



Veri Madenciliği Kullanarak Beton Basınç Dayanımının Belirlenmesi

Cengiz ÖZEL¹, Alper TOPSAKAL²

¹ Süleyman Demirel Üniversitesi, Teknoloji Fakültesi, İnşaat Mühendisliği Bölümü, 32260 Isparta, TÜRKİYE

² Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Yapı Eğitimi ABD, 32260 Isparta, TÜRKİYE

Received: 12.11.2013; Accepted: 25.12.2013

Özet. Beton basınç dayanımı betonun sahip olduğu diğer özelliklerle yakından ilişkili olduğundan en önemli özelliklerden biridir. Bu nedenle beton basınç dayanımının önceden belirlenmesine yönelik birçok çalışma son zamanlarla yoğun olarak yapılmaktadır. Bu çalışmada beton basınç dayanımının belirlenmesi için alternatif bir metot olarak veri madenciliği kullanılarak modeller geliştirilmiştir. Çalışma sonucunda beton basınç dayanımının modellenmesinde veri madenciliğinin başarılı bir şekilde kullanılabileceği sonucuna varılmıştır.

Anahtar Kelimeler: Beton, Basınç Dayanımı, Veri Madenciliği

Prediction of Concrete Compressive Strength Using Data Mining

Abstract. Compressive strength is one of the most important mechanical properties of hardened concrete because it is related to other properties or performance of concrete. Therefore, many research of the early prediction of concrete properties has been intensively achieved in recent times. In this study, models for the determination of concrete compressive strength have been developed using data mining as an alternative method. These results suggested that the data mining algorithms can be used as an alternative approach to predict the concrete compressive strength.

Keywords: Concrete, Compressive Strength, Data Mining

1. GİRİŞ

Beton günümüzde en yaygın olarak kullanılan yapı malzemesidir. Şekil verilebilirliği, temin edilmesi, diğer taşıyıcı malzemelere göre daha ekonomik olması gibi sahip olduğu birçok avantajların yanı sıra betondan temel anlamda beklenen en büyük özellik basınç dayanımıdır. Betonun basınç dayanımı, eğilme - çekme dayanımı, elastisitesi ve durabilitesi gibi birçok özellikleri ile yakından ilişkilidir [1]. Bu nedenle son yıllarda yapılan çalışmaların büyük çoğunluğu betonun basınç mukavemeti üzerinde etken parametrelerin bulunması, bu parametrelerin optimizasyonu ve/veya betonunun basınç dayanımının bu parametrelere bağlı olarak karışım öncesinde belirlenmesine yöneliktir [2-15]. Deneysel çalışmalarda elde edilen veriler arasındaki ilişkiler her zaman lineer ve kolay anlaşılabilir olmayabilir. Bu ilişkilerin ortaya çıkarılmasında, özellikle kalabalık ve karmaşık veriler arasında ilişki kurmayı kolaylaştırmak amacıyla,

* Corresponding author. Email address: cengizozel@sdu.edu.tr, alper topsakal@gmail.com

istatistiki programlardan veya “Sezgisel” (Heuristics) metotların ile yapay zeka tekniklerinden yararlanır. Bulanık mantık, yapay sinir ağları, genetik algoritma, veri madenciliği bu sezgisel metotların en yaygın kullanılanlarıdır.

Bu çalışmada betonun basınç dayanımının karışım tipi, çimento dozajı, numune alma zamanı ve basınç deneyi yapılan numune boyutuna bağlı olarak veri madenciliği kullanılarak belirlenmesi, beton basınç dayanımı üzerinde bu dört parametrenin etkisinin belirlenmesi amaçlanmıştır.

2. VERİ MADENCİLİĞİ

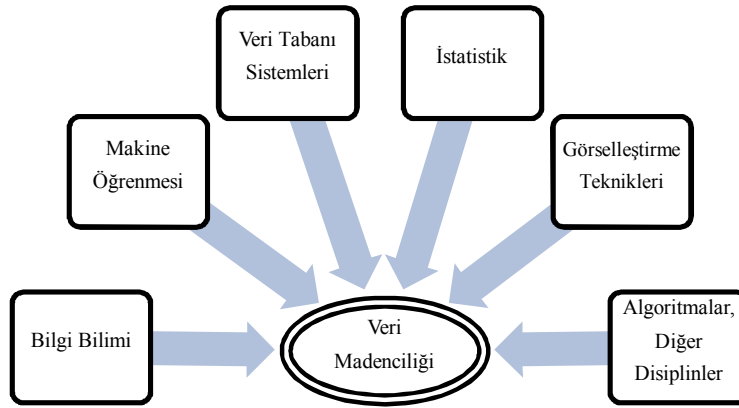
Veri madenciliği “Data Mining (DM)” veya Veri Tabanlarında Bilgi Keşfi “Knowledge Discovery Data (KDD)”, özellikle karmaşık ve yoğun veriler arasında, farklı açılardan verileri analizi ve veriden yararlı bilgi çıkarma sürecidir. Başka bir deyişle, büyük veri tabanlarından gizli kalmış örüntüleri (patterns) çıkarma sürecine veri madenciliği adı verilmektedir. DM kullanıcılar için verileri çok farklı açılardan ve boyutlardan, analiz ve sınıflama yapar. Geleneksel yöntemler kullanılarak çözülmesi çok zaman olan problemlere veri madenciliği süreci kullanılarak daha hızlı bir şekilde çözüm bulunabilir. Veri madenciliğinin ana amacı elimizde bulunan veriden gizli kalmış örüntüleri çıkarmak, elimizdeki verinin değerini arttırmak ve veriyi bilgiye dönüştürmektir. Veri madenciliği bir yöntem değildir bir süreçtir. Bu süreçte ana unsur süreci gerçekleştiren uygulamacıdır. Süreçte bulunan adımlar doğru olarak yerine getirilmediğinde istenilen sonuca ulaşamaz [16-18].

Temel olarak veri madenciliği bilgisayar destekli bir bilgi çözümleme işlemidir. Veri madenciliği, eldeki verilerden çok net olmayan, önceden bilinmeyen ancak potansiyel olarak kullanışlı bilginin çıkarılmasıdır. Bu işlem kümeleme, veri özetleme, değişikliklerin analizi, sapmaların tespiti gibi belirli sayıda teknik yaklaşımları içerir. Başka bir deyişle, veri madenciliği, verilerin içerisindeki örüntülerin, ilişkilerin, değişimlerin, düzensizliklerin, kuralların ve istatistiksel olarak önemli olan yapıların keşfedilmesidir [19]. Veri madenciliğini istatistiksel bir yöntemler serisi olarak görmek

Veri Madenciliği Kullanarak Beton Basınç Dayanımının Belirlenmesi

mümkün olabilir. Ancak veri madenciliği, geleneksel istatistikten birkaç yönde farklılık gösterir. Veri madenciliğinde amaç, kolaylıkla mantıksal kurallara ya da görsel sunumlara çevrilebilecek nitel modellerin çıkarılmasıdır. Bu bağlamda, veri madenciliği insan merkezlidir ve bazen insan – bilgisayar ara yüzü birleştirilir. Veri madenciliği sahası, istatistik, makine bilgisi, veritabanları ve yüksek performanslı işlem gibi temelleri de içerir [20].

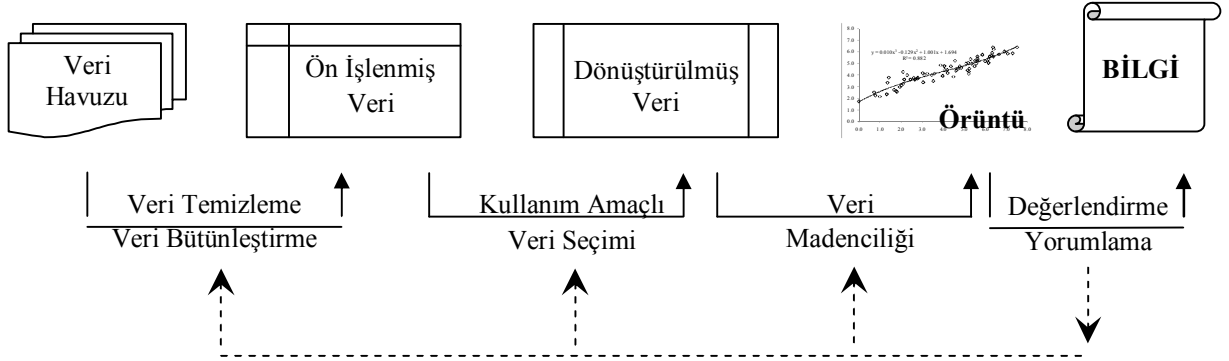
DM çok disiplinli bir alandır; istatistik analizleri, makine öğrenmesi “machine learning (ML)”, örüntü tanıma, yapay zeka “artificial intelligence (AI)” ve veritabanı yönetimi gibi bir dizi genel teknikleri kapsar (Şekil 1). Son zamanlarda birçok araştırmacı ve yazar DM’i sosyal, eğitim, pazarlama, iletişim ve mühendislik alanlarında optimizasyon işlemlerinde uygulamış, sınıflama, kümeleme ve diğer DM işlevleri için bir çok model önermişlerdir [21-24].



Şekil 1. Veri madenciliğinin etki parametreleri [19].

Veri madenciliği süreci Şekil 2’de verilmiştir. Bu süreçte çeşitli kaynaklardan elde edilen veriler temin edilir ve girdi (bağımsız değişken) – çıktı (bağımlı değişken) parametrelerine ayrılır. Bu süreçte eksik veya kayıp veriler için bütünleştirme ya da gereksiz veya fazla veriler için temizleme işlemi de yapılmış olur “Ön İşlenmiş Veri”. Bu süreç filtreleme süreci olarak da anılır. Daha sonraki süreçte veriler kullanılacak olan algoritmalar için normalize edilir ya da uygun formata gerilmek için dönüştürülür “Dönüştürülmüş Veri”. Veriler analizler için uygun boyutlara getirildikten sonra ise girdi ve çıktı parametreleri arasındaki örüntü ve ilişkilerin ortaya çıkarılması işlemine

“Veri Madenciliği” geçilir. Geliştirilen modeller değerlendirilir, eğer uygunluk yok ise algoritma ve/veya girdi-çıkı parametreleri değiştirilerek süreç yeniden başlatılır.



Şekil 2. Veri madenciliği süreci [25].

Veri madenciliğinde kullanılan bazı analiz ve yöntemler Tablo 1’de verilmiştir.

Tablo 1. Veri madenciliğinde kullanılan teknikler [19].

Sınıflama (Classification) ve Regresyon (Regression)	Genetik Algoritmalar (Genetic Algorithms), K-En Yakın Komşu (K-Nearest Neighbor), Naive-Bayes, Çoklu Regresyon, Lojistik Regresyondur (Logistic Regression), Faktör ve Ayırma analizleri (factor and discriminant)
Kümeleme (Clustering)	Bölme yöntemleri (Partitioning methods), Hiyerarşik yöntemler (Hierarchical methods), Yoğunluk tabanlı yöntemler (Density-based methods), Izgara tabanlı yöntemler (Grid-based methods), Model tabanlı yöntemler (Model-based methods)
Birliktelik Kuralları (Association Rules)	Amaç birlikte gerçekleşmesi muhtemel olayların kurallarının ortaya konmasıdır. Birliktelik kuralları, veri kümeleri arasında birliktelik ilişkileri bulurlar.
Bellek Tabanlı Yöntemler	Bu yönteme en iyi örnek en yakın k komşu algoritmasıdır (k-nearest neighbor)

Veri Madenciliği Kullanarak Beton Basınç Dayanımının Belirlenmesi

Yapay Sinir Ağları (YSA)	Bu yöntemler veri madenciliğinin en etkili yöntemleri arasında yer alan yapay sinir ağları, genetik algoritmalar, genetik programlama, bulanık mantık gibi teknikleri içerir.
--------------------------	---

Karar Ağaçları	Karar ağacı, bir ağaç görünümünde, tahmin edici bir tekniktir. Karar ağaçları kural çıkarma algoritmalarıdır. Bu algoritmalar bir veri kümesinden kullanıcıların çok kolay anlayabileceği (IF-THEN) türündeki kuralları bir ağaç yapısında türetebilirler.
----------------	--

Veri madenciliği uygulamalarını gerçekleştirmek için bugüne kadar birçok araç geliştirilmiştir. Bu araçlardan biri Waikato Üniversitesi tarafından Java platformu üzerinde açık kodlu olarak geliştirilen ve devamlı güncellenen WEKA'dır. WEKA bir proje olarak başlayıp bugün dünya üzerinde birçok insan tarafından kullanılmaya başlanan bir veri madenciliği uygulaması geliştirme programıdır. WEKA Java platformu üzerinde geliştirilmiş açık kodlu bir programdır.

Bu çalışmada beton basınç dayanımının karışıma tipi, çimento dozajı, taze betondan numune alma zamanı ve numune boyutuna bağlı olarak belirlenmesi için model geliştirilmesi amaçlanmıştır. Bu amaç için deneysel olarak elde edilen veriler arasındaki ilişkiler veri madenciliği (data mining) ile de değerlendirilmiştir. DM sürecinde WEKA'da bulunan algoritmalar kullanılmıştır.


3. MODELLEME VE DEĞERLENDİRME

3.1. Verilerin Elde Edilmesi

Deneysel çalışmalar için en büyük tane boyutu 16 mm kalker agregası (783-744-704 kg/m³), kırma kum (1187-1128-1068 kg/m³), CEM I 42.5 R tipi çimento (350 – 400 ve 450 kg/m³ olmak üzere üç farklı dozajda), modifiye polikarboksilat esaslı (yoğunluğu 1.09 kg/l) yüksek performanslı hiperakışkanlaştırıcı katkı kullanılmıştır. Kimyasal katkı her çimento dozajındaki performansın izlenebilmesi için tüm karışımlarda sabit oranda (% 1) kullanılmıştır.

Karıştırma tipinin etkisini belirlemek için iki farklı mikser ile; cihazın alt kısmında dönerik karışan bir kazan ve üstte sabit karıştırıcı sistemden oluşan Düşey eksenli cebri karıştırmalı mikser ve kendi eksenini etrafında dönen yatay eksenli bir tambur kazandan oluşan Yatay eksenli (tambur) mikser ile eş zamanlı olarak üretilmiştir.

Karışım süreci tüm karışımlarda karşılaştırılabilir olması açısından, Şekil 3'te belirtildiği gibi 30 sn kuru karışım (iri agrega, ince agrega, bağlayıcı), 90 sn ıslak karışım (ilk 1 dk su ilavesi), 60 sn dinlenme ve 120 sn son karışım olmak üzere toplam 300 sn'de (5 dk.) yapılmıştır [16].




Şekil 3. Beton karışım işlem aşamaları [16].

Karıştırma süreci tamamlandıktan sonra her iki mikser tipinden alınan beton örnekleri üzerinde betonların taze haldeki özelliklerini belirlemek için çökme ve çökmede yayılma deneyi uygulanmıştır. Taze beton deneylerinin yapılmasından sonra beton numuneleri, karıştırma sürecinin bitiminden itibaren 5. dakikada 7x7x7 cm, 10x10x10 cm ve 15x15x15 cm'lik kalıplarda kalıplanmıştır. Bu işlemler 35., 65. ve 95. dakikalarda her iki mikser tipi içinde tekrarlanmıştır. Kalıplanan numuneler bir gün sonra kalıptan çıkarılarak 28 gün kür havuzunda kürlenmiş ve basınç dayanımı deneyi yapılmıştır.

Denevlerden elde edilen veriler Şekil 4'de verilmiştir. Şekil 4.a'da düşey, Şekil 4.b'de ise yatay eksenli mikserden elde edilen veriler verilmiş olup her mikser tipinden elde edilen 36'şar (toplam 72 veri) modellemelerde kullanılmıştır.

Veri Madenciliği Kullanarak Beton Basınç Dayanımının Belirlenmesi



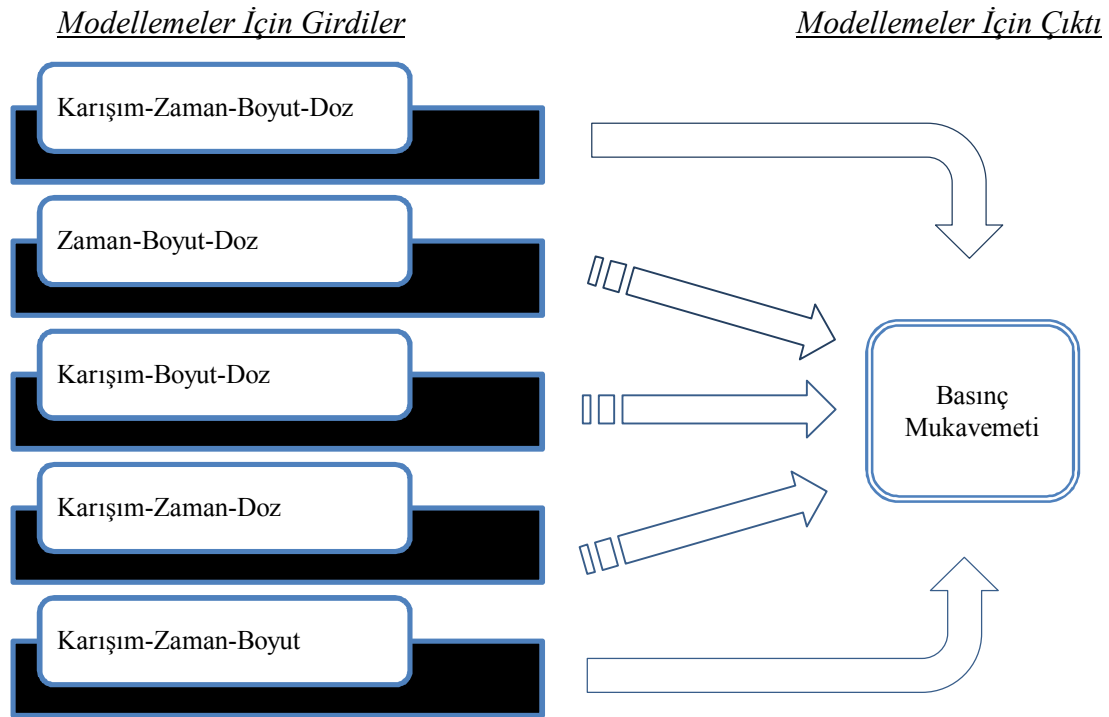
Şekil 4. Deneysel çalışmalardan elde edilen veriler

Şekil 4’de görüldüğü gibi zamana bağlı olarak tüm numunelerin çökme değerlerinde azalma elde edilmesine rağmen yayılma ve basınç dayanımı değerlerinde birçok numune için 35. dakika değerlerinde kritik değişimler elde edilmiştir.

3.2. Verilerin Modellenmesi ve Analizler

Veri madenciliği sürecinin model kurma aşamasında, deneysel olarak elde edilen veriler aynı boyutta olması açısından normalize edildikten sonra, girdi (karışım, numune alma zamanı, numune boyutu ve çimento dozajı) ve çıktı (basınç mukavemeti) olarak düzenlenmiştir (Şekil 5). Deneysel olarak bulunan ve hesaplanan tüm veriler %20’şer olmak üzere beş gruba ayrılmıştır.

Tüm verilerin %80’i model eğitimleri ve model oluşturulması için test veri seti olarak, sıra ile beş gruptan her biri (%20’lerden her biri “Cross-Validation”) sıra ile analiz veri seti olarak (model oluşturulmasında kullanılmayan, elde edilen modellerin geçerliliğinin sınanması ve model sonuçları ile önceden bilinen veriler arasındaki korelasyon katsayısının belirlenmesi için) kullanılmış ve modeller geliştirilmiştir. Böylece geliştirilen model için tüm veriler hem girdi hem de çıktı olarak kullanılmıştır.



Şekil 5. Modelleme için girdi ve çıktı parametreleri

WEKA programında var olan tüm algoritmalar bu veri dosyaları üzerinde sırayla çalıştırılmış ve en yüksek korelasyon katsayısı veren dokuz algoritma için değerlendirilme yapılmıştır. Bu algoritmalar aşağıda belirtilmiştir.

Veri Madenciliği Kullanarak Beton Basınç Dayanımının Belirlenmesi

1. **Gaussian Processes:** Normal dağılım, stokastik süreç
2. **Lineer Regresyon:** Bir veya daha fazla bağımsız değişkenle, bağımlı bir değişken arasında ilişkiyi belirleyen matematiksel model
3. **Multilayer Perceptron:** Geribesleme kullanarak eğitilen sinir ağları
4. **SMOreg:** Destek vektör regresyonu için sıralı en düşük optimizasyon algoritması
5. **IBK :** k en yakın komşu sınıflaması
6. **KStar:** Genelleştirilmiş uzaklık fonksiyonu ile en yakın komşu
7. **Additive Regression:** Kalanlarla tekrarlı eşlemeler yaparak bir regresyon metodunun performansını artırma
8. **Bagging (Bootstrap aggregation):** Bir tahminde çeşitli çıktılarının birleştirilmesiyle farklı modeller için kombinasyon kararı, ön istatistiksel sınıflama ve regresyon
9. **M5 Rules:** M5’kullanılarak model ağaç (karar ağaçları) oluşumundan elde edilen kurallar

3.3. Model Sonuçları

Yapılan modellemeler sonucunda değişik girdi grupları ile çıktı (basınç mukavemeti) arasındaki model sonuçlarının istatistiksel analiz sonuçları Tablo 2’de verilmiştir. Yine model sonuçları ile gerçek sonuçlar arasındaki korelasyon katsayılarının algoritmalara göre değişimi Şekil 6’da verilmiştir.

Tablo 2. Girdi parametrelerine göre modellerin istatistiksel sonuçları

Algoritma	İstatistiksel Değerler	Karışım-Zaman-Boyut-Doz	Zaman-Boyut-Doz	Karışım-Boyut-Doz	Karışım-Zaman-Doz	Karışım-Zaman-Boyut
Gaussian Processes	Korelasyon Katsayısı	0.8518	0.8341	0.8222	0.6482	0.3941
	Ortalama Mutlak Hata (MAE)	0.8321	0.8672	0.8846	1.1538	1.5204
	Karekök Ortalama Hata (RMSE)	0.988	1.0311	1.0579	1.4086	1.7727
	Nisbi Mutlak Hata (RAE)	%51.52	%53.69	%54.77	%71.43	%94.13
Linear Regression	Korelasyon Katsayısı	0.8744	0.8391	0.8238	0.6424	0.6338
	Ortalama Mutlak Hata (MAE)	0.7299	0.8221	0.8696	1.1637	1.1543
	Karekök Ortalama Hata (RMSE)	0.8971	1.0059	1.0484	1.4175	1.4325
	Nisbi Mutlak Hata (RAE)	%45.19	%50.90	%53.84	%72.04	%71.46

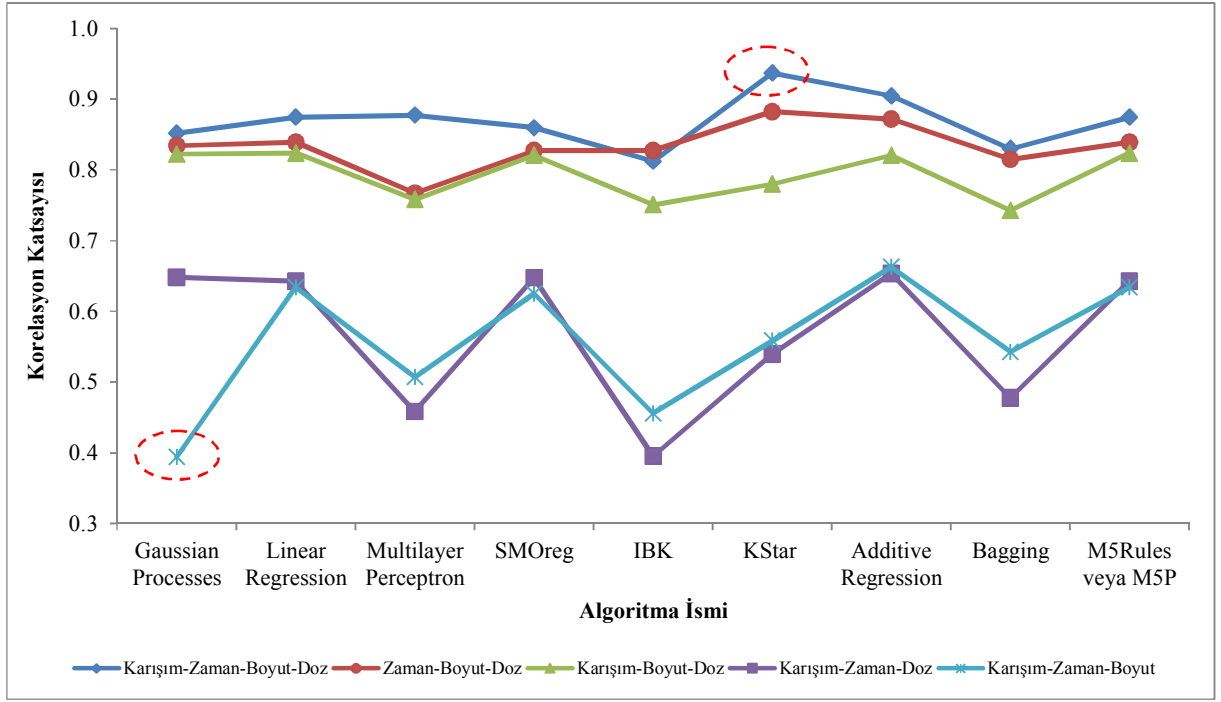
Multilayer Perceptron	Korelasyon Katsayısı	0.8775	0.7672	0.7584	0.4584	0.5072
	Ortalama Mutlak Hata (MAE)	0.6946	0.9225	1.0113	1.4482	1.358
	Karekök Ortalama Hata (RMSE)	0.8983	1.2017	1.2488	1.7435	1.6679
	Nisbi Mutlak Hata (RAE)	%43.00	%57.11	%62.61	%89.65	%84.07
SMOreg	Korelasyon Katsayısı	0.8598	0.8271	0.8206	0.6473	0.6250
	Ortalama Mutlak Hata (MAE)	0.7393	0.8288	0.8859	1.1425	1.1947
	Karekök Ortalama Hata (RMSE)	0.9604	1.0526	1.0645	1.4388	1.4598
	Nisbi Mutlak Hata (RAE)	%45.77	%51.31	%54.84	%70.73	%73.96
IBK	Korelasyon Katsayısı	0.8122	0.8274	0.7507	0.3953	0.4557
	Ortalama Mutlak Hata (MAE)	0.9493	0.9058	1.0352	1.5765	1.4887
	Karekök Ortalama Hata (RMSE)	1.1386	1.0813	1.245	1.8913	1.7822
	Nisbi Mutlak Hata (RAE)	%58.77	%56.08	%64.09	%97.60	%92.16
KStar	Korelasyon Katsayısı	0.9369	0.8824	0.7799	0.5392	0.5584
	Ortalama Mutlak Hata (MAE)	0.7631	0.7956	0.9839	1.3124	1.2836
	Karekök Ortalama Hata (RMSE)	0.9321	0.9554	1.1765	1.5583	1.5399
	Nisbi Mutlak Hata (RAE)	%47.24	%49.25	%60.91	%81.25	%79.47
Additive Regression	Korelasyon Katsayısı	0.9045	0.8719	0.8206	0.6536	0.6630
	Ortalama Mutlak Hata (MAE)	0.6282	0.7178	0.8732	1.1824	1.1539
	Karekök Ortalama Hata (RMSE)	0.7925	0.9068	1.0581	1.4069	1.3892
	Nisbi Mutlak Hata (RAE)	%38.89	%44.44	%54.06	%73.20	%71.43

Tablo 2. Girdi parametrelerine göre modellerin istatistiksel sonuçları (Devamı)

Bagging	Korelasyon Katsayısı	0.8298	0.8150	0.7428	0.4776	0.5430
	Ortalama Mutlak Hata (MAE)	0.8468	0.8569	1.0304	1.4	1.2959
	Karekök Ortalama Hata (RMSE)	1.0408	1.0726	1.2392	1.645	1.561
	Nisbi Mutlak Hata (RAE)	%52.42	%53.05	%63.79	%86.67	%80.22
M5Rules	Korelasyon Katsayısı	0.8744	0.8391	0.8238	0.6424	0.6338
	Ortalama Mutlak Hata (MAE)	0.7299	0.8221	0.8696	1.1637	1.1543
	Karekök Ortalama Hata (RMSE)	0.8971	1.0059	1.0484	1.4175	1.4325
	Nisbi Mutlak Hata (RAE)	%45.19	%50.90	%53.84	%72.04	%71.46

Veri Madenciliği Kullanarak Beton Basınç Dayanımının Belirlenmesi

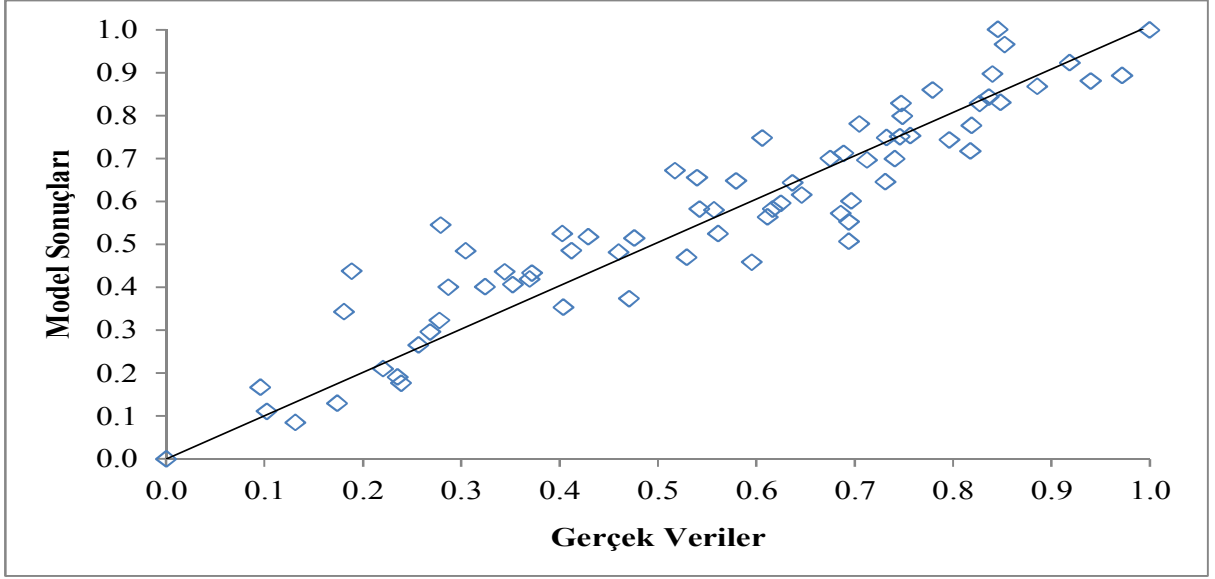
En yüksek korelasyon katsayısı değeri KStar algoritmasından elde edilmişken en düşük korelasyon katsayısı Gaussian Processes'den elde edilmiştir. Çimento dozajı veya boyutun girdi olarak kullanıldığı modellerden genellikle düşük korelasyon katsayıları elde edilmişken en yüksek korelasyon katsayıları dört değişkeninde (Karışım-Zaman-Boyut-Doz) girdi olarak kullanıldığı modellerden elde edilmiştir.




Şekil 6. Model sonuçları için korelasyon katsayılarının almaya göre değişimi

Korelasyon katsayıları dikkate alınarak değişkenlerin etkinlik dereceleri dikkate alındığında modellerin geçerliliği üzerinde (korelasyon katsayısı değerlerinde) karışım tipinin %1.8-12.6, numune alma zamanının %3.5-16.8, numune boyutunun %23.9-51.3 ve çimento dozajının %26.7-53.7 değişime neden olmaktadır. Bu oranlara göre çalışmada ele alınan dört girdi arasında basınç dayanımını üzerinde “Karışım<Zaman<Boyut<Çimento Dozajı” etki sıralaması yapılabilmektedir.

Yine algoritmalar arasındaki ilişki korelasyon katsayısı değerlerine göre incelendiğinde, KStar'a göre “Karışım-Zaman-Boyut-Doz” girdisi için diğer algoritmalarda %3.5-13.3, “Zaman-Boyut-Doz” için %1.2-13.1, “Karışım-Boyut-Doz” için %2.8-5.6, “Karışım-Zaman-Doz” için %11.4-26.7, “Karışım-Zaman-Boyut” için %2.8-29.4 oranında korelasyon katsayısı değişmektedir. En iyi korelasyon katsayısı değerinin elde edildiği KStar algoritmasının gerçek değerler ve model sonuçları arasındaki ilişkisi Şekil 7 ve 8’de gösterilmiştir.



Şekil 7. Model sonuçları ile deneysel sonuçlar arasındaki ilişki



Şekil 8. Model sonuçları ile deneysel sonuçların değişimi

Şekil 8’de görüldüğü gibi model sonuçları gerçek değerlere benzer eğim davranışlarını yakalamış olsa da değer olarak bazı verilerde tam uyum yerine kısmi hatalı sonuçlar vermiştir. Bu hataların veri havuzunun ve örneklemelerin geliştirilmesiyle öğrenme kabiliyetinin artmasıyla azalacağı düşünülmektedir.

4. SONUÇ VE ÖNERİLER

Çalışma sonucunda Veri Madenciliğinin beton basınç dayanımlarının tahmininde ve İnşaat Mühendisliği uygulamalarında başarılı olarak kullanılabileceği sonucuna varılmıştır. Kullanılan girdi parametrelerine göre en uygun algoritma ise KStar ($R= 0.9369$) olarak belirlenmiştir. Bununla birlikte diğer algoritmalarında özellikle dört girdili modelde benzer sonuçlar verdiği belirlenmiştir.

Daha başarılı modellemelerin yapılabilmesi için beton karışım bileşenlerinin de girdi olarak kullanıldığı ve/veya değişik karışım bileşenlerine sahip veri havuzlarının kullanılmasının faydalı olacaktır.

Beton basınç dayanımı üzerinde incelenen veriler içinde etken parametre sıralaması Çimento Dozajı>Numune Boyutu>Numune Alma Zamanı>Karıştırma Metodu olarak elde edilmesine rağmen Çimento Dozajı ve Numune Boyutu'nun etkisi diğer iki etkiye göre 2~3 kat daha fazladır.

Sezgisel metotların kullanılmasıyla büyük ve karmaşık veri tabanları için zamanın ve maliyetin optimum olacağı modeller geliştirilebilir. Bu sayede hem güvenilir yapılabileceği gibi, hem de uzman bilgilerin gelecek nesillere daha kolay aktarımı sağlanabilecektir.

KAYNAKLAR

- [1] Özel, C., Soykan, O., Zengin, B., 2012. Filler Olarak Mermer Tozu İçeren Beton Özelliklerinin Bulanık Mantık Kullanılarak Belirlenmesi, e-Journal of New World Sciences Academy Engineering Sciences, 2A0075, 7, (2), 28-46.
- [2] Han, S.H., Kim, J.K., Park, Y.D., 2003. Prediction of compressive strength of fly ash concrete by new apparent activation energy function, Cem. Concr. Res., 33 (7), 965-971.
- [3] Chen, H.S., Sun, W., Stroeven, P., 2003. Prediction of compressive strength and optimization of mixture proportioning in ternary cementitious systems, Mater. Struct., 36 (260), 396-401.
- [4] Gupta, R., Kewalramani, M.A., Goel, A., 2006. Prediction of concrete strength using neural-expert system, J. Mat. Civ. Engrg., 18 (3), 462-466.
- [5] Peng, C.H., Yeh, I.C., Lien, L.C., 2009. Modeling strength of high-performance concrete using genetic operation trees with pruning techniques, Comput. Concr., 6 (3), 203-223.

- [6] Sobhani, J., Najimi, M., Pourkhorshidi, A.R., Parhizkar, T., 2010. Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models, *Const. Build. Mat.*, 24, 709–718.
- [7] Ozbay, E., Oztas, A., Baykasoglu, A., 2010. Cost optimization of high strength concretes by soft computing techniques, *Comput. Concr.*, 7 (3), 221-237.
- [8] Bilgehan, M., Turgut, P., 2010. The use of neural networks in concrete compressive strength estimation, *Comput. Concr.*, 7 (3), 271–283.
- [9] Atici, U., 2011. Prediction of the strength of mineral admixture concrete using multivariable regression analysis and an artificial neural network, *Expert Syst. Appl.*, 38 (8), 9609-9618.
- [10] Duan, Z.H., Kou, S.C., Poon, C.S., 2013. Prediction of compressive strength of recycled aggregate concrete using artificial neural networks, *Construction and Building Materials*, 40, 2013, 1200-1206.
- [11] Dantas, A.T.A., Leite, M.B., Nagahama, K. J., 2013. Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks. *Construction and Building Materials*, 38, 2013, 717-722.
- [12] Erdal, H. İ., 2013. Two-level and hybrid ensembles of decision trees for high performance concrete compressive strength prediction, *Engineering Applications of Artificial Intelligence*, 26 (7), 2013, 1689-1697.
- [13] Chou, J.S., Pham, A.D., 2013. Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength, *Construction and Building Materials*, 49, 554-563.
- [14] Yuan, Z., Wang, L. N., Ji, X., 2014. Prediction of concrete compressive strength: Research on hybrid models genetic based algorithms and ANFIS, *Advances in Engineering Software* 67, 156–163.
- [15] Metwally, A.A.E., 2014. Compressive strength prediction of Portland cement concrete with age using a new model *Housing and Building National Research Center (HBRC Journal)* <http://dx.doi.org/10.1016/j.hbrj.2013.09.005>, (In Press).
- [16] Özel, C., 2007. Katkılı Betonların Reolojik Özelliklerinin Taze Beton Deney Yöntemlerine Göre Belirlenmesi, S.D.Ü. Fen Bilimleri Enstitüsü İnşaat Mühendisliği A.B.D, Isparta.
- [17] Yücel, K.T., Özel C, 2012. Modeling of mechanical properties and bond relationship using data mining process, *Advances in Engineering Software* 45, 54–60.

- [18] Terzi, Ö., Küçüksille, E.U., Keskin, M.E., 2005. Modeling of Daily Pan Evaporation Using Data Mining. International Symposium on Innovations in Intelligent Systems and Applications, 182-185, İstanbul.
- [19] Uyan, M., Çay, T. 2008. Mekânsal Uygulamalar İçin Veri Madenciliği Yaklaşımı, 2. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, 13-15 Ekim 2008, 531-538, Kayseri.
- [20] Terzi, Ö., Küçüksille, E.U., Ergin, G., İlker, A., 2011. Veri Madenciliği Süreci Kullanılarak Güneş Işınımı Tahmini. SDU International Technologic Science, 3 (2), 29-37.
- [21] Terzi, S., 2006. Modelling the pavement present serviceability index of flexible highway pavements using data mining. J. Appl. Sci., 6 (1), 193–197.
- [22] Zhang, J., Shi, Y., Zhang, P., 2009. Several multi-criteria programming methods for classification. Comput. Operat. Res., 36, 823–836.
- [23] Keskin, M.E, Terzi, Ö., Küçüksille, E.U., 2009. Data mining process for integrated evaporation model. J. Irrig. Drain. Eng., 135(1), 39–43.
- [24] Küçüksille, E.U., Selbas, R., Şencan, A., 2009. Data mining techniques for thermophysical properties of refrigerants. Energy Convers. Manage, 50, 399–412.
- [25] Han, J., Kamber, M., 2006. Data Mining: Concepts and Techniques, Second Edition, Elsevier, 743 p.