

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**YAPILARDA KULLANILAN BETONUN BASINÇ DAYANIMI
DENEY SONUÇLARININ MAKİNE ÖĞRENME TEKNİKLERİ
İLE TAHMİN EDİLMESİ**

Melike DEMİR

Yüksek Lisans Tezi

EKO BİLİŞİM ANABİLİM DALI

OCAK 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ekobilişim Anabilim Dalı

Yüksek Lisans Tezi

YAPILARDA KULLANILAN BETONUN BASINÇ DAYANIMI DENEY
SONUÇLARININ MAKİNE ÖĞRENME TEKNİKLERİ İLE TAHMİN
EDİLMESİ

Tez Yazarı
Melike DEMİR

Danışman
Dr. Öğr. Üyesi Ahmet ŞENPINAR

OCAK 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ekobilişim Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Yapılarda Kullanılan Betonun Basınç Dayanımı Deney Sonuçlarının Makine Öğrenme Teknikleri ile Tahmin Edilmesi
Yazarı:	Melike DEMİR
İlk Teslim Tarihi:	31.12.2021
Savunma Tarihi:	28.01.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Dr. Öğr. Üyesi Ahmet ŞENPINAR Fırat Üniversitesi, Teknik Bilimler MYO	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Abdulkadir ŞENGÜR Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Muzaffer ASLAN Bingöl Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Yapılarda Kullanılan Betonun Basınç Dayanımı Deney Sonuçlarının Makine Öğrenme Teknikleri ile Tahmin Edilmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

28.01.2022

Melike DEMİR



ÖNSÖZ

Yapılar için gerçekleştirilen beton basınç dayanımı testleri yapıların güvenilirliği için büyük bir önem arz etmektedir. Bu testlerin gerçekleştirilmesi uzun ve meşakkatli bir süreçtir. Çünkü en iyi basınç dayanımının sağlanması amacıyla hangi bileşenlerden ne kadar miktarda kullanılması gerektiğini bilmek için birçok kez tekrarlanan testler ve iyi yapılmış analizler gereklidir. Kullanılan bileşenlere göre deney yapmadan makine öğrenme teknikleri ile beton basınç dayanımını tahmin etmek, hem yapılan test sayısını azaltacaktır hem de beton yapımı sürecindeki kullanıcı hatasından kaynaklanan durumların önüne geçecektir.

Melike DEMİR

ELAZIĞ, 2022



İÇİNDEKİLER

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	ix
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	1
2. REGRESYON ALGORİTMALARI.....	3
2.1. Lineer Regresyon.....	3
2.2. Multi-Lineer Regresyon	4
2.3. Polinomial Lineer Regresyon	4
2.4. Karar Ağaçları	5
2.5. Rastgele Değişken	7
2.6. K-En Yakın Komşuluk (K-EYK)	8
2.7. Destek Vektör Makineleri (DVM).....	9
2.8. Güçlendirme (Boosting) Algoritmaları.....	17
2.8.1. AdaBoost ve Gradyan Artırma (Gradient Boosting).....	17
2.9. Determinasyon Katsayısı ve Kök Ortalama Kare Hata	19
3. MATERYAL VE METOT	20
3.1. Kullanılan Bileşenlere Göre Beton Basınç Dayanımı Laboratuvar Deney Sonuçları.....	20
3.2. Metot	21
4. BULGULAR VE TARTIŞMA	23
4.1. Keşifsel Veri Analiziyle Deneysel Sonuçların Yorumlanması.....	23
4.2. Beton Basınç Dayanımı Tahmini için Regresyon Analizi Sonuçları.....	29
5. SONUÇLAR.....	32
KAYNAKLAR	33
ÖZGEÇMİŞ	

ÖZET

Yapılarda Kullanılan Betonun Basınç Dayanımı Deney Sonuçlarının Makine Öğrenme Teknikleri ile Tahmin Edilmesi

Melike DEMİR

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

Ekobilisim Anabilim Dalı

Ocak 2022, Sayfa: x + 34

Beton basınç dayanımının ölçülmesi yapı dayanıklılığı hakkında bilgi veren için çok önemli bir işlem olarak inşaat sektöründe yer almaktadır. Beton basınç dayanımı deneylerinin yapılması bir dizi işlem ve uygun adımlar gerektirmektedir. Deney aşamalarında en önemli unsur alınan beton numunelerinde gerekli olan bileşenlerin gerekli oranda eklenmesidir. Ayrıca en iyi beton basınç dayanımını elde etmek için deneylerin belirli bir süre zarfında yapılması gerekmektedir. Ayrıca, bu deneyleri gerçekleştirilmesi için ciddi bir maliyete ve alanında uzman kişilere ihtiyaç duyulmaktadır. Buna rağmen, iş yükü yoğunluğundan dolayı basınç deney sonuçlarının alınmasında ve kaydedilmesinde yanlışlıklar olabilmektedir.

1990 yılların başından beri yapay zekâ algoritmaları otomatik sınıflandırma ve regresyon problemlerinde aktif olarak kullanılmaya başlanmıştır. Zaman ilerledikçe veri tipleri ve boyutları ile birlikte yapay zekâ algoritmaları geliştirilmiş ve nesne tanıma, doğal dil işleme, ses, görüntü ve video sınıflandırma görevlerinde bu algoritmalar karar destekleyici olarak büyük başarı sağlamıştır. Güvenlik, enerji, metalürji ve tıp gibi birçok alanda kullanılan yapay zekâ algoritmaları inşaat mühendisliği alanında da sıkça kullanılmıştır.

Bu tez çalışmasında modern yapay zekâ algoritmaları (makine öğrenmesi) ile basınç dayanımı tahminleri gerçekleştirilmiştir. Bu algoritmaları uygulamak için 1030 kez yapılan kapsamlı bir deney veri seti kullanılmıştır. Bu deney 8 farklı beton bileşenin karışım oranlarına göre beton basınç dayanım sonuçlarını içermektedir. Makine öğrenmesi algoritmaları uygulanmadan önce keşifsel veri analizi yapılmış ve bileşenlerin beton basınç dayanımı üzerindeki etkisi incelenmiştir. Daha sonra 9 farklı makine öğrenmesi algoritması ile beton basınç dayanımı tahminleri yapılmıştır. Gradyan Artırma algoritması ile en iyi ve güvenilir bir tahmin sonucu elde edilmiştir.

Anahtar Kelimeler: Beton basınç dayanımı tahmini, Keşifsel veri analizi, Makine Öğrenmesi, Regresyon algoritmaları

ABSTRACT

Prediction of Compressive Strength Experiment Results of Concrete Used in Buildings Using Machine Learning Techniques

Melike DEMİR

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Eco-informatics

January 2022, Pages: x + 34

Measuring concrete compressive strength takes place in the construction industry as a very important process for giving information about the durability of the structure. Performing concrete compressive strength tests requires a series of processes and appropriate steps. The most important element in the test stages is the addition of the necessary components in the concrete samples taken at the required rate. In addition, in order to obtain the best concrete compressive strength, the tests must be carried out within a certain period of time. In addition, a serious cost and experts in the field are needed to carry out these experiments. However, inaccuracies in obtaining and recording pressure test results may occur due to the workload intensity.

Since the early 1990s, artificial intelligence algorithms have been actively used in automatic classification and regression problems. As time progresses, artificial intelligence algorithms with data types and sizes have been developed and these algorithms have achieved great success as decision supporters in object recognition, natural language processing, audio, image and video classification tasks. Artificial intelligence algorithms, which are used in many fields such as security, energy, metallurgy and medicine, have also been frequently used in the field of civil engineering..

In this thesis study, compressive strength estimations were made with modern artificial intelligence algorithms (machine learning). An extensive experimental dataset of 1030 times was used to implement these algorithms. This test includes concrete compressive strength results according to the mixing ratios of 8 different concrete components. Before applying the machine learning algorithms, exploratory data analysis was made and the effect of the components on the concrete compressive strength was examined. Then, concrete compressive strength estimates were made with 9 different machine learning algorithms. A best and reliable estimation result was obtained with the Gradient Boosting algorithm.

Keywords: Concrete compressive strength estimation, Exploratory data analysis, Machine Learning, Regression algorithms

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Lineer Regresyon	4
Şekil 2.2. İkinci dereceden Polinomial Regresyon	4
Şekil 2.3. KA algoritması temsili gösterimi	5
Şekil 2.4. Düzensizlik fonksiyonunun olasılık değerine göre değişim grafiği	7
Şekil 2.5. Düzensizlik fonksiyonunun olasılık değerine göre değişim grafiği	8
Şekil 2.6. K-EYK örnek gösterimi	9
Şekil 2.7. DVM temsili gösterimi.....	10
Şekil 2.8. DVM’de destek vektörlerin ayırlamaması	12
Şekil 2.9. İki dereceden polinomal fonksiyon için gösterim	16
Şekil 2.10. Gauss kernel ile hiperdüzlem ve destek vektörler	17
Şekil 3.1. Önerilen metodun temsili gösterimi	22
Şekil 4.1. Çimento miktarına göre beton basınç dayanımının değişimi	23
Şekil 4.2. Yüksek fırın cürufu miktarına göre beton basınç dayanımının değişimi.....	24
Şekil 4.3. Uçucu kül miktarına göre beton basınç dayanımının değişimi.....	24
Şekil 4.4. Uçucu Su miktarına göre beton basınç dayanımının değişimi	25
Şekil 4.5. Süper akışkanlaştırıcı miktarına göre beton basınç dayanımının değişimi.....	25
Şekil 4.6. İri agrega miktarına göre beton basınç dayanımının değişimi.....	26
Şekil 4.7. İnce agrega miktarına göre beton basınç dayanımının değişimi.....	26
Şekil 4.8. Veri setinin kutu grafiği gösterimi	27
Şekil 4.9. Veri setinin kutu grafiği gösterimi	28
Şekil 4.10. Makine öğrenmesi modelleri RMSE değerleri	30

TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. DVM için popüler çekirdek fonksiyon bilgileri.....	16
Tablo 3.1. Kırılma zamanına göre basınç dayanım başarı yüzdesi.....	20
Tablo 3.2. Beton basınç dayanımı veri setinden örnekler	21
Tablo 4.1. Regresyon analizi sonuçları	30



SİMGELER VE KISALTMALAR

Simgeler

kg	: Kilogram
m ³	: Metreküp
MPa	: MegaPascal

Kısaltmalar

AÖM	: Aşırı Öğrenme Makinesi
ÇURS	: Çok Değişkenli Uyarlamalı Regresyon Eğrisi
DVM	: Destek Vektör Makineleri
FC	: Fırın Cürufu
GKİ	: Gri Kurt İyileştirici
K-EYK	: K-En Yakın Komşu
PSO	: Parçacık Sürüşü Optimizasyonu
RMSE	: Kök Ortalama Kare Hata
SDA	: Su Döngüsü Algoritması
UK	: Uçucu kül
UNBÇS	: Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
YDB	: Yüksek Dayanımlı Beton
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Betonun insan yapımı bir yapay taş olarak ortaya çıkmasından bu yana, birçok inşaat projesi başarıyla gerçekleştirilmiştir. Bununla birlikte, sertleşmiş betonun özelliklerini tahmin etmek her zaman beton teknolojisindeki temel zorluklardan biri olmuştur. Bunun temel nedeni, birçok öngörülebilir veya öngörülemeyen faktörün betonun özelliklerini önemli ölçüde etkileyebilmesidir [1, 2]. Basınç dayanımı, mühendislik yapılarının tasarımında önemli bir rol oynayan beton özelliklerinden biridir. Mevcut uygulamada, betonun basınç dayanımını belirlemek için, birkaç kübik veya silindirik numune imal edilmekte ve numunelerin farklı yaşlarında test edilmektedir. Ancak, bu testler yalnızca maliyetli değil, aynı zamanda zaman alıcıdır [3, 4]. Ayrıca, betonun karışım tasarımındaki değişiklikler, tamamen farklı özelliklere sahip betonla sonuçlanabilir. Bu nedenle, bir bileşenin içeriği değişse bile testlerin tekrarlanması gerekir [5]. Çimentonun kısmen puzolan tozları ile değiştirildiği beton durumunda bu sorun daha iyi hissedilebilir. Puzolan tozları olarak uçucu kül (UK) ve fırın cürufu (FC), çimentonun kısmi bileşenleri olarak yaygın olarak kullanılmaktadır [6, 7]. UK genellikle termik santrallerin fırınlarında pülverize kömürün yakılmasından elde edilen kalıntı olarak elde edilir. UK'nın özellikleri, elde edildiği yanma sürecine bağlıdır [8]. Kuru işleme, partikül boyutunda homojen olan UK'ya yol açarken, ıslak işleme yüksek oranda ayrılmış agregalarla UK ile sonuçlanabilir [9]. Çimento için kısmi bir bileşen olarak betona UK eklenmesi, basınç dayanımı ve çökme değerlerini azaltır; ancak betonun işlenebilirliğini ve bütünlüğünü artırır [10]. FC, kimyasal bileşimi üretildiği hammaddelere bağlı olan yüksek fırınlarda demir ve çelik üretiminin yan ürünüdür. Yüksek fırınlarda cüruf demirin üzerinde yüzer ve ayırmak için boşaltılır [11]. Erimiş cürufun hızlı soğutulması, onu hidrolik özelliklere sahip kristal olmayan bileşenlere dönüştürür [12]. Çimentonun FC ile kısmen değiştirilmesi, daha yüksek basınç dayanımı ve dayanıklılığı olan beton ile sonuçlanır. Bununla birlikte, daha yüksek bir FC dozu, betonun mukavemetini ve mekanik özelliklerini olumsuz yönde etkileyen termos-higral hasarlara ve çatlaklara neden olabilir [13, 14]. UK ve FC'nin betonda kullanımı sadece bu atık malzemelerin imhası için bir yolu ele almakla kalmaz, aynı zamanda fazladan üretimi büyük miktarda karbondioksit (CO₂) emisyonuna neden olur [6, 15, 16]. Bununla birlikte, basınç dayanımının çeşitli parametrelere bağımlılığı ve karışım oranlarına yüksek hassasiyet nedeniyle, deney yapma ihtiyacını mümkün olduğunca ortadan kaldırmak için ve aynı zamanda daha basit bir araç sağlamak için daha gelişmiş yöntemlerin kullanılması gerektiği görülmektedir.

Yazılımsal hesaplardan Genel olarak yapılan bu konuda kullanılabilecek verimli bir yaklaşım olarak bahsedilebilir. Yazılımsal hesaplamanın en önemli avantajı, matematiksel modellerin probleme dâhil olan parametreler arasındaki ilişkinin kolayca ifade edilemediği durumlarda doğrusal veya doğrusal olmayan problemler için çözümler üretmesidir [17]. Dahası, yazılımsal hesaplama yöntemleri hesaplamada insan temelli bilgi, tanıma, anlama ve öğrenmeyi

kullanır [18]. Son yıllarda, birçok araştırmacı, farklı beton türlerinin özellik tahmininde, yazılımsal hesaplama yöntemlerinin alt dalları olarak yapay zekâ yöntemlerini ve makine öğrenimi tekniklerini kullanmıştır.

Öztaş vd. [19], yüksek dayanımlı betonun (YDB) çökme değerini ve basınç dayanımını tahmin etmede yapay sinir ağı (YSA) kullanma potansiyelini araştırdı. Bu çalışma, YDB'nin özellik tahmininde YSA'nın yüksek kapasitesini ortaya çıkarmıştır. Alshihri vd. [20], hafif betonun basınç dayanımı tahmininde bir YSA modeli kullandı ve YSA kullanımının, maliyeti azaltabileceği ve zamandan tasarruf sağlayabileceği sonucuna vardı. Başka bir çalışmada, YSA'nın tatmin edici performansı, betonun basınç dayanımı tahmininde rapor edilmiştir [21]. Khademi vd. [22], normal dayanımlı betonun basınç dayanımını tahmin etmek için bir YSA modeli, Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (UNBÇS) modeli ve Multi-Lineer Regresyon modelini kullandı. Problem doğrusal olmadığından, Multi-Lineer Regresyon modelinin basınç dayanımı tahmini durumunda yeterince uygulanabilir olmadığı, YSA ve UNÇBS modellerinin bu alanda kullanılabilecek kadar güvenilir olduğu sonucuna varmışlardır. Yaseen vd. [23], hafif köpüklü betonun basınç dayanımı tahmininde Aşırı Öğrenme Makinesinin (AÖM), Destek Vektör Regresyonunun, Çok Değişkenli Uyarlamalı Regresyon Eğrisinin (ÇURS) ve M5 ağaç modelinin performansını karşılaştırdı. AÖM'nin üstün performansı bu araştırmada rapor edilmiştir. Alshamiri vd. [24] YDB'nin basınç dayanımı tahmininde AÖM'nin kapasitesini incelemiş ve bir YSA modeliyle karşılaştırmıştır. Bu durumda, AÖM modelinin YSA modeline göre daha iyi performans verdiği gözlemlenmiştir. Han vd. [25] öğütülmüş granülde yüksek fırın cürufunun farklı miktarlarda kullanılması ile betonun basınç dayanımını tahmin etmek için YSA ile Parçacık Sürüsü Optimizasyonu (PSO) algoritmasını birleştirdi ve hibrit YSA-PSO modelinin sonucunu bir YSA modeliyle karşılaştırdı. PSO ile birleştikten sonra YSA performansında iyileşmeler olduğunu bildirilmiştir. Golafshani vd. [26], bir YSA ve bir UNBÇS modelini Gri Kurt İyileştirici (GKİ) algoritması ile birleştirdi ve modellerin GKİ ile hibridizasyonunun hem YSA hem de UNÇBS modellerinin eğitim ve genelleme kapasitesini geliştirdiğini gösterdi. Sun vd. [27] ayrıca hibrit bir Yapay Arı Kolonisi-YSA modeli ile silika dumanı ve uçucu kül içeren betonun basınç dayanımı üzerindeki etkili faktörleri tahmin etmiş ve optimize etmiştir. Bir araştırmada Ashrafian vd. [28], tipik bir ÇURS modelini bir Su Döngüsü Algoritması (SDA) ile birleştirdi ve köpüklü hücreli hafif betonun basınç dayanımını tahmin etmek için hibrit bir ÇURS-SDA modeli önerdi.

Bu tez çalışmasında 8 farklı değişkenle 1030 kez yapılmış bir deneyin sonuçları kullanılarak 1 metre küp hacmindeki betonun basınç dayanımı tahmini, makine öğrenmesi algoritmalarıyla yapılmıştır. 2. bölümde makine öğrenmesi algoritmalarına genel olarak değinilmiştir. 3. bölümde materyal ve kullanılan metotlar açıklanmıştır. 4. bölümde bulgular verilmiş ve bu bulgular üzerine tartışılmıştır. Son bölümde çalışmanın sonuçlarından bahsedilmiştir.

2. REGRESYON ALGORİTMALARI


Makine öğrenmesinin temelinde istatistik, olasılık ve optimizasyon algoritmaları yer almaktadır. Regresyon analizi de makine öğrenmesinin ilgi alanlardan biridir. Doğru model için doğru tekniği seçmek tahmin başarımını olumlu yönde etkiler. Bu tercihi yapmak için problem verisini iyi analiz etmek ve regresyon algoritması hakkında bilgi sahibi olmak gerekir. Regresyon analizi, değişkenler arasındaki ilişkileri tahmin etmek için kullanılan istatistiksel bir tekniktir. Regresyon denklemlerinde, verilerin bir denklemle uyuma derecesi belli bir oranlarda belirlenebilir. Bu işlem, geleceğe yönelik tahminleri, geçmiş davranış göstergeleri kullanarak geleceğe yönelik tahminler yapılarak gerçekleştirilir. Örneğin, bir çocuğun boyu senede bir ölçülürse, her sene ortalama 3 santim arttığı görülebilir. Bu eğilimle regresyon denklemi çocuğun boyu her yıl üç santim büyüyor şeklinde oluşturulabilir. Başka bir örnek vermek gerekirse, bir yerleşim bölgesinin geçmiş yıllara ait hava tahmini verilerini kullanarak, gelecek yıllardaki hava tahmini yapılabilir. Bu gibi durumlarda en iyi sonucu regresyon algoritmalarıyla elde edilir. Ayrıca, dünyada bu tipteki birçok problem değişik regresyon algoritmaları ile analiz edilebilir.

2.1. Lineer Regresyon

Lineer regresyonda, iki değişkenin birbiri arasındaki doğrusal ilişkinin bir doğru denklemi olarak tanımlanması durumunda, değişkenlerden birinin değeri biliniyorsa diğeri hakkında tahmin yapılmasına olanak sağlanır. Değişkenler arasında gerçekçi çıkarımlar yapılabilmesi için değişkenler arasındaki bağıntıyı en iyi tanımlayacak doğruyu bulmak gerekir [29]. Bu doğru oluşturulurken tüm değişken verilerine en yakın doğru bulunmalıdır. Lineer regresyonda Denklem 2.1’de gösterildiği gibi 1 bağımlı bir bağımsız değişken bulunur.

$$y = B_1x + B_0 \quad (2.1)$$

Burada y bağımlı ve x bağımsız değişkendir. Bilinen y ve x örnekleri ile birlikte bu iki değişken arasındaki en bağıntıyı sağlayacak B_1 ve B_0 değerini bulmak lineer regresyon algoritmasının görevidir. Lineer Regresyon temsili gösterimi Şekil 2.1’de verilmiştir.



Şekil 2.1. Lineer Regresyon

2.2. Multi-Lineer Regresyon


Bir bağımlı ve birden çok bağımsız değişken arasındaki bağıntıyı ifadeye etmeye çalışan algoritmadır [30]. Multi-Lineer Regresyon algoritması Denklem 2.2'deki gibi ifade edilir.

$$y = \sum_{i=1}^N B_i x_i + B_0 \quad (2.2)$$

2.3. Polinomial Lineer Regresyon

Bir bağımlı ve birçok bağımsız değişken arasında polinomial bir artış söz konusu ise regresyon denklemini bu algoritma ile oluşturulur [31]. Polinomial lineer regresyon denkleminin genel ifadesi Denklem 2.3'te verilmiştir. Ayrıca 2. dereceden polinomial lineer regresyon durumunun gösterimi Şekil 2.2'de verilmiştir.


$$y = B_n x_n^m + \dots + B_1 x_1 + B_0 \quad (2.3)$$



Şekil 2.2. İkinci dereceden Polinomial Regresyon

2.4. Karar Ağaçları

Böl ve yönet tekniğini kullanan karar ağaçları (KA) algoritmaları ağaç yapılarını baz almıştır. KA algoritmaları gözetimli öğrenme kategorisinde yer almakta ve verilerin saçılımına bakmadan tahmin yapar. Diğer veri saçılımından bağımsız yöntemlerin (K-EYK) aksine mesafe kullanılmadığından çok sayıda eğitim örneği içeren veri setlerinde hesaplama yükü fazla olmaz. Karar ağaçları içeride karar işlemlerinin yapıldığı düğümler ve yaprak adı verilen bileşenlerden meydana gelmektedir ki yaprak çıktıları tahmin değerlerini oluşturur [32]. KA algoritmasının temsili gösterimi Şekil 2.3'te verilmiştir.



Şekil 2.3. KA algoritması temsili gösterimi

Şekil 2.3'ün (a) bölümünde girişlerin x_1 ve x_2 değişkenleri ile bağlantılı saçılımı ve karar düğümü içinde uygulanması istenen koşulların kesim sınırları (ω_1 ve ω_2) verilmiştir. Bu kesim sınırlarına göre Şekil 2.3'ün (b) bölümünde KA için akış diyagramı düzenlenmiştir. Gösterilen akış diyagramı için elips karar düğümünü, dikdörtgen yaprağı temsil eder. Bu akış diyagramında girişler x_1 ekseninde bulunan ω_1 kesim bölgesinden küçükse bütün sınıflar daire olduğu için işlem bitirilir. Fakat giriş örnekleri x_1 ekseninde kesim sınırı değerinden (ω_1) büyük olursa yeni bir karar düğümü bölgesine geçiş yapılır ve bu düğüm için kesim bölgesindeki değere (ω_2) göre değerlendirme yapılır. Bu düğümdeki girişler ω_2 kesim değerinden küçük olursa daire, büyük olursa üçgen olarak değer alır ve algoritma sonlandırılır.

Genel anlamda karar ağacı algoritmalarının çalışma mantığı şöyledir:

Aşama 1: M adet giriş veri kümesi ile eğitime başlayın.

Aşama 2: M adet veri kümesi için en iyi ayrımı yapan nitelik faktörünü bilgi kazancı kriterine göre belirleyin.

Aşama 3: Belirli nitelikte karar ağacının belirleyici karar düğümünü oluşturun.

Aşama 4: Belirleyici karar düğümünden sonra alt belirleyici karar düğümlerini ve yapraklarını oluşturun.

Aşama 5: Alt belirleyici karar düğümlerini kullanarak alt veri kümelerini oluşturun.

Aşama 6: Aşama 5'te oluşturulmuş her alt veri kümesi için giriş örnekleri;

- Aynı sınıfta bulunuyorsa
- Giriş örneklerinde ayrım yapacak nitelik bulunmuyorsa
- Kalan giriş örnekleri için temsil edici nitelik yoksa algoritmayı sonlandırın. Aksi halde Aşama 4'e geri dönün ve yeni giriş verisi kümelerini kullanarak karar düğümlerini ve yaprakları oluşturun.

Belirleyici karar düğümü ve alt belirleyici karar düğümleri oluşturulması için en kritik faktör bilgi kazancıdır. KA algoritmalarında bilgi kazancı hesaplanmasında düzensizlik fonksiyonu ele alınır. Düzensizlik fonksiyonunun hesaplanması Denklem 2.4'te gösterilmiştir.

$$D = -p \log_2 p - (1 - p) \log_2 (1 - p) \quad (2.4)$$


Buradaki p , giriş verilerinin belirlenmiş karar düğümüne ait olma olasılığını temsil eder. Düzensizlik fonksiyonunun p olasılığı ile değişim grafiği Şekil 2.4'te verilmiştir. Giriş verisinin türüne bağlı olmadan düzensizlik fonksiyonu Denklem 2.5'te gösterilmiştir.

$$D_n = -\sum_{i=1}^K p_n^i \log_2 p_n^i \quad (2.5)$$

Bu düzensizlik fonksiyonuyla M adet veri kümesi için niteliklere ait bilgi kazanç değerleri Denklem 2.6 ile hesaplanır ve hangi niteliğin bilgi kazanç değeri fazlaysa belirleyici karar düğümünde aranan nitelik bulunmuş olunur.

$$Kazanç(M, A) = D(M) - \sum P_r D(M_r) \quad (2.6)$$

Buradaki $D(M)$, toplam veri kümesi için her bir girişe ait toplam düzensizlik değerini gösterir. P_r , aranan niteliğin alt veri kümelerindeki girişlerin tüm veriye ait olasılığına karşılık gelir ve $D(M_r)$ alt veri kümelerindeki girişe ait düzensizlik değerini temsil eder.



Şekil 2.4. Düzensizlik fonksiyonunun olasılık değerine göre değişim grafiği

2.5. Rastgele Değişken

Rastgele Değişken (RD) algoritması, makine öğreniminde denetimli öğrenme tekniklerinin kapsamına girer ve hem regresyon hem de sınıflandırma amacıyla kullanılan en popüler algoritmalarından biridir. RD algoritması, performansı artırmak için birçok sınıflandırıcıyı bir araya getirir ve öğrenmeyi birleştirme kavramına dayanmaktadır. Basitçe söylemek gerekirse, RD algoritması bir grup karar ağacıdır ve tahmin ve sonuçları iyileştirmek için karar ağaçlarının tahminlerinin çoğunluk oylamasını (ÇO) kullanır [33]. RD yaklaşımının temsili gösterimi Şekil 2.5'te verilmiştir.

RD algoritması, KA algoritmasının geliştirilmiş bir versiyonudur. KA algoritmalarında aşırı uydurma problemi ortaya çıkabilmektedir, ancak RD algoritmasında, her ağaçtan tahmin alınarak ve ağaçlardan gelen çoğunluk oylarına dayanarak bu problemin üstesinden gelinir. RD algoritmasında ağaç sayısı ne kadar yüksek olursa, doğruluk o kadar iyi olur ve aşırı uydurma problemi önlenir veya azaltılır. RD algoritmasının basitçe aşamaları aşağıdaki gibidir.


Aşama 1: Veri kümesinden rasgele bazı örnek verileri rastgele seçin.

Aşama 2: Seçilen örnek verileri kullanarak karar ağaçları oluşturun.

Aşama 3: Oluşturulacak karar ağaçlarının sayısını seçin.

Aşama 4: Seçilen sayı kadar Aşama-1 ve Aşama-2 safhalarını tekrar edin.

Aşama 5: Herhangi bir yeni örnek veri/veriler için, her bir karar ağacının tahminini hesaplayın ve ağaçların çoğunluk oylarını kullanarak nihai tahmin değerini hesaplayın.



Şekil 2.5. Düzensizlik fonksiyonunun olasılık değerine göre değişim grafiği

2.6. K-En Yakın Komşuluk (K-EYK)

K-EYK algoritması, gözetimli öğrenme sınıfında yer alıp hem sınıflandırma hem de regresyon görevlerinde sıklıkla tercih edilmektedir. İlk olarak Cover ve Hart tarafından [34] 1967 yılı içerisinde önerilmiştir. K-EYK algoritmasında alanında uzman kişiler tarafından etiketlenmiş olan veriler bulunmaktadır. Tahmin edilecek yeni örnek verilerin bu veriler ile ilişkisi temel alınır. Bu ilişkilerde uzaklık bağıntıları kullanılır. Bu uzaklıklar, Denklem 2.7-2.9 arasında verilen Öklid, Minkowski ve Manhattan gibi uzaklık denklemleri ile hesaplanır.

$$\text{Öklid} = \sqrt{\sum_{i=1}^N (x_i - y_i)^2} \quad (2.7)$$


$$\text{Manhattan} = \sum_{i=1}^N |x_i - y_i| \quad (2.8)$$

$$\text{Minkowski} = (\sum_{i=1}^N (|x_i - y_i|^r))^{1/r} \quad (2.9)$$

Minkowski denklemi için $r=1$ verildiğinde Manhattan, $r=2$ verildiğinde ise Öklid uzaklığı hesaplanmış olur.

Kaç adet veri ile yeni örnek verinin tahmininin yapılacağı K değişkeni ile hesaplanır. Yeni verinin tahmin değeri yeni örnek veriye en yakın K kadar veri değerine ÇO uygulanarak belirlenir. Şekil 2.6’da K-EYK yaklaşımının temsili gösterimi verilmiştir. K=1 seçildiği durumda yeni örnek veri daireye ait değeri almakta, K=3 seçildiği durumda ise yeni örnek üçgene ait değeri almaktadır. Bu nedenle yeni örnek veri değerinin belirlenmesinde K değişkeninin etkisi fazladır.

Diğer makine öğrenmesi algoritmalarıyla karşılaştırıldığında K-EYK algoritmalarında eğitim işlemine gereksinim olmaması, gürültü faktörüne dayanımlı olması K-EYK algoritmasının avantajı iken, büyük veriler için hesaplama yükünün çok olması, K-EYK performansının sadece kontrol edilemeyen uzaklık fonksiyonuna göre değişimi ve K değişkeni ile tahmin sonucunun değişmesi dezavantajdır.



Şekil 2.6. K-EYK örnek gösterimi

2.7. Destek Vektör Makineleri (DVM)

Vapnik tarafından önerilen [35] DVM yaklaşımı, regresyon ve sınıflandırma problemlerinde sıkça kullanılmaktadır. DVM yaklaşımında hiperdüzlem uydurma işlemine dayanmaktadır. DVM algoritmasında iki ayrı örnek arasında bulunması gereken hiperdüzlem maksimum kenar payını arayan optimizasyon yöntemiyle bulunmaya çalışılır. DVM tekniği lineer ve lineer olmayan tahmin görevlerinde tercih edilmektedir.

Bir regresyon probleminde tahmin edilmesi istenen değerlerden birinin “+1” değerinin “-1” olduğunu kabul edelim. $X = \{x_i, y_i\}$ öğrenim örnekleme giriş verileri “ x_i ” $\in T_1$ olursa $y_i = 1$ “ x_i ” $\in S_T$ olursa $y_i = -1$ değerleri elde edilsin. Böyle bir durumda “ ω ” ağırlık parametreleri ile “ ω_0 ” bias değişkenleri için gerekli şartlar Denklem 2.10 ve 2.11’de gösterilmiştir.

$$\omega x_i + \omega_0 \geq +1 \rightarrow y_i = +1 \quad (2.10)$$

$$\omega x_i + \omega_0 \leq -1 \rightarrow y_i = -1 \quad (2.11)$$


Denklem 2.10 ve 2.11 tekrar düzenlenirse Denklem 3.48 oluşturulur.

$$y_i(\omega^T x_i + \omega_0) \geq +1 \quad (2.12)$$

Böyle bir durumda $y_i(\omega x_i + \omega_0) \geq 0$ olması istenmez. Bu durum giriş verilerinin konumunun hiperdüzleme yakın olmasından kaynaklanmaktadır. Bu nedenle, iyi bir genelleme yapmak için giriş verilerinin hiperdüzleme belli bir mesafede olması gerekmektedir. Hiperdüzlemin her iki tarafından eşit mesafe bırakılarak oluşturulan uzaklığa kenar payı adı verilmektedir. Kenar payı büyüdükçe daha iyi bir genelleme yapılmış olunur fakat bununla birlikte yapılan tahmin doğruluğu da azalır.

Şekil 2.7’de verilen giriş örneklerinin (x_i) hiperdüzleme mesafesi Denklem 2.13’de gösterildiği hesaplanır.

$$d_1 = \frac{|\omega x_i + \omega_0|}{\|\omega\|} \quad (2.13)$$



Şekil 2.7. DVM temsili gösterimi

$x_i \in \{-1, +1\}$ şartında Denklem 2.13, Denklem 2.14’de olduğu gibi tekrar oluşturulur

$$d_2 = \frac{x_i(\omega x_i + \omega_0)}{\|\omega\|} \quad (2.14)$$

Denklem 2.14’den elde edilmiş değerlerin istenen eşik değerinde (q) olması hedeflenirse Denklem 2.15 elde edilmiş olunur.

$$\frac{x_i(\omega x_i + \omega_0)}{\|\omega\|} \geq q \quad (2.15)$$

Buradaki ω ağırlık parametrelerinin ölçeklenmediği durum için q değerlerinin mümkün olduğu kadar büyüklüğü hedeflenir. Dolayısıyla, bir tahmin sonucunu almak için $q\|\omega\| = 1$ olarak ayarlandıktan sonra kenar payının olabildiğince artırılması için $\|\omega\|$ değerlerinin olabildiğince düşürülmesi gereklidir [35]. Bu yüzden Denklem 2.12’de, Denklem 2.16’daki kısıt kullanılarak $\|\omega\|$ minimum değerinin bulunması gereklidir.

$$\min \frac{1}{2} \|\omega\|^2 \text{ kısıt: } y_i(\omega x_i + \omega_0) \geq +1, \forall i \quad (2.16)$$

Burada “ ω ” değerini temel alan ikinci dereceli bir optimizasyon problemi söz konusudur ve bu problem ele alınıp gerekli çözümler yapıldığında ω ve ω_0 sınıflandırma ve regresyon problemlerinde en iyi performansı verir. Ayrıca, bu problem çözüldüğünde hiperdüzlemin en yakınında bulunan gerçek tahmin verileri veri ile hiperdüzlem arasındaki mesafe $\frac{1}{\|\omega\|}$ ve kenar payları arasındaki mesafe $\frac{2}{\|\omega\|}$ olmaktadır.

Hedeflenen hiperdüzlemi elde etmek için optimizasyon tekniğinde giriş büyüklüğü N kullanılmaktadır. Böylece doğrusal ayırım sağlamak için kullanılan çekirdek fonksiyonlarında kolaylık sağlanır.

Denklem 2.16 kısıtlamasına Lagrange katsayıları eklenerek Denklem 2.17 elde edilir.

$$L_p = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^N \alpha_i [y_i(\omega x_i + \omega_0)] + \sum_{i=1}^N \alpha_i \quad (2.17)$$

Bu denklem ile $\alpha_i \geq 0$ çarpanları kullanılarak ω ile ω_0 değerlerinin minimum değer alması optimizasyon tekniğinin asıl amacıdır. Bu durumu sağlamak için Denklem 2.17’ün ω ile ω_0 parametrelerine göre kısmi türevi alınır ve sıfıra eşitlenir.

$$\frac{\partial L_p}{\partial \omega} = 0 \implies \omega = \sum_i \alpha_i y_i x_i \quad (2.18)$$

$$\frac{\partial L_p}{\partial \omega_0} = 0 \implies \sum_i \alpha_i y_i = 0 \quad (2.19)$$


Denklem 2.18 ve 2.19, Denklem 2.17’de yerine koyulduğunda Denklem 2.20 oluşturulur.

$$L_d = -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i^T x_j + \sum_i \alpha_i \quad (2.20)$$

Denklem 2.20’nin kısıtı α_i parametreleri büyütülürken, $\sum_i \alpha_i y_i = 0$ eşitliğinin ve $\alpha_i \geq 0$ eşitsizliğinin sağlanmasıdır. Bu optimizasyon probleminin derecesi iki olup işlem karmaşıklığı N (giriş sayısı) değerine bağlıdır.

Optimizasyon tamamlandığında α_i 'nin aldığı değerlerin çoğu sıfır olur. Diğer durumda $\alpha_i > 0$ şartını düşük bir oranla gerçekleştiren x_i değerleri destek vektörlerini oluşturur. Şekil 2.8'de destek vektörlerin temsili gösterimi, kenar payı üzerindeki artı ve eksi simge değerleri çember içine alınarak vurgulanmıştır. Destek vektör değerleri yerine koyulduğunda $y_i(\omega x_i + \omega_0) = 1$ koşulunun sağlandığı görülür. Ayrıca destek vektörlerden bir tanesi ile ω_0 değeri bulunabilir. Tahmin doğruluğunu artırmak için bu operasyon bütün destek vektörler üzerinde uygulanıp bulunan ω_0 değerlerinin ortalaması hesaplanır. Bu adımlar ile elde edile hiperdüzleme Destek Vektör Makinesi (DVM) yaklaşımı denilmektedir. DVM yaklaşımında $\alpha_i = 0$ eşitliği halinde bütün girişler üzerinde $y_i(\omega x_i + \omega_0) > 1$ şartı sağlanmaktadır ve böyle bir durumda girişler hiperdüzlemden yeteri kadar mesafelidir ve bu girişlerin artık hiperdüzlemden herhangi bir etkisi yoktur. Bu girişlerden herhangi biri veya birileri, eğitim setinden çıkarılması veya eklenmesi durumunda da algoritma etkilenmez. Çünkü DVM, destek vektörlerini oluşturacak girişleri bulmuştur ve diğer girişler DVM tekniğini ilgilendirmez. Dolayısıyla, destek vektörler bulunduktan sonra ilgisiz girişler eğitim setinden çıkarılabilir ve DVM karmaşıklığı azaltılabilir.

Bununla birlikte DVM algoritmasında veri karakteristiğinden dolayı değerlerin %100 doğrulukla tahmin edilmesi mümkün olmaz. Bunun için en kabul edilebilecek sapma ile hiperdüzlemin konumlandırılması sağlanır. Böylece destek vektörlerdeki kenar paylarına belirli sapmalar oluşturan gösteren artık parametreler ($\delta_i \geq 0$) eklenilmesi uygundur. Destek vektörler için mevcut sapma durumlarında, girişler ya hiperdüzlemin yanlış bölgesindedir ya da hiperdüzlemin doğru bölgesindedir ancak yeterli uzaklıkta değildir [35]. Bu durumlar sırasıyla Şekil 2.8'de (c) ve (d) olarak gösterilen durumlar için verilmiştir.



Şekil 2.8. DVM'de destek vektörlerin ayrılamaması

Artık parametreler ile Denklem 2.12 düzenlenirse Denklem 2.21 elde edilir.

$$y_i(\omega^T x_i + \omega_0) \geq 1 - \delta_i \quad (2.21)$$

Denklem 2.21'de $\delta_i = 0$ olması durumunda destek vektörlerde artık parametre uygulamasına gerek yoktur. $0 < \delta_i < 1$ aralığında bulunuyorsa tahmin doğru yapılmıştır ancak destek vektörler kenar payı ile hiperdüzlem arasında bulunmaktadır. $\delta_i \geq 1$ olursa destek vektörler yanlış bölgededir ve doğru bir tahmin yapılmış olunmaz. Burada $\delta_i \geq 1$, yanlış tahmin edilen girişleri ve $\sum_i \delta_i$ lineer ayrılmayan giriş sayısını verir. Lineer ayrılmayan girişleri minimum yapmak için bir düzeltme değeri (C), Lagrange optimizasyon yaklaşımına Denklem 2.22'de gösterildiği gibi eklenir.

$$L_p = \frac{1}{2} \|\omega\|^2 + C \sum_i \delta_i \quad (2.22)$$

Düzeltilme değeri ile gerçekleştirilen çözümlerlerde sadece hatalı tahminler değil kenar payları ile hiperdüzlem arasındaki doğru tahminlerde de sayılmaktadır. Denklem 2.17, düzeltme değerine göre düzenlenerek Denklem 2.23 oluşturulur.

$$L_p = \frac{1}{2} \|\omega\|^2 + C \sum_i \delta_i - \sum_{i=1}^N \alpha_i [y_i(\omega x_i + \omega_0) - 1 + \delta_i] - \sum_{i=1}^N \sigma_i \delta_i \quad (2.23)$$

Buradaki σ_i , δ_i değişkenlerinin negatif olmasını engelleyen güncellenmiş Lagrange katsayılarıdır. Burada L_p fonksiyonunun ω ve ω_0 'a göre kısmi türevi alınarak sıfıra eşitlenmesi durumunda Denklem 2.18 ve 2.19 tekrar oluşturulmuş olunur. L_p fonksiyonunun δ_i değişkenine göre kısmi türevi alınarak sıfıra eşitlenmesi durumunda Denklem 2.24 oluşturulmuş olunur.

$$\frac{\partial L_p}{\partial \delta_i} = C - \alpha_i - \sigma_i = 0 \quad (2.24)$$

$\sigma_i \geq 1$ olduğunda, $0 \leq \alpha_i \leq C$ şartının sağlanması gereklidir. Denklem 2.18, 3.19 ve 2.24 Denklem 2.23'da değerlendirilirse Denklem 2.25 oluşturulur.

$$L_d = -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i^T x_j + \sum_i \alpha_i \quad (2.25)$$

Denklem 2.25 α_i değerleri büyütülürken kısıtlamalar, $\sum_i \alpha_i y_i = 0$ ve i değerleri için $0 \leq \alpha_i \leq C$ olması durumudur. Denklem 2.25 hesaplandığında doğru tahmin edilen ve kenar paylarından yeterli mesafede olan girişlerde $0 < \alpha_i$ durumu vardır. Girişlerdeki destek vektörlerde, $\alpha_i \leq C$ şartını sağlayan girişler kenar payının üstüne denk gelmektedir ve ω_0 değeri hesaplanır. Dahası bu koşulda $\delta_i=0$ ile $y_i(\omega x_i + \omega_0) = 1$ eşitlikleri de sağlanmış olur. ω_0 değerleri hesaplanırken $y_i(\omega x_i + \omega_0) = 1$ eşitliğini sağlayan destek vektör değerlerinin büyük bir çoğunluğu elde edilen ω_0 değerlerinin ortalamasının alınması daha güvenilir tahminler yapılmasını

sağlar. Kenar paylarının içerisinde bulunan ve hatalı sınıflandırılmış girişlerde $\alpha_i = C$ durumu vardır.

DVM yaklaşımında yapılan optimizasyon işlemi hedeflenen hata değeri elde edilinceye kadar sürdürülür. DVM yaklaşımında hedeflenen hata oranları, doğru tahmin edilmiş destek vektör sayısının eğitilmiş giriş sayısına bölümünden büyük olmaması gerekir. Aksi takdirde destek vektörler ya yanlış tahmin edilmiştir veya kenar payları içinde kalmıştır. Bu duruma Menteşe kaybı denilmektedir. Menteşe kaybının alacağı değer, Denklem 2.26'daki koşula göre değişkenlik gösterir.

$$L_h(y_i^g, y_i) = \begin{cases} 0 & \text{eğer } y_i^g y_i \geq 1 \\ 1 - y_i^g & \text{değilse} \end{cases} \quad (2.26)$$

Burada y_i^g , tahmin edilmiş değerleri, y_i de gerçek değerleri temsil etmektedir. Tahmin verilerinin artık değişkenlerle lineer olarak ayrılmadığı durumlar için başka bir çözümleme yöntemi farklı boyutlara (uzaylara) verileri taşımaktır. Bu yaklaşımda belirli kernel adı verilen fonksiyonlar kullanılmaktadır. Bu taşıma işlemi regresyon problemleri içinde kullanılmaktadır. Yeni boyutlara kernel fonksiyonlarıyla taşıma Denklem 2.27'deki gibi belirtilmektedir.

$$s = \phi(x) \text{ öyle ki } s_m = \phi_j(x), j = 1, 2, \dots, m \quad (2.27)$$

Burada s yeni uzayı, x eski uzayı, ϕ ise kernel fonksiyonunu temsil etmektedir. Güncellenmiş uzay için hiperdüzlem denklemi Denklem 2.28'de gösterilmiştir.

$$g(x) = \omega \phi(x) = \sum_{j=1}^m \omega_j \phi_j(x) \quad (2.28)$$

Denklem 2.28'de başlangıç ağırlık değeri hesaba katılmamaktadır. Çünkü bu değer ($g(0)$) 1 olarak manuel ayarlanır.

Yeni uzay için de yeni boyutlara geçildiğinde düzeltme değerine ihtiyaç duyulabilir. Böylelikle veri örneklerini lineer ayırıştırma performansı artırılmış olunur.

Böyle bir durumda Denklem 2.22 güncellenmiş uzay için değişmez. Ancak kısıtlama Denklem 2.29'da gösterildiği gibi olur.

$$y_i \omega^T \phi(x_i) + \geq 1 - \delta_i \quad (2.29)$$

Denklem 2.29 için Lagrange katsayıları da kullanılması durumunda Denklem 2.30'a ulaşılır.

$$L_p = \frac{1}{2} \|\omega\|^2 + C \sum_i \delta_i - \sum_{i=1}^N \alpha_i [y_i (\omega \phi(x_i)) - 1 + \delta_i] - \sum_{i=1}^N \sigma_i \delta_i \quad (2.30)$$

ω ve δ_i değişkenleri kullanılarak kısmi türev işlemlerinin sıfıra eşitlenmesi durumunda Denklem 2.31 ve 3.32'a ulaşılır ve bu iki denklem Denklem 2.30'da değerlendirilirse Denklem 2.33'e ulaşılır.

$$\frac{\partial L_p}{\partial \omega} = 0 \implies \omega = \sum_i \alpha_i y_i \phi(x_i) \quad (2.31)$$

$$\frac{\partial L_p}{\partial \delta_i} = C - \alpha_i - \sigma_i = 0 \quad (2.32)$$

$$L_d = -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j \phi(x_i^T) \phi(x_j) + \sum_i \alpha_i \quad (2.33)$$

Denklem 2.33'ü α_i değerleri ile büyütülürken kısıtlamalar, $\sum_i \alpha_i y_i = 0$ ve $0 \leq \alpha_i \leq C$ eşitlik ve eşitsizlikleridir.

Örnek verileri farklı uzaya taşıırken temel strateji, kernel fonksiyonlarını iç çarpım ($\phi(x_i^T) \phi(x_j)$) olarak kullanmaktansa $K(x_j, x_i)$ gibi kernel fonksiyonu olarak eklemesidir. Bu durumda Denklem 2.33, Denklem 2.34'de gösterildiği gibi tekrar güncellenir.

$$L_d = -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j K(x_j, x_i) + \sum_i \alpha_i \quad (2.34)$$

Kernel fonksiyonu Denklem 2.35'de gösterildiği gibidir.

$$g(x) = \sum_i \alpha_i y_i k(x, x_i) \quad (2.35)$$

Denklem 2.35 sonucundan edilen değerın karar fonksiyonu olması için signum fonksiyonunu içeren Denklem 2.36 elde edilir.


$$f(x) = \text{sign}(\sum_i \alpha_i y_i k(x, x_i) + b) \quad (2.36)$$

Literatürde birçok çekirdek fonksiyonu olmasına rağmen en çok popüler çekirdek fonksiyonları Tablo 2.1'de vurgulanmıştır.


Tablo 2.1. DVM için popüler çekirdek fonksiyon bilgileri

Çekirdek Fonksiyonları	Matematiksel Gösterimleri
Lineer	$K(x, x_i) = x^T x_i + c$
Polinomal	$K(x, x_i) = (x^T x_i + c)^n$
S biçimli → (Tanh)	$K(x, x_i) = \tanh(2x^T x_i + c)^n$
→ (Sigmoid)	$K(x, x_i) = \text{sigmoid}(2x^T x_i + c)^n$
Gauss → Öklid uzaklığı	$K(x, x_i) = \exp\left[-\frac{\ x_i - x\ ^2}{2s^2}\right]$
Laplace	$K(x, x_i) = \exp\left[-\frac{\ x_i - x\ }{\sigma}\right]$

Polinomal fonksiyonda $c = 1$ ve $n = 2$ olması halinde girişin boyut değeri “2” olarak seçilmesi halinde fonksiyon, $K(x, y) = (x^T y + 1)^2 = (x_1 y_1 + x_2 y_2 + 1)^2$ olur. Bu fonksiyon ile elde edilen hiperdüzlem ve destek vektörlerin durumu Şekil 2.9’da gösterilmiştir.

**Şekil 2.9.** İki dereceden polinomal fonksiyon için gösterim

Çekirdek fonksiyonu olarak Gauss seçilen bir tahmin probleminde hiperdüzlem ve destek vektörlerin durumu Şekil 2.10’da gösterilmiştir.



Şekil 2.10. Gauss kernel ile hiperdüzlem ve destek vektörler

Gauss çekirdek fonksiyonundaki s sınırlarda yumuşamaya neden olur ve s büyütüldükçe sınırlarda yumuşama meydana gelir.

2.8. Güçlendirme (Boosting) Algoritmaları

Güçlendirme, birkaç zayıf öğrenim algoritmasını güçlü bir öğrenim algoritmasında birleştirebilen herhangi bir Topluluk yöntemini ifade eder. Çoğu güçlendirme algoritmasının genel fikri, tahmin edicileri sırayla eğitmek ve bir önceki tahmin edicideki hataları düzeltmeye çalışmaktır. Mevcut birçok güçlendirme yöntemi vardır, ancak açık ara en popüler olanları AdaBoost ve Gradient Boosting'dir [36].

2.8.1. AdaBoost ve Gradyan Artırma (Gradient Boosting)

Yeni bir tahmin edicinin öncekini düzeltmesinin bir yolu, öncekinin eksik olduğu eğitim örneklerine biraz daha dikkat etmektir. Bu, zor durumlara giderek daha fazla odaklanan yeni tahmincilerle sonuçlanır. AdaBoost tarafından kullanılan teknik budur.

Örneğin, bir AdaBoost sınıflandırıcısını eğitirken, algoritma önce bir temel sınıflandırıcıyı (Karar Ağacı gibi) eğitir ve bunu eğitim kümesi üzerinde tahminler yapmak için kullanır. Algoritma daha sonra yanlış sınıflandırılmış eğitim örneklerinin göreceli ağırlığını artırır. Ardından, güncellenmiş ağırlıkları kullanarak ikinci bir sınıflandırıcıyı eğitir ve tekrar eğitim seti üzerinde tahminler yapar, örnek ağırlıklarını günceller [36].

AdaBoost algoritmasında ilk tahmin edici çoğu örneği yanlış alır, bu nedenle ağırlıkları artırılır. İkinci tahmin edici bu nedenle aynı örneklerde daha iyi bir iş çıkarır ve en uygun tahmin edici sayısına kadar bu işlem tekrarlandıkça performans artar. Tahmin edici geçişlerinde ağırlıklar

öğrenme oranı kadar artırılır. Bu yönüyle AdaBoost algoritmasının öğrenme tekniğinin Gradyan Azaltma tekniği ile bazı benzerlikleri vardır, ancak AdaBoost algoritmasında tek bir tahmin edicinin parametrelerini bir maliyet fonksiyonu üzerinden en aza indirmek için ayarlamak yerine, AdaBoost topluluğa tahmin ediciler ekleyerek kademeli olarak daha iyi hale getirir.

AdaBoost algoritmasına daha yakından bakılacak olunursa her örnek ağırlığı ω başlangıçta $1/m$ 'ye ayarlanır. Birinci tahmin edici eğitilir ve bu tahmin edicinin ağırlıklı hata oranı r , eğitim setinde Denklem 2.37'deki gibi hesaplanır.

$$r_j = \frac{\sum_{i=1}^m \omega^{(i)} \mathbb{1}_{y_p^{(i)} \neq y^{(i)}}}{\sum_{i=1}^m \omega^{(i)}} \quad (2.37)$$

Tahmin edicinin ağırlığı α daha sonra Denklem 2.38 kullanılarak hesaplanır, burada η öğrenme hızı hiper parametresidir (varsayılan 1'dir). Tahmin edici ne kadar doğru olursa, ağırlığı o kadar yüksek olur. Sadece rastgele tahmin yapıyorsa, ağırlığı sıfıra yakın olacaktır. Bununla birlikte, çoğunlukla yanlışsa (yani rastgele tahminden daha az doğruysa), ağırlığı negatif olacaktır.

$$\alpha_j = \eta \log \frac{1-r_j}{r_j} \quad (2.38)$$

Ardından, AdaBoost algoritması, yanlış sınıflandırılan örneklerin ağırlıklarını artıran Denklem 2.39'u kullanarak örnek ağırlıklarını günceller.

$$\omega^{(i)} \leftarrow \begin{cases} \omega^{(i)} \leftarrow y_p^{(i)} = y^{(i)} \\ \omega^{(i)} \exp(\alpha_j) \leftarrow y_p^{(i)} \neq y^{(i)} \end{cases} \quad (2.39)$$

Ardından tüm örnek ağırlıkları normalleştirilir (yani, $\sum_{i=1}^m \omega^{(i)}$ 'e bölünür).

Son olarak, güncellenmiş ağırlıklar kullanılarak yeni bir tahminci eğitilir ve tüm süreç tekrarlanır (yeni tahmin edicinin ağırlığı hesaplanır, örnek ağırlıkları güncellenir, ardından başka bir tahmin edici eğitilir, vb.). Algoritma, istenen sayıda tahmin ediciye ulaşıldığında veya mükemmel bir tahmin edici bulunduğunda durur.

Tahminlerde bulunmak için AdaBoost, tüm tahmin edicilerin tahminlerini basitçe hesaplar ve tahmin edici ağırlıkları α kullanarak Denklem 2.40'daki gibi ağırlıklandırır. Tahmin edilen sınıf, ağırlıklı oyların çoğunluğunu alan sınıftır.

$$y_p(x) = \arg \max_k \sum_{j=1}^N \alpha_k \mathbb{1}_{y_p(x)=k} \quad (2.40)$$

Burada, N tahmin edicilerin sayısıdır.

Bir diğer çok popüler güçlendirme algoritması Gradyan Artırma (Gradient Boosting) algoritmasıdır. Tıpkı AdaBoost gibi, Gradient Boosting de bir topluluğa sırayla tahmin ediciler ekleyerek çalışır ve her biri bir öncekini düzeltir [36]. Ancak, AdaBoost'un yaptığı gibi her

yinelemede örnek ağırlıklarını değiştirmek yerine, bu yöntem yeni tahminciyi önceki tahmin edici tarafından yapılan artık hatalara uydurmaya çalışır.

2.9. Determinasyon Katsayısı ve Kök Ortalama Kare Hata

Determinasyon katsayısı (R^2) regresyon analizlerinde en çok kullanılan metriktir. Bu metriğin alabileceği en büyük değer 1'dir ve R^2 , 1'e ne kadar yakınsa regresyon probleminde uydurulan eğri bir o kadar iyidir denilebilir [37]. Ayrıca ne kadar çok veri ile işlem yapılıyorsa R^2 sonucu o kadar güvenilirdir. Örnek vermek gerekirse R^2 0,85 ise bu bağımlı değişkenin %85'nin açıklanabildiği ve %15'nin açıklanamadığı anlamına gelir. Bağımlı ve bağımsız değişkenleri kullanarak R^2 Denklem 2.41'deki gibi hesaplanır.

$$R^2 = 1 - \frac{\sum (y_i - y_i^*)^2}{\sum (y_i - \bar{y})^2} \quad (2.41)$$

Burada, y_i deneysel olarak bulunmuş gerçek değerler, y_i^* regresyon analizinde tahmin edilen değerler, $\bar{y}$ deneysel olarak bulunmuş değerlerin ortalaması olarak tanımlanabilir.

Regresyon analizlerinde kullanılan bir diğer önemli metrik ise kök ortalama kare hata (RMSE) değeridir. RMSE değerinin hesaplanması Denklem 2.41'de verilmiştir.

$$RMSE = \frac{\sum_{i=1}^n (y_i - y_i^*)^2}{n} \quad (2.42)$$

RMSE makine öğrenmesi modellerinde, tahminleyicilerin tahminleri ile gerçek değerler arasındaki hata değerlerinin bulunması için kullanılan karesel bir ölçüm tekniğidir. RMSE, tahmin değerlerinde bulunan hataların standart sapması olarak tanımlanabilir. RMSE tahmin değerlerinin gerçek değerlerden ne kadar uzakta olduğunuzu bize söyler. Diğer bir ifadeyle, verilere en iyi bir şekilde uyum sağlayan uydurma çizgisi etrafında tahmin verilerinin hangi yoğunlukta olduğu hakkında bilgi verir. RMSE değerleri sıfırdan sonsuza kadar değer alabilir. RMSE değerleri sıfıra ne kadar yakınsa o kadar iyi tahmin performansı elde edilmiş olunur. RMSE metriğinde tahmin değerinde ne kadar uzaklaşırsa karesel bir hesaplama yapıldığından hata değeri de karesel olarak artar. Ayrıca RMSE metriği, hesaplama işlemlerinde kullanılması istenilmeyen mutlak değerlerin kullanılması durumunu ortadan kaldırır.

3. MATERYAL VE METOT

Betonun basınç dayanımını test etmek için geleneksel süreç, ilgili sınıf için (M5, M10, M15 vb.) birkaç küp dökmeyi ve betonun dayanımını 7 ila 28 gün arasında değişen bir süre boyunca gözlemlemeyi içerir. Beton bileşenlerinin çeşitli kombinasyonları seçilir ve her kombinasyon için küpler dökülür ve 7, 14 ve 28. günlerdeki test dayanımı not edilir. Bu, zaman alan bir süreçtir.

Basınç dayanımında bir diğer önemli faktör kürlenmedir. Kürlenme, betonun kesintisiz hidrasyonunu sağlamak için nemi muhafaza etme işlemidir. Beton küp, kürlenmiş / kürlenmemiş küpler için basınç dayanımlarında davranışsal farklılıklar gösterir. Beton küpler periyodik olarak kürlenirse beton basınç dayanımı artar. Mukavemetteki artış oranı Tablo 3.1’de gösterilmektedir.

Tablo 3.1. Kürlenme zamanına göre basınç dayanım başarı yüzdesi

Zaman (gün)	Basınç Dayanım Başarımı (%)
1	16%
3	40%
7	65%
14	90%
28	99%

Bu çalışmada, girdi olarak çeşitli bileşenler kullanılarak betonun basınç dayanımını maksimum doğruluk ile tahmin edilmesi amaçlanmaktadır.

3.1. Kullanılan Bileşenlere Göre Beton Basınç Dayanımı Laboratuvar Deney Sonuçları

Çalışılan metot için 7 farklı bileşen için 1030 tane deney sonuçları kullanılmıştır. Bu bileşenler sırasıyla şunlardır:

- Bir metreküplük betonda kilogram cinsinden bulunan çimento miktarı
- Bir metreküplük betonda kilogram cinsinden bulunan yüksek fırın cürufu miktarı
- Bir metreküplük betonda kilogram cinsinden bulunan uçucu kül miktarı
- Bir metreküplük betonda kilogram cinsinden bulunan su miktarı
- Bir metreküplük betonda kilogram cinsinden bulunan süper akışkanlaştırıcı miktarı
- Bir metreküplük betonda kilogram cinsinden bulunan iri agregat miktarı
- Bir metreküplük betonda kilogram cinsinden bulunan ince agregat miktarı


Bu bileşenlere zaman faktörü de eklendiğinde oluşturulan veri setinin bazı deneyleri için elde edilen sonuçlar Tablo 3.2’de verilmiştir.

Tablo 3.2. Beton basınç dayanımı veri setinden örnekler

Çimento (kg)	Yüksek Fırın Cürufu (kg)	Uçucu Kül (kg)	Su (kg)	Süper Akışkanlaştırıcı (kg)	İri Agrega (kg)	İnce Agrega (kg)	Süre (Gün)	Beton Basınç Dayanımı (MPa)
540.0	0.0	0.0	162.0	2.5	1040.0	676.0	28	79.99
540.0	0.0	0.0	162.0	2.5	1055.0	676.0	28	61.89
332.5	142.5	0.0	228.0	0.0	932.0	594.0	270	40.27
332.5	142.5	0.0	228.0	0.0	932.0	594.0	365	41.05
198.6	132.4	0.0	192.0	0.0	978.4	825.5	360	44.30
266.0	114.0	0.0	228.0	0.0	932.0	670.0	90	47.03
380.0	95.0	0.0	228.0	0.0	932.0	594.0	365	43.70
380.0	95.0	0.0	228.0	0.0	932.0	594.0	28	36.45
266.0	114.0	0.0	228.0	0.0	932.0	670.0	28	45.85
475.0	0.0	0.0	228.0	0.0	932.0	594.0	28	39.29
198.6	132.4	0.0	192.0	0.0	978.4	825.5	90	38.07
198.6	132.4	0.0	192.0	0.0	978.4	825.5	28	28.02
427.5	47.5	0.0	228.0	0.0	932.0	594.0	270	43.01
190.0	190.0	0.0	228.0	0.0	932.0	670.0	90	42.33

3.2. Metot

Önerilen metot için regresyon analizi uygulamadan önce bağımsız değişkenlerin (öznitelikler) her biri ve bağımlı değişken arasında keşifsel veri analizi yapılmıştır. Regresyon analizi için çimento, yüksek fırın cürufu, uçucu kül, su, süper akışkanlaştırıcı, iri agrega, ince agrega ve geçen süre kullanılmıştır. Toplamda 1030 deneyden oluşan veri seti rastgele bir biçimde eğitim için 0,7 ve test için 0,3 oranında ayrılmıştır. Regresyon analizinde makine öğrenmesi algoritmaları (Multi-Linear Regresyon Polinomial Lineer Regresyon (2. Derece), Polinomial Lineer Regresyon (3. Derece), Karar Ağacı, AdaBoost, Rastgele Orman, K-EYK, DVM, Gradyan Artırma) kullanarak eğitim işlemi gerçekleştirilmiştir. Önerilen metodun performansını ölçmek için R^2 ve metriği kullanılmıştır. Önerilen metodun temsili gösterimi Şekil 3.1’de verilmiştir.




Şekil 3.1. Önerilen metodun temsili gösterimi

4. BULGULAR VE TARTIŞMA

Bu bölümde, ilk olarak deneysel sonuçlar kullanılarak betonun basınç dayanımı ile ilgili keşifsel veri analizi yapılmıştır. İkinci olarak, deneysel sonuçlar regresyon analizi algoritmalarında kullanılmıştır. Bu algoritmalar Multi-Lineer Regresyon, ikinci ve üçüncü dereceden Polinomial-Linear Regresyon algoritmalarından oluşmaktadır.

4.1. Keşifsel Veri Analiziyle Deneysel Sonuçların Yorumlanması


Bu altbölümde, 8 tane bağımsız değişkenin basınç dayanımı üzerindeki etkisi keşifsel veri analizi ile yorumlanmıştır. Keşifsel veri analizi ile yakın değere sahip bağımsız değişkenler aynı grupta yer alır. Böylece bağımlı değişken ile bağımsız değişken arasında özet bir grafiksel gösterim elde edilir. Kullanılan bağımsız değişkenlerden birisi olan çimento miktarının betonun basınç dayanımı üzerindeki etkisi Şekil 4.1’de gösterilmiştir.



Şekil 4.1. Çimento miktarına göre beton basınç dayanımının değişimi

Şekil 4.1’den görüldüğü gibi, çimento içeriğinin 150 kg ile 400 kg arasında model üzerinde doğrusal bir etkiye sahip olduğu görülebilir.


Şekil 4.2’de, kullanılan bağımsız değişkenlerden birisi olan yüksek fırın cürufu miktarının betonun basınç dayanımı üzerindeki etkisi gösterilmiştir.



Şekil 4.2. Yüksek fırın cürufu miktarına göre beton basınç dayanımının değişimi


Şekil 4.2’de verilen grafikte, yüksek fırın cürufu 50 kg/m^3 olarak ayarlandığında, yanma mukavemeti artar. Bu durumda basınç dayanımı üzerinde olumlu etkiye sahiptir.

Şekil 4.3’te, kullanılan bağımsız değişkenlerden birisi olan uçucu kül miktarının betonun basınç dayanımı üzerindeki etkisi gösterilmiştir.




Şekil 4.3. Uçucu kül miktarına göre beton basınç dayanımının değişimi

Şekil 4.3’te verilen grafikten görüleceği üzere beton karışımında $0-50 \text{ kg/m}^3$ ve $75-150 \text{ kg/m}^3$ değişim aralığında bulunan uçucu kül beton basınç dayanımını arttırmıştır.




Şekil 4.4. Uçucu Su miktarına göre beton basınç dayanımının değişimi

Şekil 4.4'te, 1 metreküp betonda kullanılan su miktarına göre betonun basınç dayanımı verilmiştir. Şekil 4.4'ten görüleceği üzere yaklaşık olarak 150 kg-200kg arasında su eklenmesi basınç dayanımını arttırmaktadır.




Şekil 4.5. Süper akışkanlaştırıcı miktarına göre beton basınç dayanımının değişimi

Şekil 4.5'te, 1 metreküp betonda kullanılan süper akışkanlaştırıcı miktarına göre betonun basınç dayanımı verilmiştir. Şekil 4.5'ten görüleceği üzere yaklaşık olarak 1 kg ve 10-12 kg arasında süper akışkanlaştırıcı eklenmesi basınç dayanımını arttırmaktadır.



Şekil 4.6. İri agrega miktarına göre beton basınç dayanımının değişimi


Şekil 4.6’da, 1 metreküp betonda kullanılan iri agrega miktarına göre betonun basınç dayanımı verilmiştir. Şekil 4.6’dan görüleceği üzere yaklaşık olarak 900-1100 kg arasında iri agrega eklenmesi basınç dayanımını arttırmaktadır.



Şekil 4.7. İnce agrega miktarına göre beton basınç dayanımının değişimi

Şekil 4.7’de, 1 metreküp betonda kullanılan ince agrega miktarına göre betonun basınç dayanımı verilmiştir. Şekil 4.7’den görüleceği üzere yaklaşık olarak 750-900 kg arasında ince agrega eklenmesi basınç dayanımını arttırmaktadır.


Kullanılan veri setinin kutu grafiği Şekil 4.8’de gösterilmiştir.



Şekil 4.8. Veri setinin kutu grafiği gösterimi

Şekil 4.8’deki kutu grafiği incelendiğinde en çok aykırı değer Süre değişkeninde olduğu görülmektedir. İkinci olarak en çok aykırı değer Su değişkeninde olmakla beraber Yüksek Fırın Cürufu, Süper Akışkanlaştırıcı, İnce Agregat ve Beton Basınç Dayanımı değişkeninde bir aykırı değer bulunmaktadır.

Şekil 4.9’da Python programlama dilindeki “Pair Plot” tekniği kullanılarak verilerin birbiri ile olan ilişkisi çok yönlü incelenmiştir. Bu teknikte diyagonal ekseninde değişkenlerin kendisi ile olan ilişkisi çizilmiştir. Diyagonal eksenin alt tarafında ise değişkenlerin diğer eksenlerle olan ilişkisi çizilmiştir. Diyagonal eksenin üst kısmında kalan bölgede ise değişkenlerin diğer değişkenlerle olan saçılım grafiği verilmiştir.



Şekil 4.9. Veri setinin kutu grafiği gösterimi

Şekil 4.9'den çıkarılacak özet yorumlama şöyledir. Diyagonal eksen için çimento dağılımı kendi içerisinde neredeyse normaldir. Yüksek fırın cürufu ve uçucu kül değişkenleri kendi içerisinde Gauss dağılımına benzer bir yapı göstermiştir. İri agrega ve ince agregaların değişimi benzerlik göstermektedir. Ayrıca süre değişkenindeki keskin değişimler aykırı değerlerin varlığına işaret etmektedir. Bununla birlikte beton basınç dayanımı normal olarak dağılmıştır. Diyagonal olmayan eksen için çimentonun basınç dayanımı ve süre ile kuvvetli bir ilişkisinin olduğu görülmektedir. Fakat yüksek fırın cürufu, uçucu kül, ince agrega ve iri agregaların zayıf belirleyici olduğu görülmektedir. Su değişkeninin basınç dayanımı ile negatif bir ilintiye sahip olduğu Şekil 4.9'dan görülmektedir. Ayrıca çimento ile yüksek fırın cürufu arasında pozitif güçlü bir ilinti söz konusu iken su ve süper akışkanlaştırıcı arasında negatif güçlü bir ilinti bulunmaktadır.

Şekil 4.1-4.9 arasında verilen grafiklerden kullanılan tüm bileşenleri betonun basınç dayanımı üzerinde fikirler verse de bu bileşenleri birbirinden bağımsız düşünmek imkânsızdır. Genel olarak yapılan analizde elde edilen sonuçlar aşağıdaki gibi yorumlanabilir:

- Çimento içeriğinin ve süper akışkanlaştırıcının varlığının basınç dayanımı üzerinde doğrusal bir etkiye sahip olduğu söylenebilir. Çimento içeriği 300'den az olduğunda basınç dayanımı azalır. Çimento içeriği 300'ün üzerine çıktıkça basınç dayanımı da artar. Ayrıca basınç dayanımı, daha yüksek süper akışkanlaştırıcı içeriği ile birlikte artar.
- Yüksek fırın cürufu 50 kg/m³'ten büyük olduğunda, yanma mukavemeti artar. Süre ile birlikte bu özellik, basınç dayanımından sorumludur.
- Uçucu kül bulunmadığı durumda süper akışkanlaştırıcı içeriğine sahip karışımın basınç dayanımı üzerinde olumlu bir etkisi olduğu gözlemlenmiştir. Uçucu kül miktarı arttıkça basınç dayanımında azalan bir eğilim izlenmektedir. Uçucu kül 75-150 kg/m³ aralığında olduğunda, süper akışkanlaştırıcı içeriği 10 kg/m³ ile gözlemlenen en yüksek basınç dayanımına yol açmaktadır. Benzer şekilde, uçucu kül miktarı 150 kg/m³'ten fazla olduğunda en düşük basınç dayanımı gözlenmiştir.
- Su ve yüksek fırın cürufunun interaktif etkisiyle birlikte basınç dayanımına katkıda bulunduğu gözlemlenmektedir. Düşük yüksek fırın cürufu ile 150 kg / m³'ten az su içeriği en yüksek basınç dayanımını sağlamaktadır. 150 kg/m³'ten daha büyük su içeriği için, daha yüksek basınç dayanımına sahip olması istendiğinde daha yüksek yüksek fırın cürufu tercih edilmektedir.
- 10-12 kg/m³ aralığındaki süper akışkanlaştırıcılar, yüksek fırın cürufu ile birlikte basınç dayanımını artırır.
- Artan iri agrega ile beton bileşen içeriğini daha düşük tutmanın basınç dayanımı üzerinde olumlu bir etkiye sahip olduğunu göstermektedir.
- Yaklaşık 650 kg/m³'ün altındaki ince agregalar için su içeriği 180 kg/m³'ten büyük olmalıdır. Ayrıca, ince agrega içeriği 650 kg/m³'ten büyükse, su içeriği 170 kg/m³'ten az olmalıdır.
- Artan süre birlikte basınç dayanımı kesinlikle artar, ancak farklı su içeriğinin kesinlikle süre ile birlikte etkisi vardır. 28 günlük mukavemet için su içeriği 300kg/m³'ten büyük olması istenir.

4.2. Beton Basınç Dayanımı Tahmini için Regresyon Analizi Sonuçları


Alt bölüm 3.1'de bahsedilen beton basınç dayanımı deneylerinin sonuçları kullanılarak regresyon analizi yapılmıştır. Regresyon analizi için makine öğrenmesinde popüler algoritmalar kullanılmıştır. Kullanılan verisetinin %70'i eğitim için %30'u test için kullanılmıştır. Regresyon

tahminleri elde etmek için Windows 10 işletim sistemine kurulu Python 3.7 programlama dili kullanılmıştır. Tablo 4.1’de regresyon analizi sonuçları verilmiştir.

Tablo 4.1. Regresyon analizi sonuçları

Regresyon Algoritması	R^2 (Eğitim)	R^2 (Test)
Multi-Lineer Regresyon	0.619	0.598
Polinomial Lineer Regresyon (2. Derece)	0.817	0.780
Polinomial Lineer Regresyon (3. Derece)	0.934	0.788
Karar Ağacı	0.757	0.619
AdaBoost	0.831	0.780
Rastgele Orman	0.831	0.741
K-EYK	0.902	0.749
DVM	0.732	0.665
Gradyan Artırma	0.972	0.904

Tablo 4.1’den görüleceği üzere doğrusal regresyon algoritmaları içinde en iyi performans değerine (eğitim:0.934 ve test:0.788) 3. dereceden polinomial regresyon algoritması vermiştir. Genel olarak bakıldığında DVM, K-EYK, Rastgele Orman, Karar Ağacı ve Ada Boost algoritmaları 3. dereceden polinomial regresyon algoritmasından daha kötü performans vermiştir. Bununla birlikte Gradyan Artırma regresyon algoritması hem eğitim hem de test için en iyi performansa ulaşmıştır.



Şekil 4.10. Makine öğrenmesi modelleri RMSE değerleri

Şekil 4.10’da kullanılan makine öğrenmesi modellerinin kullanılan veri seti üzerinde RMSE değerleri verilmiştir. Şekil 4.10 incelendiğinde en kötü RMSE değerine (10.05) Karar Ağacı algoritması ile ulaşılırken en iyi RMSE değeri (6.48) Gradyan Artırma algoritması ile elde edilmiştir.

Literatür çalışmasında da bahsedildiği gibi beton basınç dayanımı tahmini üzerine araştırma topluluğunda birçok çalışma bulunmaktadır. Bu çalışmalar özellikle 2000-2010 yılları arasında yoğun bir şekilde bulunmaktadır. Bununla birlikte, modern yapay zeka da olarak bilinen makine öğrenmesi algoritmaları geliştirildikçe beton basınç dayanımı tahmini üzerine yapılan çalışmalarda 2010 yılından sonra ya azalma olmuştur ya da spesifik bileşenler eklendiğinde basınç dayanımının ne olduğu üzerine çalışmalar yapılmıştır [8,10,12,15,28,38]. Bu azalma ve konu değişiminin en büyük sebebi yeni makine öğrenmesi algoritmalarında büyük veri ile eğitim yapma gerekliliğidir. Dolayısıyla, günümüz şartlar düşünüldüğünde beton basınç dayanımı testleri hem zaman alıcı hem de maliyetlidir. Ayrıca bu veri setlerinin alanında uzman kişiler tarafından oluşturulması ve düzenlenmesi gerekmektedir. Bu açıdan bakıldığında gerçekleştirilen bu tez çalışmasının bu alanda yapılacak diğer çalışmalar için temel metot olacağı düşünülmektedir.

5. SONUÇLAR

Bu tez çalışmasında beton basınç dayanımının makine öğrenme teknikleri ile tahmin edilmesi üzerine çalışılmıştır. Önerilen yöntemlerin değerlendirilmesi için 1030 adet beton basınç dayanımı deney sonuçlarını içeren bir veri seti kullanılmıştır. Her bir deney sonucunda 8 ayrı değişkene (çimento, yüksek fırın cürufu, uçucu kül, su, süre, süper akışkanlaştırıcı, iri agreg, ince agreg) göre betonun basınç dayanımı Mega Pascal cinsinden verilmiştir. Basınç dayanım tahmini yapılmadan önce keşifsel veri analiziyle değişkenlerin birbiri ile olan ilişkisi değerlendirilmiştir. Yapılan analizde basınç dayanımı üzerinde çimento ve süre değişkenlerinin kuvvetli belirleyici olduğu sonucuna varılmıştır. Basınç dayanımı tahmini için, Multi-Lineer Regresyon, ikinci ve üçüncü dereceden polinomial Lineer Regresyon, Karar Ağaçları, Rastgele Orman, AdaBoost, DVM, K-EYK, Gradyan Artırma algoritmaları kullanılmıştır. Bu regresyon algoritmalarının çalıştırılması için veri seti %70 oranında eğitim ve %30 oranında test için ayrılmıştır. Deneysel sonuçlarda en iyi R^2 performansı Gradyan Artırma algoritması ile elde edilmiştir. En kötü performansı ise Multi-Lineer regresyon algoritması vermiştir. Deneysel sonuçlarda en iyi RMSE performansı Gradyan Artırma algoritması ile edilmiştir. En kötü performansı ise Karar Ağacı algoritması vermiştir. Sonuçlar genel olarak değerlendirildiğinde Gradyan Artırma algoritması hariç lineer regresyon algoritmalarının diğer makine öğrenmesi algoritmalarından daha iyi performans sağladığı görülmüştür. Nihai sonuç olarak Gradyan Artırma algoritması ile yüksek bir başarımla elde edilmiştir. Bununla birlikte, ileri ki dönem çalışmalar için yeni makine öğrenmesi algoritmaları ile performansın daha da artırılması mümkündür.

KAYNAKLAR

- [1] M. Shariati, S. Rafie, Y. Zandi, R. Fooladvand, B. Gharehaghaj, P. Mehrabi, A. Shariat, N.T. Trung, M.N.A. Salih, S. Poi-Ngian, Experimental investigation on the effect of cementitious materials on fresh and mechanical properties of self-consolidating concrete, *Adv. Concr. Constr.* 8 (2019) 225–237.
- [2] I.B. Topcu, M. Sarıdemir, Prediction of compressive strength of concrete containing fly ash using artificial neural networks and fuzzy logic, *Comput. Mater. Sci.* 41 (2008) 305–311.
- [3] P. Chopra, R.K. Sharma, M. Kumar, Prediction of compressive strength of concrete using artificial neural network and genetic programming, *Adv. Mater. Sci. Eng.* 2016 (2016).
- [4] A. Toghrli, P. Mehrabi, M. Shariati, N.T. Trung, S. Jahandari, H. Rasekh, Evaluating the use of recycled concrete aggregate and pozzolanic additives in fiber-reinforced pervious concrete with industrial and recycled fibers, *Constr. Build. Mater.* 252 (2020) 118997.
- [5] H. Naderpour, A.H. Rafiean, P. Fakharian, Compressive strength prediction of environmentally friendly concrete using artificial neural networks, *J. Build. Eng.* 16 (2018) 213–219.
- [6] B. Abdelkader, K. El-Hadj, E. Karim, Efficiency of granulated blast furnace slag replacement of cement according to the equivalent binder concept, *Cem. Concr. Compos.* 32 (2010) 226–231.
- [7] S.K. Antiohos, V.G. Papadakis, E. Chaniotakis, S. Tsimas, Improving the performance of ternary blended cements by mixing different types of fly ashes, *Cem. Concr. Res.* 37 (2007) 877–885.
- [8] Astm, Standard Specification for Coal Fly Ash and Raw or Calcined Natural Pozzolan for Use, *Annu. B. ASTM Stand.* 618 (2010) 3–6.
- [9] F. Faleschini, M.A. Zanini, K. Brunelli, C. Pellegrino, Valorization of co-combustion fly ash in concrete production, *Mater. Des.* 85 (2015) 687–694.
- [10] G. Li, X. Zhao, Properties of concrete incorporating fly ash and ground granulated blast-furnace slag, *Cem. Concr. Compos.* 25 (2003) 293–299. [https://doi.org/10.1016/S0958-9465\(02\)00058-6](https://doi.org/10.1016/S0958-9465(02)00058-6).
- [11] D. Suresh, K. Nagaraju, Ground granulated blast slag (GGBS) in concrete--a review, *IOSR J. Mech. Civ. Eng.* 12 (2015) 76–82.
- [12] M.A. Abd-Elaziz, S. Abd.el.aleem, M. Heikal, Physico-chemical and mechanical characteristics of pozzolanic cement pastes and mortars hydrated at different curing temperatures, *Constr. Build. Mater.* 26 (2012) 310–316. <https://doi.org/10.1016/j.conbuildmat.2011.06.026>.
- [13] E. Ozbay, M. Erdemir, H.I. Durmus, Utilization and efficiency of ground granulated blast furnace slag on concrete properties--A review, *Constr. Build. Mater.* 105 (2016) 423–434.
- [14] H. Bıncı, M.Y. Durgun, T. Rızaoğlu, M. Koluçolak, Investigation of durability properties of concrete pipes incorporating blast furnace slag and ground basaltic pumice as fine aggregates, *Sci. Iran.* 19 (2012) 366–372.
- [15] A. Toghrli, M. Mohammadhassani, M. Suhatri, M. Shariati, Z. Ibrahim, Prediction of shear capacity of channel shear connectors using the ANFIS model, *Steel Compos. Struct.* 17 (2014) 623–639. <https://doi.org/10.12989/scs.2014.17.5.623>.
- [16] E. Douglas, G. Pouskouleli, Prediction of compressive strength of mortars made with portland cement-blast-furnace slag-fly ash blends, *Cem. Concr. Res.* 21 (1991) 523–534.
- [17] W. Gao, M. Karbasi, A.M. Derakhsh, A. Jalili, Development of a novel soft-computing framework for the simulation aims: a case study, *Eng. Comput.* 35 (2019) 315–322.
- [18] J. Singh, A.K. Verma, H. Banka, T.N. Singh, S. Maheshwar, A study of soft computing models for prediction of longitudinal wave velocity, *Arab. J. Geosci.* 9 (2016) 224.
- [19] A. Öztürk, M. Pala, E. Özbay, E. Kanca, N. Caglar, M.A. Bhatti, Predicting the compressive strength and slump of high strength concrete using neural network, *Constr. Build. Mater.* 20 (2006) 769–775.
- [20] M.M. Alshihri, A.M. Azmy, M.S. El-Bisy, Neural networks for predicting compressive strength of structural light weight concrete, *Constr. Build. Mater.* 23 (2009) 2214–2219.

- [21] B.K.R. Prasad, H. Eskandari, B.V.V. Reddy, Prediction of compressive strength of SCC and HPC with high volume fly ash using ANN, *Constr. Build. Mater.* 23 (2009) 117–128.
- [22] F. Khademi, M. Akbari, S.M. Jamal, M. Nikoo, Multiple linear regression, artificial neural network, and fuzzy logic prediction of 28 days compressive strength of concrete, *Front. Struct. Civ. Eng.* 11 (2017) 90–99.
- [23] Z.M. Yaseen, R.C. Deo, A. Hilal, A.M. Abd, L.C. Bueno, S. Salcedo-Sanz, M.L. Nehdi, Predicting compressive strength of lightweight foamed concrete using extreme learning machine model, *Adv. Eng. Softw.* 115 (2018) 112–125.
- [24] A.K. Al-Shamiri, J.H. Kim, T.-F. Yuan, Y.S. Yoon, Modeling the compressive strength of high-strength concrete: An extreme learning approach, *Constr. Build. Mater.* 208 (2019) 204–219.
- [25] I.-J. Han, T.-F. Yuan, J.-Y. Lee, Y.-S. Yoon, J.-H. Kim, Learned Prediction of Compressive Strength of GGBFS Concrete Using Hybrid Artificial Neural Network Models, *Materials (Basel)*. 12 (2019) 3708.
- [26] E.M. Golafshani, A. Behnood, M. Arashpour, Predicting the compressive strength of normal and High-Performance Concretes using ANN and ANFIS hybridized with Grey Wolf Optimizer, *Constr. Build. Mater.* 232 (2020) 117266.
- [27] L. Sun, M. Koopialipour, D.J. Armaghani, R. Tarinejad, M.M. Tahir, Applying a meta-heuristic algorithm to predict and optimize compressive strength of concrete samples, *Eng. Comput.* (2019) 1–13.
- [28] A. Ashrafiyan, F. Shokri, M.J. Taheri Amiri, Z.M. Yaseen, M. Rezaie-Balf, Compressive strength of Foamed Cellular Lightweight Concrete simulation: New development of hybrid artificial intelligence model, *Constr. Build. Mater.* 230 (2020) 117048. <https://doi.org/10.1016/j.conbuildmat.2019.117048>.
- [29] S. Kilic, Linear regression analysis, John Wiley & Sons, 2013. <https://doi.org/10.5455/jmood.20130624120840>.
- [30] Z. Du, Y. Hu, N.A. Buttar, Analysis of mechanical properties for tea stem using grey relational analysis coupled with multiple linear regression, *Sci. Hortic. (Amsterdam)*. 260 (2020) 108886. <https://doi.org/10.1016/j.scienta.2019.108886>.
- [31] T.M.H. Hope, Linear regression, in: *Mach. Learn. Methods Appl. to Brain Disord.*, Elsevier, 2019: pp. 67–81. <https://doi.org/10.1016/B978-0-12-815739-8.00004-3>.
- [32] A.J. Myles, R.N. Feudale, Y. Liu, N.A. Woody, S.D. Brown, An introduction to decision tree modeling, *J. Chemom.* 18 (2004) 275–285. <https://doi.org/10.1002/cem.873>.
- [33] M.R. Segal, Machine Learning Benchmarks and Random Forest Regression, *Biostatistics*. (2004) 1–14. <http://escholarship.org/uc/item/35x3v9t4.pdf>.
- [34] T.M. Cover, P.E. Hart, Nearest Neighbor Pattern Classification, *IEEE Trans. Inf. Theory*. 13 (1967) 21–27. <https://doi.org/10.1109/TIT.1967.1053964>.
- [35] C. Cortes, V. Vapnik, Support vector machine, *Mach. Learn.* 20 (1995) 273–297.
- [36] N. Duffy, D. Helmbold, Boosting methods for regression, *Mach. Learn.* 47 (2002) 153–200. <https://doi.org/10.1023/A:1013685603443>.
- [37] G.A.F. Seber, A.J. Lee, Linear regression analysis, John Wiley & Sons, 2012.
- [38] T.T. Nguyen, H.T. Thai, T. Ngo, Optimised mix design and elastic modulus prediction of ultra-high strength concrete, *Constr. Build. Mater.* 302 (2021) 124150. <https://doi.org/10.1016/j.conbuildmat.2021.124150>.

ÖZGEÇMİŞ

Melike DEMİR

