlikte veri seti üzerine özellik mühendisliği uygulanarak veri seti özellikleri 50 ye çıkarılmıştır. Oluşturulan bu yeni veri seti üzerinde aynı makine öğrenimi yöntemleri tekrar uygulanmıştır. Deneysel çalışmalardan elde edilen bulgular özellik mühendisliği ile birlikte YSA kullanımının her iki veri seti üzerinde yapılan diğer deneysel çalışmalardan daha etkili ve verimli sonuçlar elde ettiğini göstermiştir.

Ayrıca deneysel çalışmalar özellik mühendisliği ile birleştirilen yöntemlerin daha iyi performans ortaya koyduklarını da göstermiştir. Bu yöntem özelliklerle az özelliğe sahip veri setleri üzerinde daha performanslı sonuçlar elde edilebileceğini gösterilmiştir.

İleriki çalışmalarda özellik mühendisliği ve YSA ile kurulan yapı temel alınarak beton basınç dayanımı tahmini için uygulamalar geliştirilebilir.

Kaynakça

- [1] Vu, C. C., Tran, H. H. 2023. Performance analysis of methods to estimate Weibull parameters for the compressive strength of concrete. *Case Studies in Construction Materials*, 19, e02330. doi:10.1016/j.cscm.2023.e02330.
- [2] Li, W., Wang, R., Ai, Q., Liu, Q., Lu, S. X. 2023. Estimation of compressive strength and slump of HPC concrete using neural network coupling with metaheuristic algorithms. *Journal of Intelligent & Fuzzy Systems*, 1-15. doi:10.3233/JIFS-230005.
- [3] Weng, P., Xie, J., Zou, Y. 2023. Compressive strength prediction of admixed HPC concrete by hybrid deep learning approaches. *Journal of Intelligent & Fuzzy Systems*, 44(5), 8711-8724. doi:10.3233/JIFS-221714
- [4] Chengquan, Z., Aghajaniifah, H., Zykova, K. I., Moayedi, H., Le, B. N. 2023. Predicting concrete's compressive strength through three hybrid swarm intelligent methods. *Computers and Concrete*, 32(2), 149-163. doi:10.12989/cac.2023.32.2.149.
- [5] Singh, M., Choudhary, P., Bedi, A. K., Yadav, S., Chhabra, R. S. 2022. Compressive Strength Estimation of Waste Marble Powder Incorporated Concrete Using Regression Modelling. *Coatings*, 13(1), 66. doi:10.3390/coatings13010066.
- [6] Zhang, Y., Bai, Z., Zhang, H. 2023. Compressive strength estimation of ultra-great workability concrete using hybrid algorithms. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 6(3), 389-400. doi:10.1007/s41939-023-00145-0.
- [7] Maherian, M. F., Baran, S., Bicakci, S. N., Toreyin, B. U., Atahan, H. N. 2023. Machine learning-based compressive strength estimation in nano silica-modified concrete. *Construction and Building Materials*, 408, 133684. doi:10.1016/j.conbuildmat.2023.133684.
- [8] Mustapha, I. B., Abdulkareem, M., Jassam, T. M., AlAteah, A. H., Al-Sodani, K. A. A., Al-Tholaia, M. M., Nabus, H., Alih, S. C., Abdulkareem, Z., Ganiyu, A. 2024. Comparative Analysis of Gradient-Boosting Ensembles for Estimation of Compressive Strength of Quaternary Blend Concrete. *International Journal of Concrete Structures and Materials*, 18(1), 1-24. doi: 10.1186/s40069-023-00653-w.
- [9] Zhou, J., Su, Z., Hosseini, S., Tian, Q., Lu, Y., Luo, H., Xu, X., Huang, J. 2024. Decision tree models for the estimation of geo-polymer concrete compressive strength. *Mathematical Biosciences and Engineering*, 21(1), 1413-1444. doi: 10.3934/mbe.2024061.
- [10] Joshi, D. A., Menon, R., Jain, R. K., Kulkarni, A. V. 2023. Deep learning based concrete compressive strength prediction model with hybrid meta-heuristic approach. *Expert Systems with Applications*, 233, 120925. doi:10.1016/j.eswa.2023.120925.
- [11] Yeh, I. C. 1998. Modeling of strength of high-performance concrete using artificial neural networks. *Cement and Concrete research*, 28(12), 1797-1808. doi:10.1016/S0008-8846(98)00165-3.
- [12] Konak, F., Bülbül, M. A., Türkoğlu, D. 2024. Feature Selection and Hyperparameters Optimization Employing a Hybrid Model Based on Genetic Algorithm and Artificial Neural Network: Forecasting Dividend Payout Ratio. *Computational Economics*, 63, 1673-1693. doi:10.1007/s10614-023-10530-z.
- [13] Liu, M., Guo, C., Xu, L. 2024. An interpretable automated feature engineering framework for improving logistic regression. *Applied Soft Computing*, 153, 111269. doi:10.1016/j.asoc.2024.111269.
- [14] Xiang, Y., Pei, X., Zhang, Y., Jiang, D. 2023. Feature-Engineering Enabled Multi-Objective Evolutionary

- Impedance Fitting Technique. IEEE Transactions on Industrial Electronics. doi:10.1109/TIE.2023.3288191.
- [15] Pekel, E. 2020. Estimation of soil moisture using decision tree regression. Theoretical and Applied Climatology, 139(3), 1111-1119. doi:10.1007/s00704-019-03048-8.
- [16] Chowdhury, M. S., Rahaman, M. N., Sheikh, M. S., Sayeid, M. A., Mahmud, K. H., Hafsa, B. 2024. GIS-based landslide susceptibility mapping using logistic regression, random forest and decision and regression tree models in Chattogram District, Bangladesh. Heliyon, 10(1). doi:10.1016/j.heliyon.2023.e23424.
- [17] Huo, D., Chen, J., Wang, T. 2024. Chaos-based support vector regression for load power forecasting of excavators. Expert Systems with Applications, 246, 123169. doi:10.1016/j.eswa.2024.123169.
- [18] Yaswanth, K. K., Sathish Kumar, V., Revathy, J., Murali, G., Pavithra, C. 2024. Compressive strength prediction of ternary blended geopolymer concrete using artificial neural networks and support vector regression. Innovative Infrastructure Solutions, 9(2), 32. doi:10.1007/s41062-023-01343-y.
- [19] Eskandari, M., Zeinadini, A., Seyedmohammadi, J., Navidi, M. 2023. Estimating quantity of date yield using soil properties by regression and artificial neural network. Communications in Soil Science and Plant Analysis, 54(1), 36-47. doi:10.1080/00103624.2022.2109661.
- [20] Bülbül, M. A. 2024. Optimization of artificial neural network structure and hyperparameters in hybrid model by genetic algorithm: iOS–android application for breast cancer diagnosis/prediction. The Journal of Supercomputing, 80(4), 4533-4553. doi:10.1007/s11227-023-05635-z.
- [21] Türkmen, V., Doğukan, Ö. 2023. Makine Öğrenmesinde Regresyon Algoritmalarının Veteriner Hekimliği Alanında Uygulamaları. Veteriner Farmakoloji ve Toksikoloji Derneği Bülteni, 14(3), 118-132. doi:10.38137/vftd.1307581.
- [22] Wichitakorn, N., Kang, Y., & Zhang, F. 2023. Random feature selection using random subspace logistic regression. Expert Systems with Applications, 217, 119535. doi:10.1016/j.eswa.2023.119535.