



# İnşaat Mühendisliğinde Yapay Zeka ile Optimizasyon

Yazılım Mühendisliği Ana Bilim Dalı

Tezsiz Yüksek Lisans Projesi

Ayşe Tuba Tuğrul

Y210240040

Danışman: Prof. Dr. Femin Yalçın Küçükbayrak

Aralık 2022



# İnşaat Mühendisliğinde Yapay Zeka ile Optimizasyon

## ÖZ

Yapay zeka, insan beynine özgü bir takım davranışların makinalar tarafından taklit edilmesi anlamına gelir. Bir çok alanda olduğu gibi inşaat mühendisliğinde yapay zekanın kullanımı oldukça hızlı bir şekilde yaygınlaşmaktadır. Mevcut çalışmalar inşaat mühendisliğinde yapay zekanın kullanımı konusunda umut vadeci bir yönde ilerlemektedir. Bu çalışmanın ikinci bölümünde son yıllarda gerçekleştirilmiş inşaat mühendisliğinde yapay zeka uygulamaları ile ilgili çalışmalar, makina öğrenmesi, derin öğrenme, görüntü işleme, yapay sinir ağları ve bulanık mantık konularına göre ayrı ayrı incelenmiştir. Üçüncü bölümde son yıllarda inşaat mühendisliğinde yapay zeka ile optimizasyon ile ilgili çalışmalar, inşaat mühendisliğinin yapı, geoteknik, ulaştırma, hidrolik-hidroloji ve yapı işletmesi alanlarına göre ayrı ayrı incelenmiştir. Son bölümde konut fiyatlarının tahmini üzerine bir makina öğrenmesi modelinin GridSearchCV algoritması ile optimizasyonu konulu örnek bir çalışma yapılmıştır. Elde edilen modelin konut fiyatlarının tahmini üzerine kullanılabileceği görülmüştür. Bu çalışmanın inşaat mühendisliğinde optimizasyon yöntemleriyle ilgili çalışma yapacak kişilere ışık tutması amaçlanmaktadır.

**Anahtar Sözcükler:** Yapay zeka, optimizasyon, inşaat mühendisliği, makine öğrenmesi, konut fiyat tahmini.

# Optimization by Artificial Intelligence in Civil Engineering

## Abstract

Artificial intelligence means the imitation of some behaviours specific to the human brains by machines. As in many fields, the use of artificial intelligence in construction technology is getting widespread very quickly. Current studies are progressing in a promising way in the use of artificial intelligence in civil engineering. In the second part of this study, studies on artificial intelligence applications in civil engineering, which have been carried out in recent years, are examined separately according to machine learning, deep learning, image processing, artificial neural networks and fuzzy logic. In the third chapter, studies on artificial intelligence and optimization in civil engineering in recent years have been examined separately according to the construction, geotechnical, transportation, hydraulic-hydrology and construction management fields of civil engineering. In the last chapter, a case study on the optimization of a machine learning model on the prediction of housing prices with the GridSearchCV algorithm has been made. It is concluded that the obtained model can be used on the estimation of housing prices. It is aimed that this study will shed light on the people who will work on optimization methods in civil engineering.

**Keywords:** Artificial intelligence, optimization, civil engineering, machine learning, house price prediction

# İçindekiler

Öz.....	ii
Abstract .....	iii
İçindekiler.....	iv
Şekiller Listesi .....	vii
Tablolar Listesi .....	viii
Kısaltmalar Listesi .....	ix
Bölüm 1 Giriş .....	1
Bölüm 2 İnşaat Mühendisliğinde Yapay Zeka Kullanım Alanları.....	2
2.1 Makina Öğrenmesi Uygulamaları .....	2
2.1.1 Çıtırık (2022) – Makine Öğrenmesi ile Konsol Dayanma Duvarı Stabillitesi Konusundaki Çalışması .....	2
2.1.2 Kayhan (2022) – Makina Öğrenmesi ile Otomatik Üretim Teknolojisine Uygun Betonların Basınç Dayanımlarının Tahmini .....	3
2.1.3 Ersoy (2022) – Makine Öğrenmesi ile Aylık Akış Tahminlerinin İyileştirilmesi 5	
2.1.4 Diğer Çalışmalar .....	6
2.2 Derin Öğrenme Uygulamaları.....	8
2.2.1 Gültekin (2022) – Derin Öğrenme ile Betonarme Yapılarda Hasar Tespiti .....	8
2.2.2 Kılınç (2021) – Derin Öğrenme ile Nehir Akımlarının Tahmini .....	8

2.2.3	Diğer Çalışmalar .....	10
2.3	Görüntü İşleme Uygulamaları .....	11
2.3.1	İlgün vd. (2021) - Görüntü İşleme ile Tek Katlı Duvar Deformasyonunun Belirlenmesi .....	11
2.3.2	Diğer Çalışmalar .....	13
2.4	Yapay Sinir Ağları Uygulamaları .....	14
2.4.1	Bahadır (2021) - M5 Karar Ağacı Ve Yapay Sinir Ağları Yöntemleriyle Yeraltı Suyu Seviye Değişiminin Belirlenmesi .....	14
2.4.2	Diğer Çalışmalar .....	18
2.5	Bulanık Mantık Uygulamaları .....	19
2.5.1	Arpacık (2022) - Taşınmaz Kültür Varlıklarının Taşınma Yöntem Ve Hesaplarının Bulanık Mantık Modellemesi Ile Karşılaştırmalı Analizi .....	19
2.5.2	Diğer Çalışmalar .....	20
Bölüm 3 İnşaat Mühendisliğinde Optimizasyon Yöntemleri .....		22
3.1	Yapı Alanında Optimizasyon .....	22
3.2	Geoteknik Alanında Optimizasyon .....	23
3.3	Hidrolik - Hidroloji Alanında Optimizasyon .....	23
3.4	Ulaştırma Alanında Optimizasyon .....	24
3.5	Yapı İşletmesi Alanında Optimizasyon .....	24
Bölüm 4 Konut Fiyatlarının Tahmini Konusunda Örnek Çalışma .....		26
4.1	Ames Housing Veri Seti .....	26
4.2	Hiperparametre Optimizasyonu .....	30
4.3	Bulgular ve Sonuçlar .....	31

Kaynaklar .....	33
Ek A.....	39
Özgeçmiş.....	42

# Şekiller Listesi

Şekil 2.1: Otomatik yapı üretimine uygun taze beton örneği [5].....	4
Şekil 2.2: Çalışmanın algoritması.....	4
Şekil 2.3: Dört ötelemeli senaryoya göre test veri setine ait saçılma grafiği.....	9
Şekil 2.4. Dört ötelemeli senaryoya göre eğitim veri setine ait saçılma grafiği.....	9
Şekil 2.5. Üç ötelemeli senaryoya göre eğitim veri setine ait saçılma grafiği.....	10
Şekil 2.6. Üç ötelemeli senaryoya göre test veri setine ait saçılma grafiği.....	10
Şekil 2.7: Deney numunesinin şematik gösterimi. ....	12
Şekil 2.8: Tek katlı duvar deformasyonuna ait saçılma grafiği.....	13
Şekil 2.9: Yeraltı su seviyesi eğitim verileri için ölçüm ve M5 Karar Ağacı saçılım grafiği. ....	15
Şekil 2.10: Yeraltı su seviyesi test verileri için ölçüm ve M5 Karar Ağacı saçılım grafiği. ....	16
Şekil 2.11: Yeraltı su seviyesi eğitim verileri için ölçüm ve ÇDR saçılım grafiği.....	17
Şekil 2.12: Yeraltı su seviyesi test verileri için ölçüm ve ÇDR saçılım grafiği. ....	17
Şekil 4.1: Satış değeri özniteliğine ait histogram.....	29
Şekil 4.2: Satış değeri özniteliğine ait logaritmik dönüşüm yapılmış histogram.....	30
Şekil 4.3: Hiperparametre optimizasyonu.....	31



# Tablolar Listesi

Tablo 2.1: YASS tahmininde kullanılan model sonuçlarının karşılaştırılması.....	18
Tablo 4.1: Verisetine ait öznitelikler.....	27
Tablo 4.2: En yüksek boş veri oranına sahip 4 adet öznitelikteki boş (null) veri oranı.....	29
Tablo 4.3: Şömine kalitesi verisinde çok iyi ve iyi özellikleri oranı.....	29

# Kısaltmalar Listesi

ANFIS	Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
ANN	Yapay Sinir Ağları
CSA	Karga Arama Optimizasyonu
DL	Derin Öğrenme
DT	Karar Ağaçları
ENN	Evrşimsel Sinir Ağları
FL	Bulanık Mantık
GP	Genetik Programlama
GSP	Gezgin Satıcı Problemi
IP	Görüntü İşleme
KNN	k-En Yakın Komşu
KOKH	Kök Ortalama Kare Hata
KSF	Kalman Smooth Filtreleme
LO	Doğrusal Optimizasyon
MAPE	Ortalama Mutlak Yüzde Hatası
MAE	Ortalama Mutlak Hata
MDAE	Medyan Mutlak Hata
ME	Maksimum Hata
MGD	Ortalama Gama Sapması
ML	Makina Öğrenmesi
MLR	Çoklu Doğrusal Regresyon
MPD	Ortalama Poisson Sapması
MSE	Ortalama Kare Hatası

MSLE	Ortalama Kare Logaritmik Hata
M5T	M5 Karar Ağacı
PSO	Parçacık Sürü Optimizasyonu
RMSE	Ortalama Kare Hata
RF	Rastgele Orman
R2	Determinasyon Katsayısı
SOA	Simbiyotik Organizmalar Arama Optimizasyonu
SVM	Destek Vektör Makinaları
SVR	Destek Vektör Regresyonu
TSA	Ağaç Tohumu Optimizasyon Algoritması
USGS	Amerika Birleşik Devletleri Jeolojik Araştırma Enstitüsü
XGBoost	Aşırı Gradyan Artırma

# Bölüm 1

## Giriş

Yapay zeka, insan beynine özgü bir takım davranışların makinalar tarafından taklit edilmesi anlamına gelir.

Antik Yunanlar, Çinli ve Mısırlı çağ öncesi bilim insanları robotlarla ilgili mitlere sahiptiler [1]. Ancak yapay zeka kavramından ilk defa, 1956 yılında İngiltere'de New Hampshire'da bulunan Dartmouth College'da yapılan bir konferansta bahsedilmiştir. Kesinliği arttırması, daha fazla doğruluk ve daha az hata sağlaması, çalışma verimliliğini arttırması, değerli içgörüler için daha fazla ve daha derin verileri analiz etmesi, çeşitli cihazların yeteneklerine katkıda bulunabilmesi (GPS takip cihazları, sesli asistanlar ve ev otomasyon sistemleri gibi) gibi avantajları ile yapay zeka önümüzdeki yıllarda sistemlerde çok daha fazla yer alacaktır.

Günümüzde yapay zeka kavramı sadece bilimsel çalışmalarda kullanılmamaktadır. Bir çok sektörde bilim insanları yapay zekayı dahil ederek önemli çözüm sistemleri üretmektedirler. Bir çok alanda olduğu gibi inşaat mühendisliğinde yapay zekanın kullanımı oldukça hızlı bir şekilde yaygınlaşmaktadır. İnşaat mühendisliğinde yapay zeka, maliyet aşımının doğrudan önlenmesi, daha iyi tasarımlar, riskin en aza indirilmesi, iş güvenliği, şantiye alanlarının daha verimli hale getirilmesi gibi alanlarda kullanılmaktadır. Mevcut çalışmalar inşaat mühendisliğinde yapay zekanın kullanımı konusunda umut vadeci bir yönde ilerlemektedir.

## Bölüm 2

# İnşaat Mühendisliğinde Yapay Zeka Kullanım Alanları

İnşaat mühendisliğinde en çok kullanılan yapay zeka teknikleri, makina öğrenmesi, yapay sinir ağları, görüntü işleme, bulanık mantık ve derin öğrenme olarak sıralanabilir [2].

Yapay zeka yöntemleri mühendislikte, daha çok optimizasyon için kullanılmakta ve diğer klasik yöntemlere göre daha iyi sonuç verdiği gözlemlenmektedir. [1].

### 2.1 Makina Öğrenmesi Uygulamaları

Bu bölümde inşaat mühendisliğinde makine öğrenmesinin kullanıldığı son yıllarda yapılmış bazı çalışmalar incelenmiştir.

#### 2.1.1 Çıtırık (2022) – Makine Öğrenmesi ile Konsol Dayanma Duvarı Stabilitesi Konusundaki Çalışması

Çıtırık [4], yüksek lisans tez çalışmasında iki zemin kotu arasında oluşan yatay zemin basıncını taşıması için tasarlanan dayanma duvarlarının dış stabilite kontrollerinin ML algoritmaları ile tahmin edilmesini araştırmıştır.

Dış stabilite tahkikleri olarak,

- yanal olarak ötelenmeme
- burun noktasında dönmeme
- duvardan zemine aktarılan yüklerin güvenli şekilde taşınması için taşıma gücü

dikkate alınmıştır. Dayanma duvarının güvenlik sayıları Türkiye Bina Deprem Yönetmeliği'ne göre elde edilmiş ayrıca depremsiz durum için statik yük etkisindeki güvenlik sayıları hesaplanmıştır.

Türkiye'nin farklı 2 konumunda 5 farklı yerel zemin sınıfı (ZA, ZB, ZC, ZD, ZE) olmak üzere 10 farklı tasarım koşulu değerlendirilmiştir. 1024 adet dayanma duvarı modeli dikkate alınmıştır. Duvar verileri eğitim ve test olarak %80 - %20 oranında ayrılmıştır.

Makina öğrenmesi algoritmaları olarak, KNN, RF ve DT algoritmaları güvenlik sayılarının tahmininde kullanılmıştır. Modellerin performansını değerlendirmek için kök ortalama kare hata (RMSE), ortalama kare hatası (MSE), ortalama mutlak yüzde hatası (MAPE), ortalama mutlak hata (MAE), ortalama kare logaritmik hata (MSLE), medyan mutlak hata (MDAE), maksimum hata (ME), ortalama gama sapması (MGD), ortalama poisson sapması (MPD) ve son olarak R2 performans değerlendirme metrikleri olarak kullanılmıştır.

Sonuç olarak DT algoritmasının test ve eğitim seti üzerinde farklı başarı oranı sergilediği hatta eğitim setinde test veri setinden daha başarılı olduğu gözlemlenirken, KNN ve RF algoritmalarının test ve eğitim setleri üzerindeki başarı oranının daha yakın olduğu gözlemlenmiştir.

## 2.1.2 Kayhan (2022) – Makina Öğrenmesi ile Otomatik Üretim Teknolojisine Uygun Betonların Basınç Dayanımlarının Tahmini

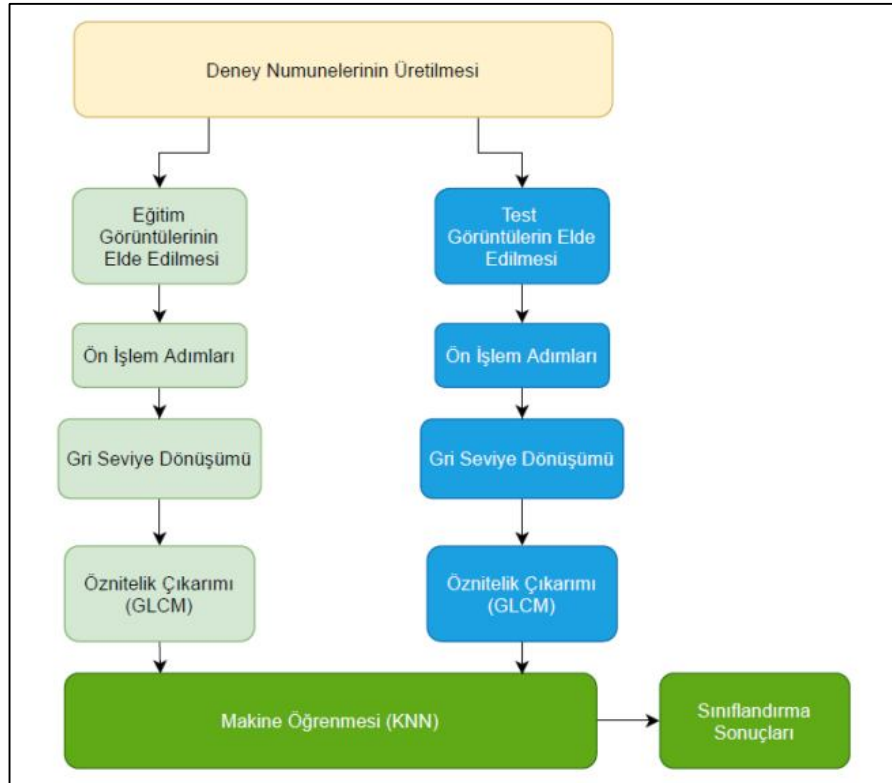
Kayhan [5], yüksek lisans tezinde, otomatik üretim teknolojisine uygun betonların basınç dayanımlarının ML ve DL algoritmaları ile tahmin edilmesi konusunda çalışma yapmıştır.

Çalışma kapsamında, otomatik yapı üretim teknolojisine uygun olan 24 farklı karışım oranına sahip 192 adet küp beton numunesi üretilmiştir. Karışımlarda agrega dane çapı, çimento oranı ve lif değişken olarak kullanılmıştır.



Şekil 2.1: Otomatik yapı üretimine uygun taze beton örneği [5].

Beton numunelerinin görüntü işleme yöntemleri ile basınç dayanımlarını tahmin etmek için görüntüleri alınmıştır. Beton görüntülerinin gri seviye eş oluşum matrisi ve histogram teknikleri kullanılarak öznelikleri çıkartılmıştır. Çalışmanın algoritması Şekil 2.2’de verilmiştir.



Şekil 2.2: Çalışmanın algoritması.

Makina öğrenmesi algoritmaları olarak, KNN, SVM ve geliştirilen bir DL modeli kullanılmıştır.

Sonuç olarak, KNN ve SVM algoritmasının doğruluk oranları sırasıyla %88,44 ve %88,19 olarak gözlemlenmiştir. Önerilen DL algoritmasıyla %90,12 oranıyla en yüksek tahmin başarımına ulaşılmıştır.

### 2.1.3 Ersoy (2022) – Makine Öğrenmesi ile Aylık Akış Tahminlerinin İyileştirilmesi

Yağış-akış modellemesinde en yaygın hibridizasyon uygulaması, ML yaklaşımlarının eğitimi için kavramsal yağış-akış modellerinin belirli çıktılarının kullanılmasına şeklindedir. Bu yöntemde, kavramsal ve ML modellerinin parametre tahminleri arka arkaya gerçekleştirilmektedir. Ancak hem kavramsal hem de ML modellerinin parametreleri arasındaki karşılıklı etkileşimin dikkate alınmaması bu hibritleme yönteminin önemli dezavantajlarından biri olarak değerlendirilmektedir. Ayrıca ardışık kalibrasyonlar, hesap yoğunluğunu aşırı artırabilmektedir.

Ersoy [6] tarafından yapılan bu tez çalışmasında, bahsi geçen dezavantajların üstesinden gelmek için, iki yapay zekâ modeli (ANN ve SVM), toplu bir kavramsal model olan dinamik su bütçesi modeli (dynwbm) ile hibritlenmiştir. Daha sonra önerilen hibrit modellerde tanımlanan tüm potansiyel parametreler eş zamanlı olarak kalibre edilmiştir.

Hibrit parçacık sürü optimizasyon algoritması ile eğitilen bu yeni hibrit modeller Gediz Havzası'nda bulunan dokuz adet akım gözlem istasyonunda denenmiştir. Tez çalışması kapsamında modeller MATLAB ortamında kodlanmıştır.

Sonuç olarak, performans indislerine göre, seri hibrit modeller tekil modellerden ve paralel hibrit tiplerden daha iyi performans sergilemişlerdir. Netice itibari ile kavramsal bir modelin ve makine öğrenimi algoritmalarının öncül özelliklerini harmanlayan yeni bir modelleme yaklaşımının tutarlılığı ve uygulanabilirliği detaylı bir şekilde kanıtlanmıştır. Tez çalışmasında elde edilen bazı tespitler aşağıda listelenmiştir.



- Önerilen seri şema ile işletilen modellerin hem yüksek simülasyon performansı sunmaları hem de standart paralel hibritlemedeki gibi iki ardışık kalibrasyon sürecine ihtiyaç duymamaları avantaj olarak değerlendirilebilir.
- Önerilen seri hibrit modellerin herhangi bir gecikmeli yağış ve akış girdisine ihtiyaç duymamaları (içsel bağımlı yapıda olmamaları) bunları iklim değişikliği senaryoları altında hazne işletme çalışmaları ve hidrolojik projeksiyon hazırlanması gibi uygulamalarda da güvenle kullanılabilir kılmaktadır.
- Seri hibritlemede kavramsal modelin genel yapısının korunması da önemli bir detaydır. Örneğin çalışmada dynwbn modelinin yeraltı suyu depolama elemanları dışındaki birçok kavramsal çıktısı aynı iterasyon adımında yaptırılan iç içe otomatik kalibrasyonun sonucu olarak değişken parametre varyasyonlarına tepki verebilmektedir. Böylelikle kalibrasyon ve doğrulama sonrasında modelin ürettiği zemin nemi içeriği ve gerçek evapotranspirasyon gibi çıktılar (akım bileşenleri hariç) kuraklık analizi vb. uygulamalara girdi niteliği taşıyabilecektir.
- Diğer yandan, önerilen modellerin uygulanabilmesi için kapsamlı bir kodlama ve uzmanlık bilgisine ve kaliteli bir bilgisayar donanımına gereksinim duyulmaktadır.
- Seri hibritlemenin ANN ile yapılması kalibre edilebilir çok fazla serbest parametrenin oluşmasına neden olabilmektedir. Özellikle gizli katmandaki hücre sayısının değişkenliği bu durumu tetiklemektedir. Tez çalışmasında anılan bu aşırı parametrisasyonun azaltılması adına seri şema içinde ANN yerine iki kontrol parametrelili SVR'nin kullanılması uygun bulunmuştur. Fakat bu varyantta da kavramsal modele SVR entegrasyonunun tüm parametreleri aşırı hassas konuma taşıdığı görülmüştür. Bu nedenle bu tarz modellerin eğitimi aşamasında kullanılacak optimizasyon algoritmasının nitelikli olması ve güvenilir parametre tahminleri elde etmek için seçilen algoritmanın birçok kez koşturulması gerekmektedir.

#### 2.1.4 Diğer Çalışmalar

Arama vd. [7] çalışmalarında, ince taneli zeminlerin kıvam sınıfı belirlenmesi için ML ile regresyon analizi yapmışlardır. Bunun için İstanbul'da zemin etüt çalışmalarından

elde edilen 500 örnekli bir veri seti oluşturulmuştur. Veri setindeki zeminler yüksek ve çok yüksek plastik killi örneklerdir. Çalışmada, basit regresyon analizi ile killi topraklardan sadece belirli killerin sıvı limit değerleri dikkate alınarak kıvam özellikleri değerlendirilerek bu zorlukların üstesinden gelinmesi amaçlanmıştır. Çalışma sonucunda elde edilen denklemlerin literatür kaynakları ile karşılaştırıldığında kullanılabilir olduğu görülmüştür.

Arslan vd. [8], Keban Baraj Gölü'ndeki seviye değişimlerinin SVM ve ANFIS yöntemi ile tahmini ile ilgili bir çalışma yapmışlardır. Elde edilen tahmin sonuçları gerçek gözlem sonuçları ile karşılaştırılmıştır. Elde edilen modelin tahminlerde kullanılabileceği sonucuna varılmıştır.

Cao vd. [9], kolon-kiriş birleşimlerdeki momentleri tahmin eden ML modelleri geliştirmişlerdir. Öngörülen tahminin doğruluğu ANN ve Genetik Programlama (GP) ile karşılaştırılmış ve ML algoritmalarının daha iyi performans sağladığı sonucuna varılmıştır.

Gao ve Lin [10], kiriş-kolon birleşimlerinde hasar analizi ile ilgili ML yöntemlerini kullanarak tahmin modeli oluşturmuşlardır. 580 adet test verisi üzerinde gerçekleştirilen çalışmanın sonucuna göre ML algoritmalarından RF ve XGBoost algoritması tahmin modelleri için yüksek doğruluk oranlarına ulaşmıştır. XGBoost doğruluk değeri nispeten daha yüksek elde edilmiştir.

Hwang vd. [11] çalışmasında, çerçeve sistemli sünek betonarme binanın sismik talebi ve göçme tahmini için ML tabanlı çalışma yapmıştır. Çalışmada veri seti olarak Kaliforniya'da oldukça sismik bir bölgede tasarlanmış çerçeve sistemli farklı kat sayısındaki betonarme yapıların analizlerinden elde edilen sonuçlar kullanılmıştır. Elde edilen sonuçlara göre XGBoost algoritması, regresyon tabanlı diğer ML algoritmalarından daha iyi performans göstermiştir.

Khai vd. [12], baraj su seviyelerinin günlük tahmini için ML tabanlı çalışma yapmıştır. Çalışma neticesinde, zaman serisi regresyon tahmin modelinin SVM modelinden daha iyi sonuç verdiği görülmüştür.

## 2.2 Derin Öğrenme Uygulamaları

### 2.2.1 Gültekin (2022) – Derin Öğrenme ile Betonarme Yapılarda Hasar Tespiti

Gültekin [13], yüksek lisans tez çalışmasında hasar tespit çalışmaları sırasında yardımcı olabilecek, kararların doğru ve hızlı şekilde verilmesini sağlayacak bir DL algoritması geliştirmiştir. Derin öğrenme modeli olarak ENN kullanılmıştır.

Son yıllarda ülkemizde meydana gelen İstanbul (Silivri), Elazığ (Sivrice) ve İzmir (Seferihisar) depremleri sonrası yapılan hasar tespit çalışmalarından elde edilen hasar görüntüleri toplanmıştır. Model için kullanılan veri seti ilk olarak bu tez çalışması için toplanmış ve işlenmiştir. Çalışmada verilerin %85'i eğitim, %15'i ise test verisi olarak kullanılmıştır. 1804 kolon hasarı görüntüsünden 1533 tanesi eğitim, 271 tanesi test verisi sınıfına, 3010 kiriş hasarı görüntüsünden 2559 tanesi eğitim, 451 tanesi test verisi sınıfına, 145 perde hasarı görüntüsünden ise 123 tanesi eğitim ve 22 tanesi test verisi sınıfına atanmıştır. Toplam 4721 yapısal olmayan eleman hasarından 4013 tanesi eğitim, 708 tanesi test verisi olarak ayrılmıştır. Özet olarak 9680 görüntüden %85'ine tekabül eden 8228 tanesi modeli eğitmek için, kalan 1452 tanesi modeli test etmek amacıyla kullanılmıştır.

Sonuç olarak geliştirilen yapısal eleman hasarlarını yapısal olmayan eleman hasarlarından ayıran sistemin tahmin başarısı %93,12 olarak elde edilmiştir.


### 2.2.2 Kılınç (2021) – Derin Öğrenme ile Nehir Akımlarının Tahmini

Kılınç [14], bu çalışmada Göksu Nehri üzerindeki Aşağıçöplü köyü, Akdere AGİ'den (akım gözlem istasyonu) elde edilen günlük akım verileri üzerinde, DL modeli oluşturularak, modelin performansının analiz etmiştir.

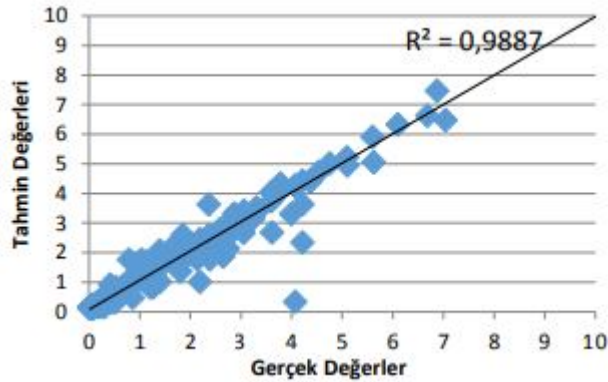
Çalışmada, Göksu Nehri'nin D21A83 No'lu Aşağıçöplü köyü akdere akım gözlem istasyonundan elde edilen 2011-2018 yılları arasındaki akım değerleri veri seti olarak kullanılmıştır.

Tahmin sırasında iki ayrı zaman ötelemesi ile senaryolar geliştirilmiş ve üç ötelemeli ve dört ötelemeli olmak üzere iki ayrı veri seti elde edilmiştir. 3 ötelemeli veri seti 730, 4 ötelemeli veri seti ise 584 veriden oluşmaktadır. Hem 4 ötelemeli senaryoya ait verilerin hem de 3 ötelemeli senaryoya ait verilerin %80'i eğitim için %20'si ise test için kullanılmıştır.


Gerçeğe en yakın değerler en büyük  $R^2$  değerine sahip 4 ötelemeli senaryoya ait sonuçlardır. 4 ötelemeli senaryo için modelden çıkan eğitim ve test sonuçlarına ait  $R^2$  değerleri 0,9850 (Şekil 2.3) ve 0,9887 (Şekil 2.4) iken; 3 ötelemeli senaryo için  $R^2$  değerleri 0,9619 (Şekil 2.5) ve 0,9438 (Şekil 2.6) olarak belirtilmiştir.



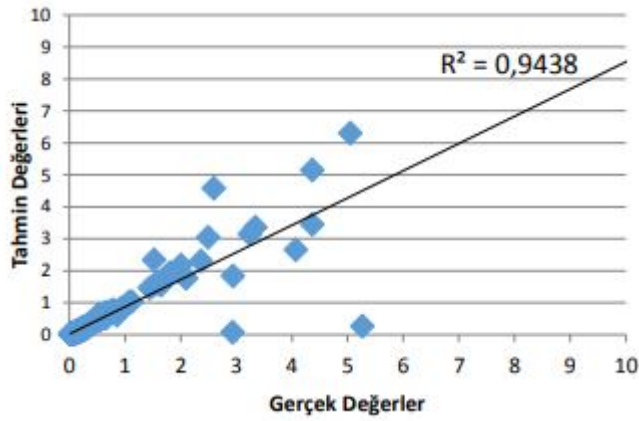
Şekil 2.3: 4 ötelemeli senaryoya göre test veri setine ait saçılma grafiği



Şekil 2.4: 4 ötelemeli senaryoya göre eğitim veri setine ait saçılma grafiği



Şekil 2.5: 3 ötelemeli senaryoya göre eğitim veri setine ait saçılma grafiği



Şekil 2.6: 3 ötelemeli senaryoya göre test veri setine ait saçılma grafiği

Sonuç olarak, sadece akım değerleri kullanılarak tahminde bulunulmuş ve başarılı sonuçlar elde edilmiştir. Yağış, sıcaklık gibi girdi değişkenleri eklenerek farklı senaryolar oluşturulması gelecek çalışmalar için düşünülebilir. Ayrıca tahmin edilen bu akım değerlerinin Göksu nehri yakınlarına kurulması düşünülen potansiyel bir demiryolu hattının projelendirilmesinde yardımcı olacağı düşünülmektedir.

### 2.2.3 Diğer Çalışmalar

Zhang vd. [15], geoteknik alanında DL algoritmalarının uygulanmasına dayalı eleştirel bir çalışma yapmıştır. Yapılan incelemenin sonucunda geoteknik mühendisliği dalında yapılan literatür çalışmalarında DL algoritmalarının trend kazandığı sonucuna varılmıştır.

Çakırođlu ve Süzen [16], inşaat mühendisliğinde DL algoritmalarının kullanılması ile ilgili bir literatür çalışması yapmıştır. Sonuç olarak DL modellerinin inşaat mühendisliği alanında kullanımının pratik ve maliyet açısından avantajlı olduğuna dikkat çekilmiştir.

Mangalathu ve Burton [17], depremden etkilenen binaların DL'ye dayalı bir yöntemle sınıflandırılması üzerine bir çalışma yapmışlardır. Çalışmada veri seti olarak 2014 yılında Kaliforniya depremi sonucu 3423 binada meydana gelen hasarlar kullanılmıştır. Binalar az, orta ve çok hasarlı olmak üzere sırasıyla yeşil, sarı ve kırmızı renklerle etiketlenmiştir. Oluşturulan sınıflandırma modelinin performansı değerlendirilmiş ve %86 tahmin başarısı elde edilmiştir.


Zhong vd. [18] bina kalitesi problemlerinin DL'ye dayalı sınıflandırılması üzerine bir çalışma yapmıştır. Bu çalışma, bina kalitesi şikayetleri ile ilgili toplanmış kısa metinleri otomatik olarak sınıflandırmak için DL yöntemini içeren yeni bir ENN tabanlı yaklaşımı incelemiştir.

## 2.3 Görüntü İşleme Uygulamaları

### 2.3.1 İlgün vd. (2021) - Görüntü İşleme ile Tek Katlı Duvar Deformasyonunun Belirlenmesi

İlgün vd. [19], bu çalışmada basit ve uygulanabilir bir sistem geliştirmişlerdir. Bu çalışmada doğal taşlar ile 20x30x10 cm boyutlarında 9 adet tek katmanlı duvar sisteminde başlangıç kayma deneyi yapılmıştır.

Numuneler EN 1052-3'e uygun olarak ilk kademedede 20x10x10 cm boyutlarında 1 adet, ikinci kademedede 10x10x10 cm boyutlarında 2 adet ve son kademedede 20x10x10 cm boyutlarında 1 adet bireysel taş elemanı olacak şekilde üç kademe olarak kireç harcı ile üretilmiştir. Deney numunesine ait şematik gösterim Şekil 2.7'de yer almaktadır.

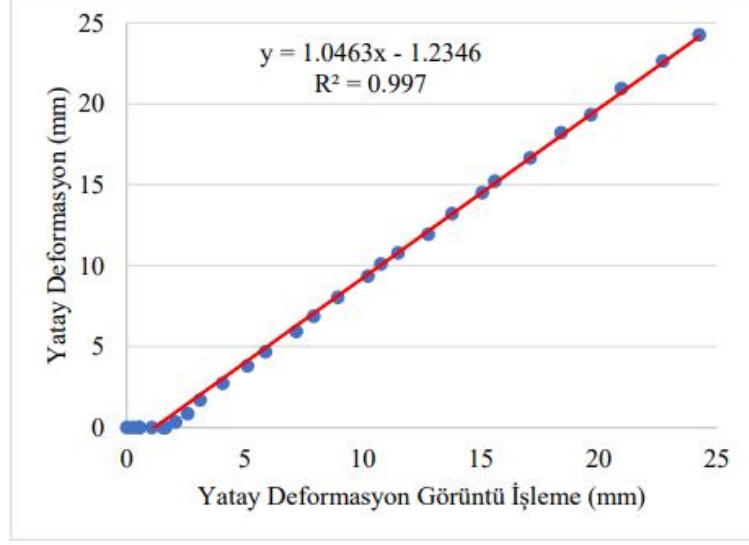


Şekil 2.7: Deney numunesinin şematik gösterimi

Deneyleerde, yük altında duvarlarda oluşan deplasman değerleri potansiyometrik lineer cetveller yardımıyla ölçülmüştür.

Deney esnasında başlangıç durumundan, deneyin sonuçlanmasına kadar belli aralıklarla görüntüler alınmıştır. Bu çalışmada görüntü işleme aşamasında; 64MP, 0.8µm, 1/1.7" CMOS görüntü sensörüne sahip algılayıcı (Redmi Note 8 Pro) ve ArcGIS bilgisayar yazılımı kullanılmıştır. Optik algılayıcı, deney düzeneğinden 1.5 m uzaklıkta deneyin başından sonuna kadar (469.25 saniye) deneyin her aşamasında 2 sn aralıklarla görüntü alınmıştır. Deney sonunda 30 adet 4624x2136 piksel çözünürlüğüne sahip görüntü kullanılmıştır. Duvarda oluşan değişim görüntüleri, ArcGIS programında sayısallaştırılarak dijital verilere dönüştürülmüştür.

Deneysel veriler ile sayısallaştırılan görüntüler üzerinden tespit edilen veriler karşılaştırılmıştır. Bu karşılaştırma sonucunda deneysel değerler ile sayısallaştırılan değerler arasında ortalama %84 benzerlik görülmüştür. Deney sonucunda, 30 adet görüntü üzerinden gerçekleştirilen çalışmanın MAE değerinin 0.580 mm, KOKH değerinin ise 0.810 mm olarak elde edilmiştir. Determinasyon katsayısı ise 0.997 olarak elde edilmiştir. Deneye ait saçılma grafiği Şekil 2.8'de verilmiştir.



Şekil 2.8: Tek katlı duvar deformasyonuna ait saçılma grafiği

Çalışma sonucunda yapılan görüntü sayısallaştırma uygulamasının oldukça başarılı sonuçlar verdiği gözlemlenmektedir. Deneysel ve görüntü işleme tekniği ile elde edilen veriler arasında ortalama %84 benzerlik görülmüştür. Bu yüzden görüntü işleme tekniğinin tek katmanlı doğal taş duvarların davranışının incelenmesinde kullanılabileceği söylenebilir.

### 2.3.2 Diğer Çalışmalar

Bingöl vd. [20], DL yöntemlerini IP yöntemleriyle birlikte kullanarak düzensiz taşıyıcı sistem tespitinde kullanılacak bir düzensizlik kontrol asistanı sistemi yapmışlardır. Sonuç olarak bu asistanın taşıyıcı sistem düzensizlikleri hakkında tutarlı ve doğru yorum yapabildiğine sonucuna varmışlardır.

Doğan vd. [21], IP tabanlı bir yöntemle betonarme kolonların hasar seviyelerinin belirlenmesi üzerinde çalışması yapmıştır. Çalışmada deney olarak, depreme benzeştirilen yüklemeler ile kolonlarda hasarlar oluşturulmuştur. Bu şekilde toplam 390 adet görüntü elde edilmiştir. Veri setinin IP tabanlı yöntemlerle değerlendirilmesi ile kolon hasar performans değerleri açısından %64-80 arasında değişen tahmin başarısı ile elde edilmiştir.

Kaçın ve Aydın [22], betonarme kirişlerde deplasman değerlerinin IP yöntemleri ile belirlenmesi üzerine çalışmıştır. Elde edilen görsel verileri, deney sırasında deplasman



ölçerler tarafından ölçülen değerler ile karşılaştırılmıştır. Neticede elde edilen sonuçların birbirine çok yakın olduğu tespit edilmiştir.

Pekgöz [23], çalışmasında betonda gerilme-şekil değiştirme davranışını IP ile incelemiştir. Görüntüler bilgisayar ortamında değerlendirilerek, maksimum gerilmelerde betonda meydana gelen deformasyonlar ve çatlaklar belirlenmiştir. Betonda oluşan şekil değiştirmelerinin IP yöntemi ile başarıyla belirlenebildiği sonucuna varılmıştır.

Avcı [24], çalışmasında sarsma tablası deneyi ve sayısal analizlerden elde edilen dinamik parametrelerin IP tekniği ile karşılaştırılması üzerine çalışmıştır. Çalışmada üç boyutlu çelik bir çerçeve model olarak alınmıştır. Çerçevenin hem sarsma tablasında deneyleri yapılmış hem de Abaqus programı yardımıyla modellenip deprem etkisinde nasıl davranacağı hakkında bir analiz yapılmıştır. IP yöntemiyle elde edilen sonuçlar ile Abaqus'ten elde edilen sonuçlar karşılaştırılmıştır. Sonuçların birbiri ile tutarlı oldukları sonucuna varılmıştır.

## 2.4 Yapay Sinir Ağları Uygulamaları


### 2.4.1 Bahadırlı (2021) - M5 Karar Ağacı Ve Yapay Sinir Ağları Yöntemleriyle Yeraltı Suyu Seviye Değişiminin Belirlenmesi

Bahadırlı [25] yüksek lisans tez çalışmasında, yeraltı suyunun davranışını bağımlı değişken olarak yeraltı suyu seviyesi ve bağımsız değişkenler olarak yağış, sıcaklık ve önceki günkü yeraltı suyu seviyesini kullandığı bir stokastik modelle araştırmıştır.

Yeraltı suyu seviyesinin yüksek olduğu Amerika Birleşik Devletleri Minnesota şehrinde Prairie Adası yakınlarındaki bir gözlem kuyusu istasyonu seçilmiştir. 2025 günlük yağış, sıcaklık ve önceki günkü yeraltı suyu seviyesi bilgilerini içeren bu veriler, Amerika Birleşik Devletleri Jeolojik Araştırma Kurumundan (USGS) alınmıştır.


Model olarak, Yapay Sinir Ağları (ANN), Çoklu Doğrusal Regresyon (MLR) ve M5 Karar Ağacı (M5T), yeni yeraltı su seviyesi değerlerinin tahmini için eğitilmiştir.

Yeraltı su seviyesi tahmininde MT5 modeli için girdi katmanı nodları olarak, USGS'den elde edilen önceki geçmiş günlük yeraltı su seviyesi, sıcaklık ve yağış verileri kullanılmıştır. İlk aşama olarak eğitim için 2006-2012 yılları arasında USGS'den alınan 1419 günlük önceki gün yeraltı suyu seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmıştır. Çıkan sonuçlar, Şekil 2.9'da saçılım grafiği şeklinde gösterilmiştir. M5T modelinin determinasyon katsayısının  $R^2 = 0,9943$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.



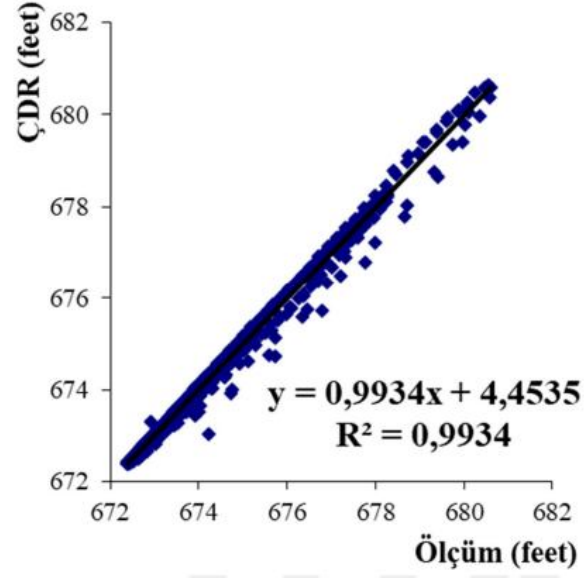
Şekil 2.9: Yeraltı su seviyesi eğitim verileri için ölçüm ve M5 Karar Ağacı saçılım grafiği

Eğitim verilerinin analizi ile elde edilen M5T modeli, geriye kalan diğer 606 günlük önceki günkü yeraltı su seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve test edilmiştir. Test sonuçlarının saçılım grafiği aşağıdaki Şekil 2.10'da gösterilmiştir. M5T modelinin determinasyon katsayısının  $R^2 = 0,9901$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.



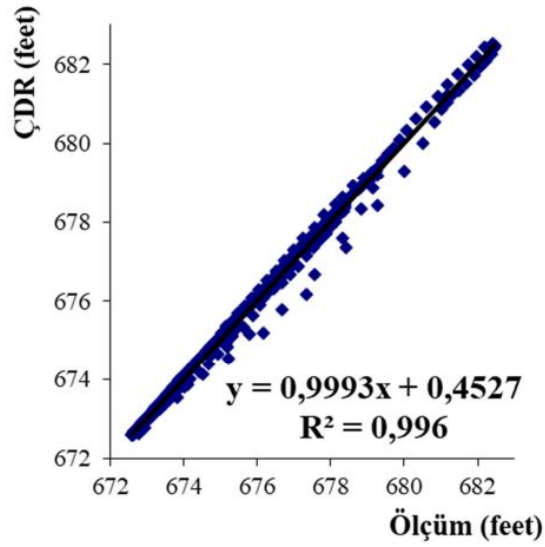
Şekil 2.10: Yeraltı su seviyesi test verileri için ölçüm ve M5 Karar Ağacı saçılım grafiği

Yeraltı su seviyesi tahmininde MLR modeli için girdi katmanı nodları olarak, USGS'den elde edilen önceki geçmiş günlük yeraltı su seviyesi, sıcaklık ve yağış verileri alınmıştır. İlk aşama olarak eğitim için 2006-2012 yılları arasında USGS'den alınan 1419 günlük önceki gün yeraltı suyu seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve MLR modelinde uygulanmıştır. Çıkan sonuçlar Şekil 2.11'de saçılım grafiği şeklinde gösterilmiştir. M5T modelinin determinasyon katsayısının  $R^2 = 0,9934$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.



Şekil 2.11: Yeraltı su seviyesi eğitim verileri için ölçüm ve ÇDR saçılım grafiği

Eğitim verilerinin analizi ile elde edilen MLR modeli, geriye kalan diğer 606 günlük önceki günlük yeraltı su seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve test edilmiştir. Test sonuçlarının saçılım grafiği aşağıdaki Şekil 2.12’de gösterilmiştir.



Şekil 2.12: Yeraltı su seviyesi test verileri için ölçüm ve ÇDR saçılım grafiği

Tablo 2.1: YASS tahmininde kullanılan model sonuçlarının karşılaştırılması

MODELLER	GİRDİ	KOKH(m)	OMH(m)	R <sup>2</sup>
M5T	Y(t), S(t), YASS(t-1)	0,38	0,22	0,990
YSA	Y(t), S(t), YASS(t-1)	0,29	0,17	0,992
ÇDR	Y(t), S(t), YASS(t-1)	0,21	0,11	0,996

**KOKH:** Kök Ortalama Kare Hata, **OMH:** Ortalama Mutlak Hata, **R<sup>2</sup>:** Determinasyon Katsayısı.

**Y(t):** Günlük Ortalama Yağış, **S(t):** Günlük Ortalama Sıcaklık, **YASS(t-1):** Önceki günkü Günlük Ortalama Yeraltı Suyu Seviyesi

Modellerin tahmin sonuçları Determinasyon Katsayısı (R<sup>2</sup>), ortalama mutlak hata (OMH) ve kök ortalama kare hata (KOKH) kriterlerine göre karşılaştırılmıştır (Tablo 2.1). Bu karşılaştırmaya göre tüm modeller birbirine yakın sonuçlar göstermiş ve yeraltısuyu seviye tahmininde başarılı olmuştur. Bu gözlem istasyonu için oluşturulacak olan modeller, Minnesota’da yeraltı suyunun takip edilmesi ve kontrol altına alınması, gelecekteki olası değişimlerinin izlenmesi açısından ve oluşabilecek sorunlara önlem alma konusunda faydalı olacağı düşünülmektedir.

## 2.4.2 Diğer Çalışmalar

Acar ve Saplıoğlu [26], akarsulardaki sediment taşınımının ANFIS ve ANN yöntemleri kullanılarak tespiti üzerine çalışma yapmışlardır. Fırat havzası üzerinde bulunan Murat nehri, Göynük çayı ve Peri suyu nehirler üzerinde sediment taşınımı üzerine araştırma yapılmıştır. Çalışmaya ait veri setinde yağış, sıcaklık, sediment ve debi verileri bulunmaktadır. Regresyon katsayısı sonuçları karşılaştırıldığında en başarılı sonuç ANN modelinden elde edilmiştir. Ortalama yüzde hata değeri açısından iki model yakın sonuçlar vermiştir.

Cansız vd. [27], yapay zekâ ve regresyon yöntemleri ile karayolları enerji tüketiminin modellenmesi üzerine çalışmıştır. Çalışma kapsamında ANN, ANFIS ve MLR yöntemleri kullanılmıştır. En iyi sonuç MLR yönteminden elde edilen tahminlerden elde edilmiştir.

Marangu [28], ANN ve SVM kullanarak kil esaslı çimento harçlarının basınç dayanımı tahmini üzerine bir çalışma yapmıştır. Kil esaslı çimento ve Portland çimentosunun belirli oranlarda karıştırılmasıyla elde edilen numunelerin basınç dayanım tahminlerine göre ANN'nin daha başarılı olduğu gözlemlenmiştir.

Moayed vd. [29], geoteknik alanında ANN kullanımını üzerine bir derleme çalışması yapmışlardır. ANN'nin, karmaşık geoteknik problemlerinde güvenilir bir araç olduğu ve kullanıcı dostu özelliği ile zaman tasarrufu sağladığı sonuçlarına varılmıştır.

Sağlam [30] çalışmasında, farklı malzemeler kullanılarak üretilen hafif betonların karışım tasarımlarının belirlenmesinde 4 farklı ANN modelini kullanmıştır. ANN'den elde edilen sonuçlar ile literatürdeki deneysel çalışmalardan elde edilen sonuçlar karşılaştırılmıştır. Sonuç olarak geliştirilen yöntemin hafif beton karışımlarında kullanılabilir pratik bir yöntem olduğu sonucuna varılmıştır.

## 2.5 Bulanık Mantık Uygulamaları

### 2.5.1 Arpacık (2022) - Taşınmaz Kültür Varlıklarının Taşınma Yöntem Ve Hesaplarının Bulanık Mantık Modellemesi İle Karşılaştırmalı Analizi

Arpacık [31] bu çalışmada, taşınmaz kültür varlıklarının yeni bir konuma taşınması, taşınmış yapılar üzerinden mevcut veriler kullanılarak bulanık mantık metodu yöntemiyle değerlendirilmiştir. Örnek bir alanda bulunan bir yapı üzerinden taşınmada dikkat edilmesi gereken genel sonuç olarak ortaya konulmuştur.

Batman'ın Ilisu barajı inşaatı sebebiyle sular altında kalmaması için Hasankeyf bölgesinde bulunan ve yeni Arkeopark alanına bütüncül olarak tek parça halinde taşınan yapılar incelenmiştir. Taşıma projelerinin karmaşık yapısı ve her yapının kendine özgü problemlere sahip olması gibi sebeplerle, uygun yöntemlerin belirlenmesinde rehber kurallara ihtiyaç duyulmaktadır. Taşıma projelerinin yapısal ve durumsal özelliklerinin kavramsal tanımları üzerinden bulanık mantık yöntemiyle kural şemaları yazılmıştır.

Tanımlanan deęişkenler MATLAB programında bulunan Fuzzy Logic Toolbox yardımıyla analiz edilmiştir. Hasankeyf'te 2017 yılında taşınan Zeynel Bey Türbesi'nin taşıma projesinin risk analizi yapılmıştır. Analizler sonucunda elde edilen çıktı deęerleri sayısal ve grafiksel olarak ifade edilmiş ve yapıya ait genel sonuçlar mevcutta uygulanan süreçle kıyaslanmıştır.

Sonuç olarak, taşınmaz kültür varlıklarının taşınmasının, bulanık mantık gibi yapay zekâ modelleri kullanılarak risk analizlerinin çok kısa bir sürede yapılabildięi gösterilmiştir. Elde edilen rehber tanımlar ileride taşınacak tarihi nitelikteki yapıların taşıma projelerine ışık tutacaktır.

## 2.5.2 Dięer Çalışmalar

Mohanaselvi ve Hemapriya [32], deprem hasar tahminlerini amacıyla bir FL yöntemi üzerinde çalışmışlardır. Çalışmada kullanılan bina örnekleri düşük, orta ve yüksek olmak üzere hasar seviyelerine göre üç gruba ayrılmıştır. FL yönteminin binaların hasar derecesinin tahmininde oldukça yüksek oranda başarı sağladığı sonucuna varılmıştır.

Özdülkar vd. [33], günlük buharlaşma miktarını tahmin etmek için FL yöntemini kullanmıştır. Çalışmada USGS'ten alınan 2008-2012 yılları arasında elde edilmiş buharlaşma miktarı verileri kullanılmıştır. Çalışmada kullanılan Mamdani-Bulanık Mantık (M-BM) ve Sugeno-Bulanık Mantık(S-BM) tabanlı yöntemlerden en yüksek başarı S-BM yönteminden elde edilmiştir.





## Bölüm 3

# İnşaat Mühendisliğinde Optimizasyon Yöntemleri

İnşaat mühendisliğinde yapay zeka ile optimizasyon, çok farklı alanlarda kullanılmaktadır. Bu bölümde bazı inşaat mühendisliğinde yapay zeka ile optimizasyon çalışmaları, yapı, geoteknik, hidrolik – hidroloji, ulaştırma ve yapı işletmesi alanlarına göre incelenmiştir.

### 3.1 Yapı Alanında Optimizasyon

Abed [34], güncel metasezgisel optimizasyon algoritmaların çelik yapıların optimum boyutlandırılması problemindeki performanslarının incelenmesi konulu tez çalışmasında, son yıllarda geliştirilen metasezgisel yöntem olan ağaç tohumu optimizasyon (TSA) yöntemi, karga arama optimizasyon (CSA) yöntemi ve simbiyotik organizmalar arama optimizasyon (SOA) yönteminin sinüs boşluklu kiriş ve kafes sistemlere uygulanması yapılmıştır.

Sinüs boşluklu kirişin optimizasyonunda sınır koşulları olarak Eurocode'da belirtilen kapasite ve tasarım esasları dikkate alınmıştır. Kiriş tasarımı için profil tablosundan seçilecek kesit ve sinüs boşluklu kirişin boşluk geometrik boyutları tasarım değişkenleri olarak alınmıştır.

Kafes sistemin optimizasyonunda sızır koşulları olarak Amerikan yönetmeliği (ASD-89) dikkate alınmıştır. Tasarım değişkenleri olarak ise boru kesit profil tablosundan seçilecek profil olarak belirlenmiştir.

TSA, CSA ve SOA optimizasyon yöntemleri ile 2 adet sinüs boşluklu giriş ve iki adet uzay kafes sistemin ağırlık optimizasyonu yapıp bunların problemlerde verdikleri sonuçlara göre performansları tartışılmıştır.

## 3.2 Geoteknik Alanında Optimizasyon

Ataş [35], ince daneli zeminlerin jet grout tekniği ile zemin iyileştirmesinin yapılabilişirliğinin optimizasyonu konulu çalışmasında, jet grout imalatı ve jet grout zemin iyileştirme metoduyla ilgili literatür derlemesinin yanında, uygulanabilirliği, üretim sürecinin maliyet ve saat verileri ortaya konulmuştur. Çalışmalar iki aşamadan oluşmaktadır. İlk olarak Afyonkarahisar ilinde yapılan konut projesine ait zemin ıslahı ile imalat öncesi ve sonrası zemin değerleri karşılaştırılmış ve maliyet analizi yapılmıştır. İkinci aşamada ise Afyonkarahisar ilinde yapılmış olan jet grout projesinin kazık taşıma kapasitesi sabit bırakılarak, kazık çapı, kazık boyu ve uygulanan jet grout yöntemi değiştirilerek yapılacak olan jet kolon imalatının optimum değerleri hesaplanmıştır.

Kalemci vd. [36], düşük ağırlığa sahip, tabanında dış kesit bulunan betonarme bir konsol istinat duvarı tasarımı optimizasyonu konusunda bir çalışma yapmışlardır. Optimizasyon amacıyla Rao\_1 algoritması kullanılmıştır. Problemi tanımlamak için 12 tasarım değişkeni ve 26 kısıt kullanılmıştır. Duvarın kayma, dönme ve temel taşıma gücüne karşı güvenlik katsayıları sınır koşulları olarak kullanılmıştır. İç stabilite kontrollerinde ACI 318-05 standardı göz önüne alınmıştır. Tasarım, taban plağı dişli ve dişsiz konsol istinat duvarları olan iki ayrı sayısal örnekle desteklenmiştir.

## 3.3 Hidrolik - Hidroloji Alanında Optimizasyon

Alkan [37] optimizasyon teknikleri kullanılarak kuraklık hibrit tahmin modeli adlı çalışmasında Seyhan-Ceyhan Havzalarının 1989-2020 yılları arasında 14 meteoroloji istasyonu verileriyle 3, 4, 6 ve 12 aylık periyotlarda standartlaştırılmış yağış indeksi (SYİ) ve standartlaştırılmış yağış evapotranspirasyon indeksi (SYEİ) ile kuraklık analizleri yapmıştır.

Genetik algoritma kullanılarak SYİ deęerleri hesap edilerek kuraklık tahmin modeli oluřturulmuřtur. Sonra, farklı eęitim, test ve doęrulama oranlar kullanılarak SYİ ve SYEİ tabanlı ANN, RF ve SVM algoritmaları kullanılarak kuraklık tahminleri yapılmıřtır. SYEİ temelli kuraklık tahmininde ayırık dalgacık dnřm (ADD) ve kalman smooth filtreleme (KSF) n iřleme teknikleri kullanılarak ANN, XGBoost, SVM, RF ve KNN algoritmaları ile de beř farklı hibrit model oluřturulmuřtur.

alıřmanın sonucunda, SVM ve XGBoost hibrit modellerinin dięer n iřleme ve filtreleme teknikleriyle oluřturulan hibrit modellere gre daha iyi performans gstermiř oldukları sonucu elde edilmiřtir.

### 3.4 Ulařtırma Alanında Optimizasyon

Gndoędu [38] yk tařımacılıęında optimizasyon tekniklerinin karřılařtırılması adlı tez alıřmasında, tařımacılık maliyetlerinin dřrlmesi amacı ile lkemizdeki 81 Őehirdeki Organize Sanayi Blgeleri (OSB) arasında karayolu tařımacılıęının optimum mesafe deęeri hesaplanması zerinde alıřmıřtır.

Yapılan alıřmada Gezgin Satıcı Problemi (GSP) baz alınarak Genetik Algoritma (GA), Lineer Optimizasyon (LO) ve Paracıklı Sr Optimizasyon (PSO) yntemleri kullanılmaktadır.

LO ile yapılan analizler sonucunda elde edilen optimum mesafe deęeri 9923 km olarak hesaplanmaktadır. GA ile yapılan analizler sonucunda elde edilen optimum mesafe deęeri 10689 km olarak hesaplanmaktadır. PSO ile yapılan analizler sonucunda elde edilen optimum mesafe deęeri 11313 km olarak hesaplanmaktadır. LO, PSO ve GA yntemleri sonucu elde edilen deęerler birbirleri ile kıyaslandığında, Lineer Optimizasyonun genel anlamda daha iyi sonu verdięi sonucuna varılmıřtır.

### 3.5 Yapı İřletmesi Alanında Optimizasyon

Noori [39] meta-sezgisel algoritmalar ile sre maliyet-kalite dnleřim problemlerinin optimizasyonu konulu tez alıřmasında, inřaat projelerindeki sre- maliyet- kalite dnleřim problemine en yakın zm elde etmek iin guguk kuřu arama algoritması kullanılmıřtır. Guguk kuřu arama algoritması ile en iyi ya da en yakın sonuları en

kısa sürede elde etmek amaçlanmıştır. Sonuçlar tez hedeflerine ulaşıldığını göstermektedir. Tez çalışması sonuçlarında elde edilen çözümler diğer algoritma çözümleriyle karşılaştırılmıştır.

## Bölüm 4

# Konut Fiyatlarının Tahmini Konusunda Örnek Çalışma

Konutlar her ne kadar insanların barınma sorununa karşın ortaya çıkmış bir ihtiyaç ve tüketim malı gibi görünse de aynı zamanda bir yatırım aracı olarak da görülmektedir. Bu sebeple konutlar sadece sosyal bir ihtiyaç olmayıp, aynı zamanda ekonomik, kültürel, hukuksal ve teknolojik boyutları da olan bir üründür. Konut fiyatlarının tahmini konusunda geliştirilecek bir model birçok sektörde kullanılabileceği gibi bireylerin kullanımı konusunda da fayda sağlayabilir.

Bu proje kapsamında konut fiyatlarının tahmini konusunda Python programlama dili ile bir tahmin modeli ve optimizasyon çalışması yapılmıştır. Modelin oluşturulmasında Kaggle internet sitesinden elde edilen konut fiyat tahmini amacıyla oluşturulmuş 2919 örnekle bir veri seti kullanılmıştır [40]. Tahmin modeli için XGBoost'a ait XGBRegressor algoritması, optimizasyon için ScikitLearn'e ait GridSearchCV algoritması kullanılmıştır. XGBoost, C++, Java, Python, R, Julia, Perl ve Scala için düzenli bir gradyan artırma çerçevesi sağlayan açık kaynaklı bir yazılım kitaplığıdır. Sonuç olarak ortalama mutlak hata değeri hesaplanmış, model değerlendirilmesi yapılmıştır.

### 4.1 Ames Housing Veri Seti

Bu çalışmada kullanılan veri seti, Kaggle websitesinden elde edilmiştir [40]. Ames Housing veri seti ABD Ames Iowa'daki 2919 adet konut örneğini 79 adet öznitelikle tanımlamaktadır. Bu veri seti, veri bilimi eğitiminde kullanılmak üzere Dean De Cock tarafından derlenmiştir. Sıklıkla alıntılanan Boston Housing veri setinin modernize edilmiş ve genişletilmiş bir versiyonunu arayan veri bilimciler için bir alternatiftir.

Tablo 4.1: Verisetine ait öznitelikler

Öznitelik Adı	Açıklaması
SalePrice	Mülkün dolar cinsinden satış fiyatı. Bu, tahmin etmeye çalıştığımız hedef değişkendir.
MSSubClass	Bina sınıfı
MSZoning	Genel imar sınıflandırması
LotFrontage	Mülke cadde tarafından cephe uzunluğu
LotArea	Metrekare cinsinden arsa büyüklüğü
Street	Yol erişim türü
Alley	Patika erişim türü
LotShape	Mülkün genel şekli
LandContour	Mülkün düzlüğü
Utilities	Mevcut yardımcı özellikler
LotConfig	Arsa yapılanması
LandSlope	Arsanın eğimi
Neighborhood	Ames şehir sınırları içindeki fiziksel konum
Condition1	Ana yola veya demiryoluna yakınlık
Condition2	Ana yola veya demiryoluna yakınlık (saniye)
BldgType	Konut tipi
OverallQual	Genel malzeme ve kaplama kalitesi
OverallCond	Genel durum
YearBuilt	Orijinal yapım tarihi
YearRemodAdd	Yenileme tarihi
RoofStyle	Çatı tipi
RoofMatl	Çatı malzemesi
Exterior1st	Evin dış kaplaması
Exterior2nd	Evin dış kaplaması (birden fazla malzeme varsa)
MasVnrType	Duvar kaplama tipi
MasVnrArea	Metrekare cinsinden duvar kaplama alanı
ExterQual	Dış malzeme kalitesi
ExterCond	Dış yüzeydeki malzemenin mevcut durumu
Foundation	Temel türü
BsmtQual	Bodrum yüksekliği
BsmtCond	Bodrumun genel durumu
BsmtExposure	Yürüyüş veya bahçe seviyesindeki bodrum duvarları
BsmtFinType1	Bodrum bitmiş alanının kalitesi
BsmtFinSF1	Tip 1 bitmiş fit kare
BsmtFinType2	İkinci bitmiş alanın kalitesi (varsa)
BsmtFinSF2	Tip 2 bitmiş fit kare
BsmtUnfSF	Bodrum alanının bitmemiş metrekaresi
TotalBsmtSF	Bodrum alanının toplam fit karesi
Heating	Isıtma tipi
HeatingQC	Isıtma kalitesi ve durumu
CentralAir	Merkezi klima
Electrical	Elektrik sistemi
1stFlrSF	Birinci Kat fit kare
2ndFlrSF	İkinci kat metrekare

Tablo 4.1 (devamı): Verisetine ait öznitelikler

LowQualFinSF	Düşük kaliteli bitmiş fit kare (tüm katlar)
GrLivArea	Zemin üstü yaşam alanı fit kare
BsmtFullBath	Bodrumdaki tam banyolar
BsmtHalfBath	Bodrumdaki yarım banyolar
FullBath	Seviye üzerinde eksiksiz banyolar
HalfBath	Seviye üzerinde yarım banyo
Bedroom	Bodrum seviyesinin üzerindeki yatak odası sayısı
Kitchen	Mutfak sayısı
KitchenQual	Mutfak kalitesi
TotRmsAbvGrd	Seviye üzerindeki toplam oda sayısı (banyoları içermez)
Functional	Ev işlevsellik derecesi
Fireplaces	Şömine sayısı
FireplaceQu	Şömine kalitesi
GarageType	Garaj konumu
GarageYrBlt	Garajın inşa edildiği yıl
GarageFinish	Garajın iç kaplaması
GarageCars	Araç kapasitesi olarak garajın boyutu
GarageArea	Garajın fit kare cinsinden boyutu
GarageQual	Garaj kalitesi
GarageCond	Garaj durumu
PavedDrive	Asfaltlanmış araba yolu
WoodDeckSF	Fitkare olarak ahşap güverte alanı
OpenPorchSF	Fitkare cinsinden açık sundurma alanı
EnclosedPorch	Metrekare cinsinden kapalı sundurma alanı
3SsnPorch	Metrekare cinsinden üç bölmeli sundurma alanı
ScreenPorch	Metrekare cinsinden düz sundurma alanı
PoolArea	Metrekare cinsinden havuz alanı
PoolQC	Havuz kalitesi
Fence	Çit kalitesi
MiscFeature	Diğer kategorilerde yer almayan çeşitli özellikler
MiscVal	Çeşitli özelliğin dolar cinsinden değeri
MoSold	Satış ayı
YrSold	Satış yılı
SaleType	Satış türü
SaleCondition	Satış durumu

En yüksek boş veri oranına sahip 4 adet öznitelikteki boş (null) veri oranı %80 üzerindedir (Tablo 4.2). Bu 4 öznitelik anlamsız veri olarak değerlendirilebilir. Şömine kalitesi verisinde çok iyi ve iyi özellikleri çok baskındır. Dolayısıyla bu veri de kullanılmayabilir. (Tablo 4.3).

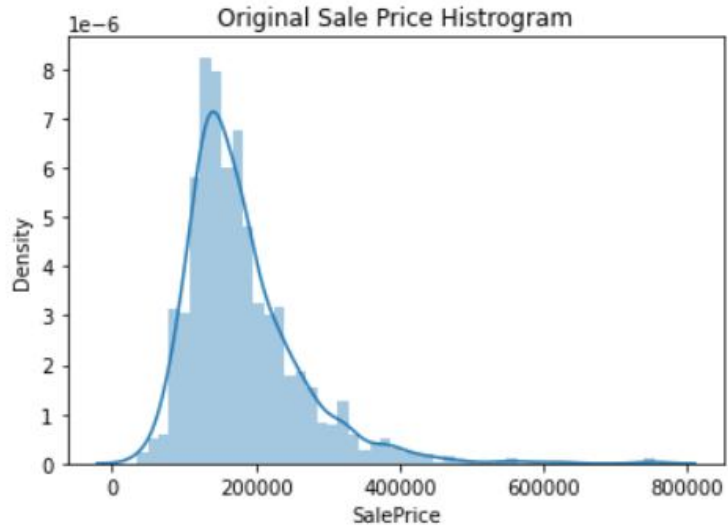
Tablo 4.2: En yüksek boş veri oranına sahip 4 adet öznitelikteki boş (null) veri oranı

Özellikler	Tanım	Boş Sayısı	Yüzde
PoolQC	Havuz Kalitesi	1453	99.52%
MiscFeature	Diğer Kategorilerde Tanımlanmayan Özellikler	1406	96.30%
Alley	Patika Ulaşım Şekli	1369	93.77%
Fence	Çit Kalitesi	1179	80.75%
FirePlaceQu	Şömine Kalitesi	690	47.26%

Tablo 4.3: Şömine kalitesi verisinde çok iyi ve iyi özellikleri oranı


Veri	Tanım	Sayı
Ex	Çok iyi – harici duvardan şömine	380
Gd	İyi – temel ölçüde duvar şömine	1406

Satış değeri özniteliğine ait histogram Şekil 4.1’de verilmiştir. Satış değeri özniteliğine ait logaritmik dönüşüm yapılmış histogram Şekil 4.2’de verilmiştir.



Şekil 4.1: Satış değeri özniteliğine ait histogram






Şekil 4.2: Satış değeri özneliğine ait logaritmik dönüşüm yapılmış histogram

## 4.2 Hiperparametre Optimizasyonu

Makine öğrenmesi algoritmalarında onlarca hiperparametre ve bu hiperparametrelerin alabileceği onlarca değer olduğu göz önüne alındığında, tüm kombinasyonları deneyip en iyi kombinasyonu seçmek oldukça zor olacaktır [42]. Bu sebeple hiperparametre optimizasyonu için farklı yöntemler geliştirilmiştir. Hiperparametre optimizasyonu, bir makine öğrenmesi algoritması için belirlenen metriğe göre en uygun hiperparametre kombinasyonunu bulmak anlamına gelir. Hiperparametre optimizasyonu ile model karmaşıklığı dengelenerek overfitting ve underfitting dengesi sağlanabilir. Yine modelin esnekliğinden kaynaklanan aşırı öğrenme problemi hiperparametreler ile getirilen kısıtlamalarla çözülebilir (Şekil 4.3) [42].



Şekil 4.3: Hiperparametre optimizasyonu

Projede uygulanan optimizasyon, Python kütüphanelerinden Scikitlearn'e ait GridSearchCV algoritması ile gerçekleştirilmiştir [41]. GridSearchCV algoritması, çapraz doğrulama temeline dayalı bir arama algoritmasıdır. Modelde denenmesi istenen hiperparametreler ve değerleri için bütün kombinasyonlar ile ayrı ayrı model kurulur ve belirtilen metriğe göre en başarılı hiperparametre seti belirlenir. Tüm kombinasyonları denendiği için en iyi performans gösteren hiperparametre setini belirlemeyi garanti eder. Küçük veri setlerinde ve sadece birkaç tane hiperparametre denenmek istendiğinde çok iyi çalışır. GridSearchCV algoritmasına ait Python kodu Eşitlik 4.1'de verilmiştir.

```
class sklearn.model_selection.GridSearchCV(estimator, param_grid, *, scoring=None,
n_jobs=None, refit=True, cv=None, verbose=0, pre_dispatch='2*n_jobs', error_score=nan,
return_train_score=False) (Eşitlik 4.1)
```

### 4.3 Bulgular ve Sonuçlar

Yapay zeka teknolojilerinin her alanda ilerlediği günümüzde, bir yatırım aracı olarak konutların fiyat tahmininde yapay zeka tabanlı sistemlerin yaygınlaşacağı öngörülebilir. Kesinliği arttırması, daha fazla doğruluk ve daha az hata sağlaması, çalışma verimliliğini arttırması, değerli içgörüler için daha fazla ve daha derin verileri analiz etmesi, çeşitli cihazların yeteneklerine katkıda bulunabilmesi (GPS takip

cihazları, sesli asistanlar ve ev otomasyon sistemleri gibi) gibi avantajları ile yapay zeka önümüzdeki yıllarda sistemlerde çok daha fazla yer alacaktır.

Bu çalışmada ABD, Ames, Iowa'daki 2919 adet konut örneğini barındıran bir veri seti kullanılarak bir tahminleyici modeli oluşturulmuştur. Modelin oluşturulması için Python programlama dili ile makine öğrenmesi amacıyla XGBoost'a ait XGBRegressor algoritması kullanılmıştır. Modelin parametre optimizasyonu için Scikitlearn'e ait GridSearchCV algoritması kullanılmıştır.

Model sonuçları ortalama mutlak hata (MAE) değeri hesaplatılarak değerlendirilmiştir. MAE değeri 25015.0543 olarak elde edilmiştir.

Model değerlendirildiğinde konut fiyatlarının tahmininde XGBoost regresyonu kullanıldığında, GridSearchCV arama algoritması ile optimizasyon yapılmasının uygun olacağı sonucuna varılmıştır.

# Kaynaklar

- [1] Yapay Zekâ (Artificial İntelligence) Nedir?. [İnternet]. Denizli; 2022 [erişim tarihi 12.12.2022]. <https://kvksis.com/blog-detay/yapay-zeka-artificial-intelligence-nedir-yapay-zeka-alaninda-kisisel-verilerin-korunmasi>
- [2] Gültekin B., Doğan G., İnşaat mühendisliğinde yapay zeka çalışmaları. İleri Mühendislik Çalışmaları ve Teknolojileri Dergisi, 2(2), 117-138
- [3] Uygunoğlu T, Yurtcu Ş. Yapay zeka tekniklerinin inşaat mühendisliği problemlerinde kullanımı. Yapı Teknolojileri Elektronik Dergisi 2 (2016 ): 61-70, <https://dergipark.org.tr/tr/pub/yted/issue/22220/238539>
- [4] Çıtırık BN. Dinamik yüklemeye maruz konsol dayanma duvarı stabilitesinin makine öğrenmesi algoritmaları ile araştırılması (yüksek lisans tezi). Konya: Karatay Teknik Üniversitesi; 2022. <https://tez.yok.gov.tr/>
- [5] Kayhan H. Otomatik üretim teknolojisine uygun betonların basınç dayanımlarının makine öğrenmesi ve derin öğrenme yöntemleri ile tahmin edilmesi (yayımlanmamış yüksek lisans tezi). Bilecik: Bilecik Şeyh Edebali Üniversitesi; 2022.
- [6] Ersoy ZB. Dinamik su bütçesi modeline makine öğrenmesi entegrasyonu ile aylık akış tahminlerinin iyileştirilmesi. (Yayımlanmamış yüksek lisans tezi). Balıkesir Üniversitesi Fen Bilimleri Enstitüsü, 2021.
- [7] Arama ZA, Akın MS, Nuray SE, Dalyan İ. estimation of consistency limits of fine-grained soils via regression analysis: a special case for high and very high plastic clayey soils in Istanbul. International Advanced Researches And Engineering Journal 2020; 4(3), 255-266.
- [8] Arslan H, Fatih Ü., Demirci M., Taşar B, Yılmaz A. Keban baraj gölü seviye değişiminin anfis ve destek vektör makineleri ile tahmini. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi 2020; 3(2), 1-7.
- [9] Cao Y, Wakil K, Alyousef R, Jermsittiparsert K, Ho LS., Alabduljabbar H, Mohamed AM. Application of extreme learning machine in behavior of beam to column connections. In Structures. Elsevier 2020; 25, 861-867,

- [10] Gao X, Lin C. Prediction model of the failure mode of beam-column joints using machine learning methods. *Engineering Failure Analysis*, 120, 105072.
- [11] Hwang SH, Mangalathu S, Shin J, Jeon JS., Machine learning-based approaches for seismic demand and collapse of ductile reinforced concrete building frames. *Journal of Building Engineering* 2020; 101905.
- [12] Khai WJ, Alraih M, Ahmed AN, Fai CM, El-Shafie A. Daily forecasting of dam water levels using machine learning. *International Journal Of Civil Engineering And Technology (Ijciet)* 2019.
- [13] Gültekin B. Betonarme yapılarda yapısal ve yapısal olmayan hasarların derin öğrenme ile tespiti. (yüksek lisans tezi). Konya: Konya Teknik Üniversitesi 2022. <https://tez.yok.gov.tr/>
- [14] Kılınç HÇ. Nehir akımlarının derin öğrenme ile tahmini ve akımların demiryolları güzergahına etkisi. *Demiryolu Mühendisliği* 202; no. 13, pp. 106-114, doi:10.47072/demiryolu.831702.
- [15] Zhang W, Li H, Li Y, Liu H, Chen Y, Ding X. Application of deep learning algorithms in geotechnical engineering: a short critical review. *Artificial Intelligence Review* 2021, 1-41.
- [16] Çakıroğlu MA, Süzen AA. Assessment and application of deep learning algorithms in civil engineering. *El-Cezeri Journal Of Science And Engineering*, 7(2), 906-922.
- [17] Mangalathu S, Burton HV. Deep learning-based classification of earthquake-impacted buildings using textual damage descriptions. *International Journal of Disaster Risk Reduction* 2019, 36, 101111.
- [18] Zhong B, Xing, X, Love P, Wang X. ve Luo H. Evrişimli sinir ağı: bina kalitesi problemlerinin derin öğrenmeye dayalı sınıflandırılması. *İleri Mühendislik Bilişimi* 2019, 40, 46-57.
- [19] İlgün A, Zia AJ, Demir V, Müsevitoğlu A, Sancioğlu S. Tek katlı duvar deformasyonunun görüntü işleme teknikleri kullanılarak belirlenmesi. *Journal of Mathematics, Engineering, Natural & Medical Sciences* 2021, 8(17), 21–29.
- [20] Bingöl K, Akan AE, Örmecioğlu HT, Er A. Depreme dayanıklı mimari tasarımda yapay zeka uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti, *Journal of the Faculty of Engineering and Architecture of Gazi University* 2022, Volume 35, Issue 4, 2197 – 2210.

- [21] Dogan G, Arslan MH, Baykan OK. Determination of damage levels of Rc columns with a smart system oriented method. *Bulletin of Earthquake Engineering* 2020, 1-23.
- [22] Kaçın S, Aydın M. Görüntü işleme yöntemi ile betonarme kiriş deplasmanlarının belirlenmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi* 2020, 23(2), 107-117.
- [23] Pekgöz M. Görüntü işleme yöntemiyle betonda gerilme-şekil değiştirme davranışının değerlendirilmesi (yüksek lisans tezi). *Adıyaman Üniversitesi Fen Bilimleri Enstitüsü* 2020, Adıyaman.
- [24] Avcı N. sarsma masası deneyi ve sayısal analizlerden elde edilen dinamik parametrelerin görüntü işleme tekniği ile karşılaştırılması (yüksek lisans tezi). *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, 2019 İstanbul.
- [25] Bahadırılı, ZM. Yeraltı suyu seviye değişiminin M5 karar ağacı ve yapay sinir ağları yöntemleriyle belirlenmesi (yüksek lisans tezi). *İskenderun Teknik Üniversitesi / Lisansüstü Eğitim Enstitüsü* 2021, Hatay.
- [26] Acar R, Saphoğlu K. Akarsulardaki sediment taşınımının yapay sinir ağları ve ANFIS yöntemleri kullanılarak tespiti. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi* 2020, Cilt 9, Sayı 1, 437 – 450.
- [27] Cansız ÖF, Ünsalan K, Erginer İ. Karayolları enerji tüketiminin yapay zekâ ve regresyon yöntemleri ile modellenmesi. *Uludağ University Journal of the Faculty of Engineering* 2020, 25(3), 1297-1314.
- [28] Marangu JM. Prediction of compressive strength of calcined clay based cement mortars using support vector machine and artificial neural network techniques. *Journal of Sustainable Construction Materials and Technologies* 2020, 5(1), 392-398.
- [29] Moayedı H, Mosallanezhad M, Rashid ASA, Jusoh WAW, Muazu MA. Geoteknik mühendisliğinde yapay sinir ağı uygulamasının sistematik bir incelemesi ve meta-analizi: teori ve uygulamalar. *Nöral Hesaplama ve Uygulamalar* 2020, 32 (2), 495-518.
- [30] Sağlam RN, Ulaş MA, Alyamaç KE. Hafif beton üretimi için gerekli olan hafif agrega miktarının yapay sinir ağı ile tahmin edilmesi, *Fırat Üniversitesi Müh. Bil. Dergisi* 2022, 34(2), 889-898.

- [31] Arpacık T, Taşınmaz kültür varlıklarının taşınma yöntem ve hesaplarının temel mühendisliği bağlamında bulanık mantık modellemesi ile karşılaştırmalı analizi (yüksek lisans tezi). Konya: Konya Teknik Üniversitesi 2022. <https://gcris.ktun.edu.tr/handle/20.500.13091/2520>
- [32] Mohanaselvi S, Hemapriya G. Application of fuzzy logic to earthquake damage predictions. AIP Conference Proceedings, 2112(1), (p. 020043) 2019. AIP Publishing LLC.
- [33] Özdülkar K, Üneş F, Demirci M, Kaya YZ. Günlük buharlaşma miktarının bulanık mantık yöntemleri kullanılarak bölgesel olarak modellenmesi. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi 2019, 2(1), 23-29.
- [34] Abed GR, Güncel metasezgisel optimizasyon algoritmaların çelik yapıların optimum boyutlandırılması problemindeki performanslarının incelenmesi (yüksek lisans tezi). Antalya: Akdeniz Üniversitesi Fen Bilimleri Enstitüsü 2020.
- [35] Ataş FH, İnce daneli zeminlerin jet grout tekniği ile zemin iyileştirmesinin yapılabirliğinin optimizasyonu (yüksek lisans tezi) Tekirdağ: Namık Kemal Üniversitesi 2021.
- [36] Kalemci EN, İkizler SB, Dede T, Angın Z. Rao\_1 optimizasyon algoritması kullanılarak taban plağı dişli betonarme konsol istinat duvarı tasarımı. Uludağ Üniversitesi Mühendislik Fakültesi Dergisi 2019, Cilt 24, Sayı 3.
- [37] Alkan A, Optimizasyon teknikleri kullanılarak kuraklık hibrit tahmin modeli geliştirilmesi (yüksek lisans tezi). Eskişehir: Eskişehir Teknik Üniversitesi 2022.
- [38] Gündoğdu H, Yük taşımacılığında optimizasyon tekniklerinin karşılaştırılması (yüksek lisans tezi). Hatay: İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü 2020.
- [39] Noori M. İnşaat projelerinde meta-sezgisel algoritmalar ile süre-maliyet-kalite ödünleşim problemlerinin optimizasyonu (yayınlanmamış yüksek lisans tezi). Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü 2021.
- [40] House Prices – Advanced Regression Techniques. [İnternet] Denizli; 2022 [erişim tarihi 12.12.2022]. <https://www.kaggle.com/competitions/house-prices-advanced-regression-techniques/data>

- [41] sklearn.model\_selection.GridSearchCV, [İnternet] Denizli; 2022 [erişim tarihi 12.12.2022]. [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.GridSearchCV.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html)
- [42] Hiperparametre Optimizasyonu. [İnternet] Denizli; 2022 [erişim tarihi 12.12.2022]. <https://medium.com/bili%C5%9Fim-hareketi/hiperparametre-optimizasyonu-9ba0e7f32e6f>



# Ekler

# Ek A

## Proje Kodu

```
# Optimizing the XGBoost regressor parameters
import numpy as np
import pandas as pd
import os

from sklearn.compose import ColumnTransformer
from sklearn.pipeline import Pipeline
from sklearn.impute import SimpleImputer
from sklearn.preprocessing import OneHotEncoder, RobustScaler
from sklearn.metrics import mean_absolute_error
from xgboost import XGBRegressor

for dirname, _, filenames in os.walk('/kaggle/input'):
    for filename in filenames:
        print(os.path.join(dirname, filename))
X = pd.read_csv('train.csv', index_col='Id')
X_test = pd.read_csv('test.csv', index_col='Id')
X.dropna(axis=0, subset=['SalePrice'], inplace=True)
y = X.SalePrice
X.drop(['SalePrice'], axis=1, inplace=True)
cols_with_missing = [col for col in X.columns if X[col].isnull().any()]
for col in cols_with_missing:
    X[col+'_was_missing'] = X[col].isnull()
    X_test[col+'_was_missing'] = X_test[col].isnull()
categorical_cols = [cname for cname in X.columns if
                    X[cname].nunique() < 10 and
                    X[cname].dtype == "object"]
```

```

numerical_cols = [cname for cname in X.columns if
                  X[cname].dtype in ['int', 'float']]
my_cols = categorical_cols + numerical_cols
X = X[my_cols].copy()
X_test = X_test[my_cols].copy()
numerical_transformer = Pipeline(steps=[
    ('num_imputer', SimpleImputer(strategy='median')),
    ('num_scaler', RobustScaler())
])
categorical_transformer = Pipeline(steps=[
    ('imputer', SimpleImputer(strategy='most_frequent')),
    ('onehot', OneHotEncoder(handle_unknown='ignore', sparse=False))
])
preprocessor = ColumnTransformer(
    transformers=[
        ('num', numerical_transformer, numerical_cols),
        ('cat', categorical_transformer, categorical_cols)
    ]
)
model = XGBRegressor(random_state=0,
                    learning_rate=0.005, n_estimators=1000,
                    max_depth=4, colsample_bytree=0.5, subsample=0.5,
                    min_child_weight = 1, gamma = 0, scale_pos_weight = 1)
pipeline = Pipeline(steps=[('preprocessor', preprocessor),
                           ('model', model)
                          ])
from sklearn.model_selection import GridSearchCV
param_grid = {'model__n_estimators': np.arange(4400, 5500, 100)}
model = XGBRegressor(random_state=0,
                    learning_rate=0.01, n_estimators=3460,
                    max_depth=4, colsample_bytree=0.5, subsample=0.5)
pipeline = Pipeline(steps=[('preprocessor', preprocessor),
                           ('model', model)
                          ])

```

```
from sklearn.model_selection import cross_val_score
scores = -1 * cross_val_score(pipeline, X, y,
                              cv=5, n_jobs=-1,
                              scoring='neg_mean_absolute_error')
print("Average MAE score:", scores.mean())
pipeline.fit(X, y)
preds_test = pipeline.predict(X_test)
output = pd.DataFrame({'Id': X_test.index,
                       'SalePrice': preds_test})
output.to_csv('submission.csv', index=False)
```

# Özgeçmiş

Adı Soyadı: Ayşe Tuba Tuğrul  
E-mail (1): att\_0896@yahoo.com.tr  
E-mail (2): aysetubatugrul@gmail.com

## Eğitim:

2009-2014 Pamukkale Üniversitesi, İnşaat Mühendisliği (Lisans)  
2014-2019 Pamukkale Üniversitesi, İnşaat Mühendisliği (Yüksek Lisans-Tezli)  
2020-2022 Anadolu Üniversitesi, Web Tasarım ve Kodlama (Önlisans)  
2021-2023 İzmir Kâtip Çelebi Üniversitesi, Yazılım Mühendisliği (Yüksek Lisans-Tezsiz)

## İş Deneyimi:

2019 – ... İnşaat Mühendisi - Tuğrul Mühendislik İnşaat & Jeoloji (Denizli)

## Yayınlar:

1. Bacanlı, Ü. G. ve Tuğrul, A. T., ‘‘Baraj göllerinin iklimsel etkisi ve Vali Recep Yazıcıoğlu Gökpınar baraj gölü örneği’’, Pamukkale Univ Muh Bilim Derg., 22(3), 154-159, (2016).
2. Tuğrul, A. T., ‘‘İstinat yapılarının depreme dayanıklı tasarımı.’’ Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, (2019).