

**T.C.
İSTANBUL GEDİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**KAZI DESTEKLEME SİSTEMLERİNİN OLASI DEPLASMANLARININ
TAHMİNİ İÇİN PYTHON PROGRAMINA DAYALI YAPAY SİNİR AĞLARI
ALGORİTMALARININ GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

Caner KARABULUT

İnşaat Mühendisliği Ana Bilim Dalı

İnşaat Mühendisliği Tezli Yüksek Lisans Programı

OCAK 2022

T.C
İSTANBUL GEDİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**KAZI DESTEKLEME SİSTEMLERİNİN OLASI DEPLASMANLARININ
TAHMİNİ İÇİN PYTHON PROGRAMINA DAYALI YAPAY SİNİR AĞLARI
ALGORİTMALARININ GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

**Caner KARABULUT
(191282003)**

İnşaat Mühendisliği Ana Bilim Dalı

İnşaat Mühendisliği Tezli Yüksek Lisans Programı

Tez Danışmanı: Dr. Öğr. Ü. Redvan GHASEMLOUNIA

Eş Tez Danışmanı: Dr. Öğr. Ü. Mert TOLON

OCAK 2022



T.C.
İSTANBUL GEDİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ

Yüksek Lisans Tez Onay Belgesi

Enstitümüz, İnşaat Mühendisliği Tezli Yüksek Lisans Programı 191282003 numaralı öğrencisi **Caner KARABULUT**'un “Kazi Destekleme Sistemlerinin Olası Deplasmanlarının Tahmini İçin Python Programına Dayalı Yapay Sinir Ağları Algoritmalarının Geliştirilmesi” adlı tez çalışması 28/01/2022 tarihinde yapılan tez savunma sınavında aşağıdaki jüri tarafından *Oy Birliği* ile Yüksek Lisans tezi olarak *Kabul* edilmiştir.

Öğretim Üyesi Adı Soyadı

Jüri Onay Tarihi: 28/01/2022

| | | |
|--------------------|------------------------------------|-----|
| Eş Tez Danışmanı : | Dr. Öğr. Üyesi Mert TOLON | ... |
| Tez Danışmanı : | Dr. Öğr. Üyesi Redvan GHASEMLOUNIA | ... |
| Jüri Üyesi : | Dr. Öğr. Üyesi Nil TAYLAN KUTLU | ... |
| Jüri Üyesi : | Dr. Öğr. Üyesi Gökhan KAZAR | ... |
| Jüri Üyesi : | Dr. Öğr. Üyesi Bozkurt NAZİLLİ | ... |

**T.C
İSTANBUL GEDİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



YÜKSEK LİSANS TEZİ

**CANER KARABULUT
(191282003)**

İnşaat Mühendisliği Anabilim Dalı

İnşaat Mühendisliği Tezli Yüksek Lisans Programı

**İstanbul Gedik Üniversitesi Lisansüstü Eğitim Enstitüsü, İnşaat
Mühendisliğinde Yapılan Bu Tez Çalışması, Geoteknik Anabilim Dalı Yüksek
Lisans Derecesi Gereksinimlerini Sağlamaktadır.**

Tez Danışmanı: Dr. Öğr. Ü. Redvan GHASEMLOUNIA

Eş Tez Danışmanı: Dr. Öğr. Ü. Mert TOLON

OCAK 2022

YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “Kazi Destekleme Sistemlerinin Olası Deplasmanlarının Tahmini İçin Python Programına Dayalı Yapay Sinir Ağları Algoritmalarının Geliştirilmesi” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim (28/01/2022).

Caner KARABULUT



Geleceğe İthafen....

ÖNSÖZ

Yüksek lisans eğitimim sırasında ve tez sürecimdeki gerek akademik gerekse bireysel olarak özveriyle yakından ilgilenen, desteğini esirgemeyen, değerli bilgi ve tavsiyeleriyle her zaman varlığını yanımda hissettiren kıymetli danışman hocam Dr. Öğr. Üyesi Mert Tolon'a ayrıca değerli yönlendirmeleri ile tezimin şekillenmesini sağlayan çok kıymetli danışman hocam Dr. Öğr. Ü. Redvan GHASEMLOUNIA'a, değerli jürime, tez konumu seçerken görüşlerini samimi bir şekilde paylaşan değerli hocam Dr. Öğr. Ü. Ahmet GÜLLÜ'ye, bir abi bir hoca gibi tüm bilgi ve deneyimlerini benimle cömertçe paylaşan Yük. İnşaat Mühendisi Habip KÖSE'ye, arkadaşlarım M. Mücahit YAZICI, Mahmut ÖZCAN, Fatih DURAN, Selen YEŞİLDAL'a en samimi teşekkürlerimi sunuyorum. Geoteknik ve yapay zeka konusunda heyecanımı sürekli olarak korumamı sağlayan ve bu heyecanımı benimle içten bir şekilde paylaşan sevgili ailem; annem, babam, halam ve özellikle abim Serdar KARABULUT ve kuzenim Alperen UĞURLU'ya çok teşekkür ederim, iyi ki varsınız.

Ocak 2022

Caner KARABULUT

İnşaat Mühendisi

İÇİNDEKİLER

Sayfa

| | |
|--|------------|
| SİMGE VE KISALTMALAR | ix |
| TABLO LİSTESİ | x |
| ŞEKİL LİSTESİ | xi |
| ÖZET | xiv |
| ABSTRACT | xvi |
| 1. GİRİŞ | 2 |
| 2. LİTERATÜR ÖZETİ | 6 |
| 2.1. Zemin ve Kaya | 6 |
| 2.2. Zemin Mekaniği Önemi | 6 |
| 2.3. Zemin Deprem İlişkisi ve Önemi | 7 |
| 2.4. Zemin Stabilite Problemi | 8 |
| 2.4.1. Kazı stabilitesi | 11 |
| 2.4.2. Derin kazılar ve destekleme sistemleri | 12 |
| 2.4.3. Yanal zemin hareketi..... | 18 |
| 2.4.4. Sükunetteki zeminin gerilme durumu | 19 |
| 2.4.5. Aktif zemin gerilme durumu | 20 |
| 2.4.6. Pasif zemin gerilme durumu | 22 |
| 2.4.7. Rankine teoremi ve coulomb teoremi | 25 |
| 2.4.8. Derin kazı destekleme sistemi..... | 30 |
| 2.4.8.1. Diyafram duvarlar | 30 |
| 2.4.8.2. Ankrajlı kazı destekleme sistemleri | 38 |
| 2.4.8.3. Palplanş duvar | 47 |
| 2.4.8.4. Kazıklı destekleme sistemleri..... | 51 |
| 2.4.8.5. Yukardan-Aşağıya destekleme sistemi (top-down) | 54 |
| 2.4.9. Destekleme sistemleri üzerine değerlendirme | 55 |
| 2.4.10. Destekleme elemanlarının aletsel gözlemlenmesi | 56 |
| 2.5. Yapay Zeka Uygulama Alanları..... | 57 |
| 2.5.1. Geoteknik mühendisliği problemlerinde veri işleme uygulamaları | 58 |
| 2.5.2. Verilerin işlenmesi | 58 |
| 2.5.3. Python ve inşaat mühendisliğinde kullanım alanları | 59 |
| 3. ÇALIŞMA KAPSAMINDA KULLANILAN GEOTEKNİK VERİLER | 63 |
| 3.1. Veri Setinin Geoteknik ve İstatistik Olarak Değerlendirilmesi | 67 |
| 3.2. Veri Seti Korelasyonu | 83 |
| 4. PYTHON İLE MAKİNE ÖĞRENMESİ BAZINDA GELİŞTİRİLEN MODELİN İNCELENMESİ | 86 |
| 4.1. Yapay Sinir Ağları | 86 |
| 4.1.1. Yapay sinir ağı bileşenleri..... | 91 |
| 4.1.1.1. Girdiler | 91 |
| 4.1.1.2. Ağırlıklar | 91 |
| 4.1.1.3. Toplama-Birleştirme Fonksiyonları | 91 |
| 4.1.1.4. Aktivasyon Fonksiyonları | 92 |
| 4.1.1.5. Çıktılar | 95 |
| 4.2. Yapay Sinir Ağları Modeli Özellikleri..... | 96 |
| 4.2.1. Geliştirilen Modeller | 96 |
| 4.2.1.1. Kod Yazımı | 96 |

| | |
|--|------------|
| 4.2.2. Nihai verilerin görselleştirilmesi..... | 125 |
| 4.2.3. Geliştirilen Modellerin incelenmesi | 130 |
| 5. SONUÇLAR..... | 141 |
| 6. TARTIŞMA VE TAVSİYELER..... | 151 |
| KAYNAKLAR | 154 |
| EKLER..... | 162 |
| ÖZGEÇMİŞ..... | 168 |



SİMGE VE KISALTMALAR

| | |
|-------------------------------|--|
| YSA | : Yapay Sınır Ağı |
| E | : Elastisite Modülü |
| C_u | : Drenajsız kohezyon |
| N | : Ölçülmüş SPT darbe vuruş sayısı |
| γ_s | : Zeminin birim hacim ağırlığı |
| γ_w | : Suyun birim hacim ağırlığı |
| P | : Zemin birim hacim ağırlığı |
| δ_v | : Zeminde düşey deplasman |
| δ_h | : Zeminde yatay deplasman |
| H | : Kazı derinliği |
| P_a | : Aktif toprak basıncı |
| P_a | : Pasif toprak basıncı |
| EI | : Eğilme rijitliği |
| σ'_v | : Düşey efektif gerilme |
| K_a | : Yanal aktif toprak basıncı katsayısı |
| K_p | : Yanal pasif toprak basıncı katsayısı |
| K_0 | : Sükunetteki toprak basıncı katsayısı |
| γ' | : Zeminin efektif birim hacim ağırlığı |
| ϕ' | : Efektif kayma mukavemeti açısı |
| ϕ | : Kayma mukavemeti açısı |
| α | : Duvarın düşeyden eğikliği |
| θ | : Duvar – zemin arayüzeyinin sürtünme açısı |
| m | : Metre |
| cm | : Santimetre |
| mm | : Milimetre |
| YASS | : Yeraltı su seviyesi |
| Q1 | : Küçükten büyüğe sıralanmış değerler arasından 25. Sıradaki değer |
| Q3 | : Küçükten büyüğe sıralanmış değerler arasından 75. Sıradaki değer |
| IQR | : Çeyrek açıklığı veya Q3 ile Q1 arasındaki fark |
| 3B | : Üç boyut |
| CPD | : Bitişik kazık duvar |
| DD | : Diyafram duvar |
| CDSM | : Bileşik derin toprak karıştırma kolonları |
| SPD | : Palplanş duvar |
| CSN | : Bileşik zemin çivisi duvarı |
| DSM | : Derin zemin karıştırma kolonları |

TABLO LİSTESİ

Sayfa

| | |
|---|-----|
| Tablo 2. 1: Aktif Zemin Gerilmesinin Sağlanabilmesi İçin Oluşması Gereken Destekleme Sistemi Hareketi | 22 |
| Tablo 2. 2: Pasif Zemin Gerilmesinin Sağlanabilmesi İçin Oluşması Gereken Destekleme Sistemi Hareketi | 24 |
| Tablo 3.1: Zemin Türüne Göre Değişen Toprak Basınç Katsayısı | 66 |
| Tablo 3. 2: Korelasyon Katsayıları İlişki Düzeyi | 85 |
| Tablo 4.1: Aykırılık Analizi Öncesi Ve Sonrası Kiyas Tablosu | 129 |
| Tablo 4.2: Korelasyonlardaki Değişim Miktarı - Minimum 0,15'lik Değişim Baz Alınmıştır | 130 |
| Tablo 4.3: Lineer Regresyon Modelleri Metrik Değerleri | 133 |
| Tablo 4.4: En İyi Lineer Modelin Test Verisindeki Metrik Değerleri | 134 |
| Tablo 4.5: Lineer Regresyon Ridge Model Tahmininin, Girdi Parametreleri Katsayıları | 136 |
| Tablo 4.6: Doğrusal Olmayan Modellere Ait Hiperparametreler Ve Eğitim-Test Ayrimindeki Parametreleri Verilmektedir. | 137 |
| Tablo 4.7: YSA İle Geliştirilen En İyi Model Üzerinden Geliştirilen Diğer Modeller | 139 |
| Tablo 4.8: En İyi Model Üzerinden Geliştirilen Diğer Modellerin Metrikleri..... | 140 |
| Tablo 5.1: Değerlendirme Ölçütleri - Metrikler | 146 |
| Tablo 5.2: Eğitim Aşamasındaki Çıktı Verilerinin Ortalama Hedef Değer Dağılımları - Model5 Ve Model6 | 148 |

ŞEKİL LİSTESİ

Sayfa

| | |
|--|----|
| Şekil 2. 1: Mekanik Stabilizasyona Örnek - Dinamik Kompaksiyon..... | 10 |
| Şekil 2. 2: Zeminlerin Kimyasal Stabilizasyonuna Örnek - Kireçle Stabilizasyon. .. | 11 |
| Şekil 2. 3: Tuna Taksim Otel İksa Projesi – Dünya Zemin | 13 |
| Şekil 2. 4: Vadipark Seyrantepe Rezidans İksa Projesi - Dünya Zemin..... | 13 |
| Şekil 2. 5: Kazi Derinliği Boyunca Duvarın Yatay Hareketi - Yukardan Aşağıya Metod | 16 |
| Şekil 2. 6: Kazi Derinliği Boyunca Duvarın Yatay Hareketi- Bileşik Zemin Çivisi. 16 | |
| Şekil 2. 7: Kazi Derinliği Boyunca Duvarın Yatay Hareketi - Dıyafram Duvar, Bitişik Kazık Duvar, Bileşik Derin Karıştırma | 17 |
| Şekil 2. 8: Kazi Derinliği Boyunca Duvarın Yatay Hareketi - Derin Karıştırma..... | 17 |
| Şekil 2. 9: Kazi Derinliği Boyunca Duvarın Yatay Hareketi - Palplanş Duvar..... | 18 |
| Şekil 2. 10: Sükunetteki Zeminin Toprak Basıncı | 19 |
| Şekil 2. 11: Aktif Ve Pasif Zemin Gerilme Durumu İçin Mohr Coulomb Göçme Zarfi | 20 |
| Şekil 2. 12: Aktif Ve Pasif Zemin Gerilme Durumlarının Ayri Ayri Gösterimi - Mohr Coulmb Göçme Zarfi | 21 |
| Şekil 2. 13: Pasif Toprak Basıncı Hareti..... | 23 |
| Şekil 2. 14: Aktif Ve Pasif Toprak Basıncın Destekleme Sistemei Üzerine Etkisi... 24 | |
| Şekil 2. 15: Dayanma Yapıları Arkasındaki Zemin Basınçlarının A) Teorik Ve B) Gözlenen Durum | 26 |
| Şekil 2. 16: Destekleme Sistemeine Etki Eden Aktif Toprak Basıncı Ve Destekleme Sisteminin Arkasında Yer Alan Zeminin Yatayda Yaptığı Açık..... | 26 |
| Şekil 2. 17: Pasif Durum İçin Rankin Serbest Cıvım Dıyagramı..... | 28 |
| Şekil 2. 18: Dıyafram Duvar Makinesi | 30 |
| Şekil 2. 19: Klavuz Duvar Gösterimi - Dıyafram Duvar | 32 |
| Şekil 2. 20: Vinçe Montelenmiş Kepçe Ağzı..... | 32 |
| Şekil 2. 21: Kelly'e Montelenmiş Kepçe Ağzı - Boom Üzerindedir | 33 |
| Şekil 2. 22: Ters Sirkülasyon Tekniği Ve Hidrolik Kesici - Dıyafram Duvar | 33 |
| Şekil 2. 23: Durdurucular - Dıyafram Duvar | 34 |
| Şekil 2. 24: Panellerin Kumdan Arındırılması - Dıyafram Duvar | 35 |
| Şekil 2. 25: Donatıların Yerleştirilmesi -Dıyafram Duvar..... | 36 |
| Şekil 2. 26: Beton Döküm İşlemi - Dıyafram Duvar | 37 |
| Şekil 2. 27: Su Geçirimsiz Dıyafram Duvar | 37 |
| Şekil 2. 28: Dıyafram Duvar Uygulamasının Genel İlerleyişi | 38 |
| Şekil 2. 29: Ankraj Çalışma Prensipleri | 39 |
| Şekil 2. 30: Tıpkı Zemin Ankrağı..... | 39 |
| Şekil 2. 31: Öngermeli Zemin Ankraj Sistemi | 40 |
| Şekil 2. 32: Boru Destek Uygulama Örneği - Kasımpaşa P1 House Rezidans İksa | |

| | |
|---|----|
| Projesi, Dünya Zemin..... | 41 |
| Şekil 2. 33: İş Makinasının Perde İçin Kazı Çalışması - Perde Duvar | 42 |
| Şekil 2. 34: Panele Strafor Uygulaması Ankraj İçin Yer Açılıyor - Perde Duvar, Zetaş | 43 |
| Şekil 2. 35: Metal Panelin Kapatılması Geri Dolgu Yöntemi İle Sıkıştırma - Perde Duvar | 43 |
| Şekil 2. 36: Zemin Çıvısı | 44 |
| Şekil 2. 37: Başlıkların Püskürtme Beton İle Çelik Hasırlara Tutturulması..... | 45 |
| Şekil 2. 38: Batardo - Çelik Palpaş Perde..... | 48 |
| Şekil 2. 39: Betonarme Palpaş Perde | 49 |
| Şekil 2. 40: Ahşap Palpaş Perde - Zemine Çakılma İşlemi Ve Kesit Durumu..... | 50 |
| Şekil 2. 41: Uygulama Örneği - Ahşap Palpaş Perde | 50 |
| Şekil 2. 42: Kazıklı Destekleme Sistemi Uygulamaları | 52 |
| Şekil 2. 43: Fore Kazık Uygulama Adımları | 53 |
| Şekil 2. 44: Kazık Perde Uygulaması - Fore Kazık – Ümraniye Okan Sokak Yanı Zemin Altı Otopark İksa Projesi - Dünya Zemin..... | 54 |
| Şekil 2. 45: Yukardan - Aşağıya Kazı Destekleme Sistemi - Şantiye Aşaması | 55 |
| Şekil 2. 46: İnklometre Çalışma Prensipleri | 57 |
| Şekil 2. 47: Iris Çiçeğine Ait Grafik Dağılımı - Verilerin İşlenmesi..... | 59 |
| Şekil 2. 48: Abd’de 2017-2020 Yılları Arasında İşverenler Tarafından En Çok Tercih Edilen Programlama Dilleri | 60 |
| Şekil 3. 1: Yapay Sinir Ağı Mimarisi Ve Parametreleri | 65 |
| Şekil 3. 3: Matris Grafiği | 69 |
| Şekil 3. 6 : $E_i \setminus N(Knm^2/M)$ Ve $\Delta h_{Olcum}(Mm)$ Saçılım Grafiği | 71 |
| Şekil 3.7: $\Delta v_{Olcum}(Mm)$ Ve $\Delta h_{Olcum}(Mm)$ Saçılım Grafiği | 71 |
| Şekil 3.8: Ham Verilerin Çekirdek Yoğunluğu Matris Grafiği | 72 |
| Şekil 3.9: Destekleme_Aralığı(Mm) 'İna Ham Verilere Ait Veri Seti İçerisindeki Dağılımı..... | 73 |
| Şekil 3.10: Çekirdek Yoğunluğu Grafiği, $\Delta h_{Olcum}(Mm)$ Ve Destek_Aralığı(Mm) | 73 |
| Şekil 3.11: Ham Verilerin Saçılım Matris Grafiği - Destekleme Sistemine Göre Dağılım..... | 75 |
| Şekil 3.12: Destekleme Sistemine Göre $\Delta h_{Olcum}(Mm)$ Ve Destek_Aralığı(Mm) Saçılım Grafiği | 76 |
| Şekil 3.14: Destekleme Sistemine Göre $\Delta h_{Olcum}(Mm)$ Ve $H_{Kazi}(Mm)$ Saçılım Grafiği | 77 |
| Şekil 3.15: Destekleme Sistemine Göre $\Delta h_{Olcum}(Mm)$ Ve $\Delta v_{Olcum}(Mm)$ Saçılım Grafiği | 77 |
| Şekil 3.16: $\Delta h_{Olcum}(Mm)$ Ve Destek_Aralığı(Mm) Lineer Dağılım Grafiği..... | 78 |
| Şekil 3.17: $\Delta h_{Olcum}(Mm)$ Ve $E_i \setminus N(Knm^2/M)$ Lineer Dağılım Grafiği..... | 78 |
| Şekil 3.18: $\Delta h_{Olcum}(Mm)$ Ve H_{Kazi} Lineer Dağılım Grafiği | 79 |
| Şekil 3.19: $\Delta h_{Olcum}(Mm)$ Ve $\Delta v_{Olcum}(Mm)$ Lineer Dağılım Grafiği..... | 79 |
| Şekil 3.20: Destekleme Sistemine Göre $\Delta h_{Olcum}(Mm)$ Ve Destek_Aralığı(Mm) Lineer Dağılım Grafiği..... | 80 |
| Şekil 3.21: Çok Sıra Palpaş Perde - Ham Veri Seti | 81 |
| Şekil 3.22: Destekleme Sistemine Göre $\Delta h_{Olcum}(Mm)$ Ve $E_i \setminus N(Knm^2/M)$ Lineer Dağılım Grafiği | 81 |
| Şekil 3.23: Destekleme Sistemine Göre $\Delta h_{Olcum}(Mm)$ Ve H_{Kazi} Lineer Dağılım Grafiği | 82 |

| | |
|--|-----|
| Şekil 3.24: Destekleme Sistemine Göre $\Delta h_{Olcum}(Mm)$ Ve $\Delta v_{Olcum}(Mm)$ Lineer Dağılım Grafiği | 82 |
| Şekil 3.25: Ham Veri Setinin Korelasyon Haritası | 84 |
| Şekil 3.26: Kutu Grafik Yöntemi İle Aykiri Veri Analizi - $\Delta h_{Olcum}(Mm)$ Aykiri Değerleri | 85 |
| Şekil 4.1: Bir Sinir Hücresinin Matematiksel Gösterimi | 88 |
| Şekil 4.2: Yapay Sinir Ağı Hücre Modeli | 89 |
| Şekil 4.3: Sigmoid Fonksiyonunun Grafiği | 93 |
| Şekil 4.4: Relu Aktivasyon Fonksiyonunun Grafiği | 94 |
| Şekil 4.5: Doğrusal Aktivasyon Fonksiyonu | 94 |
| Şekil 4.6: Hiperbolik Tanjant - Aktivasyon Fonksiyonu | 95 |
| Şekil 4.7: Python Programı İle Jupyterlab'ta İlk Beş Veri Setinin Gözlemlenmesi .. | 97 |
| Şekil 4.8: Son Beş Verinin Gözlemlenmesi | 97 |
| Şekil 4.9: Veri Seti Hakkında Bilgi Edinmek | 99 |
| Şekil 4.10: Veri Setinin Betimsel İstatistikleri – Ham Veri | 100 |
| Şekil 4.11: Localoutlierfactor Algoritmasının Çalışma Mantığı | 101 |
| Şekil 4.12: Belirlenen Argümanlar Sonrasında Oluşan İlişkisel - Aykiri Gözlem Grafiği | 103 |
| Şekil 4.13: Aykiri Veriler | 104 |
| Şekil 4.14: $\Delta h_{Olcum}(Mm)$ Sütununa Ait Aykiri Değerler – 2-Sigma Yöntemi .. | 106 |
| Şekil 4.15: Kutu Grafik Yöntemi İle Aykiri Değer Analizi | 108 |
| Şekil 4.16: Kutu Grafik Ve Aykiri Değer Gösterimi | 108 |
| Şekil 4.17: $\Delta v_{Olcum}(Mm)$ Gözlemi, Kutu Grafik Yöntemi İle Aykiri Değer Analizi | 110 |
| Şekil 4.18: $\Delta v_{Olcum}(Mm)$ Aykiri İndeks Gözlemi, Kutu Grafik Yöntemi İle Aykiri Değer Analizi | 111 |
| Şekil 4.19: Destek_Aralığı(Mm) Gözlemi, Kutu Grafik Yöntemi İle Aykiri Değer Analizi | 112 |
| Şekil 4.20: $Ei \setminus N(Knm^2/M)$ Gözlemi, Kutu Grafik Yöntemi İle Aykiri Değer Analizi | 112 |
| Şekil 4.21: $H_{Kazi}(Mm)$ Gözlemi, Kutu Grafik Yöntemi İle Aykiri Değer Analizi | 113 |
| Şekil 4.22: $\Delta h_{Olcum}(Mm)$ Gözlemi, Kutu Grafik Yöntemi İle Aykiri Değer Analizi | 113 |
| Şekil 4.23: Veri Setinin Son Halinin Betimsel İstatistik Değerleri | 117 |
| Şekil 4.24: $\Delta h_{Olcum}(Mm)$ Ve Destek_Aralığı(Mm) Lineer Dağılım Grafiği - Aykiri Veri Temizliği Sonrası | 125 |
| Şekil 4.25: $\Delta h_{Olcum}(Mm)$ Ve $Ei \setminus N(Knm^2/M)$ Lineer Dağılım Grafiği – Aykiri Veri Temizliği Sonrası | 126 |
| Şekil 4.26: $\Delta h_{Olcum}(Mm)$ Ve H_{Kazi} Lineer Dağılım Grafiği – Aykiri Veri Temizliği Sonrası | 127 |
| Şekil 4.27: $\Delta h_{Olcum}(Mm)$ Ve $\Delta v_{Olcum}(Mm)$ Lineer Dağılım Grafiği- Aykiri Veri Temizliği Sonrası | 127 |
| Şekil 4.28: Veri Seti Nihai Korelasyon Haritası - Aykiri Veri Temizliği Sonrası .. | 128 |
| Şekil 4.29: Lineer Regresyon Eğitim Modelleri | 133 |
| Şekil 4.30: Lineer Regresyon Grafiği | 134 |
| Şekil 5.1: Ham Veri Setinin Destekleme Sistemi Tipine Göre Dağılımı | 144 |
| Şekil 5.2: Hata Metrikler Ve R^2_{Score} Oranı –Test Seti | 147 |
| Şekil 5.3: Score - Metrik | 148 |

KAZI DESTEKLEME SİSTEMLERİNİN OLASI DEPLASMANLARININ TAHMİNİ İÇİN PYTHON PROGRAMINA DAYALI YAPAY SİNİR AĞLARI ALGORİTMALARININ GELİŞTİRİLMESİ

ÖZET

Bu tez çalışması İstanbul Gedik Üniversitesi Fen Bilimleri Enstitüsü'nün İnşaat Mühendisliği'nde Geoteknik Ana Bilim Dalı ve Makine Öğrenmesi alanlarında multi-disipliner çalışmayı içermektedir ve geoteknik mühendisliği yüksek lisans derecesi gereksinimlerini kapsamaktadır.

İnşaat sektörü her geçen gün yeni teknoloji geliştiriyor ve kalite kazanıyor. Ayrıca nüfus arttıkça şehirlerdeki her arazi potansiyel inşaat alanı olarak değer görebilmektedir. Bu durumlarda geoteknik açıdan meydana gelebilecek problemlere yenilikçi çözümler geliştirilmesi zorunluluğu doğmaktadır. Dolayısıyla geoteknik mühendisliğini ilgilendiren durumlardan biri de kazı stabilitesi problemlerinin çözümüdür. Bu noktada kazı deplasmanını en doğru biçimde tahmin edebilmek için kazı stabilitesinin incelenmesi gerekmektedir. Can ve mal kaybı açısından birçok önemli durumda, kazı stabilitesi fenomeni inşaat mühendisleri için hem tasarım hem de uygulama alanlarında kritik bir konudur. Literatüre göre kazı stabilitesinin günümüze kadar klasik yöntemlerle hesaplandığı ve zemin davranışı ile ilgili araştırmaların devam ettiği bilinmektedir. Zemini bilmek ve doğru yöntemi seçmek, maliyeti düşürür ve güvenliği artırır. Bu nedenle kazı stabilitesinde yenilikçi yöntemler geliştirmek ve stabilize kriterlerini araştırmak uygun görülmüştür. Araştırma belirli parametreleri kapsamaktadır. Bu araştırmada kazı stabilitesi yöntemleri araştırılacak ve Python kodu kullanılarak yapay sinir ağlarında bir model geliştirilecektir. Böylece, sonuçların kısa sürede hesaplanması ve deplasmanların gerçeğe en uygununu elde etmek için kazı destekleme elemanlarının yatay deplasmanı Model tarafından hızlı bir şekilde hesaplanacaktır.

Bu çalışma kapsamında, 126 adet vaka kullanılmıştır. Verilerin işlenmesi ile 45 adet vaka aykırı tespit edilmiştir ve 81 adet vaka ile yapay zeka mantığında çalışan yapay sinir ağı modelleri geliştirilmiştir. Modeller arasında 3 adet model doğrusal regresyon ile oluşturulmuştur. Sklearn kütüphanesinin MLPRegressor ile çok katmanlı yapay sinir ağı olarak da 15 çeşit Model kullanıldı. Modelde verinin ham halinde 5 adet adet girdi parametresi ve 1 adet çıktı parametresi bulunmaktadır. Modellerde verinin işlenmesi sürecinden sonra 27 adet girdi katmanı ve 1 adet çıktı katmanı olmuştur. 5 adet girdi katmanının 4 tanesi Destek_Aralığı(mm), yanal rijitlik($EI_n(kNm^2/m)$), kazı derinliği($H_{Kazı}(mm)$), düşey deplasman ölçüm(δ_v Ölçüm(mm)) ve 5. girdi verisi Destekleme_Sistemidir. Destekleme Sisteminin tiplerine ayrılması ile toplamda 27 adet girdi verisi elde edilmektedir.

Bu tez kapsamında yapay zeka teknolojisinin inşaat mühendisliği problemlerinde uygulanabilirliğini, yatay deplasman tahmini yapabilen python programına dayalı yapay sinir ağı geliştirmek. Böylelikle uzun süreçler alan hesaplama işlemleri hızlı bir şekilde gerçekleştirmek ve maliyetlerin azaltılması sağlayabilmek gibi amaçları da barındırmaktadır.

Tez kapsamında aynı zamanda veri işleme sürecinin kurulan Modelle etkisi betimsel istatistik olarak değerlendirilmesi yapılmış ve önemi vurgulanmıştır. Verilerin eğitim aşamasında iken eğitim ve test seti olarak hangi oranda ayrılacağı da Modelin başarısına etkidiğini görülmüştür.

Bu araştırma da ilk olarak kazı stabilitesi analizi yöntemleri incelenmekte ve daha sonra kazı destekleme sistemleri ele alınmaktadır. Sonraki bölümlerde destekleme tiplerine göre ile ilgili parametreler saha verilerinden alınarak ve yapay sinir ağı Modeli oluşturulmaktadır.

Kurulan Model ile yapılan tahminin literatürdeki ilgili tezlerle mukayese edilmektedir. Kurulan Modellerde en başarılı Modelin Model10 olduğu ve varyansının % 86,75 olduğu görülmektedir.

Önceden belli olan sonuçlara göre, yapılan tahminlerin biriyle örtüşmesi, geliştirilecek olan makine öğrenmesinin asıl amacıdır. Kurulan Modelin ileride geliştirilerek farklı parametrelerle de yapı çukuru için muazzam öneme sahip yatay deplasman tahminleri yapılabileceği gibi diğer meslek problemlerinde de kullanılabilir. Kurulan Model sonraki aşamalarda geliştirilerek baskın parametrelerin tayinine, parametreler arasındaki ilişkilerin ortaya çıkarılması gibi alanlarda çalışılarak genişletilebilecektir.

Anahtar Kelimeler: Derin kazı ve stabilizasyonu, geoteknik model, python, makine öğrenmesi, yapay zeka, yapay sinir ağı, veri işleme.

DEVELOPMENT OF ARTIFICIAL NEURAL NETWORKS ALGORITHMS BASED ON THE PYTHON PROGRAM TO ESTIMATE POTENTIAL DISPLACEMENTS OF EXCAVATION SUPPORT SYSTEMS

ABSTRACT

This thesis study includes multi-disciplinary study in Geotechnical Department and Machine Learning in Civil Engineering of Istanbul Gedik University Graduate Education Institute and covers the requirements of Geotechnical Engineering Master's degree.

Every day, the construction sector develops new technology and improves its quality. Furthermore, when the population of cities grows, every piece of land in the city might be considered a prospective construction site. It is vital to discover novel solutions to difficulties that may arise in geotechnical terms under these situations. As a result, solving excavation stability difficulties is one of the geotechnical engineering issues. The stability of the excavation should be checked at this phase in order to get the most accurate estimate of the excavation displacement. The excavation stability phenomenon is a crucial issue for civil engineers in both design and application fields in many important circumstances involving loss of life and property. According to the literature, excavation stability has been calculated using traditional methods, and soil behaviour research continues. Knowing the terrain and selecting the appropriate method saves money and improves safety. As a result, it has been determined that developing creative methodologies and investigating stability criteria in excavation stability is necessary. Certain parameters are included in the study. In this study, excavation stability methods will be examined, and a model in artificial neural networks will be built using Python code. Thus, the model will swiftly calculate the horizontal displacement of the excavation support parts in order to calculate the results in a short time and acquire the most realistic displacements.

In this case, 126 case studies. Set up of 45 case external placements related to the data. 18 kinds of Models were applied as multipurpose artificial network with MLP of Sklearn library. In the Model, there are 5 input parameters and 1 output parameter in the raw form of the data. After the data processing process in the Models, 27 inputs and 1 came to the fore. 4 of the 5 inputs are Support_Spacing(mm), lateral stiffness (EI (kNm²/m)), pile ($H_{Excavation}$ (mm)), vertical displacement measurement (δv_{Olcum} (mm)) and its 5th data are Support_System. By splitting the ends of the Support System, a total of 27 input data is obtained.

In this thesis, the applicability of artificial intelligence technology in civil engineering problems, a wide field of view about the horizontal displacement python program. You can benefit from the right planning processes in a short time. At the same time, the impact of data on an unimaginable Model is evaluated as descriptive statistics and highlighted. The training success of the Model, in which the data will be separated as training success, training and test set, will be the training and test set.

In this research, first of all, stability stability is examined and then excavation support systems can then be discussed. In the areas related to the next support types, a network of artificial networks is created from field data.

The estimation made with the established Model is compared with the relevant theses in the literature. It is seen that the most successful Model in the established Models is Model10 and its variance is 86.75%.

The course of the obvious predictions that emerge is the main purpose of the machine to be developed. The established Model can be developed in the future, it can be enormous for the pit in different areas, it can also support professional problems in the world such as displacement estimations. The established Model can be developed in a way that can be developed by designing it as an abrasive.

Keywords: Deep excavation and stabilization, geotechnical model, python, machine learning, deep learning, neural network, data processing.



1. GİRİŞ

Bir çok bilim dalında olduğu gibi, geoteknik mühendisliğinde de yazılımı ve yapay zeka teknolojilerini etkin bir şekilde kullandığımızda, değişen ve gelişen çevremizde güncel, etkin ve güvenilir geoteknik tasarımların yanı sıra sahada hızlı karar verme fırsatları elde ederiz. Bu çalışmada, veri seti üzerinden veri madenciliği ile Yapay Sinir Ağları metodolojisi kullanılarak bir tahmin modeli oluşturulması önerilmektedir. Geoteknik mühendisliği teknikleri ve süreçleri, teknolojiye paralel olarak güncellenebilirler.

Bu tez çalışmasında:

- Yapı çukuru destekleme sistemi, destek aralığı, destekleme sistemi eğilme rijitliği, gerçekleşen düşey deplasman miktarı, kazı derinliğini ve yatay deplasman miktarlarının parametrelerini kullanarak yatay yer değiştirmeleri tahmin etmek,
- Bu tahmin işlemini yaparken python programında yapay sinir ağı modellemek,
- Geliştirilen model ile derin kazılarda yatay yer değiştirmeleri tahmin etmek, amaçlanmaktadır.

Zaman geçtikçe ve sanayi geliştikçe değişen ihtiyaçlar sonucunda kırsaldan kente artan göç, kentte arazi kullanımını ve kentsel dönüşümü beraberinde getirmektedir. Metropollerde insan nüfusunun artması ile birlikte yeraltı petrol tankları, temel veya bodrum katları, metrolar, ulaşım sistemlerinin yapımı veya yer altı depolama yapılarında kazı yapılması kaçınılmazdır. İnşaat alanlarının şehir merkezlerine doğru kayması, inşaat mühendisliğinde ve diğer mühendisliklerde yaşanan gelişmeler sonucunda her arazinin artık yapı alanı olarak değerlendirilebileceği gerçeği zemin mekaniği ve geoteknik problemlerin çözülmesinin önemini arttırmaktadır.

Mühendislik özellikleri yeterince iyi olmayan zeminlere yapılan yapılar gerek yer altı gerek yer üstü olsun, zeminde farklı oturmalara, deplasmanlara, konsolidasyon oturmalarına ve sıvılaşma gibi mühendislik problemlerine neden olmaktadır. Bu tarz arazilerde uygulanacak derin kazı projelerinin kesinlikle alanında uzman mühendisler tarafından değerlendirilmesi gerekmektedir. Derin kazılarda kazı işlemleri sırasında çevre yapıları zarar vermemek, ön görülmesi önemli olan diğer problemlerden biridir. Kazı işlemleri, zeminin gerilme durumlarını değiştirir. Bu ciddi problemlere neden olabilir. Güvenli olması ve yakınındaki yapılara zarar vermemesi için kazı cephelerinde yeterli stabilitenin sağlanması ve kazının desteklenmesi hayati önem taşımaktadır. Kazı destekleme sistemlerinin projelendirilmesi, öncelikle kazı destek sistemine etkiyen yüklerin karşılanmasını sağlamak ile başlar. Ancak stabiliteyi sağlamak için doğru destek sistemleri tanımlanmalı ve boyutlandırılmalıdır. Tasarlanan destek elemanları, yakındaki binalara, yollara ve mevcut altyapıya zarar verme tehlikesi ile birlikte zeminde oluşabilecek deformasyonları ve yer değiştirmeleri minimize etmelidir. Bu problemleri gidermek için yönetmeliklere uygun yardımcı mühendislik uygulamaları geliştirilmektedir.

Günümüzde hızla gelişen bilişim dünyasında, çeşitli dillerde yazılım paketleri mevcuttur. Bu programlama dillerinden python programı akademik kurumların yanı sıra dünyanın en prestijli kurum ve kuruluşları tarafından da yaygın olarak kullanılmakta ve desteklenmektedir. İnşaat mühendisliği, bilgisayar mühendisliği, makine mühendisliği ve diğer alanlar dahil olmak üzere çeşitli mühendislik alanlarında python yazılım uygulamalarının kullanıldığını görmekteyiz (Kormaz, 2020).

Abbas Abbaszadeh Shahri, Chunling Shan, Emma Zäll, Stefan Larsson (2021) yaptıkları çalışmada sondaj sayısının yetersiz kaldığı durumlar için, üç boyutlu(3B) yazıcıları yapay zeka teknolojisi ile birleştirerek yer altı modellemesi yapmaktadırlar. Önerilen yaklaşım, bir Stockholm banliyösünde zemin kaya sondajlarından elde edilen 1968 adet veri seti üzerinde test edilmiştir. Modelleri C ve Python dillerinde geliştirip uyguladılar. Yapılan çalışmada modellerin, sondaj kuyularının sayısını ve ilgili maliyetleri azalttığı yönünde sonuçlara ulaştılar. Ayrıca makalede kod araçlarını

bilimsel metodolojilerle birleřtirmek, daha eksiksiz ve kullanıřlı 3B tahmine dayalı modellerin geliřtirilmesine de yardımcı olabileceđine deđinilmiřtir.

Tolon (2007) yaptıđı bir alıřmada, hangi parametrelerin řev stabilitesi üzerinde etkili olduđunu ve hangi parametrenin diđerlerine gore baskın olduđunu belirlemek iin yapay sinir ađına dayalı beř farklı model üzerinde eřitli kombinasyonlarla alıřmıřtır. alıřma da sismik katsayıların deprem ve geoteknik mhendisliđi iin nemine deđinilmiřtir. Ayrıca řev stabilitesine etkiyen parametrelerde, eđim yksekliđi ve su seviyesinin nemli parametreler olduđunu belirtmiřtir.

Tm bunların yanı sıra yapay zeka ok amalı bir teknolojidir. Bizler deneyimlerimizi yapay zeka sayesinde makinelere aktarma fırsatı bulduk. Yapay zeka teknolojisinin uygulamaları bizlere gnlk hayatta hemen hemen her alanda vazgeilmez rnlerler sunmaktadır. Bu rnler; web aramaları, bte modelleri, bilgisayar oyunları, otomatik iřlemciler ve diđer yapay zeka tabanlı uygulamalardır. Bunlar en iyi bilinen rneklerden sadece birkaçıdır (Tolon, 2007).

Bu tez kapsamında 4. Blm'de bahsedildiđi zere, veriler girdi ve ıktı verileri olarak dzenlenmiřtir. 5 adet girdi verisine karřılık 1 adet ıktı verisi hesaplanmasına ynelik yapılan python tabanlı yapay zeka modelinde ıktı tahmininin bařarı oranı %80-%99 aralıđında bulunmaktadır. Bylelikle yapay zeka alanında python tabanlı yapay sinir ađları modellerinin geoteknik mhendisliđinde uygulanabilmesinin n aılmak istenmektedir. Bu uygulanabilirlik ile yatay deplasmanın ve daha nice farklı modellerin geliřtirilmesi ile belirlenebilecek olan diđer nemli parametrelerin tahmini ile tasarımların; daha optimum yapılması, over-dizaynların nne geilmesi ve daha ekonomik olması, srelerin daha hızlı zlmesi, tasarım mhendisinin karar alma srecinin hızlandırılması ve bu srecin daha dođru ilerlemesine katkıda bulunulması, derin kazı destekleme sistemlerinin tasarımlarının řantiye boyunca devam ettiđi gerekđini dřnecek olursak tasarım mhendisine sađladıđı kolaylık nedeni ile tasarım mhendisinin farklı konulara odaklanmasına yardımcı olacađından sahadaki imalatın daha dođru yryebilmesini sađlayacak ve sahadaki problemleri zmeyi kolaylařtıracaktır. Bylelikle proje teslim tarihlerine olumlu bir etki sz konusu olacaktır. Etkin parametrelerin belirlenmesi ile literatr bazında odaklanmamız

gereken parametrelere farklı bir tartışma getirecektir. Yapay sinir ağıları bir çok farklı mühendislik disiplininde kullanılmakta olup geoteknik mühendisliğinde kullanımına 4. Bölüm’de yer verilmektedir. İstatistik bilimi ile ilgilenen tüm disiplinler python programı ile veri analizi ve verilerin görselleştirilmesini kullanmaktadır. Geoteknik alanında kullanımına ise 3. Bölüm ‘de yer verilmektedir. Ayrıca mevcut bir veri seti ile python programında kodlamanın nasıl yapıldığına dair bilgilere yine bu bölümde yer verilmektedir. Sonuç kısmında verilerin son haline göre model başarısını ortaya konulmaktadır. Tartışma ve Tavsiyeler Bölümü’nde bu sonuçlara göre yorumlara ve çıkarımlara yer verilmektedir. Bu bölüm, bu araştırmanın katkısını vurgular ve gelecekteki çalışmalar için önerilerde bulunur.



2. LİTERATÜR ÖZETİ

2.1. Zemin ve Kaya

İnşaat mühendisleri ve jeologlar, yer kabuğunu çoğu zaman kaya ve zemin olarak iki kısımda incelemiştir. Tabii ki de durum bu kadar basit değildir. Kaya; “yer kabuğunun büyük bir kısmını oluşturan, yekpare olarak bulunmayabilen veya bulunan, doğal bir şekilde ola gelen agrega veya mineral kütleleri” olarak tanımlanmaktadır (American Geological Institute, 1976). Buradaki, tanım patlatmaya dayalı kazı ve çimentolanmış sağlam kütleli mühendislik özelliği olarak mukavemeti iyi olanları ifade etmektedir.

Ancak yukarıdaki tanımlamalar da yeterli olmamaktadır. Bu durumu aşabilecek çeşitli argümanlar ile kaya ifade edilmeye çalışılmaktadır. Yumuşak kaya ve sağlam kaya argümanları genelde kazılabilen ve kazılamayan zeminler için kullanılsa da daha detaylı bir ayırım gerekmektedir.

Zemin ise, bir bağlayıcı madde ile tamamen veya kısmen çimentolanmamış değişik türden mineraller, organik atıklar, su ve hava karışımından oluşan bir malzeme olarak adlandırılabilir (Akın, Önalp., Ersin, Arel. 2018).

Yer kabuğunun kaya ve zemin olarak ayrışması biz geoteknik mühendislerine çoğu zaman almak durumunda olduğumuz yeraltı verilerini, yapacağımız deneyleri ve analizleri belirlemede ve onları yorumlamada kolaylık sağlamaktadır (Goodman, 1990).

2.2. Zemin Mekanik Önemli

Zemin Mekanik, organik bileşenlerin bir karışımını içerip içermediğine bakılmaksızın, kayaların mekanik ve kimyasal parçalanmasıyla üretilen tortular ve diğer konsolide olmayan katı parçacık birikimleriyle ilgilenen mühendislik problemlerine mekanik ve hidrolik yasalarının uygulanmasıdır (Terzaghi, K., ve

Peck, R.B., 1948). Zemin mekaniğinin temel teorilerinden bazıları, zeminin temel tanımı ve sınıflandırılması, efektif gerilme, kesme dayanımı, konsolidasyon, yanal toprak basıncı, taşıma kapasitesi, şev stabilitesi ve geçirgenliktir. Temeller, dolgular, istinat duvarları, toprak işleri ve yeraltı açıklıkları kısmen zemin mekaniği teorileri ile tasarlanmıştır.

Drenaj yapıları, boru hatları ve tüneller gibi yeraltı yapıları, istinat duvarları ve perdeler gibi toprak istinat yapıları ancak zemin mekaniği ilkeleri ve “zemin-yapı etkileşimi” kavramı kullanılarak tasarlanabilir ve inşa edilebilir. Çeşitli toprak basıncı teorileri, zeminlerin homojen, izotropik ve yatay olarak eğimli olduğunu varsayar. Bu varsayımlar, dikey bir düzleme karşı uygulanan yanal toprak basınçlarını hesaplarken hidrostatik veya üçgen basınç dağılımlarına yol açar. Kazının üstünde ve altında küçük azalmalarla birlikte ortalama toprak basıncı yükünün, derinlikle yaklaşık olarak aynı olduğu derin istinat kazılarında yapılan saha ölçümleri sonucunda gösterilmiştir. Bu ilk olarak Terzaghi tarafından 1936-42 yılları arasında Berlin Metrosu ve Chicago Metrosu projelerinde toplanan ampirik verilere dayanarak önerilmiştir (Terzaghi, K., ve Peck, R.B., 1948).

Yer altı yapıları temeller, derin kazılar, tüneller vb., üst yapıdan gelen sürsaj yüklerini iletmek için daha çok altındaki zemine bağımlı olmaktadır. Üst yapı tasarımında kendine özgü problemlerin yanı sıra, tekrarlayan yükleme, alt zeminin şişmesi ve büzülmesi ve donma etkisi ile zeminin iç yapısındaki gerilme farklılıklarını gibi etkenler üstyapının verimli tasarımını etkiler. Bu bağlamda zemin mekaniği dikkate alınması bir zorunluluktur ve zemin mekaniği bilgisi olmadan bir yapının tasarlanıp hayata geçirilmesinden bahsedilmesi söz konusu olamaz.

2.3. Zemin Deprem İlişkisi ve Önemi

Depremlerin yapılarda yol açtığı hasarlar incelendiğinde, yerel zemin koşullarının da bu hasarlara sebebiyet verdiği gözlemlenmektedir. Deprem sırasında kimi yumuşak zeminlerde zımbalama, kimi gevşek granüler zeminlerde görece aşırı oturmalar meydana gelmektedir. Yine bu tarz zeminlerin kumlu ve/veya siltli olmaları halinde depremin oluşturacağı gerilmeler sonucunda boşluk suyu basınçlarında meydana gelebilecek artışlar sonrası zeminin sıvılaşması ile zeminde oluşan

deformasyonlarından ötürü yapıda hasarlar meydana gelebilmektedir.

Deprem sırasında, sıvılaşmanın neden olduğu zeminde gerçekleşen çökme, önemli bir hasar nedeni olmuştur ve yerel zemin koşulları sıvılaşmaya elverişli olduğunda da olmaya devam edecektir. Bu sıvılaşma olgusunun insan yaşamı ve ekonomisi üzerinde önemli etkileri olmaktadır. Bu nedenle inşaat mühendisleri deprem-zemin ilişkisini araştırmaya heveslidir (Tolon, 2013).

Yakın tarihte meydana gelen depremler 1985 Michoacan depremi, 1989 Loma Prieta depremi, 1994 Northridge depremi, 1995 Kobe depremi, 1999 Kocaeli depremi ve 1999 ChiChi depremi dahil olmak üzere çok sayıda deprem, yerel jeolojik ve jeomorfolojik koşulların önemini göstermiştir (Youssef M. A. Hashash., Camilo Phillips., David R. Groholski, 2010). Ayrıca önemli hasar ve can kaybı, yerel saha koşullarının etkileriyle doğrudan bağlantı göstermektedir. Deprem yer etkilerini anlamak için, depremin yayılmasının ana kayadan en üstteki zemin katmanına kadar olan hareketini anlamak önemlidir. Deprem sırasında meydana gelen yatay ve düşey ek zorlanmalar zemin aracılığı ile yapıya aktarılmaktadır. Etki-tepki mekanizması göz önüne alındığında burada deprem-zemin, zemin-yapı, deprem-yapı etkileşimlerini anlamlandırabilmek önem arz etmektedir.

Birçok geoteknik yapının tasarımı deprem-zemin etkileşiminin anlaşılması ile tasarıma yansıtılabilmektedir. Bilindiği üzere yapı bütün olarak sistem bazında da değerlendirilmelidir. Bu bağlamda üst yapı, temel, zemin ve tüm bunların deprem performansının bir arada değerlendirilmesi ve bu etkileşimin anlaşılıp tasarıma yansıtılması daha doğru ve sağlıklı tasarımları beraberinde getirecektir.

2.4. Zemin Stabilite Problemi

İnşaat mühendisliği yapılarında çeşitli zemin türleri kullanılmaktadır, ancak bazı zemin türleri doğaları gereği inşaat için uygun olurken bazıları ise sorunlu zeminler olarak adlandırılır ve işlem görmeden mühendislik projelerinde uygulamaya dahil edilmeleri uygun değildir. Üst yapılar tarafından uygulanan yüklere dayanabilmeleri için bu zeminlerin kazılması, ardından değiştirilmesi veya mühendislik özelliklerinin iyileştirilmesi gerekmektedir (Steinberg, 2000).

Bir mühendislik yapısına başlanılmadan önce sahada fizibilite değerlendirmesi yapılmalıdır. Yapının oturacağı zeminin özellikleri hakkında bilgi edinmek için tasarım sürecine başlamadan önce sahanın araştırılması gerekmektedir. Bu gereklilikler aşağıdaki gibi olmalıdır:

- İstenilen yapının işlevi ve tasarım yükü.
- Kullanılması gereken temel türü ve mevcut zeminin taşıma kapasitesi.
- Proje arazisini terk etmek.
- Yapının oturacağı zemini değiştirmek.
- Proje alanı sınırlamalarını karşılamak için tasarımı değiştirmek.


Zaman geçtikçe, zeminin taşıma kapasitesinin yetersiz olması nedeniyle terk edilen proje arazileri sayısında önemli bir artış gözlenmiştir. Sonuç olarak, mühendislik özellikleri iyi denilebilecek bir arazi bulunması zor bir hale gelmiştir ve bu durum doğal kaynaklara olan talebi arttırmıştır. Sıvılaşmaya eğilimli olduğu düşünülen alanlar ile organik topraklar ve yumuşak kil ile kaplı alanlar, sanayi atıkları vs. ile kirlenmiş zeminler ve heyelan riskli zeminler gibi problemlili zeminler proje alanı haline gelmiştir. Gerçek şu ki, geoteknik projelerin çoğu için, değiştirilmemiş tasarım gereksinimlerini karşılayan bir şantiye bulmak neredeyse olası değildir. Problemlili zeminlerin performansını, inşaat mühendisliği standartlarının gerektirdiği seviyelere yükseltmek mümkündür (Akar Bakhtiyar Abdullah, 2019).

Maliyet etkisinden dolayı, geoteknik mühendisleri zemin stabilize problemi ile karşılaştıklarında pratikte genellikle ince taneli zeminlerin özelliklerini stabilizasyon yoluyla değiştirmeyi tercih ederler (Buhler ve Cerato, 2007; Hussey ve diğerleri, 2010).

Zemin stabilizasyonunun amacı, zemin danelerini birbirine bağlayıp geçirimsiz sıkı daneler elde etmek, zemini su geçirmez hale getirmek veya her ikisini birden yaparak zeminin mukavemetini artırmak ve suyun etkilerine karşı zeminin direncini arttırmaktır (Sherwood, 1993).

Ayrıca zeminler türüleri arasında; silt, organik zeminler ve killi turba gibi yumuşak zeminler, zeminlerin mühendislik niteliklerini iyileştirme ihtiyacını ortaya çıkardığı en yaygın stabilizasyon alanlarıdır (Sherwood, 1993).

Genel olarak, zemin stabilitesini mekanik ve kimyasal olarak derleyebiliriz. Mekanik stabilizasyon, zemin parçacıklarının doğasının fiziksel olarak değiştirilmesidir. Kompaksiyon işlemi, kompaksiyon enjeksiyonu, dinamik kompaksiyon gibi işlemler mekanik zemin stabilizasyonuna örnek olarak verilebilmektedirler (Keller, 2011).



Şekil 2. 1: Mekanik Stabilizasyona Örnek - Dinamik Kompaksiyon.

Kaynak: (Url-1, 2021)

Kimyasal stabilizasyon ise, zemini stabilize etmek için kullanılan çimentolu vb. malzemeler ile puzolanik malzemeler arasındaki kimyasal reaksiyon yoluyla gerçekleştirilir. Zeminin kimyasal stabilizasyonunu sağlamak için tek başına veya kombinasyon halinde bitüm, uçucu kül, kireç ve çimento vb. gibi malzemelerin eklenmesini içermektedir. Zemin stabilize olduğunda daha az sıkıştırılabilirlik, daha az geçirgenlik ve daha fazla mukavemete sahip olmaktadır (Keller, 2011).



Şekil 2. 2: Zeminlerin Kimyasal Stabilizasyonuna örnek - Kireçle Stabilizasyon.

Kaynak: (Url-1, 2021)

2.4.1. Kazı stabilitesi

İnşaat mühendisliğinde bir yapıyı projelendirirken sığ temel, derin temel, istinat duvarları ve hem çevre yapıların güvenliğini sağlamak hemde yapı çukurunu güvende tutmaya çalışmak gibi çözümlenmesi gereken durumlarla karşılaşmaktadır. Bu nedenle, kazıların ve çevrelerinin stabilize edilmesi için çeşitli destek sistemleri önerilebilmektedir. Bununla birlikte, kentsel alanlarda kazıların stabilitesini artırabilecek uygun bir destek sistemi seçmek, tasarım mühendisleri için uzun zamandır bir zorluk teşkil etmektedir. Bu alanlarda zaman zaman yakın mesafedeki zemin katmanları arasında kapsamlı değişikliklere neden olan değişken jeoteknik koşullar nedeniyle, gerilme-deformasyon alanı çok karmaşık ve geniş olmaktadır. Bu da uygun ve güvenli bir destek sisteminin seçilmesini ve tasarlanmasını zorlaştırmaktadır. Kazı alanları, inşaat sırasında zemin hareketleri ve bitişik yapılar üzerindeki yapısal etkiler nedeniyle genellikle önemli bir endişe kaynağı olmaktadır. Mühendislik açısından, desteklenen sistemlerinin servis ömrü boyunca takip edilmesi ve gözlemlenmesi önemlidir. Bu amaçla literatürde önemli sayıda teorik çalışma ve vaka çalışması yapılmıştır. Tasarımcılar sığ ve/veya derin kazıların

neden olduğu yer hareketlerini tahmin etmek için ampirik yerleşim zarflarını ve diğer yarı ampirik yöntemleri (örn., Goldberg ve diğerleri 1976; Mana ve Clough 1981; Clough ve O'Rourke 1990) kullanmaktadırlar.

Literatürde ölçülen ve tahmin edilen yer değiştirmeye ilişkin iyi belgelenmiş değerlendirmelerin çoğunda geriye dönük analizler kullanılmaktadır (Whittle ve diğerleri, 1993). Elastik modül, sürtünme açısı ve zemin kohezyonu gibi bir modelin jeoteknik girdi parametreleri, geri plandaki analitik senaryolarda saha verilerine göre kalibre edilerek daha doğru zemin ve duvar hareketi tahminleri elde edilmesi sağlanmalıdır. Geri analizin jeoteknik faktörler hakkında bilgi edinmede son derece faydalı olduğu kanıtlanmıştır (Du ve diğerleri, 2006).

Yine literatürde sığ veya derin kazılarda gözlemlenen yer değiştirmeleri veri madenciliği metodu ile tahmin etmek günümüz teknolojisi ile mümkün hale gelmektedir. Özgür (2019) doktora tezinde, derin kazı yapıları için veri tabanını kullanarak derin kazılardaki yer değiştirmelerin belirlenmesinde, veri madenciliği yöntemlerini araştırmıştır. Çeşitli yöntemler arasından modern bir bilgi işleme teknolojisi olan yapay sinir ağları yaklaşımı kullanılarak bir tahmin modeli oluşturmaktadır. Böylelikle derin kazılarda yer değiştirmelerin değerlendirilmesi, kurulan tahmin modeli kullanılarak başarılı bir şekilde tamamlanmıştır.

2.4.2. Derin kazılar ve destekleme sistemleri

Kentsel alanlarda inşaat söz konusu olduğunda derin kazılar bir zorunluluk haline gelmektedir. Bunun nedeni, kentsel alanlardaki mevcut yapıların yüzeydeki alanın çoğunu kaplaması ve bu nedenle mühendislerin yeraltı genişliklerini kullanmak zorunda kalmasıdır. Derin kazılarla uğraşırken, mevcut yapıların kazı tamamlanması öncesi, kazı aşaması veya sonrasında zarar görmemesi çok önemli olmaktadır. Bu nedenle, yer hareketlerinin büyüklüğünün ve dağılımının tahmin edilmesi ve bu hareketlerin en aza indirilmesi kesinlikle kritiktir. Destek sistemleri genellikle kritik yer hareketlerini önlemek ve/veya en aza indirmek için tasarlanır ve inşa edilmektedirler (Marulanda 2005).

Aşağıdaki resimler (bkz. Şekil 2.3, Şekil 2.4) Türkiye'nin metropolü İstanbul'da inşa

edilmiş yatay destek elamanı olarak ankraj ve boru destek elemanlarının kullanıldığı, düşey destek elamanı olarak da perde ve kazık taşıyıcı elemanlarının kullanıldığı derin kazı uygulamalarını göstermektedir.



Şekil 2. 3: Tuna Taksim Otel İksa Projesi – Dünya Zemin

Kaynak: (Url-2, 2021)



Şekil 2. 4: Vadipark Seyrantepe Rezidans İksa Projesi - Dünya Zemin

Kaynak: (Url-3, 2021)

Derin kazıların destek elemanlarını tasarlarken Marulanda'ya (2005) göre üç koşul ele alınmalıdır:

- Zeminde kabarma ve borulara karşı direnç
- Destek sisteminin yenilmesi
- Çevre yapılarına zarar verebilecek yanal yer hareketlerinin azaltılması.

Bu koşullar nedeniyle mühendisler, derin kazıları analiz ederken stabilite ve deformasyonu dikkate almalıdır (Marulanda, 2005).

Clough ve O'Rourke (1990), duvarların hareketini yerinde inceleyerek, yer hareketi modellerini ve oturma dağılımlarını tahmin etmenin mevcut yollarını araştırdılar. Ayrıca inşaat faaliyetleri, kazı ve destek elemanlarının sürece etkilerini değerlendirmek için güncellenmiş mevcut verileri kullanmışlardır. Onlara göre, duvarlardaki hareketler; yeraltı suyu ve zemin durumu, kazı derinliği ve şekli, duvar destek durumu, sürşarj yükleri, duvar sertliği, duvar yapım tekniği ve bunların yapım süreleri gibi yönlerden etkilenmektedir. Ancak duvar hareketlerinin ana nedenlerinden biri de destekleme ve kazı yöntemi ile ilgilidir.

Derin kazı elemanlarında meydana gelen stabilite ve deformasyon problemleri:

- İnşaat tekniği: Deneyimsiz inşaatçılar ve jeoteknik mühendisleri, ortalamanın altında duvar inşaatına neden olarak önemli duvar hareketlerine neden olabilir.
- Duvar montaj yöntemi: Yer hareketlerine, yerinde duvar sürme yöntemleri ve konumları neden olabilir.
- Kazı derinliğini destek alanının çok altına uzatmak duvar hareketine neden olabilir.
- Derin temel inşası ve kaldırılması: Yıkım veya yenileme durumunda, mevcut derin temeller harekete neden olabilecek yenileri ile değiştirilmelidir.

Ayrıca tasarımcı, duvar hareketleri üzerinde önemli bir etkisi olan kazı destek

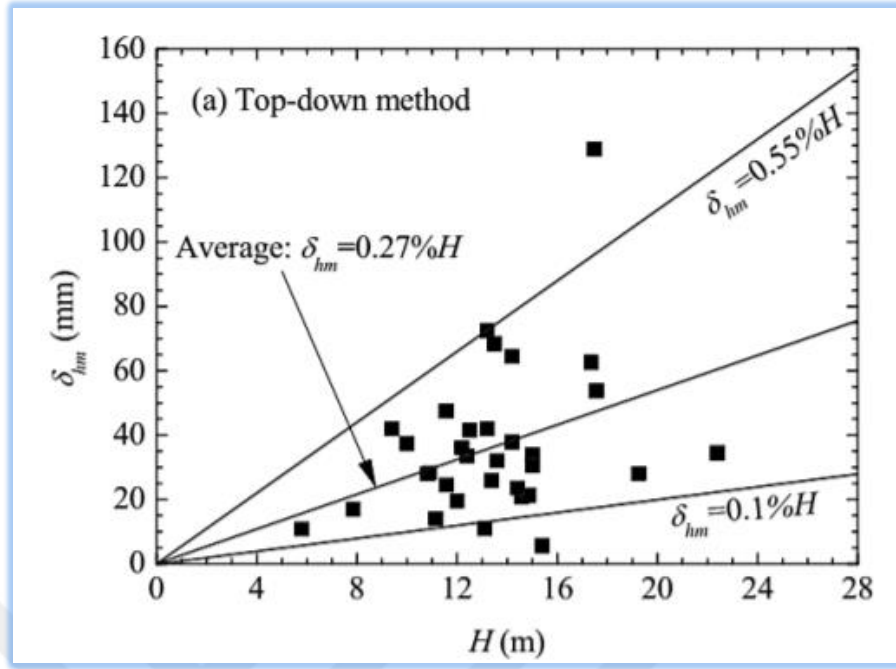
sisteminden sorumludur. Duvar hareketini azaltmak için tasarımcı duvar sertliğini artırabilir. Ek olarak, yatay ve/veya dikey destek aralığının ve rijitliğinin artırılması, duvar hareketlerini azaltacaktır. Yerinde duvarın önceden yüklenmesi, zemin hareketini azaltmak için başka bir seçenektir.

Wang ve arkadaşları (2009), yapmış oldukları araştırma sonuçlarını duvar tipine ve yapım tekniğine göre sınıflandırmıştır. Yukarıdan aşağıya yöntemi, dördü bitişik kazık duvar (CPD) ve diğer 28'i diyafram duvar (DD) olmak üzere 32 örnek oluşturmak için kullandılar. 92 vakada aşağıdan yukarıya diyafram duvar (DW), 78 vakada bitişik kazık duvar(CPD) ve 30 vakada bileşik derin toprak karıştırma kolonları (CDSM) kullanılmıştır. 11 vaka palplanş duvar (SPD), 23 vaka bileşik zemin çivisi duvarı (CSN) ve 34 vaka derin zemin karıştırma kolonları(DSM) duvarıdır. Tüm durumlar için, aşağıdaki Şekil 2. 5-9'da duvarın yatay hareketi (δ_{hm}) ile kazı derinliği (H) arasındaki ilişkiyi göstermektedir.

Wang, J. H., ve arkadaşları (2009) çalışmaları sonucunda şu sonuçlara varmıştır:


- Yukarıdan aşağıya inşaat yöntemi için δ_{hm} değerleri %0.1H ile %0.55H arasında değişmektedir; ortalama %0.27H (bkz. Şekil 2. 5).
- İnşaatların ve rijit duvarların (DD, CPD ve CDSM) aşağıdan yukarı yöntemi için δ_{hm} değerleri %0.1H ile %1.0H arasında değişmektedir; ortalama %0.4H (bkz. Şekil 2. 6).
- SPD için duvar deplasmanı %3.2H'ye kadar büyür; ortalama %1.5H (bkz. Şekil 2. 7).
- CSN duvarları için δ_{hm} değerleri %0,2H ile %0,9H arasında değişmektedir; ortalama %0.55H (bkz. Şekil 2. 8).
- DSM duvarlar için δ_{hm} değerleri %0.3H ile %2.4H arasında değişmektedir; ortalama %0.91H (bkz. Şekil 2. 9).
- Duvarların maksimum yatay hareketi büyük ölçüde duvar tipine bağlıdır.
- Hafriyat derinliği arttıkça duvar hareketleri artar.

Diğer bir değişle, sistemin rijitliği yanal yer değiştirmede önemli rol oynamaktadır.



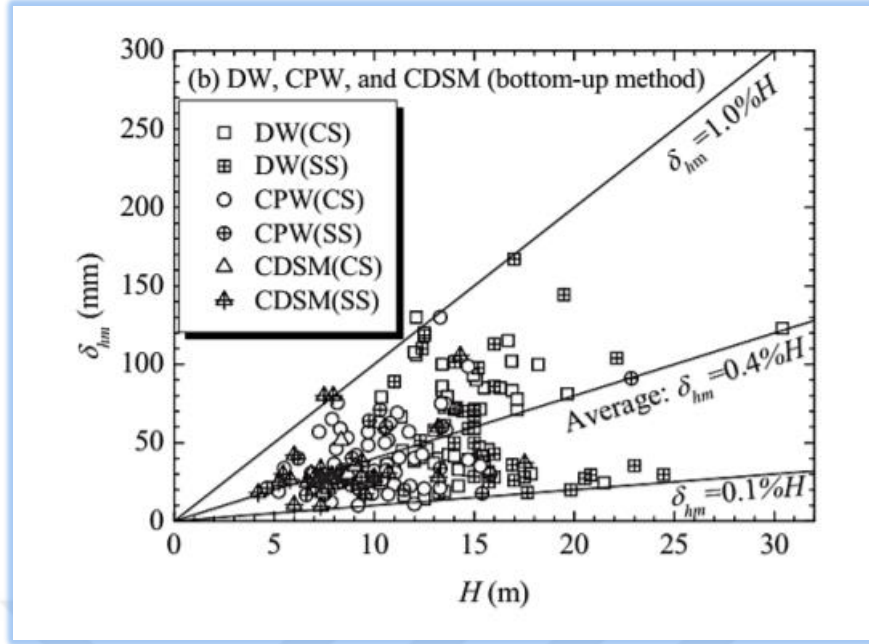
Şekil 2. 5 : Kazı Derinliği Boyunca Duvarın Yatay Hareketi - Yukardan Aşağıya Metod

Kaynak: Wang, J. H., Xu, Z. H., and Wang, W. D., (2009)




Şekil 2. 6: Kazı Derinliği Boyunca Duvarın Yatay Hareketi- Bileşik Zemin Çivisi

Kaynak: Wang, J. H., Xu, Z. H., and Wang, W. D., (2009)




Şekil 2. 7: Kazı Derinliği Boyunca Duvarın Yatay Hareketi - Dyafram Duvar, Bitişik Kazık Duvar, Bileşik Derin Karıştırma

Kaynak: Wang, J. H., Xu, Z. H., and Wang, W. D., (2009)



Şekil 2. 8: Kazı Derinliği Boyunca Duvarın Yatay Hareketi - Derin Karıştırma

Kaynak: Wang, J. H., Xu, Z. H., and Wang, W. D., (2009)



Şekil 2. 9: Kazı Derinliği Boyunca Duvarın Yatay Hareketi - Palplanş Duvar

Kaynak: Wang, J. H., Xu, Z. H., and Wang, W. D., (2009)

2.4.3. Yanal zemin hareketi

Zeminler hem yatayda hem de düşeyde gerilmeye sahiptirler. Zeminde oluşan gerilme durumu zeminin sükunet hali, aktif hali ve pasif hali olmak üzere temelde üç gerilme durumu ile ifade edilmektedir. Yan hareketlerin ana unsuru yanıl toprak basınçlarıdır. Bu tez yanıl ötelenme ile ilgili olduğu için zemin yanıl gerilmeleri ile ilgilenilmiştir.

Destekleme sistemlerine etkileyen yanıl toprak basıncını hesaplamak gerekirse; zeminin içsel sürtünme açısını(\emptyset) ve kohezyonuna(c) bağılı olan zeminin aldığı yükü ifade eden toprak basınç katsayısı K'yı, zeminin birim hacminin ağırlığını (δ), yanıl itkinin hesaplanmak istendiğı noktanın derinliğini(z), yine o noktadaki toprak basıncını (P_h) bilmek gerekir (Coduto, 2001)..

$$P_h = \delta \cdot K \cdot z \quad (2.1)$$

Yanal toprak basıncı, zemin niteliklerinin yanı sıra zemin ile istinat duvarı arasındaki yapı-zemin etkileşimi ve bunların bağılı yer değıştirmelerinden etkilenmektedir. Yukarıda tartışılan üç ana basınç türü de, zemin ile destekleme elemanı arasındaki

etkileşimi, yani bağıl hareket durumunun bir fonksiyonu olarak gerilme biçimini ve büyüklüğünü içermektedir.


2.4.4. Sükunetteki zeminin gerilme durumu

Zeminde hareketin olmadığı, zeminin ve destekleme elemanının birbirlerine göre bağıl olarak hareket etmediği durumdur.

$$P_0 = \delta \cdot K_0 \cdot z \quad (2.2)$$

P_0 ifadesi sükunetteki zeminin gerilmesini ifade etmektedir.

Destekleme elemanını, rijit ve ankastre mesnetli kabul ettiğimizde, destekleme elemanının arkasında yer alan zeminde yanal bir hareket meydana gelmemektedir. Bu durumun zeminin doğal durumuna göre bir farklılık vermemektedir. Bu haldeki zemin gerilme durumuna sükunetteki zemin gerilme durumu denilmektedir. Toprak basıncı katsayısı da K_0 olarak adlandırılmaktadır (Coduto, 2001).



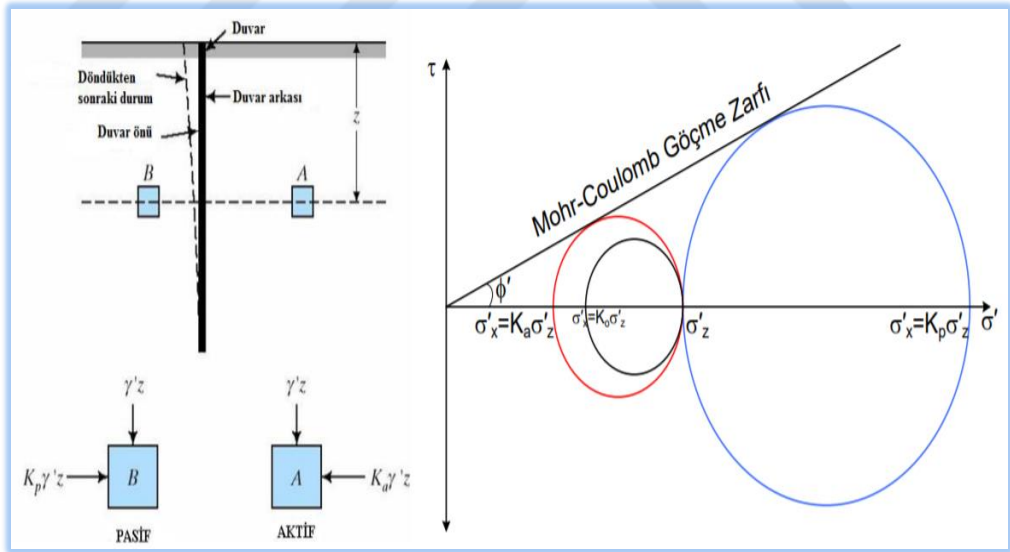
Şekil 2. 10: Sükunetteki Zeminin Toprak Basıncı

Kaynak: Coduto (2001)

2.4.5. Aktif zemin gerilme durumu

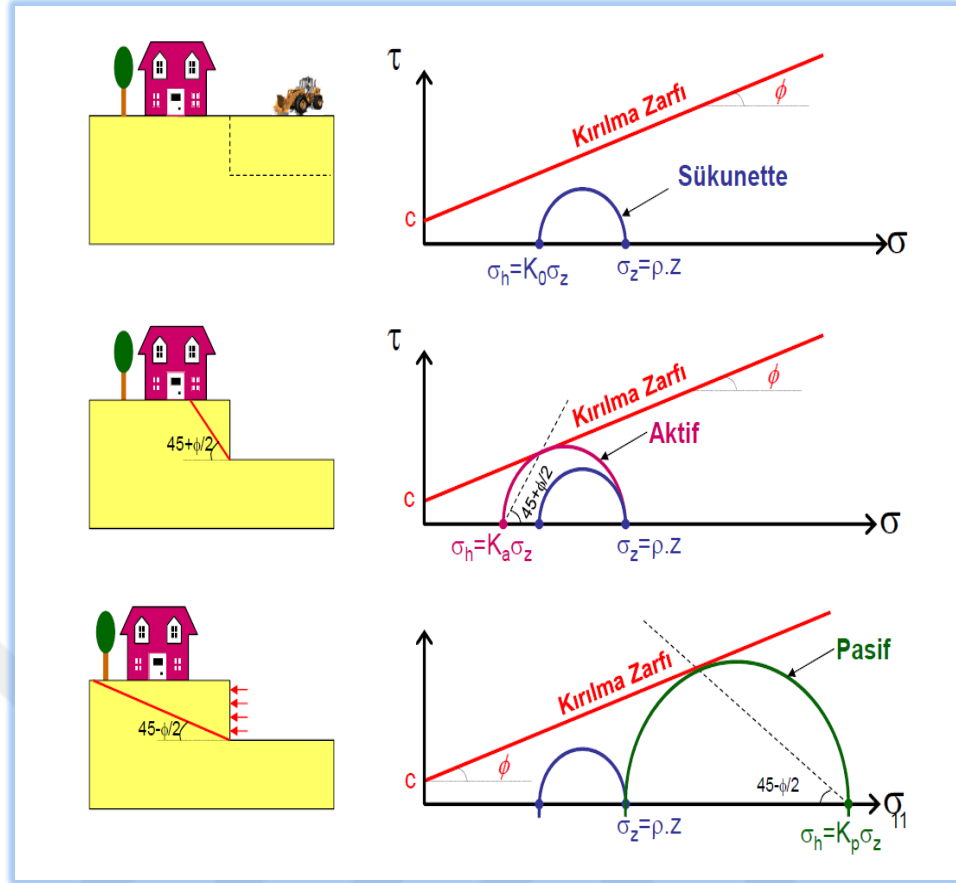
Destekleme elemanlarının arkasında yer alan zemin kitlesi yapı çukuruna doğru hareket ediyorsa bu durum aktif toprak basıncı olarak adlandırılmaktadır ve K_a ile de gösterilir. K_a aktif zemin gerilme katsayısı olmaktadır. Zemin hareketi sırasında zemin tanecikleri birbirinden uzaklaşmaya başlar, bu uzaklaşma boyunca zemin gerilmesi gittikçe azalmaktadır. Zemin elastik davranıştan plastik davranışa geçtikten sonra plastik dengeye ulaşmakta ve zemin yenilmeye uğramaktadır (Coduto, 2001).

Şekil 2. 11 'de gösterilen A ve B için; Duvar hareketi etkisiyle A için pasif zemin gerilmesi durumu, B için ise aktif zemin gerilmesi durumu oluşmaktadır. Şekilde grafik üzerinde kırmızı olarak B(aktif), Mavi olarak ise A(pasif) gösterilmektedir. Yanal gerilme durumundaki azalış A elemanında yenilmeye yani göçmeye neden olurken, yanıl gerilmedeki artış ise B elemanında göçmeye neden olacaktır. Her iki gerilme durumunda yenilmeler Mohr-Coulomb göçme zarfına teğet olunca meydana gelmektedir ve zeminlerin burada plastik dengeye ulaştıkları kabul edilmektedir (Url-4, 2021).



Şekil 2. 11: Aktif ve Pasif Zemin Gerilme Durumu için Mohr-Coulomb Göçme Zarfı

Kaynak: (Url-4, 2021)



Şekil 2. 12: Aktif ve Pasif Zemin Gerilme Durumlarının Ayrı Ayrı Gösterimi - Mohr Coulmb Göçme Zarfı

Kaynak: Sedat, S., Ertan, B., Aşkın, Ö., (2018)

Şekil 2. 11'den de anlaşılacağı üzere, pasif koşula ulaşmak için aktif koşuldaki gerilmeden daha fazla gerilme bu anlamda da hareket meydana gelmelidir.

Çeşitli zeminler için gerekli tipik hareketler Tablo 2. 1'de verilmiştir. Burada H destekleme elamanı yüksekliğini ifade etmektedir.

Tablo 2. 1: Aktif Zemin Gerilmesinin Sağlanabilmesi İçin Oluşması Gereken Destekleme Sistemi Hareketi

| Zemin Türü | Aktif Koşula Erişmek İçin Gerekli Yatay Hareket |
|---------------------|---|
| Sıkı, kohezyonsuz | 0,001H |
| Gevşek, kohezyonsuz | 0,004H |
| Sert, Kohezyonlu | 0,010H |
| Yumuşak, kohezyonlu | 0,020H |

Kaynak: Coduto (2001)

Kohezyonsuz zeminler için K_a (Denklem 2.3) (Coduto, D.P., 2001);

$$K_a = \frac{1 - \sin\phi'}{1 + \sin\phi'} = \tan^2\left(45 - \frac{\phi'}{2}\right) \quad (2.3)$$


Kohezyonlu zeminler için K_a (Denklem 2.4) (Coduto, D.P., 2001);

$$K_a = \tan^2\left(45 - \frac{\phi'}{2}\right) - \frac{2c'}{\sigma'_v} \tan\left(45 - \frac{\phi'}{2}\right) \quad (2.4)$$

Denklem 2.4 'te, σ'_v ile gösterilen sembol efektif gerilmeyi göstermektedir.

2.4.6. Pasif zemin gerilme durumu

Destekleme elemanlarının arkasında yer alan zemin kitlesi yapı çukurunun tersi yönde hareket ediyorsa bu durum pasif toprak basıncı olarak adlandırılmaktadır ve K_p ile de pasif zemin gerilme katsayısı olarak gösterilmektedir (Sedat, S., Ertan, B., Aşkın, Ö., 2018). Rankine (1857), Şekil 2. 13'de zeminin sükunetteki durumundan pasif duruma geçtiği halinin göstermektedir.



Şekil 2. 13: Pasif Toprak Basıncı Hareti

Kaynak: Rankine (1857)

Şekil 2. 13’de görülebileceği gibi pasif durumda kesme yenilmesi $45 - \frac{\phi'}{2}$ ‘de başlamaktadır.

Kohezyonsuz zeminler için K_p (Denklem 2.5) (Coduto, D.P., 2001);

$$K_p = \frac{1 + \sin \phi'}{1 - \sin \phi'} = \tan^2 \left(45 + \frac{\phi'}{2} \right) \quad (2.5)$$

Kohezyonlu zeminler için K_p (Denklem 2.6) (Coduto, D.P., 2001);


$$K_p = \tan^2 \left(45 + \frac{\phi'}{2} \right) + \frac{2c'}{\sigma'_{v'}} \tan \left(45 + \frac{\phi'}{2} \right) \quad (2.6)$$

K_p burada maksimum değer almaktadır. Zeminin pasif duruma geçebilmesi için kazı yüksekliğine ve destekleme elemanının yüksekliğine bağlı olacak şekilde bazı limit durumlara ulaşması gerekmektedir. Bu limit durumlara zeminin ulaşabilmesi aktif durumdan daha yüksek değerlerde gerçekleşmektedir.

Tablo 2. 2: Pasif Zemin Gerilmesinin Sağlanabilmesi İçin Oluşması Gereken Destekleme Sistemi Hareketi

| Zemin Türü | Aktif Koşula Erişmek İçin Gerekli Yatay Hareket |
|---------------------|---|
| Sıkı, kohezyonsuz | 0,020H |
| Gevşek, kohezyonsuz | 0,060H |
| Sert, kohezyonlu | 0,020H |
| Yumuşak, kohezyonlu | 0,040H |

Kaynak:Coduto (2001)



Şekil 2. 14: Aktif ve Pasif Toprak Basıncının Destekleme Sistemi Üzerine Etkisi

Kaynak:Coduto (2001)

Desteklenen zeminde çok daha küçük mertebelerde hareketler yaşandığında bile

yanal zemin basıncında önemli deęişmelere neden olmaktadır. Terzaghi (1934b), dayanma yapıları hakkında gerçek ölçekli arařtırmalar yapmış ve řu sonuçları gözlemlemektedir:

- Dayanma yapısının arkasında sıkıřtırılmış kum dolgu ile dayanma yapısındaki hareket, dolgu derinliğinin binde birine eşittir ve yanal toprak basıncı katsayısı 0,2'ye düşürebilir veya 1,0'e kadar arttırabilmektedir. Bu etki dięer zeminlerdeki yani kohezyonlu ve/veya içsel sürtünme açısı çok düşük olan zeminlerde geçerli deęildir.

2.4.7. Rankine teoremi ve coulomb teoremi


Bowles, J.E., (1990), zeminin hem elastik hem de plastik davranıřlar sergilediđini belirtmiřtir. Pasif ve aktif zemin gerilmesini belirlemede en yaygın kullanılan yöntemler Rankine ve Coulomb tarafından geliřtirilen teorilere dayalı formüllerdir. Coulomb ve Rankine, zeminin belirli bir yönde yenildiđi varsayımına dayalı geliřtirdikleri teoriler ile Şekil 2. 13'de gösterildiđi gibi, kırılma düzleminin oluřması için ya sınır yer deęiřtirme deđerini aşacak kadar ileriye dođru hareket etmeli ya da sınır yer deęiřtirme deđerini aşacak kadar kendisine dođru hareket etmelidir. Duvar uzunluđu ile iliřkili sınır yer deęiřtirme deđerini aşmıyorsa kırılma zarfı oluřmaz. Bunun nedeni, toprađın elastikiyetini kaybetmesine neden olan tanecikler arasının yeterince açılmasıdır ve aralarındaki çekim etkisi hala bir deđerdedir. Bu gibi durumlarda, elastoplastik özelliklere sahip zeminin elastik ve plastik davranıřları dikkate alınmalıdır.

Rankine (1857), teorisinin sađlanabilmesi için bazı kabuller yapmaktadır:

- Zemin homojen ve izotropdur.
- Şekil 2. 15'de görüldüđu gibi, Zemin yenilme durumu dođrusaldır. Gerçekte bu durum destekleme elemanının soket mesafesine yaklařtıkça içbükey bir hal almaktadır. Dođrusal Kabul bu içbükeyliđi kabul edilebilir bir şekilde basitleřtirir.
- Destekleme sistemi sonsuz uzunlukta ve iki boyutlu olarak incelenir.

- Destekleme sistemi ve arkasındaki zemin arasında sürtünme ihmal edilebilir.
- Destekleme sistemi pasif ve aktif zemin gerilmesi oluşturacak kadar hareket ettiği düşünülür (Coduto, D.P., 2001).


Bu kabuller eşliğinde aktif yanal toprak basıncı yani zemin aktif yanal gerilmesi (P_a) genel ifadesi (Denklem 1.7) ile gösterilmiştir.



Şekil 2. 15: Dayanma Yapıları Arkasındaki Zemin Basınçlarının a) Teorik ve b) Gözlenen Durum

Kaynak: Coduto (2001)

$$P_a = -2c\sqrt{K_a} + K_a \cdot \delta \cdot H \quad (2.7)$$



Şekil 2. 16: Destekleme Sistemeine Etki Eden Aktif Toprak Basıncı ve Destekleme Sisteminin Arkasında Yer Alan Zeminin Yatayda Yaptığı Aç

Kaynak: (Url-4, 2021)

Şekil 2. 16'da destekleme sisteminin arkasında yer alan zeminin yatayda yaptığı açının (β) sıfırdan farklı pozitif doğrultuda bir açı olduğunu düşünürsek;

Aktif durumda:

$\beta \leq \emptyset$ ise;

$$K_a = \frac{\cos\beta - \sqrt{\cos^2(\beta) - \cos^2(\emptyset)}}{\cos\beta + \sqrt{\cos^2(\beta) - \cos^2(\emptyset)}} \quad (2.7)$$

$\beta = 0$ ise;

K_a 'nın formülü (Denklem 2.3) te verilmektedir.

Şekil 2. 16 da duvara etkiyen teorik normal basınç ve teorik kesme gerilmeleri sırasıyla;

$$\sigma = \sigma'_z \cdot K_a \cdot \cos\beta \quad (2.8)$$

$$\tau = \sigma'_z \cdot K_a \cdot \sin\beta \quad (2.9)$$

Rankine Toerisi'nin geçerli olduğu bir durumda, üçgen dağılım gösteren yanal toprak basıncı sonucunda doğan ve birim genişlik başına düşen bileşke kuvvetin en genel hali (Denklem 2.10) da gösterilmektedir (Coduto, D.P., 2001).

$$F_a = \frac{H^2 \cdot \delta \cdot K_a}{2} \quad (2.10)$$


Pasif Durum da:

Şekil 2. 17 'de pasif duruma göre serbest cisim diyagramı gösterilmektedir. Şekil 2. 17'deki bazı sembollerin anlamları:

P_a / b = duvarın birim uzunluğu başına zemin ve duvar arasındaki normal kuvvet

V_a / b = duvarın birim uzunluğu başına zemin ve duvar arasındaki kesme kuvveti

b = duvarın birim uzunluğu (genellikle 1 ft veya 1 m)



Şekil 2. 17: Pasif Durum İçin Rankin Serbest Cisim Diyagramı

Kaynak: Coduto (2001)

$\beta \leq \emptyset$ ise;

$$K_p = \frac{\cos\beta + \sqrt{\cos^2(\beta) - \cos^2(\emptyset)}}{\cos\beta - \sqrt{\cos^2(\beta) - \cos^2(\emptyset)}} \quad (2.11)$$

$\beta = 0$ ise;

K_p 'nın formülü (Denklem 2.5) te verilmektedir.

Rankine Teorisi yukarıda anlatıldığı gibidir. Coulomb Teorisi Rankinden farklılıklar göstermektedir.

Coulomb Teorisine göre Destekleme Sistemlerinde; Coulomb (1776) teorisinin sağlanabilmesi için bazı kabuller yapmaktadır:

- Zemin tabakalar halinde olabilir(yatay olmak şartıyla) ve bu tabakaların zemin özellikleri aynıdır.
- Destekleme sistemi arkasındaki zemin yüzeyi eğimli olsa da bir düzlemdir.
- Destekleme yapısının üzerinde ve/veya zemin üzerinde bir sürsaj yükü varsa

lineer olarak tüm alana yayılır.

- Destekleme sistemi arkasındaki zemin eğimli ise kohezyonsuz zemin olması. Kohezyonlu zemin de eğim sıfır durumunda ise (Denklem 2.7) gibi formüle edilir (Birand, A., 2006).

Coulomb Teorisi ile Rankine Teorisi arasındaki en önemli farklardan biri toprak basıncı katsayısıdır. Bu K_a değerini daha basit bir biçim de ifadesi (Denklem 3.2) de gösterilmiştir (Müller-Breslau, H., 1906), Tschebotarioff, Gregory P., 1951).

$$K_a = \frac{\cos^2(\phi - \alpha)}{\cos^2 \alpha \cdot \cos(\theta - \alpha) \left(1 + \sqrt{\frac{\sin(\phi + \theta) \cdot \sin(\phi - \beta)}{\cos(\theta + \alpha) \cdot \cos(\alpha - \beta)}} \right)^2} \quad (2.12)$$

Denklem 2.12 deki eşitliği sadece $\beta \leq \phi$ olduğu zaman geçerlidir.

Denklem 2.12 deki bilinmeyen semboller:

α = duvarın düşeyden eğikliği

θ = duvar – zemin arayüzeyinin sürtünme açısıdır.

Beton veya taş duvarları tasarlarken, $\theta = 0,67\phi$ alınması yaygın bir uygulamadır. Çelik duvarların kesme sürtünmesi daha azdır (muhtemelen $\theta = 0,33\phi$ mertebesindedir).

Coulomb pasif toprak basıncı için bir formül geliştirmemiştir. Farklı araştırmacılar Coulomb 'un teorisinden faydalanarak pasif toprak basıncı formülünü geliştirmişlerdir. Destekleme sistmine etki eden sürtünme kuvvetinin hesaba dahil edilmesi ile pasif toprak basıncı önemli miktarda artmaktadır. Mühendisler çoğu zaman bu etkiyi göz ardı edebilmektedirler (Dunn, I. S., Anderson, L. R., ve Kiefer, F. W., 1980).

Aynı şekilde Birand 2006'da duvar sürtünmesinin hesaba dahil edilmesinin pasif toprak basıncının artacağını bu nedenle mühendislerin sürtünmeyi ihmal etmeyi tercih edebileceği belirtilmektedir.

Pasif toprak basıncı katsayısı (Denklem 3.3) gösterilmiştir.

$$K_p = \frac{\cos(\theta)^2}{\left(1 - \sqrt{\frac{\sin(\theta) \cdot \sin(\theta + \beta)}{\cos(\beta)}}\right)^2} \quad (2.13)$$

2.4.8. Derin kazı destekleme sistemi

Derin kazı destekleme sistemleri bir yapı çukurunda veya şevde desteklenen zeminin dengede kalmasını sağlamak amacıyla inşa edilen kalıcı ya da geçici olarak tasarlanmış zemin tutma yapısı olarak genellenebilirler. Eğer ki kalıcı bir derin kazı destekleme sisteminden bahsediliyorsa hesaplamada deprem yüklerinin dikkate alınması gerekmektedir. Geçici kazı destek elemanlarında deprem yükleri hesaba dahil edilmemektedir.

2.4.8.1. Diyafram duvarlar

Diyafram duvarlar, dünya genelinde şehir merkezlerindeki derin kazılarda yaygın olarak kullanılan bir yerinde dökme istinat duvarı sistemidir. Derin su kesme duvarları bodrumlar, alt geçitler, rıhtım duvarları ve diğer yapılarda genellikle diyafram duvarlar kullanılmaktadır. Diyafram duvar düşük gürültülü, düşük titreşimli bir teknikte inşa edilebilirler. Bu duvarlar orta derecede deformasyona sahiptir ve bu nedenle daha çok dayanma duvarı olarak kullanılmaktadır. Diyafram duvar mekanik olarak kazılmış bir hendekte inşa edilen ve betonarme bir perdeden oluşmaktadır. Kazı sırasında çökmenin önlenmesi için kazı bentonit çamuru ile doldurulmakta ve hihayetinde bulamacın yerini beton almaktadır (Puller, 2003).



Şekil 2. 18: Diyafram Duvar Makinesi


Kaynak: (Url-5, 2021)

Destekleme sistemlerinin diğere tipleri de düşünöldüğünde hem kalıcı hem de geçici olsun, diyafram duvar orta ve büyük derinliklerde maliyet ve inşaat süresi açısından genellikle verimlidir. Diğere yandan geçici tipte tasarlanan destekleme sistemleri için yerinde dökme betonarme duvarlardan daha maliyetli olabilmektedir. Bunun nedeni genellikle yüksek maliyetli makine gideri olarak bilinmektedir. Diyafram duvarlar hemen hemen her tür toprakta inşa edilebilir ve tipik olarak yeraltı suyunun düşürölmesini gerektirmemektedir (Puller, 2003).

Tripod kulelerinden veya vinçlerden iple asılan halat kepçeleri veya vinçlere bağılı Kelly çubuklarına monte edilen kepçeler en yaygın iki seçenek olarak karşımıza çıkmaktadır. Fakat bu iki metod kaya kazıları konusunda uygulanabilir değildir. Bu durumlarda alternatif olarak ters sirkölasyonlu raylı sistemler ilk olarak 1970 lerde Japonya'da çözüm olarak öne çıktı. Hydrofraise ve Trenchcutter teçhizatlarına benzer şekilde bulamaçtan kesikleri çıkarmak için çalkalayıcı elekler ve siklonlar kullandı (Puller, 2003).

Optimum kazı ekipmanı: halatlı kepçe veya kesici, çoğunlukla derinlik ve tolerans gereksinimlerinin yanı sıra belirli toprak veya kaya tipine göre belirlenir. Modern kesici makineler, 200 Mega Pascal'a (MPa) kadar basınç dayanımına sahip kayaları kesebilir ve toprakta 100 metreden fazla derinliklere kadar kazabilir. Karşılaştırılabilir işler için, kesici makineleri, kesicilerin dış kenarlarında küçük makaralı uçlarla tasarlanmıştır. Dikey olarak 50 metre derinliğe kadar %0,3 toleransa ulaşılabilir. Diyafram duvar kazı tekniğı; kılavuz duvarlar (bkz. Şekil 2. 19), ana diyafram duvar kazısı başlamadan önce inşa edilir (prefabrik kılavuz duvarlar kullanılabilir).

Kılavuz duvarların genişliğı iş makinasının çalışabilmesi için diyafram duvarın genişliğinden 5 santimetre (cm) daha geniş yapılmalıdır. Ayrıca fazla bentonit süspansiyonu için panel kazısı ve akış hendeklerine kılavuz görevi görmeyen yanı sıra referans yükseklik olarak ve inşaat demiri kafeslerini asmak için de kullanılır (Puller, 2003).



Şekil 2. 19: Klavuz Duvar Gösterimi - Diyafram Duvar

Kaynak: Puller (2003).

Ağır ve hacimli mekanik kepçeler, zorlu kazı koşullarında ve kalın veya derin paneller için kullanılır (bkz. Şekil 2. 20). Ağırlıkları, duvarın dikey kalmasına yardımcı olan bir sarkaç etkisi sağlamaktadır. Daha büyük uzunlukları aynı zamanda bir dikeylik dengeleyici görevi görmektedir. 12 tona ulaşabilen devasa ağırlıkları, sert toprak oluşumlarının yanı sıra daha yumuşak ve çatlaklı kayaların kazılmasına yardımcı olurlar. Bununla birlikte, büyük taşıyıcı kulelerin kullanımına ihtiyaç duymaktadırlar. Ayrıca çelik kablolu otomatik mekanik kepçeler daha yavaş bir manevra hızına sahip olmaktadır (Puller, 2003).



Şekil 2. 20: Vinçe Montelenmiş Kepçe Ağzı


Kaynak: Puller (2003).



Şekil 2. 21: Kelly'e Montelenmiş Kepçe Ağzı - Boom Üzerindedir

Kaynak: Puller (2003).

Hafriyat için ters sirkülasyonlu döner kesiciler ters sirkülasyonlu döner kesici, kayaları veya sert araziye yanal veya dikey olarak dönen kesici kafaları kullanarak kazmak için karmaşık bir hidrolik kesici kullanılırken, büyük çamur pompaları bentonitin ters sirkülasyonunu kontrol eder ve kazının tabanındaki kalıntıları temizlemek için karıştırır. Bentonit karışımı daha sonra desander ve desilter ile temizlenir ve yeniden kullanılırken süzölmüş çakıl, kum ve silt atılmaktadır (Şekil 2. 22).



Şekil 2. 22: Ters Sirkülasyon Tekniği ve Hidrolik Kesici - Diyafram Duvar

Kaynak: Puller (2003).

Şekil 2. 22 'deki numaralandırmalar:

1. Hendek Kesici
2. Kesici çamur pompası
3. Desander
4. Bulamaç tankı
5. Santrifüj pompa
6. Kazılan toprak
7. Santrifüj pompa
8. Bentonit karıştırıcı
9. Bentonit silosu
10. Su



Şekil 2. 23: Durdurucular - Diyafram Duvar

Kaynak: Puller (2003).



Şekil 2. 24: Panellerin Kumdan Arındırılması - Diyafram Duvar

Kaynak: Puller (2003).

Jeoteknik veriler, hendek kazısı sırasında kumlu zeminlerin (veya ana kayanın) bulamaç ile karışacağını gösteriyorsa, bu durumda, bulamacın maksimum kum içeriği ve/veya maksimum bulamaç yoğunluğu gibi kum giderme gereksinimleri, beton yerleştirmeden önce yerine getirilmelidir. Bazı durumlarda da kirlenmiş bulamacın taze bulamaçla değiştirilmesi gerekebilmektedir (Puller, 2003).

Donatı kafesinin yerleştirilmesi; donatı kafeslerinin uzunluğu projeden projeye değişmektedir. Bireysel paneller genellikle ikiden fazla kafes parçasından oluşan sürekli bir kafes içine alınır. Hendeğe indirme öncesinde ve sırasında kafes parçaları birbirine bağlanır. Duvarda önceden ayarlanmış "kutu çıkışları" kullanarak, donatı kafes yapısal veya yardımcı bağlantıları da desteklemiş olur. Kutuyu yerine yerleştirmek ve kafes parçalarının tam eşleşmesini elde etmek için her kafesin ana çubukları üzerinde işaretlemeler yapılır.



Şekil 2. 25: Donatıların Yerleştirilmesi -Diyafraam Duvar

Kaynak: Puller (2003).


Bentonit bulamaçın yerleştirilmesi; diyafram duvarlarının yapımında, betonu koymak için tipik tremi betonlama prosedürleri kullanılabilir. Tremi boruları her zaman taze betonda en az 1,5 metre derinlikte olmalıdır. Büyük panelleri dökerken, birden fazla tremi borusu kullanılabilir. Tremi tüpleri baştan sona temiz ve su geçirmez olmalıdır. Betonlama işlemi sırasında yatay soğuk derzlerin ve bunun sonucunda çamurlu derzlerin oluşmasını önlemek için tremi süreci boyunca yeterli betona sahip olmak çok önemlidir. Bunun nedeni bir panel bölümünü kesintisiz olarak etkili bir şekilde doldurmaktır. Beton karışımında kullanılan maksimum agrega boyutu, çelik donatı aralığı açısından tremi işlemine uygun olmalıdır. Beton karışımı yüksek bir çimento yüzdesi içermesi ve yüksek bir çökme ile belirli bir mukavemet sağlamak üzere tasarlanmış olması gerekmektedir. 175 mm ila 225 mm aralığındaki beton slumpı genellikle mükemmel olarak kabul edilir. Bu tremi sistemindeki betonun düzgün akmasını ve duvar panellerindeki şerbetin yer değiştirmesini sağlayacaktır. Donatı kafesi yoğun olduğunda, daha sert karışımlar panellerde segregasyona neden olabilir.



Şekil 2. 26: Beton Döküm İşlemi - Diyafram Duvar

Kaynak: Puller (2003)

Hendek kesiciler, çok çeşitli derzlerin oluşturulmasına izin verir. Kesiciler, geleneksel stop-end tüp kullanımına ek olarak üst üste binen kesici bağlantılar oluşturabilir. Halihazırda tamamlanmış iki birincil panel arasında tek veya üç kesim kesilerek ikincil bir panel oluşturulur (bkz. Şekil 2. 27).



Şekil 2. 27: Su Geçirimsiz Diyafram Duvar

Kaynak: Puller (2003)




Şekil 2. 28: Diyafram Duvar Uygulamasının Genel İlerleyişi

Kaynak: (Url-6,2021)

2.4.8.2. Ankrajlı kazı destekleme sistemleri


Ankrajlı kazı destekleme manuel-keson yaklaşımı ile karşılaştırıldığında kayada daha derin kazılara izin vermektedir. Ayrıca, inşaat ekipmanı (örneğin bir diyafram duvar makinesi) için yer sıkıntısı olduğunda, bu yöntem tercih edilebilmektedir. Ankrajlı kazı destekleme sistemlerinin diğer tip kazı destekleme sistemlerine göre temel farkı düşeyde destekleyicilerde değil yatay destek elemanlarındadır. Diğerlerine kıyasla yatay destek elemanları yapı çukurunun içinde değildir. Bu özelliği inşaat sırasında inşaat alanine daha verimli kullanılmasını sağladığı için önemlidir.

Ankrajın düşey destekleme sistemini destekleme mantığı bölüm 2.6.1 den ileri gelmektedir. Şekil 2. 29 da görüldüğü üzere aktif toprak basıncının etkisindeki “potansiyel göçme düzlemi” arkasına belirli bir mesafeye kadar ankrajların kök boyları (bkz. Şekil 2. 30) ilerletilmelidir. Bu sayede aktif bölgenin dışındaki alana yatay kuvvet etkisini taşınmaktadır. Şekil 2. 30 da bir zemin ankrajını oluşturan elemanları ve düşey destekleme sistemine göre bağlantısını gösterilmektedir.



Şekil 2. 29: Ankraj Çalışma Prensibi

Kaynak: Gökhan, (t.y)




Şekil 2. 30: Tipik Zemin Ankrajı

Kaynak: (Url-7, 2021)

Ankrajlı perde sistemlerinde, inşaat yöntemi nedeniyle kaya oluşumlarının kesik yüzleri, su ve atmosfere maruz kalmaktadır. Grovak gibi bazı kaya oluşumları bu gibi durumlarda yıpranabilmekte ve bütünlüklerini kaybedebilmektedir. Sonuç olarak, istinat duvarları kazıya doğru kaymasa bile toprak kayıpları ciddi oturmalarla neden olabilmektedir.

Adım adım, bölümlere ayrılmış betonarme duvarlar yukarıdan aşağıya doğru inşa edilir. Ön gerilimli ankrajlar duvar destek sistemi olarak kullanılmaktadır. Bununla birlikte, projenin yakınında yeraltı tesislerinin olduğu veya bitişik mülk sahiplerinin arazilerinin altında sondaj yapılmasına izin vermeyi reddettiği yerlerde bazen bunun yerine yatay destek elemanları kullanılmaktadır (bkz. Şekil 2. 31).

Şekil 2. 31 de görüldüğü üzere ankrajlar kuşak kirişlerine bağlanırlar. Zemin kök bölgesine verilen çimento enjeksiyonu ile zemin ve ankraj arasında sıkışma sağlanır ve yük aktarımı buradaki sürtünme mekanizması ile sağlanmış olur. Burada kök bölgesine enjekte edilen çimentonun zeminin olumsuz durumlarından ve yer altı suyu hareketlerinden korunması gerekmektedir. Bu sebeble bazı uygulamalarda kök bölgesine çuval geçirilir. Ankrajın gövde bölgesi ise ankraj başlığı ve kök bölgesi arasında yük aktarımının sağlıklı olmasını sağlamaktadır. Gövde bölgesinin serbest çalışması ve sadece kök ile başlık arasında yük aktarı yapabilmesi için Şekil 2. 30 da da görüldüğü gibi kılıf-koruyucu yaka ile kaplanması gerekmektedir. Aynı zamanda koruyucu kılıf gövde içinin çimento ile dolmasının önüne geçecek şekilde kök bölgesi tarafında iyice yalıtılmalıdır.



Şekil 2. 31: Öngermeli Zemin Ankraj Sistemi

Kaynak: Fatih (2018)



Şekil 2. 32: Boru Destek Uygulama Örneği - Kasımpaşa Pi House Rezidans İksa Projesi, Dünya Zemin

Kaynak: (Url-8, 2021)

Kazı tekniği bina alanı, bu yaklaşımda destek duvarı kazılırken aynı zamanda toplu olarak kazılmaktadır. Duvar binasının her dikey adımında kısım kısım kazı yapılmaktadır. Betonarme duvar inşaatı sırasında, izin verilen maksimum hafriyat kaldırma yüksekliği ve desteklenmeyen yatay uzunluk kısıtlamaları ile kazı ve destek kurulumu arasındaki maksimum kesme yüzeyi maruz kalma süresi dahil olmak üzere her aşama segmenti tanımlanmalıdır.

İlk kazı, kazı yüzeyinin genellikle 1 ila 2 gün arasında desteksiz kalmasına izin veren bir derinliğe kadar gerçekleştirilir.

Kazıdan önce anakaya oluşumunun mekanik parametreleri incelenmelidir. Anakayada ayrılmış/kırılmış bir üst bölge ve daha düşük, daha sağlam bir tortu yaygındır. Kayanın dayanıklılığına, ayrışma/kırılma derecesine, kazı derinliğine ve projenin büyüklüğüne bağlı olarak, kayayı kazmak için çeşitli yeteneklere sahip çeşitli kazı makineleri kullanılabilir. Kazıcı duvarlarda doğru dikey kesimler sağlamak için yaygın olarak kullanılmaktadır (bkz. Şekil 2. 33). Kazıdan önce, bazen geniş aralıklı küçük çaplı mikro kazıklar inşa edilir. Daha sonra kazı sınırları belirlenir ve betonarme duvar dikilene kadar kesme zemin yerinde kalır. Mini kazıklar ayrıca duvarın aşağı çekme basınçlarına karşı ekstra direnç sağlar (Mustafa, 2010).



Şekil 2. 33: İş Makinasının Perde İçin Kazı Çalışması - Perde Duvar

Kaynak: Mustafa (2010).

Açık kaya, kazı tamamlandıktan hemen sonra güçlendirilir. Bir sonraki panel yapımı sırasında takviye perdahlaması ve ayrıca manuel keson duvar yapımı, yanal ve dikey duvar sürekliliğini sağlamaktadır.

Paneller, yapının perde duvarları veya kolonları olarak çalışacak şekilde yeterince güçlendirilebilir. Paneller içerden birleştirilir. Dökümden önce, başka herhangi bir kullanım için çubuklar duvar takviyesine bağlanabilir. Şekillendirmeden önce, çeşitli uygulamalar için kutular ve boşluklar oluşturmak için strafor bloklar kullanılabilir (bkz. Şekil 2. 34).



Şekil 2. 34: Panele Strafor Uygulaması Ankraj İçin Yer Açılıyor - Perde Duvar, Zetaş

Kaynak: Mustafa (2010).

Yerinde dökme betonarme beton duvar kazısı içine duvar montajı yapılırken, tek taraflı çalışma söz konusudur. Normalde, iki form yüzü arasında bir duvara geçen bağlantılar betondan gelen gerilmeleri toplar ve bu iki form yüzü arasında tuturulmaktadır. Bu gerilmeler, tek taraflı çalışma durumunda önceden dökülmüş bir beton elemana ya da dolguya iletilmektedir (bkz. Şekil 2. 35).



Şekil 2. 35: Metal Panelin Kapatılması Geri Dolgu Yöntemi ile Sıkıştırma - Perde Duvar


Kaynak: (Mustafa, 2010).

Yerinde dökme betonarme duvarlar için kalıplar çeşitli şekillerde tasarlanabilir. Geleneksel ahşap kalıp ve mühendislik kalıp, kalıp (genellikle metal bir çerçeve) yapmak için kullanılan iki ana malzemedir. Bu tür kalıpları kullanarak kalıptan duvar inşa etmenin birçok yolu vardır.

Beton kalıbı, ortam sıcaklığına, beton sıcaklığına ve kürlenme işlemine sağlanan ivme derecesine bağlı olarak perde kalıbı dökümden 15 ile 24 saat sonra sökülebilmektedir (Mustafa, 2010).

Ankrajın pasif olarak uygulanması durumuna da zemin çivilemesi denilmektedir. Zemin çivileme yöntemi öngerme yükü olmadığı için aktif bir şekilde çalışmaz. Zeminde bir deformasyon (oturma vb.) meydana geldiğinde zemin çivileri ile zeminin sıkışması, sürtünme kuvvetinden oluşacaktır. Sistem bu sürtünme kuvvetinden faydalanmaktadır (Mustafa, 2010)..

Zemin çivisi yöntemi öngermeli duruma kıyasla kazı derinliğinin daha az olduğu ve zemin hareketlerinin görece daha az olduğu sistemlerde kullanılmaktadır. Zemin çivisi Şekil 2. 36 ve Şekil 2. 37 de görüldüğü üzere, gerek görülmesi halinde, püskürtme beton ve hasır donatı ile birlikte uygulanır. Uygulama genellikle bu şekilde yapılmaktadır. Uygulama ankrajlı yöntemle benzerlik göstermektedir. Kademeli kazı anlayışı bu yöntemde de olmak zorundadır.



Şekil 2. 36: Zemin Çivisi

Kaynak: (Url-9, 2021)



Şekil 2. 37: Başlıkların Püskürtme Beton ile Çelik Hasırlara Tuturulması

Kaynak: (Url-10, 2021)

Proje Gereksinimlerinin Tanımlanması:

Ankrajlı duvar tasarım sürecinin ilk aşaması, ankrajlı sistem için geniş geometrik gereksinimlerin belirlenmesi ve proje hedeflerinin ve kısıtlamalarının ana hatlarıyla belirlenmesidir. Bu süreç, bir duvar profilinin oluşturulmasını, güvenlik bariyerleri, tesisatlar ve drenaj sistemleri gibi duvar eklerinin konumlandırılmasını, geçiş hakkı kısıtlamalarının belirlenmesini ve inşaat sıralama ihtiyaçlarının belirlenmesini içerir. Proje ihtiyaçları ve kısıtlamaları, duvar sisteminin tasarımı, inşası ve maliyeti üzerinde önemli bir etkiye sahip olabilir, bu nedenle bunlar sürecin erken safhalarında belirlenmelidir. Çünkü bir duvar seçmeden ve tasarlamadan önce ilk aşamadaki bilgiler önemlidir.

Tasarım Öncesi İncelemeler; bir kazı ve istinat sistemi tasarlamadan ve inşa etmeden önce, bir takım araştırmaların tamamlanması gerekir. Zemin ve saha incelemeleri tipik olarak bir projenin bir bütün olarak fizibilitesini doğrulamak için yapılır, ancak bu her zaman planlı bir ankraj kurulumunun uygulanabilir olduğu anlamına gelmemektedir. Belirli bir proje için ankrajların uygulanabilirliğini ve faydalarını göstermek için yeterli veri mevcut olsa da, bu veriler, zeminin kapsamlı bir şekilde

anlaşılmasının önemini vurgulayarak, uygun maliyetli tasarım ve inşaatlarına izin vermek için yetersiz olabilmektedir.

Zemin sondajlarının delinmesi, zemin ve/veya kaya testleri (yerinde ve laboratuvar) yapılması, jeoteknik veri ve geoteknik raporların geliştirilmesi, bitişik mülklerin ve tesislerin inşaat öncesi etütlerinin yapılması ve potansiyel müdahaleleri doğrulamak için bu tesislerin konumlarının analiz edilmesi, tümü bir projenin parçası olmaktadır.

Belirli bir proje için yeraltı araştırması; herhangi bir yeraltı projesinin tasarımı ve uygulanmasından önce zemin katmanlarının ve koşullarının araştırılması gereklidir. Bu normalde, yüzey altı koşullarını değerlendirmek ve çeşitli toprak veya kaya özelliklerini belirlemek için test sondajları delinerek ve laboratuvar ve saha testleri yapılarak gerçekleştirilmektedir (Mustafa, 2010).

Ankraj tasarımına ilişkin değerlendirmeler:

Proje sahasındaki zemin ve kaya stratigrafisi, projeye özel bir yeraltı araştırmasının parçası olarak kalınlık, yükseklik ve farklı katmanların yanal kapsamı dahil olmak üzere sondajlar kullanılarak analiz edilmelidir. Yeraltı çalışması sırasında, ankraj sisteminin tasarımı ve inşası üzerinde önemli etkileri olabileceğinden, aşağıdaki potansiyel sorunlu, zemin ve kaya tanımlanmaktadır (FHWA, 1999):

- Su mevcut olduğunda dağılan (yani çöken), çatlama eğiliminde olan, titreşimin neden olduğu sıvılaşmaya veya yoğunlaşmaya eğilimli olan kohezyonsuz kumlar ve siltler.
- Kayma kararsızlığına duyarlı, zayıf zemin veya kaya tabakaları.
- Yüksek plastisiteli killer ve organik zeminler gibi uzun süreli (sünme) deformasyonlara eğilimli ve yüksek oranda sıkıştırılabilir malzemeler.
- Ankraj deliği açılmasını, derz dolgusunu ve duvar elemanlarının inşasını engelleyen engelleyen, kaya ve çimentolu zeminler.

Yeraltı sondajları, düzenli aralıklarla duvar hizalaması boyunca, arkasında ve önünde ilerletilmelidir. Delme verilerinden stratigrafinin tahmin edilebilmesi için sondajlar

duvar hizalaması boyunca sahanın uç noktalarına yerleştirilmelidir. Zemin ankrajları tipik olarak 15 ila 30 metre aralıklarla yerleştirilirken, kaya ankrajları 30 ila 60 metre aralıklarla yerleştirilir (FHWA, 1999). Geri sondajlar, kısmen zayıf veya uygun olmayan zemin veya kaya tabakalarının tanımlanmasına izin verecek şekilde ankraj bağ bölgesi içinde konumlandırılmalıdır. Sırt ve duvar delme derinlikleri, genel yeraltı koşullarına göre belirlenmeli, ancak zemin yüzeyinin altında duvar veya şev yüksekliğinin en az iki katı olmalıdır. Ön sondajlar, öngörülen duvar tabanının altındaki duvar yüksekliğine eşit bir derinlikte durdurulabilir. Derinlikte yumuşak, zayıf, çökebilir veya sıvılaştırılabilir zeminler varsa sondajlar daha derine ilerletilmelidir. Sondajlar, çok dik eğimli yer ankrajları için en azından ankraj bağlantı bölgesinin derinliğine kadar girmelidir. Bir heyelan kayma yüzeyinin geometrisini karakterize etmek için daha fazla sondaj gerekebilir.

Yeraltı suyu seviyesi ve herhangi bir tünemiş yeraltı suyu bölgesi mevcudiyeti, sistemin genel stabilitesi, duvardaki yanal basınçlar, yapılar üzerindeki dikey kaldırma kuvvetleri (yapısal tasarım), drenaj sistemi tasarımı, ankraj bağlantılarında su geçirmezlik gereksinimleri, korozyon koruma gereksinimleri ve inşaat prosedürleri üzerinde bir etkiye sahiptir. Yeraltı suyu tablası içine veya yakınına yapılacak ankraj sistemleri için asgari olarak aşağıdaki faktörler dikkate alınmaktadır (FHWA, 1999):

- Hem yüksek hem de düşük ortalama yeraltı suyu seviyeleri.
- Zemin ankrajının korozyon potansiyeli.
- Sızıntı kuvvetleri zemin ve/veya kaya şev duraysızlığına neden olma durumu.
- Hafriyat susuzlaştırma, özel delme ve enjeksiyon işlemleri prosedürleri.
- Kohezyonsuz zeminlerin sıvılaşma potansiyeli (uzun vadeli analiz).

2.4.8.3. Palplanş duvar

Palplanş duvarlar birbirlerine geçmeli yapılarıyla sürekli perde duvar özelliği gösterebilmektedir. Palplanş perdeler titreşimli bir biçimde zemine çakılmaktadırlar.

Palplanş duvarlar kazı derinliğine bağı olarak yapı çukurunu güvende tutmak için toprak basınçlarına karşı koymada ve geçmeli yapıları sayesinde sağlamış oldukları geçirimsizlikten dolayı geçirimsiz perde olarakta kullanılabilir. Yapımında kullanılan malzemeye göre palplanş duvarlar temelde üç çeşittir.

Bunlar:

- Çelik Palplanşlar
- Ahşap Palplanşlar
- Betonarme Palplanşlar

Temel olarak bu üç malzeme dışında da palplanş üretimi olmakta ve malzeme bilimi geliştikçe farklı palplanşlar görülmektedir.

Palplanş duvarların bu geçirimsizlik özelliklerinden dolayı, atık su depolama alanlarında yapılan destekleme sistem tercihlerinde görülmektedir. Aralarında en çok tercih edileni tekrar tekrar kullanım oranı yüksek olması ve diğer tiplerine nazaran daha derin kazılara imkan tanıdığından dolayı çelik palplanşlardır. Çelik palplanşları farklı kenetlenme-geçme modellerinde ve farklı geometrilerde olmaktadır.



Şekil 2. 38: Batardo - Çelik Palplanş Perde

Kaynak: (Url-11, 2021)


Betonarme palplanş perdeler de fabrikasyon üretim olduklarından istenilen kenetlenme modeli ve geometrilere yapılabilmektedirler. Kesit ve ebat olarak diğer iki palplanşa göre daha büyüktürler bu yüzden taşıma sırasında zorluklar yaşanabilmektedir. Bu da iş süresini diğerlerine kıyasla olumsuz etkilemektedir. Çakma işlemi sıra sırasında betonarme palplanş perdenin başına rijit metal başlık takılır böylelikle betonarme palplanş perdenin üst tarafındaki dökümlerin önüne geçilmektedir. Sızdırmazlık için kenetlenme yerleri desteklenmelidir (Ermanlar, 2009).



Şekil 2. 39: Betonarme Palplanş Perde

Kaynak: (Url-12, 2021)

Ahşap palplanş malzemeler ise diğerlerine kıyasla daha sığ kazılarda tercih edilmektedirler. Bunun nedeni doğal yapıları gereği çevre şartlarına diğerleri kadar dayanıklılık göstermemesi ve dayanıklı olmamasıdır. Ahşap palplanşların kesit özellikleri sekiz santimetre kalınlığa kadar iki metre yükseklik ve her bir metre yükseklik artışına bir cm kalınlık artışı olacak şekilde tavsiye edilmiştir (Ermanlar, 2009). Gradasyonu yüksek olan iri daneli zeminlerde ahşap palplanş kullanılması uygun olmayacaktır.



Şekil 2. 40: Ahşap Palplanş Perde - Zemine Çakılma İşlemi ve Kesit Durumu

Kaynak: (Url-12, 2021)



Şekil 2. 41: Uygulama Örneği - Ahşap Palplanş Perde

Kaynak: (Url-12, 2021)

Palplanş duvarlar genellikle sığ kazılarda, boru hattı döşemelerinde, alt yapı çalışmalarında hızlı ve kolay kullanım sağladığı için tercih edilen ve sık kullanılan bir destekleme sistemi çeşitidir. Kayalık zeminler hariç granüler zeminlerde

kullanılabilir ve yumuşak zeminlerde de uygulaması basittir. Kıyı liman yapılarında da kullanılmaktadır.

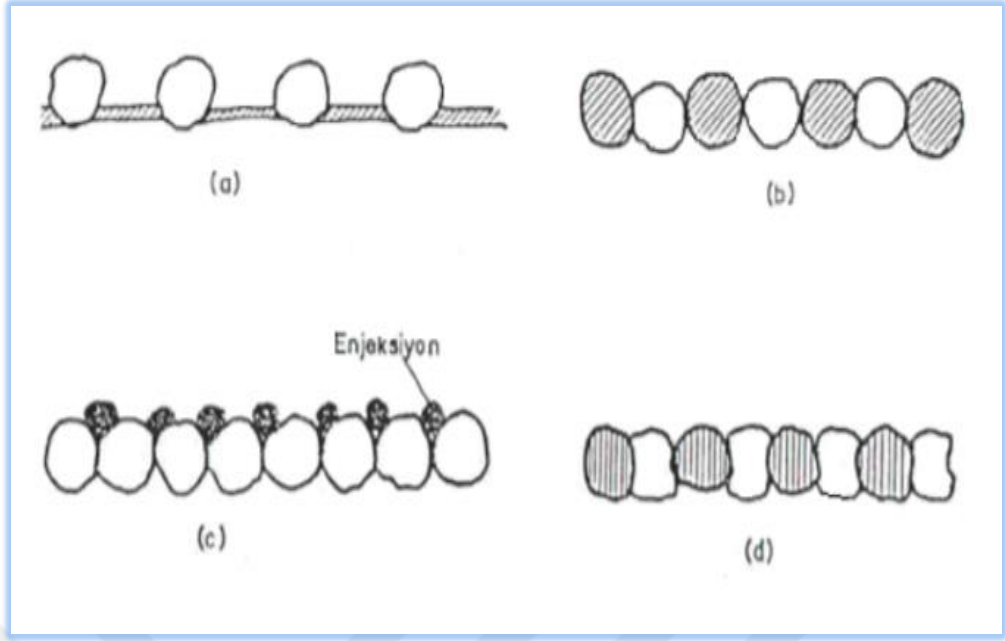
2.4.8.4. Kazıklı destekleme sistemleri

Kazıklı destekleme sistemleri de şev stabilitesini veya yapı çukurunu güvende tutmak amacı ile yapılan destekleme sistemleridir. Kazık perdeleri uygulamada fore kazıklarla sıklıkla görülmektedir. Kazık çapları değişiklik göstermektedir. Çapları 40 santimetre(cm) ve daha yukarı olanlar fore kazık, 40 cm'in altında olanlar ise mini kazık olarak adlandırılmaktadır. Kazıklı perde duvarlar kesişen kazıklar halinde imal edilirse su geçirimsiz bir koruma alanı sağlamaktadır.

Kazıklı destekleme sistemleri uygulama yöntemine göre çeşitlendirilebilir:

- Aralıklı Kazık; nispeten kendini turabilen zeminlerde uygulandıklarında (Şekil 2. 42.a).
- Kesişen ve/veya Bindirmeli Kazık; sızdırmazlık istendiği durumlarda (Şekil 2. 42.b).
- Enjeksiyonlu Kazık; sızdırmazlığın çok daha önemli olduğu durumlarda. Fore kazıkların temas yüzeylerinden enjeksiyon verilmesi ile yüksek sızdırmazlığın sağlanmasıdır (Şekil 2. 42.c).
- Bindirmeli Kazık; zemin yanal basınçlarının yüksek ve/ya da doygun zemin ortamlarında uygulanır (Şekil 2. 42.d).


Desteklenmek istenilen zemin özelliklerine göre forajı açacağımız ekipmana karar verilir. Foraj; kazık işlemi yapılacak yerin delinmesi işlemidir. Zemin kaya ise kaya augeri ya da karotiyer kullanılır. Ancak zemin yumuşak ise kil augeri kullanılır. Bunların dışında zeminde yeraltı su seviyesi yüksekse kova da kullanılmaktadır.



Şekil 2. 42: Kazıklı Destekleme Sistemi Uygulamaları

Kaynak: Burak (2009)

Kendini tutamayan zeminlerde muhafaza boruları kullanılmalıdır. Muhafaza boruları delgisi yapılan kuyunun istenilen çapta kalabilmesini sağlar. Aynı zamanda muhafaza boruları kuyuya dökülecek betonun kalitesini koruması içinde çok önemlidir. Ayrıca hareketli yer altı suyuna denk geldiğinde beton dökümü sırasında beton ayrışabilmekte ve yıkanabilmektedir. Bu bağlamda muhafaza borusunun kullanımı önemlidir. Fore kazık donatılarının sürülmesi yukarıdaki koşullarla delgisi yapılan zeminin stabilitesi sağlandıktan sonra gerçekleşmektedir. Uygulamada 12 metre(m)'yi geçen durumlarda donatı bağlantıları bağ telleri ve projedeki bindirme kıstaslarınca sağlanmalıdır (Burak, 2009).



Şekil 2. 43: Fore Kazık Uygulama Adımları

Kaynak: (Url-13, 2021)

Şekil 2.43'te fore kazık aşamaları gösterilmektedir.


Birinci aşama: Kendini tutamayan zeminler için muhafaza borusunun sürülmesi.

İkinci aşama: Forajlama işleminin yapılması. Delgi aşaması.

Üçüncü aşama: Donatıların kuyuya sürülmesi.

Dördüncü aşama: Betonlama işleminin yapılması.

Beşinci aşama: Muhafaz borusunun çıkarılması.



Şekil 2. 44: Kazık Perde Uygulaması - Fore Kazık – Ümraniye Okan Sokak Yanı Zemin Altı Otopark İksa Projesi - Dünya Zemin

Kaynak: (Url-14, 2021)

2.4.8.5. Yukardan-Aşağıya destekleme sistemi (top-down)

Bu destekleme sisteminde düşey taşıyıcılar üst yapısında taşıyıcıdır ve inşaat imalatı diğer yöntemlerin aksine burada zemin seviyesinden başlar. Yani ilk kademe için yapılan kazı aynı zamanda -1. Bodrum katın kazısıdır. Bu sistemde de harfiyat işleri kademeli olarak yapılmaktadır. Her kademede üst yapının kiriş ve döşemesinin imalatı yapılmaktadır. Böylelikle daha güvenilir bir sistem dizaynı oluşturulur. Bu sistemde kazı ve üst yapının inşaat işleri birlikte devam ettiği için bir çok aksaklık meydana gelebilmektedir. O yüzden iş planlamasını bu sistemde diğerlerine nazaran daha önemli olmaktadır. Yine imalatı yapacak ekibin tecrübesi de diğer destekleme sistemlerine kıyasla önem kazanmaktadır. Tüm bunlar göz önüne alındığında bile kazı süresinin sonunda binanın zemin alt kotunun imalatının kabası bittiği düşünüldüğünde, zaman açısından avantajlı olmaktadır. Maliyet anlamında diğer yöntemlere kıyasla pahalıdır (Url-15, 2021).



Şekil 2. 45: Yukardan - Aşağıya Kazı Destekleme Sistemi - Şantiye Aşaması

Kaynak: (Url-15, 2021)

2.4.9. Destekleme sistemleri üzerine değerlendirme

Derin veya sığ kazı inşaatları, diyafram duvar, kazıklar, ankrajların montajı vb. çok çeşitli kazı destek sistemleri, tasarımsal yük kombinasyonları, yerel jeolojik koşullar, çevresel koşullar, izin verilen inşaat süresi, bütçe, mevcut inşaat ekipmanları ve buna göre genel bir plana, en uygun tasarımın uygulanabilmesi için ihtiyaç duymaktadır. Teknolojinin gelişmesi bizlere optimum tasarımlar yapmamızı sağlamaktadır. Bu tez kapsamında python ve yapay zeka kullanılarak destekleme sistemlerinde en ideal yatay deplasmanın ne olabileceği araştırılmaktadır. Böylelikle destekleme sistemi tasarımlarında daha ön görülebilir ve daha ekonomik modellere ulaşabilecektir.

Bildiği üzere derin kazı çalışmaları, felakete yol açabilecek ve çevreyi etkileyebilecek yüksek riskler taşımaktadır. Nihayetinde, destekleme sistemleri tasarlanırken zemin/kaya-yapı etkileşiminin dikkatli bir şekilde değerlendirilmesi gerekmektedir. Yapısal malzeme modellerinin ve zeminin doğru anlaşılması, uygun modelin uygulanması, güvenli ve uygun maliyetli tasarımlar üretmek için kritik öneme sahip olmaktadır.

2.4.10. Destekleme elemanlarının aletsel gözlemlenmesi

Kazı sırasında destekleme elemanında ve zeminde istenmeyen aşırı deformasyon durumlarının önceden önüne geçebilmek ve zemin davranışının tahminlerle uyumunu inceleyebilmek için destekleme sistemlerinin gözlemlenmesi elzem olmaktadır. Böylelikle göçme meydana gelmeden önce önlem alınabilmektedir. Çevre yapılarının da gözlemlenmesi son derece önemlidir. Gözlemler, yapı zemin seviyesine ulaştıktan bir süre sonra da devam etmelidir. Ta ki desteklenen zeminin yükünün bodrum perdelerine aktarılması sağlanana kadar. Destek elemanlarında meydana gelen hareketliliği ölçmek için kullanılan aletlerden bazıları; inklometre, ekstansometre, piyozometre, çatlak ölçer ve benzeri gibidir (Engin, 2008).

Ekstansometre; en çok kullanılan çeşidi manyetik olanıdır. Ölçekli kablo, prob ve makaradan oluşmaktadır. Zemine bir kuyu açılır ve mıknatıs levhalar yerleştirilir. Bu levhalar zeminle birleştirilmiştir. Prob mıknatıslı yere iken okuma alınır. Bir önceki okumalar ile kıyaslanarak aralarındaki fark ile deformasyon değerine karar verilir (Engin, 2008).

İnklometre; en sık karşılaşılan aletsel gözlem okumasıdır. Bu tez kapsamında kazı destekleme sistemlerinin aletsel ölçümleri inklometre okumalarıdır. Destekleme sistemlerinin içine ve zeminde belirli bir yere düşeyde açılan kuyunun içine inklometre borusunun yerleştirilme aşaması ile başlamaktadır. Sonrasında yer çekimi hareketlerine duyarlı prob kuyu ya ölçekli bir kablo aracılığı ile indirilir ve bu kablo proba elektrik sağlar (Engin, 2008).

Şekil 2. 46 da görülebileceği üzere:


L: Prob boyu,

Φ : Sapma açısı,

A+ ve B+ : Birincil yön

Ve B-: İkincil yön

A ve B yönünde sapmalar hesaplanır.



Şekil 2. 46: İnclinometre Çalışma Prensibi

Kaynak: Engin (2008)

2.5. Yapay Zeka Uygulama Alanları

Günümüzde yapay zekanın getirileri ve götürüleri üzerine çokça tartışılmaktadır. Thomas H. Davenport (2019), Harvard Business Review Press'in Artificial Intelligence (Yapay Zeka) kitabında sunuş bölümündeki yazısında yapay zeka için "medeniyetimizin en önemli genel maksatlı teknolojisi" ifadesini kullanmaktadır. Bildiğimiz üzere makine öğrenmesi yapay zeka başlığı altında yer almaktadır. Tolon (2007), yapay zekanın işlevini; insanoğlunun kendi ve/veya başkalarının tecrübelerinden yaptığı çıkarımlarla kararlar almasına benzetmektedir. Nasıl ki bizler yaşadığımız, dinlediğimiz, okuduğumuz, gözlemlediğimiz vb gibi tüm bu verilerinden birer çıkarım yapıp kararlar alıyorsak yapay zeka teknolojisi de o şekilde kararlar almaktadır. Yapay zekanın bir alt dalı olan makine öğrenmesi için Harvard Business Review Press'in Artificial Intelligence (Yapay Zeka) kitabında Bölüm 1'de

“Yapay Zekanın Vaat Ettikleri” üzerine yazılarında Brynjolfson ve McAfee (2019) makinelerin kendilerine verilen görevi insanlardan bağımsız bir şekilde sonuçlandırması ve kendi performanslarını kendi kendilerine geliştirmesini makine öğrenmesi olarak tanımlamıştır.

Makine öğrenmesi, trendlerin hangi sıklıklarda değişebileceğini, baskın parametrelerin neler olabileceğini tahmin edebileceği gibi daha bir çok veri bilimi uygulamasında kullanılmaktadır. Görüntü işleme ve sınıflandırma özellikleri ile kanser hücrelerinin teşhisinde kullanılabilir. Aynı zamanda bir şantiyede yüksekten düşme riskine karşı ilgili kişileri uyarabilmektedir. Bu tarz durumlarda geliştirilen yapay zeka modeli karar verme mekanizmasını hızlandırdığı için asistan olarak kullanılmaktadır.

Qian He, Hongfei Zheng, Xinglong Ma, Lu Wang, Hui Kong ve Ziyue Zhu (2022) yaptıkları bir çalışmada, yenilenebilir enerji kaynaklı deniz suyunun tuzdan arındırılmasında yapay zeka teknolojilerinden faydalanmışlardır. Çalışmalarında genetik algoritmalar, karar destek sistemleri ve yapay sinir ağları algoritmaları farklı süreçlerde kullanılmış ve deniz suyunun arındırılması sürecinde tatlı sudaki verimliliği %10 a kadar arttırabileceklerinden bahsetmişlerdir.


2.5.1. Geoteknik mühendisliği problemlerinde veri işleme uygulamaları

Veri işleme uygulaması, çoğu zaman dağınık, yeterli özenlilikte olmayan, içerisinde aykırılıkları ve gürültüleri barındırabilecek veri kaynağından anlamlı bilgilerin çıkarılabilmesi için yürütülen süreçtir. Bu durumu yürütebilmek için yazılım programları da kullanılmaktadır. Günümüzde veri işleme sürecinde aktif olarak kullanılan programların başında R Studio, Python programlama dilleri gelmektedir. Bu tez kapsamında Özgür Yıldız (2019) Doktora Tez’inde ekte paylaştığı veriler kullanılmıştır. Bu veriler çeşitli literatürlerden derlenmektedir.

2.5.2. Verilerin işlenmesi

Verilerin işleme süreci, verilerin toplanması ile başlamaktadır. Veriler toplanır ve bilgisayar ortamında işlenecekleri programa yüklenir. Toplanan veriler ham haldedir. Ham verilerden elde edilecek sonuçlara güven olmamaktadır. Çünkü ham veriler

aykırı öznitelikleri, boşluklukları, tutarsızlıkları vb barındırabilmektedirler. Ayrıca verilerin ham hallerinde istenmeyen gözlemler olabilmektedir. Benzer sebeplerden dolayı ham verinin düzenlenmesi gerekmektedir. Burada istenmeyen gözlemlerden kurtulmak, veri setindeki boşlukları anlamlı karşılıkları ile doldurulmak, aykırılık analizi yapıp analiz sonucuna göre veriyi manipüle etmek gibi işlemler yapılmaktadır (Url-16, 2021). Veri manipülasyonları sonucunda veri seti makine öğrenmesi için hazır hale gelmiştir denilmektedir. Öğrenme aşamasından hemen önce verilerin görselleştirilmesi ve analizinin yapılması gerekmektedir. Bu görselleştirmeler sonucu yapılacak analizlerden en önemlisi hangi algoritmanın kullanılması gerektiğine karar verilmesidir. Şekil 2. 47 'de iris veri setinin saçılım grafiği gösterilmektedir. Burada veri kümelenmesi gözlemlendiğinden bu şekilde dağılım sergilenen veri kümelerinde sınıflandırma algoritmaları kullanılması gerekmektedir.



Şekil 2. 47: İris Çiçeğine Ait Grafik Dağılımı - Verilerin İşlenmesi

Kaynak: Pranshu Sharma (2021)

2.5.3. Python ve inşaat mühendisliğinde kullanım alanları

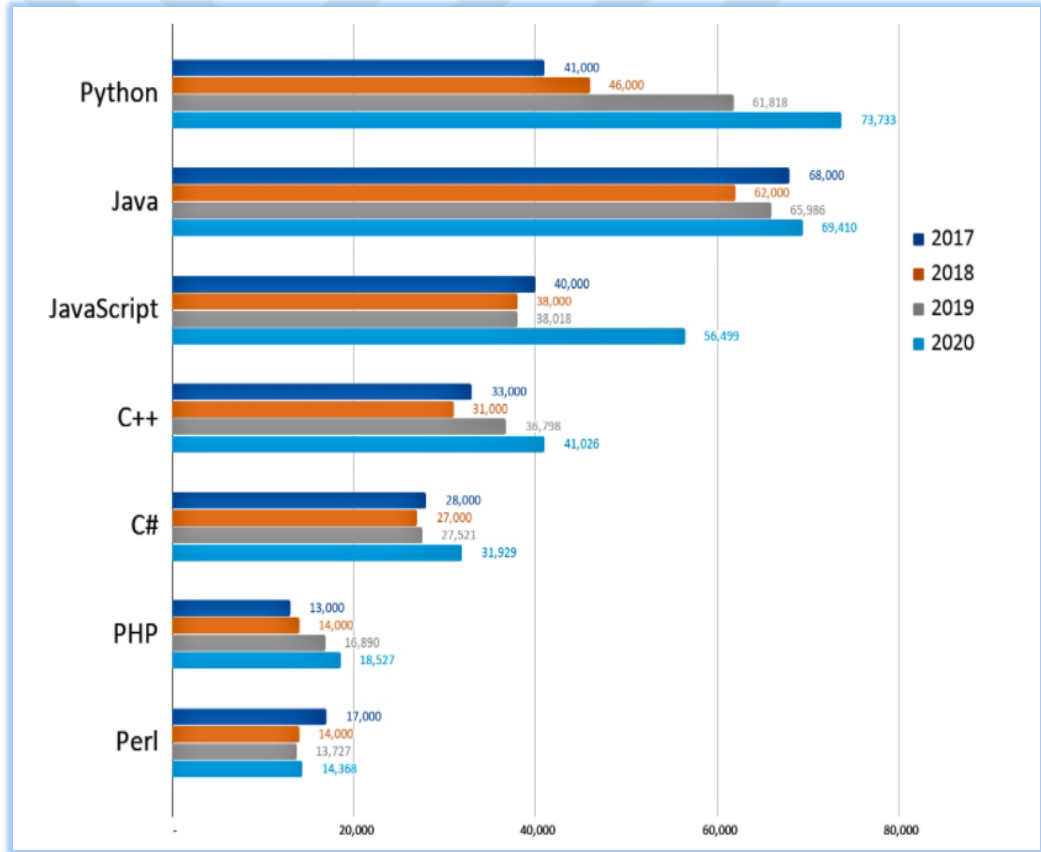
Python son dönemlerde trendde olan hem akademi camiasının hem de özel sektörün sıklıkla kullandığı programlama dilidir.

Şekil 2.48’de Amerika Birleşik Devletleri’nde ‘de 2017-2020 yılları arasında iş verenler tarafından en çok tercih edilen programlama dilleri gösterilmektedir. 2020 yılında en çok tercih edilen program dili olarak python’ı görmekteyiz.

Bu tez kapsamında Python Programlama dili ve bu dile ait olan kütüphaneler kullanılmıştır.

Bu kütüphaneler:

- Makine Öğrenmesi için, Sklearn.
- Veri görselleştirme için, Matplotlib ve Seaborn.
- Veri analizi için, Pandas ve Numpy Kütüphaneleri kullanılmıştır.



Şekil 2. 48: ABD’de 2017-2020 Yılları Arasında İşverenler Tarafından En Çok Tercih Edilen Programlama Dilleri

Kaynak: (Url-17, 2021)

Python Programlama dili aynı zaman da Dropbox, Netflix, Google ve Instagram gibi dev şirketlerin yazılım dilidir. Python dilini önemli ve seçilir kılan özellikleri:

- Python çok amaçlı bir programlama dilidir.
- Veri bilimi, veri analizi ve very görselleştirme yeteneği vardır.
- Web sitesi kurulabilir.
- Oyun geliştirilebilir.
- Yapay Zeka-Makine Öğrenmesi-Derin Öğrenme teknolojilerini oluşturabilir.
- Tüm bunlar için açık kaynak kod erişimi mümkündür.

Vb ...

İnşaat mühendisliğinde python kullanımına son dönemlerde sıklıkla rastlanmaktadır. Bunun nedeni şüphesiz yukarıda belirttiğimiz özelliklerdir. İnşaat mühendisliğinde kullanımı son yıllarda artış göstermektedir. S. Memari ve Prabhakar Clement (2021) yaptıkları bir çalışmada, toprak nemi ve kılcal basınç arasında ampirik bir ilişki sağlayan toprak su tutma fonksiyonunu python programı kullanarak modellemektedirler. Python programı içerisinde Levenberg-Marquart, Trust Region Reflective ve Dog Box üç farklı algoritmayı kullanmışlardır. Sonuçlar arasında en uygun yöntemin Trust Region Reflective algoritması olduğuna karar vermişlerdir ve grafik uydurmada kullanılan üç algoritmanında mükemmel yakın sonuçlar verdiğini belirtmişlerdir. Ayrıca veri setlerine biraz gürültü eklediklerinde Levenberg-Marquart algoritmasının grafiği pek tutturamadığını da belirtmişlerdir. Bu örnekten de anlaşılacağı üzere makine öğrenmesi ön aşaması olan very işleme aşaması çok önemli bir aşamadır. A. Bueno L, Zuccarello, A. Díaz-Moreno, J. Woollam, M. Titos, C. Benítez, I. Álvarez, J. Prudencio, S. De Angelis, (2020), python ara yüzü PICOSS'u kullanarak sismik sinyallerin sınıflandırılmasına çalışmışlardır. Çalışmalarında veri sınıflandırma verimliliğinin de artış ve veri etiketleme-sınıflandırmada kolaylık sağladığına değinmişlerdir.

Jon Sáenz, Juan Zubillaga ve Jesús Fernández (2002) yaptıkları bir çalışma

sonucunda python ile ilgili olarak şunları dile getirmişlerdir; Python, çeşitli zorlu jeofizik alanlarındaki genel veri analizlerinde uygulanabilir. Rutinler C veya Python'da yerleşiktir ve python yorumlayıcısı aracılığıyla erişilebilir. Python, bilimsel veri analizi için sayısal bir uzantıya sahip ücretsiz programlama dilidir. Amir Ali Shahmansouri, Maziar Yazdani, Mehdi Hosseini, Habib Akbarzadeh Bengar ve Hamid Farrokh Ghatte (2022) yaptıkları bir çalışmada, beton basınç dayanımını ve elektrik özdirencini tahmin etmeye dayalı üç ayrı yapay sinir ağı modeli oluşturmuşlardır.

Kapsamlı deneysel çalışmaların sonucunda çıkarılan parametreler daha sonar yapay zeka analizi için veri seti olarak kullanıldı. Eğitim, doğrulama ve test aşamalarında yapay zeka modelleri için doğrulama katsayıları (R²) beton basınç dayanımları için sırasıyla 0.995, 0.973 ve 0.973 ve elektrik özdirençleri için 0.996, 0.985 ve 0.987 idi. Ayrıca, yapay zeka Modellerinin eğitim, doğrulama ve test aşamalarındaki Ortalama Kare Hatası (RMSE) basınç dayanımları ve elektrik özdirençleri için sırasıyla 1.20, 2.16 ve 2.60 (MPa) ve 2.83, 5.66 ve 5.90 (Ω -m) idi. Yukarıda verilen değerler doğrultusunda yapay sinir ağı modellerinin tahminleri deneysel değerlere yakın bulunmaktadır.

Yukarıdaki çalışmalar inşaat mühendisliğinin geleceğine ışık tutmaktadır. Bu çalışmalar sayesinde zamandan, maliyetten, karbon ayak izinden vb... gibi kazanımlar sağlanabilmektedir.

3. ÇALIŞMA KAPSAMINDA KULLANILAN GEOTEKNİK VERİLER

Bu çalışma kapsamında Özgür Yıldız'ın (2019) "Kazi Destek Yapılarının Veri Madenciliği İlkeleri ile İncelenmesi" adlı doktora tezinin ekler kısmındaki geoteknik veriler kullanılmıştır. Geoteknik veriler Bölüm 2' de anlatıldığı gibi işlenmiştir.

Bu veriler arasından seçim yapılırken veri satırında boş verisi olan örnekler/vakalar kullanılmamıştır. Bu şekilde 126 adet veri seçilmiştir.

Bu tez kapsamında kazı destekleme sistemlerine ait parametreler kullanılarak veri tabanı oluşturulmuştur. Ve bir bilgi işleme metodu olan yapay sinir ağları aracılığıyla tahmin modelleri oluşturulmaktadır.

Bu modeller aracılığıyla kazı destekleme sistemlerinin yatay deplasman tahminini %80-%99 arasında bir genellenebilirlikte bulmak hedeflenmektedir.

Bu çalışma kapsamında, 126 adet vaka kullanıldı. Verilerin işlenmesi ile 45 adet vaka aykırı tespit edilmiş ve 81 adet vaka ile yapay zeka mantığında çalışan yapay sinir ağı modelleri geliştirilmiştir. Tahmin modelleri arasında en iyi model Model_10'dur. Sklearn kütüphanesinin içerisinde yer alan Multi-layer Perceptron Regressor(MLPRegressor) algoritması ile çok katmanlı yapay sinir ağı Model_yle 15 çeşit model kullanıldı. Veri seti modellenmeden önce ham halinde 5 adet girdi parametresi ve 1 adet çıktı parametresi bulunmaktadır. 5 adet girdi parametresinin 4 tanesi Destek_Aralığı(mm), yanal rijitlik(EI (kNm²/m)), kazı derinliği(H_Kazı(mm)), düşey deplasman ölçümü(δv _Olcum(mm)) ve 5. girdi verisi Destekleme_Sistemidir. Destekleme Sisteminin tiplerine ayrılması ile toplamda 27 adet girdi verisi elde edilmektedir. Verinin işlenmesi sürecinden sonra nihai olarak 27 adet girdi katmanı ve 1 adet çıktı katmanı ortaya çıkmaktadır.

Girdi Parametrelerinin seçilmesi:

Şekil 3. 1’de görüldüğü üzere yapay sinir ağları üzerinden kurulan model mimari yapısı ve girdi parametreleri gösterilmektedir. Burada tek katmanlı olan gizli katman modelde 7 adet katmandan oluşmaktadır. Elde edilen 27 adet girdi parametresi ve 1 adet çıktı parametresi ile yapay sinir ağı mimarisi modellenmiştir. Kullanılan parametreler şekil üzerinde de görülmektedir.

F_a , K_a , K_p gibi parametrelerinden Bölüm 2.4’de bahsedilmektedir. Bu parametreler zemine bağlı olan yanıl toprak basınç parametrelerdir. Geoteknik mühendisliđi zemin ve yapı etkileşimini içeren kompleks bir mühendislik alanıdır. O nedenle ki derin kazılarda yanıl ötelenme sadece zemine bađlı olmamakta ayrıca destekleme sistem tipine de bađlı olmaktadır. Mohr columb kırılma zarfında aktif zemin hareketinin pasif zemin hareketinden daha düşük gerilmelerde meydana geldiğinden bahsedilmektedir. K_p bu durumda K_a ’ya göre dikkate alınmamaktadır. Bu doğrultuda aktif zemin gerilme katsayısı K_a , F_a ’nın içerisinde dikkate alınmaktadır. Denklem 2.10 ‘da F_a parametresinin veri setinde yer almaması önemli bir eksiklik olarak değerlendirilmektedir. Ancak bileşke kuvvet F_a ’nın hesabında en önemli görülen parametre formüldende anlaşılacağı üzere kazı derinliğidir ve kazı derinliği veri seti içerisinde dikkate alınmaktadır.

Düşey deplasman ölçüm parametresiyle ilgili olarak;

1934 yılında Terzaghi’nin desteklenen zeminde çok daha küçük mertebelerde hareketler yaşandığında bile yanıl zemin basıncında önemli deđişmeler gözlemlenmesi, düşey deplasman ölçüm parametresini önemli kılmaktadır.

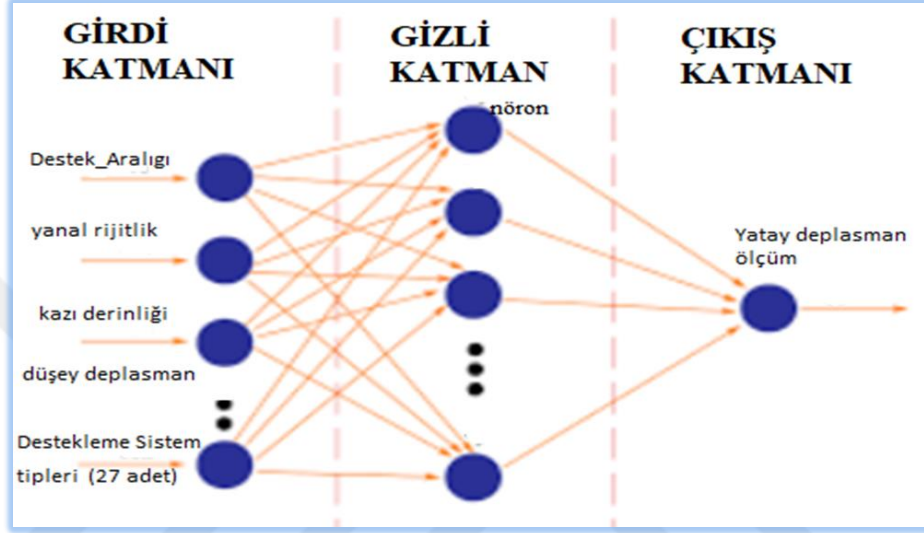
2005 yılında Marulanda’nın destekleme sistemlerinin tasarım parametresine etkiyen koşulları özetlediđi çalışmasına istinaden;

- Destek aralığı,
- yanıl rijitlik,
- destekleme sistem tipleri.

tasarımsal açıdan önemli parametreler olarak dikkat çekmektedir. Ve veri seti

içerisinde yer almaktadırlar.

Bölüm 2’de bahsedildiği üzere Wang ve arkadaşları 2009 yılında, yapmış oldukları araştırma sonuçlarını duvar tipine göre sınıflandırmışlardır. Bu araştırmaya göre; yanal rijitliğin sistemin yer değiştirmesinde önemli rol oynadığını, destekleme sisteminin yatay hareketinin büyük ölçüde destekleme sistem tipine bağlı olduğunu ve derinliğin artmasıyla yanal hareketinde arttığını belirtmişlerdir.



Şekil 3.1: Yapay Sinir Ağı Mimarisi ve Parametreleri

Veri seti içerisinde yer almayan bazı önemli parametreler ise:

- Yer Altı Su Seviyesi (YASS): YASS’daki artış sonrasında efektif gerilmede düşüş meydana gelmektedir (Sedat, S., Ertan, B., Aşkın, Ö., 2018). Efektif gerilmede yaşanan bu düşüş ile Denklem 1.8’de ve Denklem 1.9’de sırasıyla bir zemine etkileyen normal gerilme ve kayma gerilmesinde düşüş meydana gelecektir. YASS ‘da meydana gelecek hareketliliğin zemin gerilme değerlerine etkisi nedeni ile yanal deplasman parametresinde ciddi değişimler oluşmaktadır. Bu nedenden ötürü YASS’ın veri seti içerisinde yer alması önemli olmaktadır. Ancak YASS’ın veri seti içerisinde yer almama nedeni elde edilen veri seti içerisinde gözlem-sütun birimi olarak verilmemesidir.
- Şev Açısı-Eğimi: 2007 yılında Tolon “*Yapay sinir Ağları Kullanarak Şev Stabilitésinin İncelenmesi*” adlı çalışmasında şev stabilitesinde; düşey ve

yatay sismik zemin katsayılarını, şev yüksekliğini, şev eğimini ve yer altı suyu derinliğini önemli parametreler olarak sıralamaktadır. Buna göre şev eğimi, derin kazıların eğimli yapılması halinde önemli bir parameter olarak incelenmelidir. Ayrıca derin kazı yöntemlerinin değerlendirildiği Bölüm 2’de kazının şevli yapıldığı uygulamalar incelendiğinde püskürtme beton ve zemin çivisi uygulamaları dikkat çekmektedir. Bu uygulamaların veri seti içerisinde yer almamasından dolayı şev eğimine bu tez kapsamında yer verilmemesi geoteknik açıdan herhangi bir probleme neden olmamaktadır.

- Zemin Sınıfı: TBDY 2018 Bölüm-16 da zeminler 6 farklı türe ayrılmaktadır. Bunlar durabilitesi yüksek olandan düşük olana doğru ZA-ZB-ZC-ZD-ZE-ZF şeklinde sıralanmaktadır.

Kazı stabilizasyon problemlerinde zemin türlerine göre etkiyen toprak basınç katsayılarının değişmesi sonucunda model çıktı parametresi olan yanıl deplasman değeri doğrudan etkilenmektedir. Tablo 3. 1’de zemin türlerine göre değişen K_0 değerleri verilmektedir (Şengün, 2021).

Tablo 3. 1’de verilen K_0 parametresi sükunetteki toprak basıncı katsayısını ifade etmektedir. Ancak zemin türünün veri seti içerisinde yer almama nedeni veri seti içerisinde gözlem-sütun birimi olarak verilmemesidir.

Tablo 3.1: Zemin Türüne Göre Değişen Toprak Basıncı Katsayısı

| K_0 | Zemin Türü |
|---------|----------------------|
| 0,35 | Sıkı kum |
| 0,5 | Gevşek kum |
| 0,5 | Sert kil |
| 0,6 | Yumuşak kil |
| 0,5-0,7 | Normal konsolide kil |

| | |
|---------|---------------------|
| 1,0-1,5 | Sıkıştırılmış kum |
| 1,0-2,0 | Sıkıştırılmış kil |
| 1,0-4,0 | Aşırı konsolide kil |

Kaynak: Şengün, 2021.

3.1. Veri Setinin Geoteknik ve İstatistik Olarak Değerlendirilmesi

Bu tez kapsamında kullanılan verilerin betimsel istatistikleri Şekil 3. 2 'de gösterilmiştir. Şekil 3. 2'de görülen gözlem verileri(sütunlar):

- Destekleme_Sistemi; kazı destek tipini, iksalama sistemini,
- Destek_Aralığı(mm); iksa sisteminin yatay elemanlar veya payandalarca desteklenme aralığını,
- EI_n(kNm²/m); yanal rijitlik,
- H_Kazı(mm); kazı derinliği,
- δ_v_Olcum(mm); sahada ölçülen düşey deplasmanı,
- δ_h_Olcum(mm); sahada ölçülen yatay deplasmanı,

ifade etmektedir.


Şekil 3. 2'de görüleceği üzere otuz bir adet destekleme sistemi tipi mevcuttur. Görüleceği üzere bazı hücreler NaN yani boş değerler almaktadır. Bu tamamen verilerin ham veri yani işlenmemiş veri olduğu anlamına gelmektedir.

Şekil 3. 3'de ham verilerin tüm gözlemlerinin bir arada olduğu saçılım matris grafiği görülmektedir. Diyagonal'den geçen grafikler de örneğin; birinci satır birinci sütunda Destek_Aralığı(mm)-Destek_Aralığı(mm) grafiği görülmektedir. Bu grafikte köşegenlerde yer alan sütunlar/gözlemler veri seti içerisindeki dağılımlarını göstermektedir. Bu dağılımların yoğunlaştığı bölgeleri ifade eden grafik ise Şekil 3.8'de görüldüğü üzere çekirdek yoğunluğu grafiğidir. Ham verilerin bir birleri

arasındaki etkileşim matris saçılım grafiğinde görülmektedir. Şekil 3.3’de aykırılık durumları hakkında ön gözlemler yapılmaktadır.

| | Destek_Aralığı(mm) | | | | | EI'n(kNm2/m) ... | | | | | Öv_Olcum(mm) | | | | | Şh_Olcum(mm) | | | | | |
|---|--------------------|------------|-----------|-------|-------|------------------|--------------|--------------|---------|---------|--------------|-------|------------|-----------|-------|--------------|-------|------------|-----------|-------|-------|
| | count | mean | std | min | max | count | mean | std | min | max | ... | count | mean | std | min | max | count | mean | std | min | max |
| Destekleme_Sistemi | | | | | | | | | | | | | | | | | | | | | |
| Aşağıdan yukarıya + Geçici destek | 1 | 90.000000 | NaN | 90.0 | 90.0 | 1 | 4.600000e+06 | NaN | 4600000 | 4600000 | ... | 1 | 40.000000 | NaN | 40.0 | 40.0 | 1 | 35.000000 | NaN | 35.0 | 35.0 |
| Diyafram duvar | 1 | 46.700000 | NaN | 46.7 | 46.7 | 1 | 1.280000e+06 | NaN | 1280000 | 1280000 | ... | 1 | 34.000000 | NaN | 34.0 | 34.0 | 1 | 60.000000 | NaN | 60.0 | 60.0 |
| Diyafram duvar + Çok sıra destek | 2 | 30.250000 | 3.889087 | 27.5 | 33.0 | 2 | 9.100000e+05 | 5.232590e+05 | 540000 | 1280000 | ... | 2 | 15.000000 | 7.071068 | 10.0 | 20.0 | 2 | 24.000000 | 15.556349 | 13.0 | 35.0 |
| Kesifen + Tek sıra destek | 1 | 85.000000 | NaN | 85.0 | 85.0 | 1 | 1.254800e+06 | NaN | 1254800 | 1254800 | ... | 1 | 0.000000 | NaN | 0.0 | 0.0 | 1 | 3.000000 | NaN | 3.0 | 3.0 |
| Kesifen kazıklı duvar | 4 | 72.400000 | 20.243847 | 56.0 | 100.8 | 4 | 2.064500e+06 | 9.636272e+05 | 639000 | 2717000 | ... | 4 | 23.750000 | 5.560276 | 18.0 | 29.0 | 4 | 22.500000 | 10.115994 | 10.0 | 34.0 |
| Perde Duvar + Tek sıra destek | 1 | 60.000000 | NaN | 60.0 | 60.0 | 1 | 5.850000e+04 | NaN | 58500 | 58500 | ... | 1 | 2.000000 | NaN | 2.0 | 2.0 | 1 | 5.000000 | NaN | 5.0 | 5.0 |
| Perde Duvar + Çok sıra destek | 2 | 54.300000 | 29.274221 | 33.6 | 75.0 | 2 | 9.644400e+05 | 1.335640e+06 | 20000 | 1908880 | ... | 2 | 9.850000 | 4.030509 | 7.0 | 12.7 | 2 | 19.700000 | 8.061017 | 14.0 | 25.4 |
| Perde H Profili + Çok sıra destek | 9 | 40.000000 | 0.000000 | 40.0 | 40.0 | 9 | 7.350000e+04 | 0.000000e+00 | 73500 | 73500 | ... | 9 | 16.777778 | 5.953524 | 10.0 | 27.0 | 9 | 21.888889 | 11.027743 | 9.0 | 42.0 |
| Sürekli kazıklı duvar | 1 | 72.800000 | NaN | 72.8 | 72.8 | 1 | 1.198500e+06 | NaN | 1198500 | 1198500 | ... | 1 | 0.000000 | NaN | 0.0 | 0.0 | 1 | 11.000000 | NaN | 11.0 | 11.0 |
| Tek sıra destekli palplanş perde duvar | 1 | 68.000000 | NaN | 68.0 | 68.0 | 1 | 9.644000e+04 | NaN | 96440 | 96440 | ... | 1 | 27.000000 | NaN | 27.0 | 27.0 | 1 | 25.000000 | NaN | 25.0 | 25.0 |
| Tek sıra destekli perde duvar | 1 | 50.000000 | NaN | 50.0 | 50.0 | 1 | 5.000000e+04 | NaN | 50000 | 50000 | ... | 1 | 120.000000 | NaN | 120.0 | 120.0 | 1 | 85.000000 | NaN | 85.0 | 85.0 |
| Tek sıra destekli çakma profil | 1 | 50.000000 | NaN | 50.0 | 50.0 | 1 | 1.280000e+06 | NaN | 1280000 | 1280000 | ... | 1 | 26.000000 | NaN | 26.0 | 26.0 | 1 | 17.000000 | NaN | 17.0 | 17.0 |
| Yukarıdan aşağıya + Kazıklı duvar | 3 | 69.666667 | 19.502137 | 50.0 | 89.0 | 3 | 1.840000e+06 | 1.065150e+06 | 618000 | 2571750 | ... | 3 | 19.000000 | 14.933185 | 2.0 | 30.0 | 3 | 21.666667 | 10.408330 | 10.0 | 30.0 |
| Yukarıdan aşağıya ankrajlı duvar | 1 | 46.000000 | NaN | 46.0 | 46.0 | 1 | 4.600000e+06 | NaN | 4600000 | 4600000 | ... | 1 | 8.000000 | NaN | 8.0 | 8.0 | 1 | 45.500000 | NaN | 45.5 | 45.5 |
| Yukarıdan aşağıya diyafram duvar | 10 | 34.140000 | 3.779630 | 27.8 | 40.0 | 10 | 1.824975e+06 | 7.589325e+05 | 857500 | 2500000 | ... | 10 | 75.130000 | 72.156836 | 9.7 | 220.0 | 10 | 57.500000 | 37.404961 | 15.2 | 135.0 |
| Yukarıdan aşağıya perde duvar | 1 | 30.000000 | NaN | 30.0 | 30.0 | 1 | 4.838600e+05 | NaN | 483860 | 483860 | ... | 1 | 100.000000 | NaN | 100.0 | 100.0 | 1 | 48.000000 | NaN | 48.0 | 48.0 |
| Yukarıdan aşağıya çakma profil | 2 | 42.500000 | 6.363961 | 38.0 | 47.0 | 2 | 2.800000e+06 | 2.149605e+06 | 1280000 | 4320000 | ... | 2 | 22.500000 | 20.506097 | 8.0 | 37.0 | 2 | 40.000000 | 49.497475 | 5.0 | 75.0 |
| Yukarıdan aşağıya çok sıra destekli duvar | 11 | 48.727273 | 7.734221 | 41.0 | 65.0 | 11 | 4.254545e+06 | 7.685870e+05 | 2700000 | 4600000 | ... | 11 | 15.000000 | 10.630146 | 3.0 | 30.0 | 11 | 39.054545 | 21.144898 | 15.0 | 79.0 |
| Çakma kazıklı duvar | 1 | 161.000000 | NaN | 161.0 | 161.0 | 1 | 1.280000e+06 | NaN | 1280000 | 1280000 | ... | 1 | 30.000000 | NaN | 30.0 | 30.0 | 1 | 100.000000 | NaN | 100.0 | 100.0 |
| Çakma profil + Tek sıra destek | 1 | 50.000000 | NaN | 50.0 | 50.0 | 1 | 3.885000e+03 | NaN | 3885 | 3885 | ... | 1 | 0.000000 | NaN | 0.0 | 0.0 | 1 | 7.000000 | NaN | 7.0 | 7.0 |
| Çok sıra ankrajlı diyafram duvar | 8 | 47.737500 | 41.732377 | 20.0 | 150.0 | 8 | 1.226725e+06 | 1.618845e+06 | 540000 | 5184000 | ... | 8 | 27.087500 | 17.292148 | 1.0 | 54.0 | 8 | 40.837500 | 36.207455 | 15.0 | 125.0 |
| Çok sıra ankrajlı kazıklı duvar | 4 | 22.125000 | 7.051891 | 15.0 | 30.0 | 4 | 7.029975e+05 | 3.794400e+05 | 203900 | 1126000 | ... | 4 | 5.475000 | 3.368662 | 1.8 | 10.0 | 4 | 17.650000 | 4.640761 | 12.7 | 22.9 |
| Çok sıra ankrajlı çakma profil | 8 | 35.250000 | 12.375090 | 7.5 | 49.0 | 8 | 1.360166e+06 | 2.191127e+06 | 2581 | 5400000 | ... | 8 | 16.500000 | 12.421180 | 5.0 | 40.0 | 8 | 19.750000 | 12.634985 | 10.0 | 50.0 |
| Çok sıra destek - 'Arbed' | 1 | 40.000000 | NaN | 40.0 | 40.0 | 1 | 6.850000e+05 | NaN | 685000 | 685000 | ... | 1 | 75.000000 | NaN | 75.0 | 75.0 | 1 | 88.000000 | NaN | 88.0 | 88.0 |
| Çok sıra destekli diyafram duvar | 11 | 37.563636 | 14.334035 | 26.0 | 62.0 | 11 | 2.103409e+06 | 1.351017e+06 | 540000 | 4320000 | ... | 11 | 50.636364 | 30.933066 | 15.0 | 130.0 | 11 | 42.909091 | 23.657787 | 15.0 | 80.0 |
| Çok sıra destekli kazıklı duvar | 2 | 47.500000 | 10.606602 | 40.0 | 55.0 | 2 | 6.130000e+05 | 7.254916e+05 | 100000 | 1126000 | ... | 2 | 11.400000 | 9.333810 | 4.8 | 18.0 | 2 | 25.250000 | 16.617009 | 13.5 | 37.0 |
| Çok sıra destekli kesifen kazık | 2 | 65.000000 | 1.414214 | 64.0 | 66.0 | 2 | 9.695000e+05 | 2.326381e+05 | 805000 | 1134000 | ... | 2 | 17.500000 | 7.778175 | 12.0 | 23.0 | 2 | 32.000000 | 16.970563 | 20.0 | 44.0 |
| Çok sıra destekli palplanş perde | 3 | 22.000000 | 2.645751 | 20.0 | 25.0 | 3 | 6.246667e+04 | 6.652310e+03 | 57400 | 70000 | ... | 3 | 116.666667 | 28.867513 | 100.0 | 150.0 | 3 | 204.333333 | 68.966175 | 145.0 | 280.0 |
| Çok sıra destekli perde duvar | 13 | 32.361538 | 9.888001 | 19.1 | 45.0 | 13 | 4.469954e+05 | 6.093793e+05 | 40000 | 1780000 | ... | 13 | 76.176923 | 96.240776 | 4.6 | 270.0 | 13 | 58.246154 | 59.686132 | 4.8 | 220.0 |
| Çok sıra destekli sürekli kazıklı duvar | 8 | 38.000000 | 5.656854 | 24.0 | 40.0 | 8 | 9.985625e+04 | 2.869086e+04 | 18850 | 100000 | ... | 8 | 20.625000 | 15.756518 | 10.0 | 58.0 | 8 | 18.250000 | 22.783139 | 7.0 | 73.0 |
| Çok sıra destekli çakma profil | 6 | 40.000000 | 0.000000 | 40.0 | 40.0 | 6 | 3.412500e+04 | 1.928973e+04 | 26250 | 73500 | ... | 6 | 9.333333 | 3.386247 | 5.0 | 15.0 | 6 | 15.833333 | 8.352644 | 8.0 | 30.0 |


Şekil 3. 2: Veri Setinin Destekleme Sistemine Göre Gruplandırılmış Betimsel İstatistiği



Şekil 3. 3: Matris Grafiği


Şekil 3. 4 'de yatay deplasman ölçüm($\delta h_Olcum(mm)$) ile H_Kazı(mm) arasındaki ilişki görülmektedir. Burada veri kümelerinin yoğunlaştığı bölgelerin uzağında kalan veriler için aykırılığa neden olan veriler denilebilmektedir. Kazı derinliği ve yatay deplasman ölçüm parametrelerinin veri seti içerisindeki dağılımları Şekil 3. 4'de görülmektedir. Aynı zamanda yatay deplasman ölçüm verilerinin 50 mm değerinin aşığına ve kazı derinliğinde 800-1950 mm değerleri aralığında kümelendiği görülmektedir.

Ham verilerde aykırılık ilişkisi diğer saçılım grafiklerinde de geçerli olmaktadır (bkz. Şekil 3. 4-6).




Şekil 3. 4: $\delta h_{Olcum}(mm)$ ve $H_{Kazı}(mm)$ Saçılım Grafiği

Destek_Aracağı(mm) ve yatay deplasman ölçüm parametrelerinin veri seti içerisindeki dağılımları Şekil 3. 5’de görülmektedir. Aynı zamanda yatay deplasman ölçüm verilerinin 75 mm değerinin aşağısına ve kazı derinliğinde 20-60 mm değerleri aralığında kümelendiği görülmektedir.




Şekil 3. 5: $\delta h_{Olcum}(mm)$ ve Destek_Aracağı Saçılım Grafiği

Yanal rijitlik ve yatay deplasman ölçüm parametrelerinin veri seti içerisindeki dağılımları Şekil 3. 6’de görülmektedir. Aynı zamanda yatay deplasman ölçüm verilerinin 50 mm değerinin aşağısında kümelendiği ve yanal rijitlik değerlerininse parçalı bir şekilde kümelenecek aralıklar oluşturduğu görülmektedir. Aralıklı kümelene regresyon problemlerinde istenmeyen bir durum olmaktadır. Bunun nedeni regresyon eğrisi çiziminde sürekliliği olumsuz etkilemektedir.




Şekil 3.6: EI\ (kNm2/m) ve δh_Olcum (mm) Saçılım Grafiği

Düşey deplasman ölçüm ve yatay deplasman ölçüm parametrelerinin veri seti içerisindeki dağılımları Şekil 3. 7’de görülmektedir. Aynı zamanda yatay deplasman ölçüm verilerinin 65 mm değerinin aşağısına ve kazı derinliğinde 40 mm değerinin aşağısında kümelendiği ve kümelenmeden uzaklaşan değerlerin kümeden aykırı alanlarda yer aldıkları da görülmektedir.




Şekil 3.7: δv_Olcum (mm) ve δh_Olcum (mm) Saçılım Grafiği

Şekil 3. 8’deki grafikte çekirdek yoğunluğu matris grafiği gösterilmektedir. Bu grafik tüm gözlemleri aynı anda değerlendirmeye ve içerdiği grafikler sayesinde hangi veriler arasındaki duruma odaklanabileceğimize yardımcı olmaktadır.




Şekil 3.8: Ham Verilerin Çekirdek Yoğunluğu Matris Grafiği

Şekil 3. 8'in içerisinde yer alan grafiklerden destek aralığı'nın veri havuzu içerisindeki dağılımını Şekil 3. 9 'da yakından görülebilmektedir. Şekil 3.9 'da gösterilen "A" detayında veri normal dağılım dışına çıkarak ikinci bir tepe noktası oluşturmaktadır. Buradaki durum Bölüm 4'de detaylı bir şekilde kod yazım aşamasında model oluşturulmadan önce incelenmektedir.



Şekil 3.9: Destekleme_Aralığı(mm) 'na Ham Verilere Ait Veri Seti içerisindeki Dağılımı

Şekil 3. 10'da görüldüğü üzere Destek_Aralığı(mm) ve $\delta h_{\text{Olcum}}(\text{mm})$ ham verileri sırasıyla 0-50 aralığına 50'ye daha yakın, 0-100 aralığında 0'a daha yakın şekilde yoğunlaşmaktadır. Burada beklenen durum merkezdeki çekirdek etrafından başlayan yayılımların eşit mesafelerce yayılmasıdır. Birden fazla merkez olması diğer gözlem birimlerinin etkisinden kaynaklanmaktadır. Buradaki birden fazla merkez etkisine sebep olan gözlem parametresi destekleme sistem tipleri olmaktadır. Aynı zaman da çekirdek yoğunluğunun dışında kalan merkezlerin aykırılık barındırma durumları tez kapsamında Bölüm 4 'de model oluşturma öncesinde veri analizleri sırasında değerlendirilmiştir.




Şekil 3.10: Çekirdek Yoğunluğu Grafiği, $\delta h_{\text{Olcum}}(\text{mm})$ ve Destek_Aralığı(mm)

Şekil 3. 3 ve Şekil 3. 8 'de matris grafiklerinde gözlemlenen veri dağılımı ve yayılımına etkiyen durumlar her zaman irdelenmelidir. Bu bağlamda Şekil 3. 11'da ve Şekil 3. 12'de destekleme sistemi tipine göre veriler lejantlanmıştır. Bu durumunda aykırılık ve anormallik gözlemleri daha doğru ve hızlı yapılabilmektedir. Destekleme sisteminin otuz bir adet olmasından dolayı bu grafikleri tek tek gözlemlemek gerekmektedir.


Şekil 3. 10'da ham verilerin saçılım matris grafiği destekleme tiplerine göre verilmektedir. Bu grafiğe göre gözlem verilerinin bir biri arasındaki ilişki destekleme tiplerine göre bir birleri ile kıyas edilip yorumlanabilmektedir. Şekil 3. 10'da yatay deplasman ile destekleme aralığı arasında aykırılığa ve/veya anormalliğe sebebiyet veren durum çok sayıda destekleme tipi olması nedeni ile daha yakından incelenmesi için yatay deplasman ile destekleme tiplerine göre saçılım grafiği Şekil 3. 11'de görülmektedir.

Örnek olması açısından Şekil 3. 11'de, aykırılık oluşturan ham verilerin Destek_Aralığı ekseninde yaklaşık 20 değerinde, $\delta h_{Olcum(mm)}$ ekseninde yaklaşık 280 değerinde "çok sıra destek palplanş perde" 'ye ait görülmektedir. Aynı şekilde Destek_Aralığı ekseninde yaklaşık 100 değerinde, $\delta h_{Olcum(mm)}$ ekseninde yaklaşık 25 değerinde "yukardan aşağıya ankrajlı duvar" destekleme sistemi tipine ait olduğu görülmektedir.


Şekil 3. 12-14 'de yatay deplasman ölçüm parametresinin girdi parametreleri ile olan saçılım grafikleri, destekleme tiplerine göre gösterilmektedir.




Şekil 3.11: Ham Verilerin Saçılım Matris Grafiği - Destekleme Sistemine Göre Dağılım




Şekil 3.12: Destekleme Sistemine Göre $\delta h_{Olcum}(mm)$ ve Destek_Aralığı(mm) Saçılım Grafiği



Şekil 3.13: Destekleme Sistemine Göre $EI_n(kNm^2/m)$ ve $\delta h_{Olcum}(mm)$ Saçılım Grafiği



Şekil 3.14: Destekleme Sistemine Göre $\delta h_{Olcum}(mm)$ ve $H_{Kazı}(mm)$ Saçılım Grafiği




Şekil 3.15: Destekleme Sistemine Göre $\delta h_{Olcum}(mm)$ ve $\delta v_{Olcum}(mm)$ Saçılım Grafiği

$\delta h_{Olcum}(mm)$ ile diğer gözlemlerin arasındaki ilişkinin şiddetlerini lineer dağılım grafikleri Şekil 3.16-19'da göstermektedir.


Şekil 3. 16'de görüldüğü üzere destek aralığı arttıkça $\delta h_{Olcum}(mm)$ 'de azalma

meydan gelmektedir. Normal şartlar altında destek aralığının sıklaşması ile yatay deplasmandaki ölçümlerin azalması beklenmektedir.




Şekil 3.16: $\delta h_{Olcum}(mm)$ ve $Destek_Aralığı(mm)$ Lineer Dağılım Grafiği

Şekil 3. 17'da yanal rijitlik(EI (kNm^2/m)) ile yatay deplasmanın($\delta h_{Olcum}(mm)$) neredeyse nötre yakın bir ilişkisi söz konusu olsada dağılımın yönünü belirleyen optimum çizgi negatif yönlüdür. Normal şartlarda yanal ötelenme rijitliğinin artması ile yatay deplasmanlarda nötre yakın değil de şiddetli negatif azalış beklenmektedir.




Şekil 3.17: $\delta h_{Olcum}(mm)$ ve $EI(kNm^2/m)$ Lineer Dağılım Grafiği

Şekil 3. 18’de görüldüğü üzere kazı derinliği($H_{\text{Kazı}}(\text{mm})$) arttıkça yatay deplasmanlarda($\delta h_{\text{Olcum}}(\text{mm})$) artış şeklindedir. Burada kazı derinliği ile yatay deplasmanlar arasında pozitif yönlü bir ilişki olduğunu görülmektedir. Dağılımın yönünü belirleyen optimum çizginin eğimi göz önüne alındığında pozitif ilişkinin şiddetinin yüksek olduğu görülmektedir (Şekil 3 .18).



Şekil 3.18: $\delta h_{\text{Olcum}}(\text{mm})$ ve $H_{\text{Kazı}}$ Lineer Dağılım Grafiği


Şekil3. 19’de görüldüğü üzere yatay deplasman($\delta h_{\text{Olcum}}(\text{mm})$) ile düşey deplasman($\delta v_{\text{Olcum}}(\text{mm})$) arasında şiddetli pozitif bir ilişki bulunmaktadır. Destekleme sisteminin arkasında yer alan zeminde düşey deplasman arttığında destekleme sisteminde ölçülen yatay deplasmanda paralel bir şekilde artmaktadır.



Şekil 3.19: $\delta h_{\text{Olcum}}(\text{mm})$ ve $\delta v_{\text{Olcum}}(\text{mm})$ Lineer Dağılım Grafiği

Şekil 3. 20-24 'lerde destekleme sistemi bazında, Şekil 3. 16-19'lerdeki uygunsuzluklar incelemektedir.

Şekil 3. 16'de gözlemlenen normal beklentilerin dışındaki durumu Şekil 3. 20'da destekleme sistemi tipine göre incelemektedir. Şekil 3. 20 'da Destek_Aralığı(mm) 20-30 değerleri arasında ve $\delta h_{Olcum}(mm)$ 'üm 150-300 değerleri arasında destekleme tipi olarak *çok sıra destekli palplanş perde*, gözlemlenmektedir. Ve çok sıra palplanş perde gibi negatif yönlü etkiyen diğer destekleme tipleri de görülmektedir.



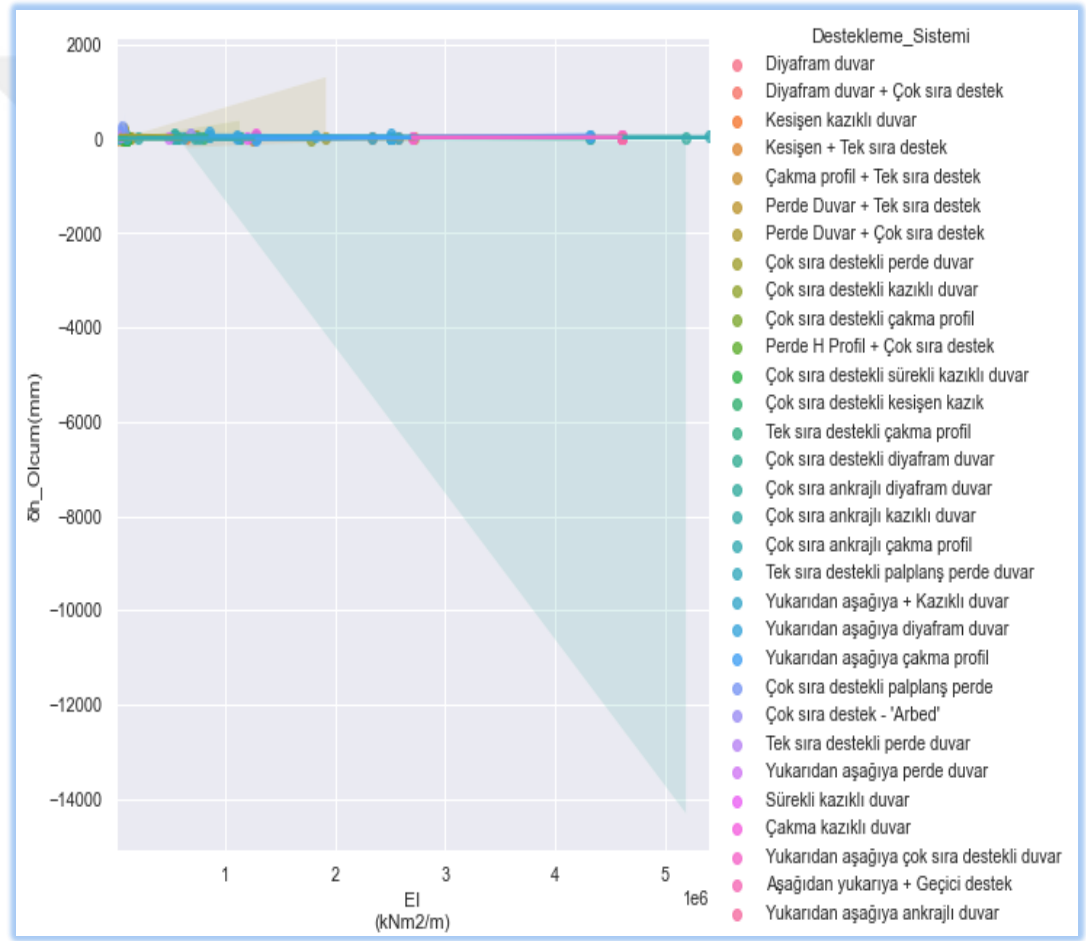
Şekil 3.20: Destekleme Sistemine Göre $\delta h_{Olcum}(mm)$ ve Destek_Aralığı(mm) Lineer Dağılım Grafiği

Şekil 3. 21 'de çok sıra palplanş perde destekleme sisteminin ham veri seti içerisindeki örnekleme yer almaktadır. Buna göre; Destek_Aralığı(mm) değeri 21 iken $\delta h_{Olcum}(mm)$ değeri 28, Destek_Aralığı(mm) değeri 20 iken $\delta h_{Olcum}(mm)$ değeri 188 ve Destek_Aralığı(mm) değeri 25 iken $\delta h_{Olcum}(mm)$ 145 değerindedir.


Şekil 3. 22-24 de gösterilen destekleme tiplerine göre lineer ilişki grafiklerinin yorumu Bölüm 4 ve 5’de anlatılmaktadır.

| | Destekleme_Sistemi | Destek_Aralığı(mm) | El\ (kNm ² /m) | H_Kazı(mm) | δv_Olcum(mm) | δh_Olcum(mm) |
|----|----------------------------------|--------------------|---------------------------|------------|--------------|--------------|
| 70 | Çok sıra destekli palplanş perde | 21.0 | 60000 | 14700 | 100.0 | 280.0 |
| 87 | Çok sıra destekli palplanş perde | 20.0 | 57400 | 12000 | 150.0 | 188.0 |
| 88 | Çok sıra destekli palplanş perde | 25.0 | 70000 | 15000 | 100.0 | 145.0 |


Şekil 3.21: Çok Sıra Palplanş Perde - Ham Veri Seti



Şekil 3.22: Destekleme Sistemine Göre δh_Olcum(mm) ve EI\ (kNm²/m) Lineer Dağılım Grafiği



Şekil 3.23: Destekleme Sistemine Göre $\delta h_{Olcum}(mm)$ ve $H_{Kazı}$ Linear Dağılım Grafiği



Şekil 3.24: Destekleme Sistemine Göre $\delta h_{Olcum}(mm)$ ve $\delta v_{Olcum}(mm)$ Linear Dağılım Grafiği

3.2. Veri Seti Korelasyonu

Çıktı verisi iki girdi verisinden oluşuyorsa bu iki veri arasında ikili korelasyon katsayısına bakarak birbirleri arasındaki ilişkiyi açıklayabilir. Ancak çıktı verisi ikiden fazla girdiden oluşuyorsa tek başına ikili korelasyonlara bakmak net bir yorum vermeyebilir. Çünkü iki girdi verisini üçüncü ve/veya daha fazla girdi parametresi etkiliyor olabilir. Eğer ki girdi verileri ikiden fazla ve çok ilişkili durumu varsa “Path Analizi” yapılmasını önerilmektedir (Orhan ve Kaşıkçı, 2002).

Bu tez kapsamında kullanılan veri setinde verilerin ikili ilişkilerini incelerken bir üçüncü ilişkinin etkisinin etkisi bulunmaktadır.

Bu üçüncül etkiler istatistiğin bir konusudur. Korelasyon değerleri veri setinin ikili ilişkileri hakkında neden – sonuç ilişki vermez (Orhan ve Kaşıkçı, 2002).

Şekil 3 .25 ‘deki korelasyon değerleri ikili ilişkiler hakkında yorum geliştirilmesini sağlamaktadır. Kesin çıkarımlar korelasyon ile yapılamamaktadır.

Tablo 3. 2’ e göre Şekil 3 .25 incelendiğinde:

İkili ilişkiler:


- Yatay deplasman($\delta h_{\text{Olcum}}(\text{mm})$) - Destek_Aralığı(mm) : -0.15
Negatif düşük düzeyde ilişki
- Yatay deplasman($\delta h_{\text{Olcum}}(\text{mm})$) - Yanal rijitlik($EI_n(\text{kNm}^2/\text{m})$) : -0.03
Negative düşük düzeyde ilişki (nötr(ilişki yok) ilişki seviyesine yakın)
- Yatay deplasman($\delta h_{\text{Olcum}}(\text{mm})$) – Kazı derinliği($H_{\text{Kazı}}(\text{mm})$) : 0.10
Pozitif düşük düzeyde ilişki
- Yatay deplasman($\delta h_{\text{Olcum}}(\text{mm})$) – Düşey deplasman($\delta v_{\text{Olcum}}(\text{mm})$):
0.65

Pozitif orta düzeyde ilişki (yüksek düzeye yakın)

Şekil 3. 25 'de köşegenlerden geçen hücreler veriler kendileri ile eşleştiklerinden ötürü korelasyon değerleri 1.00'dır.

Veri işlenmesi sırasında aykırı veri analizi yaparken korelasyon değerlerine göre yorumlamalar yapılmaktadır.

Ham veri setinde parametreler arasındaki doğrusal ilişkiler Şekil 3. 25 'de korelasyon katsayılarında gözlemlenmektedir.



Şekil 3.25: Ham Veri Setinin Korelasyon Haritası

Bölüm 4'de bahsedildiği üzere kutu grafik yöntemi ile aykırı veri analizi yapılmaktadır. δ_h _Olcum(mm) için aykırı veri analizinde 84 üst sınır değerinin üstünde gözlemlenen ve δ_h _Olcum(mm) değeri 88 'den 84'e baskılanmaktadır. Nedeni δ_v _Olcum(mm) değeri ile arasındaki ilişkinin korelasyonlarına uymasındır.

Diğer indekslerin silinme nedeni de korelasyonlarına uymamasından kaynaklanmaktadır (Bkz. Şekil 3. 26).

| | Destekleme_Sistemi | Destek_Aralığı(mm) | El\\n(kNm2/m) | H_Kazı(mm) | δ_v _Olcum(mm) | δ_h _Olcum(mm) |
|----|----------------------------------|--------------------|---------------|------------|-----------------------|-----------------------|
| 65 | Çok sıra destek - 'Arbed' | 40.0 | 685000 | 15000 | 75.0 | 88.0 |
| 68 | Tek sıra destekli perde duvar | 50.0 | 50000 | 6500 | 120.0 | 85.0 |
| 81 | Çok sıra ankrajlı diyafram duvar | 37.5 | 540000 | 16000 | 1.0 | 125.0 |
| 82 | Yukarıdan aşağıya diyafram duvar | 36.3 | 2500000 | 14500 | 220.0 | 110.0 |

Şekil 3.26: Kutu Grafik Yöntemi İle Aykırı Veri analizi - δ_h _Olcum(mm) Aykırı Değerleri

Tablo 3. 2: Korelasyon Katsayıları İlişki Düzeyi

| Korelasyon Katsayısı | İlişki Düzeyi |
|----------------------|---------------|
| 0.00 | Yok |
| 0.01 – 0.29 | Düşük |
| 0.30 – 0.70 | Orta |
| 0.71 – 0.99 | Yüksek |
| 1.00 | Mükemmel |

Kaynak: (Url-18, 2021)

4. PYTHON İLE MAKİNE ÖĞRENMESİ BAZINDA GELİŞTİRİLEN MODELİN İNCELENMESİ

4.1. Yapay Sinir Ağları

Bilgisayar ortamında verilen her bir örnekten, gerekli algoritma ve formülasyonların kullanılmasıyla bir şeyler öğrenilmesi aracılığıyla ilerleyen zaman ya da zamanlar içi ilgilenilen olay hakkında karar verecek düzeye ulaşılmasına “makine öğrenmesi” denilir. YSA bu makine öğrenmesi alanında geliştirilmiş olan uygulamalardan biridir. Örnek verileri kullanılarak genel yargılar veya sonuçlar üretilmeye çalışılır. Uygulamacı tarafından bilgisayarda kurulan ağa sadece eldeki örnekler verilir, başka bilgi verilmeden bu örnekler ile sonuçlara bakarak ağın öğrenme işlemini gerçekleştirmesi istenir. Ağ kendi sistemini kullanarak öğrenmeyi gerçekleştirir daha sonraki aşamada ise hiç görmediği örnekler için öğrendiği bilgileri kullanarak çözüm yada sonuç üretir (Öztemel,2012).

YSA, basit işlemci hücrelerden(nöron) oluşan birbirine paralel ve dağılmış bir düzende çalışan öğrendiği bilgiyi depolayan ve bilgiyi kullanmak içineğitilmiş, iyi bir şekilde tasarlanmış, içerisinde yoğun işlemlerinin sürdüğü bir işlemcidir (Alexander and Morton, 1990; Haykin, 1999; Rojas,2013).

YSA’da işlem birimleri vardır. Her işlem birimi girdiği bir ağırlık değeri ile ağırlandırılır, dönüşümünü gerçekleştirir ve sonuçta çıktıları ulaşılır. YSA’ların her ne kadar kendilerine özgü yapıları olduğu düşünülse de daha önceden geliştirilmiş tahmin, sınıflandırma kontrol vb. Modellerine benzerlikleri de bulunmaktadır. Matris ve vektör hesapları, tekli ve çoklu regresyon, stokastik süreçler, korelasyon, zaman serileri çözümlenmeleri gibi bazı Modelleme yöntemleri ile ortak mimarileri bulundurmaktadır (Şen,2004).

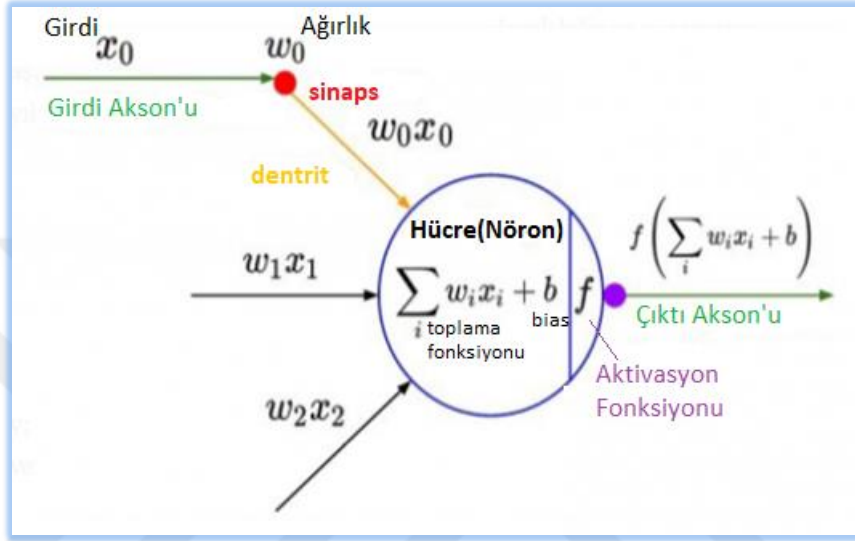
YSA'nın çalışma mantığını anlamak için insan beyninin çalışma mantığını kavramak gerekir. İnsan beyni, yapısı itibariyle çok karmaşıktır ve hala tam olarak çözümlenememiştir. Belki bu karmaşıklığı ve çözümlememe durumu beyni anlamaya yönelik ilginin hiç azalmamasına daha da artmasına yol açmıştır. Beynin nasıl karar verdiği tercih yaptığı düşündüğü vb. tüm faaliyetler her dönem merak edilmiştir. YSA'lar beyinden esinlenerek oluşturdukları için beynin benzer yapıya sahiptir (Karaatlı vd., 2005).

YSA'da insan sinir hücresine benzeyen yapılar (nöronlar) bulunmaktadır (Graupe, 2013). Yapay sinir hücresini oluşturan bu yapılar bir araya geldiğinde yapay sinir ağını oluşturur. YSA'da ise yapay sinir hücreleri beynin yaptığı işlevleri gerçekleştirmeye çalışır. Tabii ki bu yapay sinir hücreleri beyindeki gerçek sinir hücreleri ile karşılaştırıldığında çok basit yapıdadırlar. Bu yapay nöronlar tıpkı gerçek sinir hücreleri gibi bağlantı hâlinindedir. Çevreden aldıkları bilgiyi toplar bunlar üzerine bazı işlemler yapar ve sonuç ya da eylem üretirler. YSA her ne kadar insan beyin hücrelerine benzetilse de bir yönden bu hücrelerden bir üstünlüğü vardır. YSA'daki bilgilerin kaybolma veya silinme ihtimali yoktur (Çelik, 2008). Ancak insan beyin hücrelerinin hasar görmesi sonucu o zamana kadar depolanan bazı bilgiler hafızadan silinebilir. YSA kendine verilen bilgilere göre kendi ilişkilerini kurar. Kendilerine ait denklemleri yoktur. Dahası ağı içinde yapılan işlemlerin ne olduğu kesin olarak bilinemez (Aktaş, 2003). Bu özelliğinden dolayı YSA "kara kutu" olarak tanımlanabilir (Öztemel, 2003). Kara kutunun içindeki işlemlerin neler olduğu hangi işlemlerin yaşandığı hâlâ bilinmemektedir.

Bir yapay sinir ağı hücresinde ileride ayrıntıları anlatılacak olan beş bölüm yer alır. Bunlar; girişler, ağırlıklar, toplama fonksiyonu, aktivasyon (transfer) fonksiyonu ve çıkışlar olarak sıralanabilir. Gerçek sinir hücresindeki aksonlar yapay sinir hücresinde çıktıları, dendritler toplama fonksiyonunu, çekirdek aktivasyon fonksiyonunu ve sinapsler ağırlıkları temsil eder (Kaftan, 2010). Bu özellikleri ile YSA'lar tam bir sinir hücresine benzetilebilir.

Şekil 4. 1'de görüldüğü üzere bağımsız değişkenimiz x_0 ilk ağırlık değeri ile çarpılıp

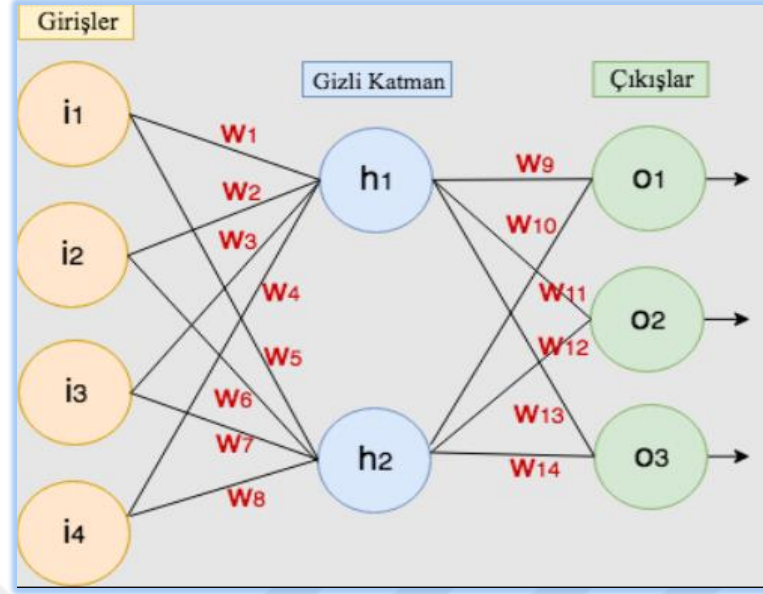
dentritler aracılığı ile sinir hücresine(nöron) iletilir. Sinir hücresine iletilen bu ağırlık değerinin toplamı diğer tüm bağımsız değişkenlerden gelen x_0 . w_i değerlerinin toplamıdır. Bu toplam birleştirme fonksiyonu ya da toplama fonksiyonu olarak geçmektedir. Toplam sonrası bir bias değeri ile toplanır ve aktivasyon fonksiyonuna maruz bırakılır ve çıkışa aktarılır bu çıkış çıktı olabileceği gibi bir başka sinir hücresinin girişi de olabilmektedir.



Şekil 4.1: Bir Sinir Hücresinin Matematiksel Gösterimi

Kaynak: (Url-19 , 2022)

Şekil 4.2 'de bir yapay sinir ağının genel görünümüne yer verilmiştir. Her ağda girdi ve çıktı setlerinin yapıları benzerdir. Yani ağda muhakkak girdiler ve bu girdilerden elde edilen çıktılar vardır. Ancak katman ve nöron sayılarının durumu araştırma konusu ve araştırmacının isteklerine göre biçimlendirilir. Her tasarlanan ağ için belli ya da sınırlı bir nöron ve/veya katman sayısı yoktur.



Şekil 4.2: Yapay Sinir Ağı Hücre Modeli

Kaynak: (Url-20 , 2021)

1940'lı yıllarda Donald Olding Heb, nörolog Warren McCulloch matematikçi Walter Pitts, nörobiyoloji alanındaki YSA çalışmalarını mühendislik alanına çekerek ilk yapay sinir hücrelerini oluşturmuşlardır (Haykin, 1999). İnsan beyninin hesap yapma özellikleri üzerinde düşünerek bu özelliklere uygun bir ağ geliştirmişlerdir. Dahası 1949'da Donald Heb, kendi adını verdiği Hebbian öğrenme kuralını geliştirmiştir (Hebb, 1949). Bu kural, şimdilerde kullandığımız öğrenme kuramlarının da temelini oluşturmuştur. YSA'nın gelişiminden bahsederken 1970 yılının anahtar yıl olması gerekir. YSA çalışmaları bu yılda başlamamıştır ancak YSA ile ilgili dönüm noktası bu yıldır. 1970 yılında Minsky ve Pappert tarafından yazılan bir kitap ile YSA'ya dayalı algılayıcıların bilimsel olmadığı, doğrusal Olmayan Modellere çözüm üretmediğinin ortaya atılması YSA çalışmalarına sekte vuran olay olmuştur. Doğrusal olmayan ve Çok katmanlı bir ağ ile çözülmesi gereken XOR problemine çözüm üretmiyor olması YSA'ya olan ilgiyi azaltmıştır (Voorhees, 2006). YSA çalışmaları bu XOR probleminin çözümüne kadar ilerleme göstermemiştir. Problemin YSA ile çözülmesinin ardından ilgiler tekrar YSA üzerine çekilmiştir (Graupe, 2013).

YSA mantığı geliştirildiği yıllardan beri, ağırları kullanarak işlem yapmak başarılı sonuçlar ortaya çıkarmıştır. Çözülmesi zaman alıcı ve karmaşık problemlerin kısa zamanda farklı bakış açılarıyla sonuçlandırabilmesi Yapay sinir ağını her alanda çok kullanılan bir uygulama hâline getirmiştir (Haykin, 1999). YSA bazen tek başına bazen de diğer uygulamalar ile melezlenerek ya da birleştirilerek kullanılmıştır (Zhang vd. 1998). YSA'nın tek başına verdiği değerler ile diğer uygulamaların sonuçlarının karşılaştırılmasında pek çok alanda YSA'nın daha başarılı sonuçlar verebildiği görülmektedir. YSA tıp, mühendislik, sağlık, savunma, ticaret, güvenlik vs. çok farklı alanlarda başarı ile uygulanmaya devam etmektedir (Anderson, 1995). Her geçen gün YSA mantığı daha da gelişmekte daha iyi sonuçların verilebilmesi için YSA'ya yeni yaklaşımlar getirilmektedir.

YSA'lar gerçek hayatta sistem Modelleme, örüntü tanıma, parmak izi tanıma, ekonomik ve finansal tahminleme. finans kurumları için kredi derecelendirme, savunma sistemlerinin oluşturulması, hastalıkların önceden tanınması, endüstriyel alanlarda enerji tahminlemesi, proses akış kontrolü, pazar araştırmalarında müşteri belirleme, ürün seçimi, teknolojik alanda ses ile hareket veya ses ile işlem yapma, parmak izi veya retina tanıma, eksik resim veya bilgiyi tamamlama, güvenlik alanında görüntü temizleme alanlarında başarı ile kullanılmaktadır (Pham & Oztemel 1995). YSA'nın tahminleme ve sınıflamadaki üstün başarısı finansal alanda da yaygın olarak kullanılmasını sağlamıştır (Trip ve Turban, 1993). Döviz, petrol, hisse senedi vb. yatırım araçlarının değerlerinin tahminlenmesi, kurumların verilerine bakarak iflas tahminlerinin yapılması, müşterilerin kredi ödeme güllerinin belirlenmesi ve kredi derecelendirmelerinin yapılması, firma veya kurumların risk analizlerinin yapılması gibi alanlarda YSA başarılı sonuçlar üretmektedir (Anderson, 1995; Coats ve Fant, 1991). Savunma alanında ise YSA; radar takip sistemleri, radar ekranı okuma, sinyal işleme, savunma araçlarının ya da uçakların etkin rotalarının belirlenmesi, kullanılacak silahların optimizasyonu, hedef takibi gibi alanlarda sıklıkla kullanılmaktadır (Collins ve Evans, 1994; Ergezer vd., 2003).

Tez kapsamında geri beslemeli yapay sinir ağı mimarisi kullanılmaktadır.

4.1.1. Yapay sinir ağı bileşenleri

4.1.1.1. Girdiler

Girdi katmanı dış dünyadan gelen bilgileri toplayan katmandır. Girdi katmanında dışarıdan gelen girdi sayısı kadar sinir hücresi bulunur. Bu katmanda girdiler genelde bir işleme tabi olmadan diğer katmana geçer (Rojas, 2013). Girdi katmanından gelen bilgiler ara katmanlara geldiğinde bilgi işlemesi yapılır. Bu girdiler yapay sinir hücresine gelen bilgileri göstermektedir.

4.1.1.2. Ağırlıklar

Ağırlıklar hücreye gelen bilginin önemini ve etkisini göstermektedir. Ağırlıklar, pozitif veya negatif olabilir (Caner & Akarslan, 2009). Pozitif veya negatif olması etkilerinin pozitif veya negatif olduğunu gösterir. Bir YSA'da dış ortamdan alınan girdiler, ağırlıkları ile hücreye bağlanır. Net girdinin değeri farklı metotlar ile hesaplanır. Net girdi değeri, aktivasyon fonksiyonunda işlenir ve sonucunda net çıktı değerleri oluşturulmaktadır. Ağ'a sunulan girdilerin ağırlıkları sabit değildir. Yapay sinir ağı kendine yeni örnekler gösterildikçe kendisi için en uygun sonucu bulana kadar ağırlık değerlerini değiştirir ve en uygun ağırlık değerlerinin bulunmasını sağlamaktadır.

YSA'ya eğitime başlandığında ağırlıklar rastgele verilmektedir ve bu rastgele ağırlıklar için eğitim seti verileri uygulanır. Eğer işlem sonunda çıkış değeri kabul edilebilir hata payına ulaşmış veya bu hatanın altında kalmışsa ağ eğitilmiştir. Aksi takdirde işlemlerde başa dönülür ve ağırlıklar yeniden ayarlanır. Bu istenilen hata seviyesine gelinceye kadar bir kaç kez tekrarlanır. Gerçek değerler ile sistemden elde edilen çıktı değerleri arasındaki hatanın minimum olması çok önemlidir.

4.1.1.3. Toplama-Birleştirme Fonksiyonları

Girdiler ve ağırlıklar çarpıldıktan sonra NET değerinin hesaplanmasında birkaç yöntem kullanılabilir. Aşağıda verilmiş olan formül birleştirme fonksiyonu olarak yani NET hesaplama yöntemi olarak "toplama"nın kullanıldığı formüldür.

$$NET \sum_{i=1}^n X_i W_i n_i = 1 \quad (4.1)$$

Denklem (4.1) de birinci girdiden n. girdiye kadar olan girdilerin her birinine ait verilmiş rastgele ağırlık değerleri ile yapılması ve elde edilen sonuçların toplanması anlatılmaktadır. i değerleri her bir girdiyi W değerleri ise her bir girdinin kendi ağırlığını göstermektedir. Tüm yapay sinir ağı modelleri için aynı birleştirme fonksiyonunun kullanılması gibi bir zorunluluk yoktur. Bazı veriler için farklı birleştirme fonksiyonları da belirlenebilir. Bunlardan hangisinin kullanılacağı deneme yanılma yolu ile bulunabilir. Literatürde bazı birleştirme fonksiyonları verilmiştir (bkz. Harrington, 1993; Öztemel, 2003; Debes vd., 2005; Çayıroğlu, 2015).


4.1.1.4. Aktivasyon Fonksiyonları

- Sigmoid Fonksiyonu:

Literatürde uygulamalara bakıldığında en çok kullanılan aktivasyon fonksiyonlarından biri sigmoid fonksiyonudur (Demuth and Beale, 2020; Öztemel, 2003). Sigmoid fonksiyonunda hem doğrusal hem de doğrusal olmayan fonksiyonların her ikisi için de dengelenmiş çıktılar üretmek modelleme yapılabilir (Öztemel, 2012). Bu fonksiyon ağırlıklı ortalama değerini 0-1 arasında bir değere dönüştürür.

Sigmoid fonksiyonu için ağırlık değeri Denklem (4.2) ile hesaplanır.

$$F(NET) = \frac{1}{1+e^{-NET}} \quad (4.2)$$



Şekil 4.3: Sigmoid fonksiyonunun Grafiği


Kaynak: (Url-19, 2021)

- ReLU(Rectified Linear Unit) Doğrultucu Aktivasyon Fonksiyonu

ReLU aktivasyon fonksiyonu Şekil 4. 4' de görülmektedir. Doğrusal bir fonksiyon olarak görülsede doğrusal olmayan durumlarda da kullanılmaktadır. Hızlı ve türevlenebilirdir. Sıfırla artı sonsuz arasında değer almaktadır. Bu sayede bazı nöronlar sıfıra yakınsarken bazı nöronlar önemi yitirecek ve bazı nöronlarda artı sonsuz değer aralığında daha önemli işlem göreceklendir(Sinan, 2021). Ancak sıfır olan nöronlarda öğrenme gerçekleşmeyecektir bu bazen olumsuz bir durum oluşturmaktadır. Ancak geri beslemeli sinir ağı mimarisinde türevi sıfır olmadığı için her nöron hatalardan öğrenme işlemine tabi tutulmaktadır. Geri besleme sırasında ağırlıkların sabit değer alması olumsuzlukları barındarabilmektedir.

Tanh ile farkı hızıdır ve tanh her nörona neredeyse aynı yakınsama ile başlar ve bu da işlem hızını yavaşlatmaktadır ve tanh değerleri (-1,1) arasına sıkıştırır. Türevi ise sıfıra yakınsadığından bu da kayıpları hesaplarken gradyanların ölmesini doğurmaktadır. Relu da bu durum gerçekleşmez.

Tez kapsamında kurulan en iyi yapay sinir ağı modelinde relu aktivasyon fonksiyonu kullanılmaktadır.

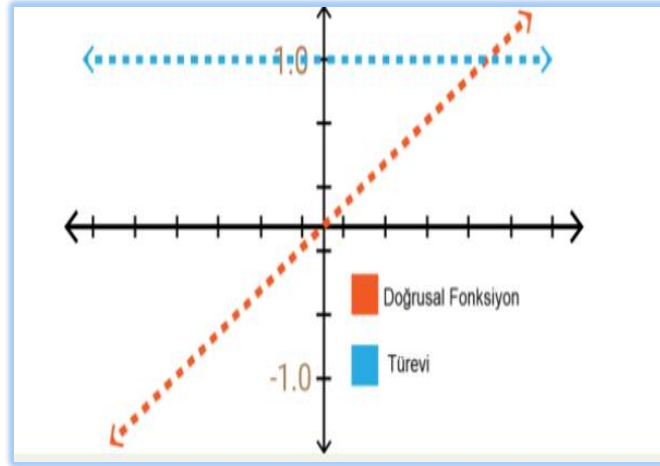


Şekil 4.4: ReLU Aktivasyon Fonksiyonunun Grafiği

Kaynak: (Url-19, 2021)

- Doğrusal(Linear) Aktivasyon Fonksiyonu

Doğrusal aktivasyon fonksiyonu Şekil 4. 5 'de görülmektedir. Aktivasyon fonksiyonu işlemi sonrasında giriş ve çıkış katmanları arasında sürekli olarak doğrusal bir ilişki kurmaktadır. Bu durum doğrusal olmayan problemlerde sorun oluşturmaktadır. Türevinin sabit olması geri yayılım durumu sırasında ağırlıkların sabit olarak dağıtılmasına neden olduğundan öğrenmenin etkisi girdilere tam anlamıyla aktarılmamaktadır (Url-19, 2021).




Şekil 4.5: Doğrusal Aktivasyon Fonksiyonu

Kaynak: (Url-19, 2021)

- Hiperbolik Tanjant (Tanh) Fonksiyonu:

YSA'da en çok kullanılan bir diğer aktivasyon fonksiyonu Hiperbolik Tanjant (Tanh) fonksiyonudur (Demuth ve Beale, 2000). Bu fonksiyonu kullanabilmek için girdi değerleri önce (-1,1) aralığında normalize edilir ve sonuç olarak çıktı değerleri (-1,1) aralığında elde edilir (Vogl vd. 1988). Çıktısının (-1,1) aralığında değerler olmasının arzu edildiği uygulamalar için bu fonksiyon çok kullanışlıdır. Tanh fonksiyonu için ağırlık değeri Denklem (4.3) ile hesaplanmaktadır (Haykin, 1999).

$$F(\text{NET}) = \frac{e^{\text{NET}} - e^{-\text{NET}}}{e^{\text{NET}} + e^{-\text{NET}}} \quad (4.3)$$



Şekil 4.6: Hiperbolik Tanjant - Aktivasyon Fonksiyonu

Kaynak: (Url-20, 2021)

4.1.1.5. Çıktılar

Bir sinir ağı tek veya çok ara katmanlı olarak tasarlanabilir. Ara katmanlardaki hücre sayıları birbirinden farklı olabilir. Ara katmanlardaki hücre sayısının artması işlemleri karmaşıktır ancak sinir ağına daha iyi sonuçlar üretme imkânı verir. Çıktı katmanı ara katmanda işlenen ve bilgiye dönüşen verinin son geçiş katmanıdır. Çıkış katmanından çıkan bilgi başka bir hücre veya hücrelere girdi olacaktır ya da direkt bilgi olarak hücreden çıkacaktır (Diler, 2003).

4.2. Yapay Sinir Ağları Modeli Özellikleri

4.2.1. Geliştirilen Modeller

4.2.1.1. Kod Yazımı

- Kütüphanelerin içe aktarılması:
 - `import pandas as pd`
 - `import numpy as np`
 - `import seaborn as sns`
 - `import matplotlib.pyplot as plt`

yukarıda belirtilen kodların açıklanması:

import ile içe aktarma işlemi yapılmaktadır. Burada pandas kütüphanesi *import* işlemi ile içe aktarılmaktadır. *as* ise sonraki kod satırlarında kütüphanenin adını *as*'den sonra belirtildiği hali ile çağırılacağını sağlamaktadır. Yukarıdaki kod satırlarında pandas kütüphanesi *pd* olarak çağırılacaktır.

- Veri setinin çağırılması:
 - `dosya= pd.read_excel("Oz_Dok_Tez_Verileri_15.12.xlsx")`
 - `data=dosya.copy()`

Burada ilk olarak pandas kütüphanesi içinden *read_excel* fonksiyonu ile excel dosya adını ve uzantısını yazılıp excel dosyasındaki verileri *DataFrame* olarak *dosya* adlı değişkene atamaktadır. Dosya *JupyterLab*'a yüklenmiş olmaktadır. *copy()* adlı fonksiyon ile *dosya* adlı veri setinin kopyası *data* adlı yeni veri setine atanmaktadır. Eşittir ifadesi(=) ile yapılan atamalarda eşitliğin sol tarafındaki kısım değişken anlamına gelmektedir. Burada değişken *data*'dır.

- İlk beş veri setinin gözlemlenmesi:

➤ `data.head()`

Şekil 4. 7 'de veri seti içerisinde yer alan ilk beş veriye ait değerler gözlemlenmektedir.

| | Destekleme_Sistemi | Destek_Aralığı(mm) | EI\n(kNm2/m) | H_Kazı(mm) | δv_Olcum(mm) | δh_Olcum(mm) |
|---|----------------------------------|--------------------|--------------|------------|--------------|--------------|
| 0 | Diyafram duvar | 46.7 | 1280000 | 14000 | 34.0 | 60.0 |
| 1 | Diyafram duvar + Çok sıra destek | 27.5 | 1280000 | 11000 | 20.0 | 35.0 |
| 2 | Kesişen kazıklı duvar | 60.0 | 2717000 | 18000 | 28.0 | 34.0 |
| 3 | Diyafram duvar + Çok sıra destek | 33.0 | 540000 | 10000 | 10.0 | 13.0 |
| 4 | Kesişen + Tek sıra destek | 85.0 | 1254800 | 9700 | 0.0 | 3.0 |

Şekil 4.7: Python Programı ile JupyterLab'ta İlk Beş Veri Setinin Gözlemlenmesi

- Son beş veri setinin gözlemlenmesi:

➤ `data.tail()`

Şekil 4. 8'de görüldüğü üzere *Nan* olarak belirtilen ve boş anlamına gelen hücreler bulunmaktadır.

| | Destekleme_Sistemi | Destek_Aralığı(mm) | EI\n(kNm2/m) | H_Kazı(mm) | δv_Olcum(mm) | δh_Olcum(mm) |
|-----|---|--------------------|--------------|------------|--------------|--------------|
| 121 | Yukarıdan aşağıya çok sıra destekli duvar | 34.0 | 4600000 | 13600 | 2.0 | NaN |
| 122 | Yukarıdan aşağıya çok sıra destekli duvar | 34.0 | 4600000 | 13600 | 5.0 | NaN |
| 123 | Yukarıdan aşağıya çok sıra destekli duvar | 49.0 | 4600000 | 27000 | 30.0 | 64.0 |
| 124 | Yukarıdan aşağıya çok sıra destekli duvar | 49.0 | 4600000 | 27000 | 24.0 | 79.0 |
| 125 | Yukarıdan aşağıya çok sıra destekli duvar | 53.0 | 2700000 | 16000 | 10.0 | 30.0 |

Şekil 4.8: Son Beş Verinin Gözlemlenmesi

- Veri bilgisi gözlemlemek:

➤ `data.info()`

Şekil 4. 9’de görüldüğü üzere:

RangeIndex : 126 Giriş var ve indekslenmesi 0’dan 125’e kadardır.

Dtype : Verinin tipi.

Column : Her bir gözlemi/sütunu.

Non-Null Count : Her bir gözlemde boş olmayan hücre adetini.

göstermektedir.

Şekil 4. 9’den anlaşılacağı üzere *Destekleme_Sistemi* Gözlemimde (Sütunumda) boş hücrenin olmadığını ve tipinin object yani nesne olduğu görülmektedir. Diğer bir gözlem *dh_Olcum(mm)* de ise 122 adet boş olmayan hücreye karşılık 4 adet boş hücre bulunmaktadır ve tipi *float64*’tür.

Float64 ve İnt64 veri tipleri de sayısal verileri ifade eder ve sırasıyla ondalıklı sayı ile tam sayı anlamına gelmektedirler.

- Veri setimin satır sütun sayısına erişmek:

➤ `data.shape`

(126, 6)

Bölüm 4’de bahsedildiği üzere 126 adet veri girişi ve 6 adet gözlem bulunmaktadır.

```

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 126 entries, 0 to 125
Data columns (total 6 columns):
#   Column                Non-Null Count  Dtype
---  -
0   Destekleme_Sistemi    126 non-null   object
1   Destek_Aralığı(mm)   126 non-null   float64
2   EI                    126 non-null   int64
3   H_Kazı(mm)           126 non-null   int64
4   δv_Olcum(mm)         125 non-null   float64
5   δh_Olcum(mm)         122 non-null   float64
dtypes: float64(3), int64(2), object(1)
memory usage: 6.0+ KB

```

Şekil 4.9: Veri Seti Hakkında Bilgi Edinmek

- Veri setinin betimsel istatistiklerini incelemek:

➤ data.describe().T

Şekil 4. 10 'de sayısal tipteki gözlemlerin betimsel istatistiksel değerleri gösterilmektedir.

Şekil 4. 10'deki ifadelerin anlamları:

Count: Kaç adet.

Mean: Ortalama.

Std : Standart sapma.

Aşağıdaki ifadelerin anlamları; o gözlemin küçükten büyüğe doğru sıranlanmış halleri için geçerlidir.

Min : Minimum değer. İlk değer.

25% : O gözlemdeki 4'te 1 'lik (1/4) değeri.

50% : O gözlemin ortasında okunan değeri.

75% : O gözlemin 4'te 3'lük (3/4) değeri.

Max : Maksimum değeri. Son değer.

| | count | mean | std | min | 25% | 50% | 75% | max |
|--------------------|-------|--------------|--------------|--------|-----------|----------|-------------|-----------|
| Destek_Araligi(mm) | 126.0 | 4.304683e+01 | 2.111839e+01 | 7.5 | 33.075 | 40.0 | 46.925 | 161.0 |
| EI\n(kNm2/m) | 126.0 | 1.435550e+06 | 1.639789e+06 | 2581.0 | 73575.000 | 726845.0 | 2500000.000 | 5400000.0 |
| H_Kazi(mm) | 126.0 | 1.488730e+04 | 5.982090e+03 | 4000.0 | 10775.000 | 13950.0 | 18300.000 | 37000.0 |
| delta_v_Olcum(mm) | 125.0 | 3.534960e+01 | 4.797575e+01 | 0.0 | 10.000 | 20.0 | 35.000 | 270.0 |
| delta_h_Olcum(mm) | 122.0 | 3.956148e+01 | 4.228506e+01 | 3.0 | 15.000 | 25.4 | 48.000 | 280.0 |

Şekil 4.10: Veri Setinin Betimsel İstatistikleri – Ham Veri

- Boş hücelere sahip girdilerden kurtulmak:

➤ `data.dropna(axis=0, how='any', inplace= True)`

`dropna()` fonksiyonu, boş hücrelerin silinmesini gerçekleştirmektedir. `dropna()` fonksiyonunun parantez içerisindeki argümanları ise silme işleminin nasıl olması gerektiği bilgisini taşımaktadırlar.

`axis`: satır ya da sütun yönlü silme bilgisini işler. Burada `axis=0` satır bazında silme işlemi gerçekleştirmektedir.

`how`: `any` ise herhangi bir satırda NaN değeri varsa silme işlemi ve `all` değeri de tüm satırlar NaN değeri ise silme işlemi gerçekleştirmektedir.

`inplace`: `True` ise yapılan bu değişikliklerin veri setinde kalıcı olarak değişmesini gerçekleştirir.

- Boş hücre sorgulama:

➤ `data.isnull().sum()`


`isnull()` ile boş hücre soruğu yaparken `sum()` ile bu soru sonucunu toplamaktadır. Böylelikle hücrelerde boş veri olmadığı gözlemlenmektedir.

- Aykırı verilerin işlenmesi:

➤ `from sklearn.neighbors import LocalOutlierFactor`

sklearn kütüphanesinin içinde yer alan neighbors kütüphanesinden LocalOutlierFactor algoritması içe aktarılmaktadır.

LocalOutlierFactor algoritması, her verinin yerel aykırı değer faktörü (LOF) algoritmasıdır. Şekil 4. 11’da görüldüğü üzere, her verini komşularına yerel olarak yoğunluklarını kıyaslayan ve yoğunluk sapmalarına odaklanarak hesap yapan denetimsiz anormallik algılama yöntemidir. Yerel olarak komşularından önemli ölçüde daha düşük yoğunluğa sahip örnekleri aykırı değer olarak kabul edilecektir (Url-26, 2021).



Şekil 4. 11: LocalOutlierFactor Algoritmasının Çalışma Mantığı

Kaynak: (Url-26, 2021)

➤ `clf= LocalOutlierFactor(n_neighbors=20, contamination=0.2)`

LocalOutlierFactor() parantez içindeki argümanlar;

n_neighbors : Bir kümenin içermesi gereken minimum örnek sayısı bilgisini taşımaktadır.

contamination : Küme içerisindeki yoğunluğun bilgisini taşımaktadır.

clf değişkeni ataması bir estimator yani nesnedir. Bu nesne farklı olarak içinde işlevsel bir potansiyel barındırır. Yapmak istenilen işlem bir şeyler tahmin etmek ise *clf* 'ye yapılan atama ile tahmin kabiliyetine sahip bir estimator oluşturulmaktadır (Uğuz, 2019).

Burada *clf LocalOutlierFactor*'un aykırı gözlem belirleme potansiyeline sahiptir. Potansiyel denilmesinin nedeni; *clf*, pythonda bir çıktı vermez bu potansiyeli aşağıdaki kodlar ile açığa çıkarmak gerekmektedir.

➤ `clf.fit_predict(data.iloc[:,1:])`

clf değişkenimi *fit* fonksiyonu ile eğitip *predict* fonksiyonu ile de çıktıları tahmin etmektedir.

`data.iloc[:,1:]` ile köşeli parantezin virgülden önceki kısmı satırları virgülden sonraki kısmı sütunları ifade etmektedir. ":" ifadesi ise tüm indeksleri, "1:" ifadesi ise de birinci indeksten başlayıp son indeksi kapsamaktadır.

➤ `data_scores= clf.negative_outlier_factor_`

negative_outlier_factor_ ile eksi bire en yakın değerleri gözlemleyebileceğim `data_scores` değişkenine atıyorum. Eksi bire(-1) ne kadar yakın o kadar iyi olarak yorumlanması yapılmaktadır (Url-27, 2021).


➤ `pd.DataFrame(np.sort(data_scores)).plot(stacked= True, xlim= [0,35], style= "-.-");`

Şekil 4. 9'de *LocalOutlierFactor* algoritması sayesinde komşularından farklı olan verileri tespit edip *plot()* fonksiyonu aracılığı ile de görselleştirilmektedir.

Burada en uygun grafiği elde etmek için *LocalOutlierFactor* algoritmasının yukarıdaki argümanlarına çeşitli denemeler yapılmaktadır ve en ideali grafik Şekil 4.12'da görüldüğü şekildedir.

Şekil 4. 12’da y eksenini(aşağı-yukarı) aykırı gözlem kümeleri ilişkisini, x eksenini(sol-sağ) küçükten büyüğe sıralanmış olan data_score değişkeninin indekslerini ifade etmektedir.

Böylelikle data_score da beşinci indeksden sonra aykırılığın düzeldiği gözlemlenmektedir.



Şekil 4.12: Belirlenen Argümanlar Sonrasında Oluşan İlişkisel - Aykırı Gözlem Grafiği

➤ `esik_deger= np.sort(data_scores)[5]`

Beşinci indeksi `esik_deger` adlı değişkene atanmaktadır.

➤ `outlier_lof_index= data[data_scores < esik_deger].index`

`data_scores` içerisinde `esik_deger`'den küçük olanları seçilmekte ve indeksleme işlemi yapılmaktadır. Sonrasında bu indeksler `outlier_lof_index` adlı değişkenine atanmaktadır.

➤ `outlier_lof_index`

Şekil 4. 13’de Aykırı verileri yani `outlier_lof_index`'leri gözlemlenmektedir.

| | Destekleme Sistemi | Destek Aralığı(mm) | El\N(kNm2/m) | H_Kazı(mm) | δv_Olcum(mm) | δh_Olcum(mm) |
|----|---------------------------------|--------------------|--------------|------------|--------------|--------------|
| 5 | Çakma profil + Tek sıra destek | 50.0 | 3895 | 6200 | 0.0 | 7.0 |
| 43 | Çok sıra ankrajlı kazıklı duvar | 30.0 | 203900 | 9000 | 5.0 | 20.0 |
| 57 | Çok sıra ankrajlı çakma profil | 30.5 | 2581 | 18300 | 22.0 | 18.0 |
| 82 | Çok sıra destekli perde duvar | 20.0 | 135500 | 18500 | 67.0 | 27.0 |
| 83 | Çok sıra destekli perde duvar | 25.0 | 127760 | 19000 | 27.0 | 42.0 |

Şekil 4.13: Aykırı Veriler

- `data.drop(index=outlier_lof_index, inplace= True)`

`drop` fonksiyonu bu aykırı verileri veri setinden silmektedir.

- `data.shape`

`shape` fonksiyonu ile 116 satır, 6 sütun bilgisine ulaşılmaktadır.

- İndeks Elemanlarını Yeniden Düzenlemek

- `data.index= np.arange(0,116)`

`drop`'lama işlemi ile indeks numaraları düzgün bir sıra ile devam etmezler. Bu durum Numpy kütüphanesinden `arange()` fonksiyonu ile 0'dan 116'ya kadar 116 sayısı hariç indeks numaraları ile yeniden düzenlenmektedir.

- 2-Sigma Yöntemi ile aykırı veri analizi:

Genel olarak 2-sigma aykırı veri analizi, ortalamadan standart sapmanın iki katının çıkarılması ile alt sınır değerinin bulunduğu ve ortalamaya iki standart sapmanın eklenmesi ile de üst sınır değerinin bulunduğu bir yöntemdir. Bu yöntem ile gözlem kümesindeki verilerin ortalamadan 2-sigma kadar sapmalarına aykırılık olarak kabul edilmiş olmaktadır. Bu durum uygulamalarda genellikle 3-sigma olarak yani ortalamadan üç standart sapma mesafedeki veriler için görülmektedir. Bu tez kapsamında 2-sigma olarak devam edilecektir. Sebebi ise Bölüm 3'te gözlemlendiği üzere verilerin dağılımıdır.

Aşağıda bir adet gözlem için aykırı veri analizi yapılmaktadır. Aşağıdaki kodlar yardımı ile diğer gözlemlerde aykırı veri analizi yapılmıştır.

$\delta h_{\text{Olcum}}(\text{mm})$ için:

➤ `std= data[" $\delta h_{\text{Olcum}}(\text{mm})$ "].std()`

$\delta h_{\text{Olcum}}(\text{mm})$ gözlemin standart sapması `std` adında değişkene atandı.

➤ `mean= data[" $\delta h_{\text{Olcum}}(\text{mm})$ "].mean()`

$\delta h_{\text{Olcum}}(\text{mm})$ gözleminin ortalaması `mean` adında değişkene atandı.

➤ `alt_2sigma= mean - 2*std`

➤ `ust_2sigma= mean + 2*std`

➤ `print(data[data[" $\delta h_{\text{Olcum}}(\text{mm})$ "] < alt_2sigma].index)`

➤ `print(data[data[" $\delta h_{\text{Olcum}}(\text{mm})$ "] > ust_2sigma].index)`

aykırı değerler gözlemlenmektedir (bkz. Şekil 4. 14). Şekil 4. 14'de görüldüğü üzere `alt_2sigma` değeri boş kümedir. Aynı zamanda `ust_2sigma` değerlerinin indeksleri Şekil 4. 14'de görüldüğü gibidir. Bu indeksleri inceleyip baskılama, silme ya da ortalamaları ile doldurma yöntemleri yapılabilir. Ancak bu seçime veriyi gözlemleyip uzman kişilerce karar vermek daha doğru olacaktır. Ayrıca aykırı gözlemleri veri setinde yeterince veriye ait vaka var ise verileri silmeyi düşünmek daha doğru olacaktır aynı zamanda verilerin içerdiği aykırılık durumu veri dağılımının çok dışında ise yine silme işlemi düşünülmektedir. Bu tez kapsamında silme yöntemi ve baskılama yöntemleri seçilmiştir. Baskılama yönteminin seçilmesi aykırı verilerin makine öğrenmesinde regresyon problemlerinde oluşturulacağı optimizasyon eğrisinin yönüne etki etmesidir. Ayrıca eldeki verilerin azlığında başka bir nedendir.

```
Int64Index([], dtype='int64')
Int64Index([67, 81, 82, 89, 90, 96], dtype='int64')
```

Şekil 4. 14: δh _Olcum(mm) Sütununa Ait Aykırı Değerler – 2-Sigma Yöntemi

➤ `aykırı_ust_index= data[data[" δh _Olcum(mm)"] > ust_2sigma].index`

Veri seti içerisinde `ust_2sigma` değerlerinden fazla olanların indeksleri `aykırı_ust_index` değişkenine atanmaktadır.

`aykırı_alt_index` ataması yapılmadı. Çünkü veri seti içerisinde böyle bir veri bulunmamaktadır.

➤ `data.drop(index=aykırı_ust_index, inplace= True)`

Veri seti içerisinde `aykırı_ust_index` temizlenmektedir.

δv _Olcum(mm) / Destek_Aralığı(mm) / $EI \backslash n(kNm^2/m)$ / H _Kazı(mm) Bu gözlemler içinde aykırı değer analizi 2-sigma yöntemine göre yapılmıştır.

➤ İndeks elemanlarını yeniden düzenlemek:

Yukarıdaki adımlardan sonra;

➤ `data.shape`

➤ `data.index= np.arange(0,90)`

➤ Aykırı gözlem analizine devam – kutu grafik yöntemi (çeyrek açıklık yöntemi):

Her bir gözlem için `BoxPlot(Kutu Grafik)` çizdirilecektir.

➤ `for column in data.iloc[:,1:]:`

➤ `sns.boxplot(data= data[column], orient= "h");`

- `plt.xlabel(column)`
- `plt.show()`

Bir for döngüsü içinde aynı işlemler tüm gözlemler için yapılmaktadır.

İlk satırdaki kod ile `data.iloc[:,1:]` ile son sütun hariç tüm satırlar dahil olacak şekilde veri setinin her bir gözleminde *in* argümanı ile *column* ifadesini gezdirilmiş olmaktadır.

İkinci satırdaki kod ile *seaborn(sns)* kütüphanesinden *boxplot* fonksiyonunu ile kutu grafik çizileceği ifade edilmektedir. *column* argümanı *data*'nın indeksi olarak yazdırılmaktadır. Böylelikle *column data[:,1:]*'in içindeki sütunlardan sırasıyla gezdirilirken hangi sütunda ise o sütunun kutu grafiği çizdirilecektir. *orient* düşeylik ya da yataylık bilgisi taşımaktadır. Burada argümanının “h” seçilmesi ile horizontal(yatay) seçilmektedir. Böylelikle *column* argümanını `data.iloc[:,1:]` içerisinde sırasıyla Destek_Aralığı(mm), EI\m(kNm²/m), H_Kazı(mm), δ_h _Olcum(mm), δ_v _Olcum(mm) kolonlarına(sutun-gözlem)'nin grafiği sırasıyla çizdirilmektedir. Bunu tam olarak yapabilmesi için devamındaki kodlara ihtiyaç vardır.

Üçüncü kod satırı, grafikte X eksenine sırasıyla her bir gözlemin adını yazdırır.

Dördüncü kod satırı, grafiğin her bir *column* argümanında çizilmesini sağlar.

Şekil 4. 15 ve Şekil 4. 16'da gösterilen Q1, Q3, IQR ve Medyan gibi bazı ifadelerin tanımını şu şekildedir:

Kutu grafik yönteminde veriler küçükten büyüğe doğru sıralanmaktadır.

Q1: %25 'e yani verinin yirmi beşinci değerine denk gelen değerdir. Yirmi beşinci (25.) kartil.


Q3: %75 'idir. Yetmiş beşinci(75.) kartil.

Ayrıca diğer tanımlar şu şekildedir:

Median: Ortanca olan değeri vermektedir.


IQR: $Q3 - Q1$ 'dir ve çeyrek açıklığı (Interquartile Range) olarak ifade edilmektedir.

Şekil 4. 15 ve Şekil 4. 16'de aykırı değerlerin aykırı değer alt sınırı $Q1 - 1,5 \cdot IQR$ değerinin altında kalan bölgelerde gözlemlenmektedir. Aykırı değerlerin ise üst sınırı: $Q3 + 1,5 \cdot IQR$ değerinden sonra başlamaktadır.



Şekil 4.15: Kutu Grafik Yöntemi ile Aykırı Değer Analizi

Kaynak: Smith, M. R., ve Martinez, T., (2011).



Şekil 4.16: Kutu Grafik ve Aykırı Değer Gösterimi

Kaynak: (Url-28, 2021)

- Şekil 4. 17'deki $\delta v_{\text{Olcum}}(\text{mm})$ gözlemi'nin kutu grafik yöntemi ile aykırı değerlerinin analizi aşağıdaki kodlar yardımı ile incelenmektedir:

➤ # $\delta v_{\text{Olcum}}(\text{mm})$ boxplot:

işareti kendisinden sonraki kısmı yorum satırına dönüştürmektedir.

➤ $Q1 = \text{data}["\delta v_{\text{Olcum}}(\text{mm})"].\text{quantile}(0.25)$

25. çeyreğin data adlı veri setimiz içerisindeki $\delta v_{\text{Olcum}}(\text{mm})$ gözlemi seçilmektedir ve $\text{quantile}()$ fonksiyonu ile %25. değeri Q1 'e atanmaktadır.

➤ $Q3 = \text{data}["\delta v_{\text{Olcum}}(\text{mm})"].\text{quantile}(0.75)$

➤ $IQR = Q3 - Q1$ # Interquartile Range - Çeyrekler açıklığı (IQR)

➤ $\text{alt_sinir_}\delta v_{\text{Olcum}} = Q1 - 1.5 * IQR$

➤ $\text{ust_sinir_}\delta v_{\text{Olcum}} = Q3 + 1.5 * IQR$

➤ $\text{print}(Q1)$

çıktı: 10

➤ $\text{print}(Q3)$

çıktı: 30.5

➤ $\text{print}(IQR, "\n")$

çıktı: 20.5

$\text{print}()$ fonksiyonu ile IQR değişkenini yazdırılmakta ve “\n” argümanı ile bir sonraki kod satırının çıktısının satır başından başlatması sağlanmaktadır.

➤ $\text{print}(\text{alt_sinir_}\delta v_{\text{Olcum}})$

çıktı: -20.75

➤ `print(ust_sinir_delta_v_Olcum, "\n")`

çıktı: 61.25

➤ `aykiri_alt_delta_v_Olcum_index=data[data["delta_h_Olcum(mm)"]<alt_sinir_delta_v_Olcum].index`

➤ `print(aykiri_alt_delta_v_Olcum_index)`

çıktı: `Int64Index([], dtype='int64')`

çıktı da görüldüğü üzere aykırı alt değer bulunmamaktadır.


➤ `aykiri_ust_delta_v_Olcum_index=data[data["delta_v_Olcum(mm)"]>ust_sinir_delta_v_Olcum].index`

➤ `print(aykiri_ust_delta_v_Olcum_index)`

çıktı: `Int64Index([58, 65, 68, 71, 78, 79, 80, 81], dtype='int64')`

çıktı: aykırı üst değer indeksleri görülmektedir.

➤ `data[data["delta_v_Olcum(mm)"] > ust_sinir_delta_v_Olcum]`



Şekil 4.17: `delta_v_Olcum(mm)` Gözlemi, Kutu Grafik Yöntemi ile Aykırı Değer Analizi

Şekil 4. 17’de aykırı değerlerin üst sınırları gözlemlenmektedir.

Aşağıda 18. ve 19. Kod satırlarında;

65. 80. indeksler veri dağılımına uygudu için baskılanmaktadır. 58., 68., 71., 78., 79., 81. İndeksler veri dağılımına uymadıkları için veri setinden çıkarılmaktadır.

- Aykırılık tespit edilen verilerin baskılanması:
 - `aykırı_ust_δv_Olcum= data["δv_Olcum(mm)"]>ust_sinir_δv_Olcum`
 - `data["δv_Olcum(mm)"][aykırı_ust_δv_Olcum] = ust_sinir_δv_Olcum`
- Aykırılık tespit edilen istenmeyen verilerin silinmesi:


`data.drop(index=[58, 68, 71, 78, 79, 81], inplace=True)`

| | Destekleme_Sistemi | Destek_Aralığı(mm) | EI\N(kNm2/m) | H_Kazı(mm) | δv_Olcum(mm) | δh_Olcum(mm) |
|----|----------------------------------|--------------------|--------------|------------|--------------|--------------|
| 58 | Yukarıdan aşağıya diyafram duvar | 33.6 | 1106125 | 19800 | 101.6 | 50.8 |
| 65 | Çok sıra destek - 'Arbed' | 40.0 | 685000 | 15000 | 75.0 | 84.0 |
| 68 | Çok sıra destekli perde duvar | 45.0 | 73800 | 11500 | 190.0 | 32.0 |
| 71 | Çok sıra destekli diyafram duvar | 26.0 | 4320000 | 13000 | 130.0 | 56.0 |
| 78 | Çok sıra destekli diyafram duvar | 53.0 | 2500000 | 16000 | 65.0 | 42.0 |
| 79 | Çok sıra destekli diyafram duvar | 32.0 | 2500000 | 16000 | 62.0 | 16.0 |
| 80 | Yukarıdan aşağıya diyafram duvar | 27.8 | 857500 | 13900 | 65.0 | 65.0 |
| 81 | Yukarıdan aşağıya perde duvar | 30.0 | 483600 | 9600 | 100.0 | 48.0 |

Şekil 4.18: δv_Olcum(mm) Aykırı İndeks Gözlemi, Kutu Grafik Yöntemi ile Aykırı Değer Analizi


Diğer gözlemler için de kutu grafik yöntemi ile aykırılık analizi modellerin geliştirilmesi öncesinde yapılmaktadır.

Şekil 4. 19’da destek aralığına ait aykırı değerler gözlemlenmektedir. Destek_Aralığı(mm) gözlemin de aykırı veriler için işlem yapılmamaktadır. Bunun nedeni veri havuzunu içerisindeki veri sayısının yetersizliğinden dolayı makine öğrenmesinin olumsuz etkilenmesinin önüne geçmek ve öğrenmenin olabilmesi için veri havuzundaki verileri azaltmamak şeklindedir.




Şekil 4. 19: Destek_Aralığı(mm) Gözlemi, Kutu Grafik Yöntemi ile Aykırı Değer Analizi

Şekil 4. 20 'de yanal rijitlik parametrelerine ait aykırı değerler gözlemlenmektedir. Modeller öncesinde EI\ (kNm²/m) gözleminde baskılama yapılmaktadır.




Şekil 4.20: EI\ (kNm²/m) Gözlemi, Kutu Grafik Yöntemi ile Aykırı Değer Analizi

Şekil 4. 21'de görüleceği üzere kazı derinliği değerleri arasında aykırı değer bulunmamaktadır.



Şekil 4.21: H_Kazı(mm) Gözlemi, Kutu Grafik Yöntemi ile Aykırı Değer Analizi

Şekil 4. 22’de yatay deplasman ölçüm parametresi $\delta h_{\text{Olcum}}(\text{mm})$ bir indeks baskılanmaktadır ve diğer indeksler silinmektedir.



Şekil 4.22: $\delta h_{\text{Olcum}}(\text{mm})$ Gözlemi, Kutu Grafik Yöntemi ile Aykırı Değer Analizi

- Değişken Dönüşümü – (One Hot Encoder):

Makine öğrenmesinde veri işlenmesi sırasında bazı veriler kategorik bazı veriler ise sayısal olmaktadır. Regresyon problemlerinde kategorik verileri de sayısal verilere dönüştürülmesi gerekmektedir. Bu bağlamda hangi verilerimin sayısal hangi

verilerimin kategorik olduğunu gözlemlemek gerekmektedir.

Kategorik verilerin sayısal nitelikleri yoktur. Genellikle tanımlamalar ile ifade edilirler.

Sayısal veriler ise ölçülebilir, analiz ve cebirsel işlemlere tabi tutulabilir, oransallaştırılabilen vb. gibi verilerdir.

Şekil 4. 9’da görüldüğü üzere Destekleme_Sistemi kategorik veri tipidir. Diğer gözlemler ise sayısal veri tipindedir. Destekleme_Sistemi gözlemini sayısal tipe dönüştürme işlemi one-hot değişken dönüşümü ile gerçekleşmektedir.

- One- Hot Encoder / Dummy Değişken Dönüşümü:
 - `data_one_hot=pd.get_dummies(data,columns=["Destekleme_Sistemi"], prefix= ["Tip:"], drop_first=True)`

pandas kütüphanesi içerisinde `get_dummies()` dönüştürücü özellikteki fonksiyonu import ile çağırılmakta ve parantez içindeki argümanlarının değerleri girilmektedir.

İlk argüman, data: hangi veri setinde dönüştürme işlemi bilgisini taşımaktadır.

İkinci argüman, columns: kategorik değişkenin bu veri setinde hangi gözlem ise onun bilgisi ifade etmektedir.

Üçüncü argüman, prefix: dönüştürülecek olan kategorik gözlemin dönüştürülmüş hali için gözlem başlığında yazması istenilen ifadenin bilgisini taşımaktadır.

Dördüncü argüman, drop_first: bu argüman True/False değerlerinden birini almaktadır. True seçilmesi halinde kategorik dönüşümler sonucunda oluşacak olan gözlem sayısından bir adet eksiltilmektedir. Böylelikle oluşan gözlem sayısı n olacak ise n-1 adet gözlem sayısı veri seti içerisinde gözlemlenmektedir.

- One – Hot Encoder ve Dummy Değişken tuzağı:

One – hot değişken dönüşümü bir birine üstünlüğü bulunmayan yani nominal olarak

adlandırılan kategorik tipleri sayısal olarak dönüştürmek için kullanılmaktadır. One-hot dönüşümünde dönüşen her değer bir birine göre mesafesi öklid denklemine hesaplanmaktadır. Bu meafeler ikili(binary) tabanda gösterilmektedir ve eşittir. Böylelikle a,b,c adında kategorik değişkenlerimiz sırasıyla [1,0,0] , [0,1,0], [0,0,1] gibi değer almaktadır. Bu sayede değerlerin birbirlerine üstünlükleri olmamaktadır (Uğuz, 2021).

Dummy değişken tuzağı kukla değişken tuzağı olarakta türkçeleştirilmektedir. Çoklu regresyon analizlerinde birbirinin aynısı ifade eden gözlemler makine öğrenmesinde sorun teşkil etmektedir. Bu sorun öğrenmeyi yavaşlatması, anlam karmaşası gibi öğrenmeyi zorlaştıran bir durumdur. Bu duruma dummy değişken tuzağı denilmektedir (Uğuz, 2021).

- Değişen veri setini kopyalamak:

➤ `df= data_one_hot.copy()`

Değişen veri seti `df` adında yeni veri seti atanır. Bundan sonra veri seti `df` adıyla çağırılmaktadır.

- Verilerin eğitilmesi:

➤ `from sklearn.Model_selection import train_test_split`

Sklearn kütüphanesi içerisinde yer alan *Model_selection* modülünden *train_test_split* modülü içe aktarılmaktadır.

train_test_split ile veriler hem eğitim ve test olarak ayrılırmaktadır (Url-29, 2021).

- Girdi verilerinin seçilmesi (X):

➤ `X = df.drop([" $\delta h_{Olcum}(mm)$ "], axis=1)`

`df` veriseti içerisinde `$\delta h_{Olcum}(mm)$` gözlemi çıkarılmaktadır ve `axis=1` ile çıkarma işleminin sütun bazında olacağı bilgisi girilmektedir.

Burada dikkat edilmesi gereken husus python da deęişken adlandırırken X'i büyük harf ile yazılması gerekmektedir. Aksi halde python cebirsel işlem yapılacağı bilgisi girilmiş olacaktır.

$\delta h_Olcum(mm)$ çıktı gözlemi olduğundan girdi gözlemleri arasından çıkarılmaktadır.

- Çıktı verilerinin seçilmesi:
 - `y=df[" $\delta h_Olcum(mm)$ "]`
- Betimsel istatistiklerin gözlemlenmesi:
 - `df.describe().T`

Şekil 4.23' de betimsel istatistikler görülmektedir. Buradaki betimsel istatistik değerleri bir sonraki aşamada verilerin eğitim ve test seti olarak ayrılması için önemli olacaktır. Çünkü eğitim test şeklinde ayrılma işlemine tabi tutulan veri setlerinin dağılımının ortalaması, standart sapması gibi istatistiksel değerleri arasındaki uyum doğrulanabilirlik açısından önem arz etmektedir.

Şekil 4.23'de verileri bölerken betimsel istatistiklerine dikkat edilmesi gereken en önemli gözlem birimi veri setinin çıktı gözlemi olan $\delta h_Olcum(mm)$ 'sütunudur. $\delta h_Olcum(mm)$ betimsel istatistiklerinin eşite yakın ya da eşit dağılması önemlidir.

- Eğitim-Doğrulama-Test olarak verileri ayırmak:
 - `X_train, X_test, y_train, y_test = train_test_split(X,y,test_size=0.15, random_state=9)`

Burada deęişkenler için (eşittirden önce yazılan ifadeler) sırasıyla `train_test_split()` 'in parantez içlerinde karşılığını bulmaktadırlar.

Buna göre;

X : X_train, X_test

y: y_train, y_test

olarak ayrılırlar.

test_size ile verisetinin %15'i test seti olarak ayrılmaktadır.

random_state=9 ile verilerin rastgele ayrılması işlemidir. Ayırma işlemi dayandırdığı yöntemi-kuralı daha sonradan da çağırabilmek için bu yöntemi-kuralı dokuz rakamı ile sabitlenmektedir.

| | count | mean | std | min | 25% | 50% | 75% | max |
|--|-------|---------------|---------------|---------|---------|----------|-----------|------------|
| Destek_Aralığı(mm) | 81.0 | 41.741975 | 13.794898 | 7.5 | 33.6 | 40.0 | 40.0 | 85.00 |
| EI\N(kNm2/m) | 81.0 | 841149.197531 | 896349.995880 | 18850.0 | 73500.0 | 567450.0 | 1280000.0 | 3089750.00 |
| H_Kazı(mm) | 81.0 | 13525.925926 | 4533.969778 | 4000.0 | 10000.0 | 12200.0 | 17000.0 | 24400.00 |
| δv_Olcum(mm) | 81.0 | 20.748148 | 15.007872 | 0.0 | 10.0 | 18.0 | 28.0 | 61.25 |
| δh_Olcum(mm) | 81.0 | 27.019753 | 19.939091 | 3.0 | 13.0 | 20.0 | 34.0 | 84.00 |
| Tip: Diyafram duvar + Çok sıra destek | 81.0 | 0.024691 | 0.156150 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Kesişen + Tek sıra destek | 81.0 | 0.012346 | 0.111111 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Kesişen kazıklı duvar | 81.0 | 0.037037 | 0.190029 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Perde Duvar + Tek sıra destek | 81.0 | 0.012346 | 0.111111 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Perde Duvar + Çok sıra destek | 81.0 | 0.024691 | 0.156150 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Perde H Profil + Çok sıra destek | 81.0 | 0.111111 | 0.316228 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Sürekli kazıklı duvar | 81.0 | 0.012346 | 0.111111 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Tek sıra destekli palplanş perde duvar | 81.0 | 0.012346 | 0.111111 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Tek sıra destekli çakma profil | 81.0 | 0.012346 | 0.111111 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Yukarıdan aşağıya + Kazıklı duvar | 81.0 | 0.024691 | 0.156150 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Yukarıdan aşağıya diyafram duvar | 81.0 | 0.074074 | 0.263523 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Yukarıdan aşağıya çakma profil | 81.0 | 0.012346 | 0.111111 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Yukarıdan aşağıya çok sıra destekli duvar | 81.0 | 0.024691 | 0.156150 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra ankrajlı diyafram duvar | 81.0 | 0.074074 | 0.263523 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra ankrajlı kazıklı duvar | 81.0 | 0.024691 | 0.156150 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra ankrajlı çakma profil | 81.0 | 0.074074 | 0.263523 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra destek - 'Arbed' | 81.0 | 0.012346 | 0.111111 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra destekli diyafram duvar | 81.0 | 0.086420 | 0.282734 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra destekli kazıklı duvar | 81.0 | 0.024691 | 0.156150 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra destekli kesişen kazık | 81.0 | 0.024691 | 0.156150 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra destekli perde duvar | 81.0 | 0.098765 | 0.300206 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra destekli sürekli kazıklı duvar | 81.0 | 0.098765 | 0.300206 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |
| Tip: Çok sıra destekli çakma profil | 81.0 | 0.074074 | 0.263523 | 0.0 | 0.0 | 0.0 | 0.0 | 1.00 |

Şekil 4.23: Veri Setinin Son Halinin Betimsel İstatistik Değerleri

- $X_{train}, X_{validasyon}, y_{train}, y_{validasyon} = \text{train_test_split}(X_{train}, y_{train}, \text{test_size}=11, \text{random_state}=16)$

Veri setleri eğitim ve test seti olarak ayrıldıktan sonra validasyon yani doğrulama olarakta ayrılabilir. Bunun nedeni eğitim sırasında algoritmaların aşırı öğrenmesini minimize etmek ve daha doğru genellenebilirlik oranı yakalamaktır.

X_train'den 11 adet veri X_validasyona olarak ayrılmaktadır.

y_train'den 11 adet veri y_validasyon olarak ayrılmaktadır.

- Eğitim-Validasyon-Test olarak ayrılan verilerin satır-sütun sayısının gözlemlenmesi:

➤ print(X_train.shape)

(57,27)

➤ print(X_test.shape)

(13,27)

➤ print(X_validasyon.shape)

(11, 27)

➤ print(y_validasyon.shape)

(11,)

➤ print(y_train.shape)

(57,)

➤ print(y_test.shape)

(13,)

- Eğitim-Validasyon-Test olarak ayrılan verilerin betimsel istatistik olarak gözlemlenmesi:

- Ortalama değer bazında bir inceleme;

➤ `pd.DataFrame(y_train).mean()`

Çıktı: 28.031579

➤ `pd.DataFrame(y_validasyon).mean()`

Çıktı: 25.590909

➤ `pd.DataFrame(y_test).mean()`

Çıktı: 23.792308

Görüldüğü üzere Eğitim-Validasyon-Test olarak ayrılan verilerin ortalama değerleri birbirine yakındır. Aynı zamanda $\delta h_{Olcum(mm)}$ 'ün ortalama değerine de yakın olmaktadır.

Şekil 4.20'de $\delta h_{Olcum(mm)}$ 'ün ortalama değeri 27,019'dur.

- Verilerin ölçeklendirilmesi – standardizasyon:

➤ `from sklearn.preprocessing import StandardScaler`

Sklearn kütüphanesi içerisinde yer alan bir başka kütüphane olan `preprocessing`'ten `StandardScaler` fonksiyonunu içe aktarımı gerçekleştirilmektedir (Url-30, 2021).

`StandardScaler()` ile verilerimi ölçeklendirme işlemi yapılmaktadır. Ölçeklendirmeye yapılmasının nedeni makine öğrenimi sırasında veriler arasındaki ölçek, boyut farkının yakınsamasını sağlamaktır. Özellikle veriler arasındaki uzaklığa dayalı çalışan algoritmalar bu durumun öğrenmenin genellenebilirliğini, öğrenmede sapmanın azalmasını ve algoritmanın çalışma hızını olumlu etkilemektedir (Sinan, 2019).

- Girdi verilerinin standardizasyonu:

➤ `scaler = StandardScaler()`

scaler adında değişkenimiz bir estimatördür. Yani Standardizasyon işlemi yapabilecek potansiyeli barındırmaktadır. Bir veriseti aldığında bu potansiyelini gerçekleştirecektir.

➤ `X_train_scaled= scaler.fit_transform(X_train)`

scaler estimatörü ve *fit* ile *X_train* veri setinin ölçeklendirilmesi yani standardizasyonu gerçekleştirilmektedir. Sonraki kod satırlarında veri setinin standardizasyonlu halini girdi olarak kullanılacaktır ve *X_train_scaled* değişkenine atama işlemi yapılmaktadır.

➤ `X_test_scaled=scaler.transform(X_test)`

X_test_scaled'a da test setinde kullanılacak olan girdi verilerinin ölçeklenmiş halinin atanması işlemidir.

- Yapay sinir ağında tahmin Modelinin kurulması:

➤ `from sklearn.neural_network import MLPRegressor`

MLPRegressor, sklearn kütüphanesinde çok katmanlı algılayıcı (Multi-Layer Preceptron) olarak derin öğrenme (neural network) modülünde yer almaktadır. MLPRegressor bir yapay sinir ağıdır. MLPRegressor import ile içe aktarılmaktadır.

- Ölçeklenen veriler ile modelin kurulup eğitilmesi:

➤ `mlp_Model= MLPRegressor().fit(X_train_scaled,y_train)`

- Tahminlerin oluşturulması:

➤ `y_pred= mlp_Model.predict(X_test_scaled)`

- İlkel optimize edilmemiş hata değeri – ortalama mutlak hata:

➤ `np.sqrt(mean_absolute_error(y_test, y_pred))`

çıktı: 3.4373989705490327

Numpy kütüphanesi içerisinde kare kök işlemi için `sqrt` fonksiyonunu çağırıldı. Ve ortalama hataların mutlak değerinin kare kökü, ilk hata değeri olarak hesaplanılmaktadır. Bunun bu hata değeri ve diğer hata değerleri ile karşılaştırılmaktadır.

- İlkel optimize edilmemiş hata değeri – ortalama hata karelerinin mutlak hata:

➤ `np.sqrt(mean_squared_error(y_test, y_pred))`

çıktı: 16.522466847545974

- İlk genelleştirilebilir başarı skorunun alınması:

➤ `r2_score(y_test, y_pred)`

Çıktı: 0.23285868975233615

`r2_score`: Sklearn kütüphanesinde regresyon puanı veya belirleme katsayısı olarak tanımlanmaktadır. 1.0 'e ne kadar yakın değer alırsa o kadar iyi şekilde belirtilmektedir. Bazen negatif değerlerde alabildiği ifade edilmiştir. Negatif değer alması kurulan model, veri setini hiç anlamadığı anlamına gelmektedir. En doğru ifade ile `r2_score`, model bağımsız değişkenlerince (X-girdi değerleri) bağımlı değişkenlerinin (y çıktı değerleri) ne kadarının açıklanabildiğini ifade etmektedir. Yani girdi değerleri ile elde edilen varyansı açıklar (Url-31, 2021).

- Varsayılan değerler:

`hidden_layer_sizes=(100,)`,

`activation='relu'`,

`solver='adam'`,

alpha=0.0001,
batch_size='auto',
learning_rate='constant',
learning_rate_init=0.001,
power_t=0.5,
max_iter=200,
shuffle=True,
random_state=None,
tol=0.0001,
verbose=False,
warm_start=False,
momentum=0.9,
nesterovs_momentum=True,
early_stopping=False,
validation_fraction=0.1,
beta_1=0.9,
beta_2=0.999,
epsilon=1e-08,
n_iter_no_change=10,
max_fun=15000 'dir.

Eğer ki bu hiperparametreler değiştirilmezlerse *MLPRegression()* içerisinde bu değerler otomatik olarak döndürülmektedirler(Url-32, 2021).

- Model doğrulama/ayarlama, hiperparametre optimizasyonu:

- `mlp_params= {"alpha": [1.3,0.001,0.09,0.9], "random_state": np.arange(1,101), "hidden_layer_sizes": [(13, 26, 13, 26, 13, 26, 13), (100), (13,13,26,13,13)], "activation": ["relu","identity", "logistic", "tanh"], "solver": ["adam","lbfgs","sgd"], "learning_rate": ["constant","invscaling", "adaptive"], "momentum": [0.26,0.71,0.75,0.80], "beta_1":[0.881,0.92,0.74], "max_iter": [200,300,400,650,800]}`

`mlp_param` ile optimizasyon ayarları bir sözlük yapısında tutulmaktadır.

- `from sklearn.Model_selection import GridSearchCV`

GridSearchCV ile bir önce ki kod satırında belirlenen parametreler için kapsamlı bir arama başlatmaktadır. Böylelikle en uygun parametreler seçilmektedir (Url-33, 2021).

- `mlp_cv_Model= GridSearchCV(mlp_Model, mlp_params, cv=3)`

`cv`: `cross_validation` yani çapraz doğrulama demektir. Her bir optimizasyon eğitimi için veriyi üç parçaya bölüp doğrulama yapacağı bilgisini taşır.

- `mlp_cv_Model.fit(X_train_scaled,y_train)`

- `mlp_cv_Model.best_params_`

- En iyi parametreleri elde etmek:

Çıktı:

`random_state=59,`

`hidden_layer_sizes= [13, 26, 13, 26, 13, 26, 13],`

```
max_iter=400,  
  
activation= 'relu',  
  
alpha= 1.3,  
  
learning_rate= 'constant',  
  
momentum= 0.26,  
  
solver= 'adam',  
  
beta_1= 0.881,  
  
beta_2=0.677
```

deneneler arasında en iyi parametrelerdir. Üzerlerinde daha farklı kombinasyonlarda daha farklı en iyi parametrelere ulaşılabilmektedir.

- Hiperparametrelerin optimizasyonu sonrasındaki hata değerleri:
 - `np.sqrt(mean_absolute_error(y_test, y_pred))`

2.285098968553465

- `np.sqrt(mean_squared_error(y_test, y_pred))`

6.866420142358727

- `r2_score` değeri:
 - `r2_score(y_test, y_pred)`

0.8675090119939972

Model girdi verileri ile çıktı verilerininin %86,75 'sını açıklayabiliyor denilmektedir.

- Eğitim setindeki başarı durumu:

➤ `mlp_Model.score(X_train_scaled,y_train)`


0.8970217078722584

Model eğitim de kullandığı veriler üzerinden girdi verileri ile çıktı verilerinin %89,70'ini açıklayabilmektedir.

4.2.2. Nihai verilerin görselleştirilmesi


Ham verilerin aykırılıkları yukarıdaki yöntemlerle incelenmiş ve uygun bir şekilde giderilmiştir. Bu bölümde, kullanılan veri setinin aykırı verilerden kurtulduktan sonraki dağılımının grafikleri ve korelasyon haritası verilmektedir. Korelasyon haritası sonuçlarının anlamlılıkları doğrulanmalıdır. Korelasyon sonuçlarının anlamlılıkları doğrulanmadan sadece yorumsal bazda gözlemlere sahip olunmaktadır.

Şekil 4. 24'de yatay deplasman ölçüm ile destek aralığının aykırı verilerinin işlenmesinden sonra ki lineer dağılımı görülmektedir. Şekil 3. 16'e göre kıyaslandığında ilişki bir önceki halindeki gibi negatiftir. Ancak aykırı verilerin işlenmesinden sonra eğimin şiddeti artmıştır.




Şekil 4.24: $\delta h_{Olcum}(mm)$ ve $Destek_Aralığı(mm)$ Lineer Dağılım Grafiği - Aykırı Veri Temizliği Sonrası

Şekil 4. 25’de yatay deplasman ölçüm ile yanal rijitlik arasındaki lineer dağılım grafiğinin aykırı verilerin işlenmesinden sonraki hali görülmektedir. Şekil 3. 17’a göre kıyasladığımızda aralarındaki dağılım, nötre yakın olan negative ilişki nötre yakınlıktan biraz uzaklaşıp düşük pozitif ilişkiye dönüşmüştür.




Şekil 4.25: $\delta h_{Olcum}(mm)$ ve $EI(kNm^2/m)$ Lineer Dağılım Grafiği – Aykırı Veri Temizliği Sonrası

Şekil 4. 26’de kazı derinliği boyunca değişen yatay deplasman miktarının aykırı verilerin işlenmesinden sonra ki hali görülmektedir Şekil 3. 18 ile kıyaslandığında pozitif yönde olan ilişkinin şiddetinin arttığı gözlemlenmektedir.




Şekil 4.26: $\delta h_{Olcum}(mm)$ ve $H_{Kazı}$ Linear Dağılım Grafiği – Aykırı Veri Temizliği Sonrası

Şekil 4. 27’de düşey deplasman ile yatay deplasman arasındaki ilişkinin aykırı verilerin işlenmesinden sonra ki hali görülmektedir. Şekil 3. 19 ile kıyaslandığında aralarındaki pozitif ilişkinin şiddetinin arttığı gözlemlenmektedir.



Şekil 4.27: $\delta h_{Olcum}(mm)$ ve $\delta v_{Olcum}(mm)$ Linear Dağılım Grafiği- Aykırı Veri Temizliği Sonrası

Şekil 4. 28’de veri setinin aykırı değerlerinin işlenmesinden sonra ki dağılımının korelasyon grafiği gözlemlenmektedir. Aykırı verilerin işlenmediği hali olan Şekil 3. 25’e göre Tablo 4. 1’de kıyaslanmaktadır.



Şekil 4.28: Veri Seti Nihai Korelasyon Haritası - Aykırı Veri Temizliği Sonrası

Tablo 4. 1’ de görüldüğü üzere yatay deplasman ile korelasyonları incelenen destek aralığı, yanal rijitlik, kazı derinliği, düşey deplasman miktarı sırasıyla;

- İndeks A; -0,15 artış meydana gelmiştir. İlişki düşük negatiften orta negatife doğru değişmektedir.
- İndeks B; +0,11 artış meydana gelmiştir. İlişki nötre yakın düşük negatiften düşük bölgenin orta seviyesine doğru düşük pozitif olarak değişmektedir.
- İndeks C; +0,16 artış meydana gelmiştir. İlişki düşük pozitifin alt seviyelerinden düşük pozitifin üst seviyelerine çıkmaktadır.
- İndeks D; +0,10 artış meydana gelmektedir. İlişki orta pozitif seviyelerde iken yüksek pozitifin alt seviyelerine çıkmaktadır.

Tablo 4.1: Aykırılık Analizi Öncesi ve Sonrası Kıyas Tablosu

| Yatay Deplasman ve Gözlemler İlgili | İşlenmiş Veri Analizi (Aykırılık Analizi) Korelasyon Değeri | Ham Veri Korelasyon Değeri | Aralarındaki Korelasyonun Değişim Miktarı | İndeks |
|-------------------------------------|---|----------------------------|---|--------|
| Destek Aralığı | -0,30 | -0,15 | -0,15 | A |
| Yanal Rijitlik | +0,08 | -0,03 | +0,11 | B |
| Kazı Derinliği | +0,26 | +0,10 | +0,16 | C |
| Düşey Deplasman Miktarı | +0,75 | +0,65 | +0,10 | D |

Yatay deplasman a göre korelasyon katsayılarının değişimi incelenmektedir. Diğer parametrelerin korelasyonları arasındaki farklar Şekil 3. 25 ile Şekil 4. 28 'in kıyaslanması ile görülebilmektedir. Buna göre en şiddetli değişimler şu şekilde gözlemlenmektedir (bkz. Tablo 4. 2).

Tablo 4.2: Korelasyonlardaki Değişim Miktarı - Minimum 0,15'lik Değişim Baz Alınmıştır

| Gözlem Birimi -I | Gözlem Birimi - II | Korelasyon Katsayısındaki Değişim Miktarı | İndeks |
|-------------------------|--------------------|---|--------|
| Düşey Deplasman Miktarı | Kazı Derinliği | +0,19 | 1 |
| Düşey Deplasman Miktarı | Yanal Rijitlik | +0,17 | 2 |

4.2.3. Geliştirilen Modellerin incelenmesi

Bölüm 2.7.1 ve Bölüm 3’de anlatıldığı kapsamda ham verilerin ilk hali 378 satır ve 7 sütundan oluşmaktadır. Bunu bir matris formatında göstermek istersek “(satır)x(sütun)” olacak şekilde “378x7” ile gösterilir. Aynı zamanda 378x7 gösterimi 378 adet vaka yani örnek ve 7 adet gözlem anlamı taşır.

$$\begin{bmatrix} a_0 & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & b_6 \\ c_0 & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & d_6 \\ \vdots & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ n_{377} & \cdot & \cdot & \cdot & \cdot & l_4 & p_5 & j_6 \end{bmatrix}_{(378 \times 7)} \quad (4.4)$$

Denklem (4.4) ‘de ifade edilen matris a_0 sıfırıncı indeksimizi ifade eder. Yani sütunlar-gözlemler sıfırıncı indeksten başlar. Örnek verecek olursak n tane gözlemimiz olsun sütunlarımızın indeksi sırasıyla; 0,1,2,3,4,5,6,.....,(n-1) şeklinde (n-1). İndekse kadar uzanır. Satır sayılarımız da ise yukarıdan aşağıya doğru aynı mantıkla devam eder. Bu bilgiler matematik bilgisi içersede temel seviyede matris bilgi ile anlaşılabilir düzeydedir. Bu bilginin veri işlemi açısından önemi verilerimiz üzerinde işlem yaparken genellikle bu indeksleme ile işlemler yapmamızdır.

Bu çalışma kapsamında kullanılan veri seti Ek'te yer almaktadır. Ek de yer alan veri seti 125x6 'dır. Buna göre 125 adet vaka ve 6 adet gözlem mevcuttur. Veri setinin ham halindeki gibi 378x7 olarak kullanılmama nedenleri Bölüm 2 de anlatılan bilgilerdir ve bu bilgilere ek olarak; verinin alanında uzman kişilerce değerlendirilmesi ile lüzumsuz gözlemlerin veri setinden kaldırılması. Ayrıca iki ve daha fazla boş veri bulundurması ve boşluğun doldurulması yeterince anlamlı olmayacak ise o satırlarında veri setinden kaldırılması.

Eksik verilerin giderilmesi işleminin bir kısmını yukarıda belirtildiği gibi excel sayfasında yaptıktan sonra veri seti makine öğrenmesi için Jupyter-Lab IDE ortamına aktarılmaktadır.

Bu tez kapsamında Project Jupyter'in Jupyter Lab uygulaması kullanılmıştır. Project Jupyter çeşitli program dillerine ortam sağlayan açık kaynak kodlu bir programdır. Python'da bu programlama dillerinden biridir.

Model de kullanılan kütüphaneler:

Numpy: Python programlama dili üzerinde matematiksel işlemler yapımını sağlayan açık kaynak kodlu bir kütüphanedir(Url-21, 2022).

Pandas: Python programlama dili üzerinde veri bilimi ilkelerinin uygulanmasını sağlayan açık kaynak kodlu bir kütüphanedir (Url-22, 2021).

Matplotlib: Python programlama dilinde görselleştirmeler, çeşitli grafikler oluşturmayı sağlayan açık kaynak kodlu görselleştirme üzerine bir kütüphanedir (Url-23, 2022).

Seaborn: Python programlama dilinde veri görselleştirme, istatistiksel grafikler oluşturma işlerini kolayca ve hızlıca haledebileceğimiz açık kaynak kodlu bir görselleştirme kütüphanesidir. Seaborn kütüphanesi matplotlib tabanlıdır (Url-24, 2022).

Sklearn: Python programlama dili için geliştirilmiş makine öğrenimi yazılımı

yapabilen açık kaynak kodlu bir kütüphanedir (Url-25, 2021).

Bu tez kapsamında geliştirilen Modellerler önce lineer regresyon ardından lineer olmayan regresyonların denenmesi üzerine, aykırı verilerin işleme şekli, veri setinin eğitim ve test olarak ayrılması sırasında eğitim ve test verilerinin farklı dağılımları ve hiperparametrelerin etkilerinin gözlemlenmesi ile oluşturulmuştur.

Buna göre; Tablo 4. 3’de lineer regresyon eğitim modellerine ait metrikler ve Tablo 4. 7’de seçilen model üzerinden aykırı değerlerin gözlemlendiği modellere ait metrikler verilirken, Tablo 4. 6’de doğrusal olmayan Modellere ait hiperparametreler ve eğitim-test ayırımındaki parametreleri verilmektedir.

Kurulan modellerin başarıları mean_absolute_error, mean_squared_error, r2_score, score gibi metriklerle ölçülecektir.

Tablo 4.8 daki metriklerin anlamları:

- mean_absolute_error : ortamala hatanın mutlak değeri
- mean_squared_error : ortalama hatanın karesi
- score : girdilerin çıktılar üzerindeki değişiminin açıklaması oranıdır.
- r2_score : bağımsız değişkenler tarafından bağımlı değişkenlerin açıklanma oranı. Bağımsız değişkenler girdiler, bağımlı değişkenler çıktılar olmaktadır (Url-34, 2022).


Tablo 5. 1 de, Tablo 4. 3, Tablo 4. 4 ve Tablo 4. 8’ de hata metriklerinin kare köklerinin sonuçları alınmaktadır.

Tablo 4. 3’de ve Şekil 4. 29 ‘da görüldüğü üzere eğitim sırasında genellenebilirlik anlamına gelen r2_score değeri en yüksek lineer regresyon Modeli RidgeReg’dir. RidgeReg’in r2_score’u %74,97 ve ortalama hata karelerini karekökü değeri de 9,43’tür. RidgeReg Modeli en yüksek genellenebilirliği vermektedir ve beklenildiği

gibi en az hata deęerini de vermektedir.

Tablo 4.3: Lineer Regresyon Modelleri Metrik Deęerleri

| Modeller | np.sqrt(mean_squared_error) | r2_score |
|-----------|-----------------------------|----------|
| LinearReg | 9,8040 | 0,7299 |
| RidgeReg | 9,4375 | 0,7497 |
| LassoReg | 12,1814 | 0,5830 |



Şekil 4.29: Lineer Regresyon Eęitim Modelleri


Lineer regresyon Modellerinden RidgeReg Modeli seęilerek test setimiz üzerindeki etkisi araştırılmıřtır. Bu baęlamda Tablo 4. 3' de görüldüęü üzere yapılan optimizasyon sonuęunda parametrelerin test verileri üzerindeki tahmini sonrasında RidgeReg modelimizin r2_score: %73,50 ve hata: 9,7108'dir.

Denklem (4.5) ve Tablo 4. 4 de görüldüęü üzere girdi parametlerinin katsayıları RidgeReg modelinden elde edilmiřtir. RidgeReg Model_ne göre elde edilen bu denklem dięer tüm modellerde olduęu gibi veri iřlenmesi yapılmıř veri setinin kazı destekleme sistem tiplerine göre ayrılmıř halini içermektedir. Şekil 4. 30 de Lineer regresyona ait denklemi çizmeye ęalıřan bir insan fięürü görülmektedir. Bu insan fięürü yerine bu denklemi makine öęrenmesi yoluyla çizilebilmekteyiz.

Tablo 4.4: En İyi Lineer Modelin Test Verisindeki Metrik Değerleri

| BestModelTest | np.sqrt(mean_squared_error) | r2_score |
|---------------|-----------------------------|----------|
| RidgeRegTest | 9,7108 | 0,7350 |

$$\begin{aligned} Y_{\text{atayDeplasman}} = & \left(50.706 - 0.666 * (\text{DestekAralığı(mm)}) - 0.000 * \left(EI \sqrt[n]{\left(\frac{kNm^2}{m} \right)} \right) + 0.000 * \right. \\ & (H_{\text{Kazı(mm)}) + 0.803 * (\delta v_{\text{Olcum(mm)})} - 14.666 * (\text{Tip: _Diyafram duvar} + \text{Çok sıra destek}) + \\ & 12.521 * (\text{Tip: _Kesişen} + \text{Tek sıra destek}) + 7.180 * (\text{Tip: _Kesişen kazıklı duvar}) - 7.551 * \\ & (\text{Tip: _Perde Duvar} + \text{Tek sıra destek}) + 4.159 * (\text{Tip: _Perde Duvar} + \text{Çok sıra destek}) - \\ & 16.952 * (\text{Tip: _Perde H Profil} + \text{Çok sıra destek}) + 12.942 * (\text{Tip: _Sürekli kazıklı duvar}) - \\ & 3.074 * (\text{Tip: _Tek sıra destekli palplanş perde duvar}) - 14.279 * \\ & (\text{Tip: _Tek sıra destekli çakma profil}) + 1.852 * (\text{Tip: _Yukarıdan aşağıya} + \\ & \text{Kazıklı duvar}) - 9.070 * (\text{Tip: _Yukarıdan aşağıya diyafram duvar}) - 19.475 * \\ & (\text{Tip: _Yukarıdan aşağıya çakma profil}) + 16.738 * \\ & (\text{Tip: _Yukarıdan aşağıya çok sıra destekli duvar}) - 28.362 * \\ & (\text{Tip: _Çok sıra ankrajlı diyafram duvar}) - 19.771 * \\ & (\text{Tip: _Çok sıra ankrajlı kazıklı duvar}) - 19.192 * (\text{Tip: _Çok sıra ankrajlı çakma profil}) + \\ & 10.290 * (\text{Tip: _Çok sıra destek - Arbed}) - 1.342 * \\ & (\text{Tip: _Çok sıra destekli diyafram duvar}) - 2.972 * (\text{Tip: _Çok sıra destekli kazıklı duvar}) + \\ & 0.000 * (\text{Tip: _Çok sıra destekli kesişen kazık}) - 4.576 * \\ & (\text{Tip: _Çok sıra destekli perde duvar}) - 25.823 * \\ & (\text{Tip: _Çok sıra destekli sürekli kazıklı duvar}) - 19.952 * \\ & (\text{Tip: _Çok sıra destekli çakma profil}) \end{aligned} \quad (4.5)$$



Şekil 4.30: Lineer Regresyon Grafiği

Kaynak: (url- 35, 2022)

Bir doğrunun denklemi bilindiği üzere denklem (4.6)'daki gibidir.

$$y = \theta_0 + \theta_1 * X_1 + \dots + \theta_n * X_n \quad (4.6)$$

Lineer regresyon da makine öğrenmesi yapılırken bulduğumuz bu denklemdaki ifadeler şu anlalara gelmektedir:

θ_0 : Doğrunun y ekseninde kestiği nokta, bias ve intercepts olarakta kullanılmaktadır.

θ_1 : Ağırlıklar, birinci bağımsız değişkenin (birinci gözlem) katsayısı.

X_1 : Bağımsız değişken (Birinci bağımsız değişken-birinci gözlem).

θ_1 : Ağırlıklar, birinci bağımsız değişkenin (birinci gözlem) katsayısı.

n : n'inci gözlem veya ağırlık indisi(Uğuz, 2021).

Denklem (4.6)' a göre RidgeReg Modelinin katsayıları incelendiğinde bazı katsayılar sıfır veya sıfıra çok yakın çıkmaktadır. Bu bazı bağımsız değişkenlerimizin yani parametrelerimizin etkisiz olduğu anlamına gelmektedir. Maksimum katsayının da en etkin parametre olduğu bilinmektedir. Tablo 4.5 ve denklem (4.6) da katsayıları sıfır ve/veya sıfıra yakın çıkan bağımsız değişkenlerimiz; yanal rijitlik, kazı derinliği, çok sıra destekli kesişen kazık olmakla birlikte katsayımızın en büyük değeri yakaladığı bağımsız değişkenler ise çok sıralı ankrajlı diyafram duvar olmaktadır. Bu katsayıların anlamlılığına sonuçlar kısmında deyinilmektedir.

Tablo 4.5: Lineer Regresyon RidgeReg Model Tahmininin, Girdi Parametreleri Katsayıları

| Bias | 'Destek_Aralığı(mm)')' | 'EI\n(kNm2/m)' | 'H_Kazı(mm)' | 'δv_Olcum(mm)' | 'Tip:_Diyafram duvar + Çok sıra destek' | 'Tip:_Kesişen + Tek sıra destek' |
|--------|--|--|---|---|--|---|
| 50.706 | -0.666 | -0.000 | 0.000 | 0.803 | -14.666 | 12.521 |
| | 'Tip:_Kesişen kazıklı duvar' | 'Tip:_Perde Duvar + Tek sıra destek' | 'Tip:_Perde Duvar + Çok sıra destek' | 'Tip:_Perde H Profil + Çok sıra destek' | 'Tip:_Sürekli kazıklı duvar', | 'Tip:_Tek sıra destekli palplanş perde duvar' |
| | 7.180 | -7.551 | 4.159 | -16.952 | 12.942 | -3.074 |
| | 'Tip:_Tek sıra destekli çakma profil' | 'Tip:_Yukarıdan aşağıya + Kazıklı duvar' | 'Tip:_Yukarıdan aşağıya diyafram duvar' | 'Tip:_Yukarıdan aşağıya çakma profil' | 'Tip:_Yukarıdan aşağıya çok sıra destekli duvar' | 'Tip:_Çok sıra ankrajlı diyafram duvar' |
| | -14.279 | 1.852 | -9.070 | -19.475 | 16.738 | -28.362 |
| | 'Tip:_Çok sıra ankrajlı kazıklı duvar' | 'Tip:_Çok sıra ankrajlı çakma profil' | 'Tip:_Çok sıra destek - 'Arbed''' | 'Tip:_Çok sıra destekli diyafram duvar' | 'Tip:_Çok sıra destekli kazıklı duvar' | 'Tip:_Çok sıra destekli kesişen kazık' |
| | -19.771 | -19.192 | 10.290 | -1.342 | -2.972 | 0.000 |
| | 'Tip:_Çok sıra destekli perde duvar' | 'Tip:_Çok sıra destekli sürekli kazıklı duvar' | 'Tip:_Çok sıra destekli çakma profil') | | | |
| | -4.576 | -25.823 | -19.952 | | | |

Tablo 4.6: Doğrusal Olmayan Modellere Ait Hiperparametreler ve Eğitim-Test Ayrımındaki Parametreleri Verilmektedir.

| Yapay Sinir Ağında Geliştirilen Modeller | | Model_1 | Model_2 | Model_3 | Model_4 | Model_5 | Model_6 | Model_7 | Model_8 | Model_9 | Model_10 | Model_11 | |
|--|--------------------------------|-------------------------|--------------------------|--------------------------|--------------------------|--------------------------|--------------------------|--------------------------|--------------------------|-------------|--------------------------|--------------------------|----------|
| aykırı verilerin işlenmesi | | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | Yöntem Aynı | |
| eğitim - test ayrımı parametreleri | <i>train: test_size</i> | 0.15 | 0.15 | 0.15 | 0.15 | 0.15 | 0.15 | 0.15 | 0.15 | 0.15 | 0.15 | 0.15 | |
| | <i>train: random_state</i> | 6 | 6 | 6 | 6 | 9 | 2 | 9 | 9 | 9 | 9 | 9 | |
| | <i>validsyon: test_size</i> | 6 | 6 | 6 | 6 | 6 | 8 | 11 | 2 | 11 | 11 | 11 | |
| | <i>validsyon: random_state</i> | 6 | 6 | 8 | 6 | 8 | 8 | 16 | 16 | 16 | 16 | 16 | |
| Hiperparametreler | <i>hidden_layer_sizes</i> | [26, 14, 14, 14, 14, 7] | [26, 26, 26, 26, 26, 13] | [13, 26, 13, 26, 13, 13] | [13, 26, 13, 26, 13, 13] | [13, 26, 13, 26, 13, 13] | [13, 26, 13, 26, 13, 13] | [13, 26, 13, 26, 13, 13] | [13, 26, 13, 26, 13, 13] | ((100,)) | [13, 26, 13, 26, 13, 13] | [13, 26, 13, 26, 13, 13] | |
| | <i>random_state</i> | 88 | 88 | 88 | 65 | 88 | 88 | 88 | 88 | 59 | 59 | 59 | |
| | <i>max_iter</i> | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 400 | 200 | 400 | 400 | |
| | <i>activation</i> | relu | relu | relu | relu | relu | relu | relu | relu | relu | relu | relu | tanh |
| | <i>alpha</i> | 0,09 | 0,09 | 0,09 | 0,09 | 0,09 | 0,09 | 0,09 | 0,09 | 0,09 | 0,0001 | 1,30 | 0,09 |
| | <i>learning_rate</i> | adaptive | adaptive | adaptive | adaptive | adaptive | adaptive | adaptive | adaptive | adaptive | constant | constant | constant |
| | <i>momentum</i> | 0,70 | 0,70 | 0,70 | 0,70 | 0,70 | 0,70 | 0,70 | 0,70 | 0,70 | 0,70 | 0,26 | 0,26 |
| | <i>solver</i> | adam | adam | adam | adam | adam | adam | adam | adam | adam | adam | adam | adam |
| | <i>beta_1</i> | 0.856 | 0.856 | 0.900 | 0.856 | 0.900 | 0.900 | 0.900 | 0.900 | 0.900 | 0.900 | 0.881 | 0.881 |
| <i>beta_2</i> | 0,999 | 0,999 | 0,999 | 0,999 | 0,999 | 0,999 | 0,999 | 0,999 | 0,999 | 0,999 | 0,677 | 0,677 | |

Tablo 4. 6 ve Tablo 4. 7’de yapay sinir ağı tarafından oluşturulan en iyi model olan Model_10 üzerinden Model_10s, Model_10c, Model_10a, Model_10m farklı kombinasyonlarda denenmişlerdir.

Bu modellerin denen amacı veri setinin etkisinin sonuçlara olan yansımalarını gözlemlemektir. Model_10 referans alınarak denen modellerin Model_10’dan farklı olduğu kısımlar Tablo 4. 7 de belirtilenlere ek olarak şu şekildedir:

- Model_10m: Veri setinde destekleme sistemi bağımsız değişkeni tiplerine ayrıldı ve makine öğrenmesi hesabına dahil edildi.
- Model_10a: Veri setinde destekleme sistemi bağımsız değişkeni tiplerine ayrıldı ve makine öğrenmesi hesabına dahil edildi.
- Model_10c: Veri setinde destekleme sistemi bağımsız değişkeni tiplere ayrılmadı ve makine öğrenmesi hesabına dahil edilmedi.
- Model_10s: Veri setinde destekleme sistemi bağımsız değişkeni tiplere ayrılmadı ve makine öğrenmesi hesabına dahil edilmedi.

Tablo 4. 7 incelendiğinde Model_10s’de denemesinde veri setinin aykırı verilerine müdahale edilmemektedir ve Model_10 ile aynı parametrelere sahip olurken destekleme tipi makine öğrenmesi hesabına dahil edilmemiştir. Bu yöntem sonucunda Tablo 4. 8 ‘de görüldüğü üzere Model_10s hata değerleri daha yüksek ve genellenebilirlik oranları $r2_score$ ve $score$ değerleri negatif çıkmaktadır.

Tablo 4. 7 incelendiğinde Model_10c denemesinin Model_10s’un veri işleme biçimleri ve makine öğrenmesi hesabına dahil edilen bağımsız girdilerin ve bağımlı çıktının aynı olması ve aradaki tek farkı optimum parametreler ile makine öğrenme sürecinin Model_10c’de yapılması. Burada Model_10c’nin Model_10s’e göre daha iyi olduğunu $r2_score$ ve $score$ metrik değerlerinden anlaşılmaktadır. Modelc için $r2_score$ değeri %80,2 ve $score$ değeri %88,5 iken Model_10s’in -%44,2 ve $score$ değeri -%45,8 ‘dir.

Tablo 4. 7 'de Model_10a ve Model_10 ile sadece aykırı veri analizi olarak ayrılmaktadır. Model_10a'da aykırı verilerin işlenmesi işlemi yapılmamaktadır. Ve elde edilen r2_score değeri %64,9 score değeri %85,9 'dur.

Tablo 4. 7 'de Model_10m ve Model_10 ile farkı görülmektedir. Tablo 4. 7 'e göre Model_10m aykırı veri analizine tabi tutulmamasından dolayı optimum parametreleri bu ham verilere uygulamıştır. Elde edilen hiperparametrelerin en iyi değerleri doğrultusunda Model_10m r2_score derğeri %73,3 olurken score değeri %83,9 olmaktadır.

Tablo 4.7: YSA ile Geliştirilen En İyi Model Üzerinden Geliştirilen Diğer Modeller

| Yapay Sinir Ağında Geliştirilen Modeller | | Model_10 | Model_10s | Model_10c | Model_10a | Model_10m |
|--|--------------------------------|------------------------------|------------------------------|-----------------|------------------------------|------------------------------|
| aykırı verilerin işlenmesi | | Yapıldı | Yapılmadı | Yapılmadı | Yapılmadı | Yapılmadı |
| eğitim - test ayrımı parametreleri | <i>train: test_size</i> | 0.15 | 0.15 | 0.15 | 0.15 | 0.15 |
| | <i>train: random_state</i> | 9 | 9 | 27 | 9 | 27 |
| | <i>validsyon: test_size</i> | 11 | 11 | 11 | 11 | 11 |
| | <i>validsyon: random_state</i> | 16 | 16 | 16 | 16 | 16 |
| Hiperparametreler | <i>hidden_layer_sizes</i> | [13, 26, 13, 26, 13, 26, 13] | [13, 26, 13, 26, 13, 26, 13] | [10, 10, 10,10] | [13, 26, 13, 26, 13, 26, 13] | [13, 26, 13, 26, 13, 26, 13] |
| | <i>random_state</i> | 59 | 59 | 57 | 59 | 46 |
| | <i>max_iter</i> | 400 | 400 | 1300 | 400 | 360 |
| | <i>activation</i> | relu | relu | relu | relu | relu |
| | <i>alpha</i> | 1,3000 | 1,3000 | 0,8000 | 1,3000 | 0,9990 |
| | <i>learning_rate</i> | constant | constant | constant | constant | constant |
| | <i>momentum</i> | 0,26 | 0,26 | 0,26 | 0,26 | 0,26 |
| | <i>solver</i> | adam | adam | adam | adam | adam |
| | <i>beta_1</i> | 0,881 | 0,881 | 0,150 | 0,881 | 0,881 |
| | <i>beta_2</i> | 0,677 | 0,677 | 0,960 | 0,677 | 0,574 |

Tablo 4.8: En iyi Model Üzerinden Geliştirilen Diğer Modellerin Metrikleri

| Modeller | np.sqrt(mean_absolute_error) | np.sqrt(mean_squared_error) | r2_score | score |
|-----------|------------------------------|-----------------------------|----------|--------|
| Model_10 | 2,285 | 6,866 | 0,868 | 0,897 |
| Model_10s | 6,509 | 70,397 | -0,442 | -0,458 |
| Model_10c | 3,798 | 18,603 | 0,802 | 0,885 |
| Model_10a | 4,659 | 34,709 | 0,649 | 0,859 |
| Model_10m | 4,092 | 21,597 | 0,733 | 0,839 |

5. SONUÇLAR

Tezin bu bölümünde, python programı üzerinde geliştirilen kodlar ile lineer regresyon algoritmaları ve yapay sinir ağı algoritmaları kullanılarak bir kazıda meydana gelebilecek yatay deplasman tahminini, Modeller ve sonuçlar üzerinden değerlendirilmektedir. Öncelikle grafikler geoteknik açıdan geliştirilen Modeller açısından yorumlanacaktır ve sonrasında makine öğrenmesi kısmı sonuçlarına deyinilecektir. Geliştirilen Modeller, sklearn kütüphanesinde yer alan MLPRegression algoritması kullanılması, hiperparametrelerinin değiştirilmesi, eğitim aşamasında veri ayırma(split) işleminde rassal seçilmelerin ve geliştirilen kod içerisinde veri işleme yöntemlerinin farklılaştırılmasının hedeflenen başarı oranına etkisi de incelenmektedir. Karşılaştırmalar hata değerleri, score ve r2_score üzerinden yapılmaktadır. Ayrıca kullanılan gözlem parametrelerinin yatay deplasman ile ilişkisi bu bölümde yorumlanacaktır.

Geliştirilecek modeller için parametre seçiminin nasıl yapıldığına dair detaylı anlatım Bölüm 3’de yer almaktadır.

Şekil 3. 16’da yatay deplasman ölçüm ile destek aralığı grafiğindeki ilişki beklentilerin dışındadır. Destek aralığının mesafesi arttıkça yatay deplasmanın da artması beklenmektedir. Ham veri setinde durumu bu şekilde gözlemlememizin nedenleri şu şekildedir:

- projeden ya da sahadan elde edilmiş olan veri parametrelerinin sağlıklı alınmamış olma ihtimali,
- verilerin çok fazla aykırılık ya da gürültü içeriyor olması,
- saha da imalatı yapılırken gerekli özenin gösterilmemiş olması, ihtimalleri.

Aynı zamanda Şekil 3. 16'da destek aralığı ve yatay deplasman ölçüm arasındaki ilişkinin nedeni destekleme tipi indirgemesinde Bölüm 3'de incelendiği gibidir. Çok sıra palplanş perde gibi negatif yönlü etkiyen diğer destekleme tipleri de görülmektedir. Çok sıra palplanş perde destekleme sistemi destekleme aralığı very seti içerisinde aykırılığa neden olsa da çok sıra palplanş perde destekleme sistem tipleri için böyle bir etkinin genellemesini yapmak çok sağlıklı olmayacaktır. Bunun nedeni Şekil 5. 1'de de görülmektedir. Şekil 5. 1'de ham veri seti içerisinde yer alan destekleme sistem tiplerinin dağılımları adet cinsinden verilmektedir ve maksimum vaka-örneklem sayısı yukardan aşağıya çok sıra destek tipine aittir ve on beş vaka sayısına sahiptir. Bunun yanında minimum vaka sayısında otuz adet destekleme sistem tipinden on üç adetinde bir adet olarak görülmektedir. Bu durum ham veri setinin %41,94'ü etmektedir. Ham veri setimiz içerisinde destekleme sistem tiplerine göre yeterli sayıda vakaya ait örneklem ve veri bulunamamaktadır. Bu nedendir ki destekleme sistem tiplerine göre genelleme yapılması mantıklı olmamaktadır.

Şekil 3. 17'de yatay deplasman ölçüm ile yanal rijitlik grafiğinde nötre yakın negatif ilişki gözlemlenmektedir. İlişkinin negatif olması olasıdır ve beklenildiği gibidir. Ancak bu ilişkinin nötre yakın olması beklenen bir durum olmasada bu iki veri arasında negatif ilişkinin şiddetinin derecesi bu veri seti havuzu için bu denli olduğu görülmektedir.

Şekil 3. 18'de yatay deplasman ölçüm ile kazı derinliğinin grafiğinde, kazı derinliği ile yatay deplasman arasında pozitif bir ilişki gözlemlenmektedir. Bu olası bir durumdur ancak Bölüm 2'de Rankine Teorisine (bkz. denklem 2.0) göre kazı derinliğinin karesi ile ilişkilendirilmektedir. Bu teorilerin ışığında ve literatur çalışmaları kapsamında bu ilişkinin pozitif yönde şiddetli bir ilişki olması gerekmektedir. Bu durumun böyle olmaması veri havuzundaki verilerin dağılımından kaynaklanmaktadır.

Şekil 3. 19'de yatay deplasman ölçüm ile düşey deplasman ölçüm arasındaki ilişki grafiğinde ilişki yönünün pozitif ve derecesinin şiddetli olduğu görülmektedir. Bu durum 1934 yılında Terzaghi'nin yaptığı çalışmalarda, desteklenen zeminde çok daha küçük mertebelerde hareketler yaşandığında bile yanal zemin basıncında önemli

değişimler gerçekleşmektedir, gözlemine uymaktadır.

Tablo 4. 2’de aykırı değerler analizi sonrası aykırılıkların işlenmesi ile en şiddetli değişim düzeyi deplasman miktarındaki veri havuzunda meydana gelmektedir.

Bölüm 4 ‘de yatay deplasman miktarı ile diğer bağımsız değişkenlerin lineer dağılım grafikleri ham veri seti dağılımları ve aykırı verilerin işlenmesinden sonra ki dağılımları olarak kıyaslandığında görülmektedir ki aykırı verilerin analizlere yapılan müdahaleler veri setindeki bağımsız değişkenler arasındaki ilişkileri doğrudan etkilemektedir. Bu bağlamda aykırı veri işlemlerinde alanında uzman kişilere danışılmalıdır ve aykırılıklarına müdahale yönteminin uzman kişi veya kişilerce yorumlanmasından sonra yapılması önem arz etmektedir.

Tablo 4.1 ve Tablo 4. 2 ye baktığımızda Lineer regresyon Modelimiz olan RidgeReg Modelinde test setindeki r^2_score değerinde düşüş ve hata ortalamasında artış gözlemlenmektedir. Bunun temel nedeni optimizasyon sırasında atanan değerlerin doğruluk oranını arttırmasıdır. Bu doğruluk oranının artması her zaman r^2_score ’unda artış ve hatalarda azalış olacağı anlamında gelmemektedir. Bu durumun yorumu lineer regresyon Modelimiz için daha doğru bir genellenebilirlik vermektedir.

Tablo 4. 4 ‘de oluşturulan Model parametreleri görülmektedir. Burada on bir farklı Model geliştirilmektedir. Bu Modeller sonucu ortaya çıkan hata değerleri ve başarı skorları Tablo 5. 1’de gösterilmektedir.

Tablo 5. 1’deki ifadelerin açıklaması Bölüm 4. ’de anlatılmaktadır.

Tablo 5. 1’de r^2_score ’ları göz önüne alındığında en başarılı Modelin Model_10 olduğu görülmektedir. Model_10, test sırasında girdi verilerinden çıktı verilerinin %86,75’ini açıklayabilmiştir. Model_10 eğitim sırasında girdi verilerinden çıktı verilerinin %89,7’sini açıklayabilmektedir. Aynı zamanda Model_10 ortalama mutlak hatanın kare kökü metriğinde en iyi ikinci Model ve ortalama hata karelerinin kare kökleri alındığında da en az hata değeri veren Modeldir.

| Destekleme_Sistemi | Destek_Aralığı(mm) | El\ñ(kNm2/m) | H_Kazı(mm) | δv_Olcum(mm) | δh_Olcum(mm) |
|---|--------------------|--------------|------------|--------------|--------------|
| | count | count | count | count | count |
| Aşağıdan yukarıya + Geçici destek | 1 | 1 | 1 | 1 | 1 |
| Diyafraam duvar | 1 | 1 | 1 | 1 | 1 |
| Diyafraam duvar + Çok sıra destek | 2 | 2 | 2 | 2 | 2 |
| Kesişen + Tek sıra destek | 1 | 1 | 1 | 1 | 1 |
| Kesişen kazıklı duvar | 4 | 4 | 4 | 4 | 4 |
| Perde Duvar + Tek sıra destek | 1 | 1 | 1 | 1 | 1 |
| Perde Duvar + Çok sıra destek | 2 | 2 | 2 | 2 | 2 |
| Perde H Profil + Çok sıra destek | 9 | 9 | 9 | 9 | 9 |
| Sürekli kazıklı duvar | 1 | 1 | 1 | 1 | 1 |
| Tek sıra destekli palplanş perde duvar | 1 | 1 | 1 | 1 | 1 |
| Tek sıra destekli perde duvar | 1 | 1 | 1 | 1 | 1 |
| Tek sıra destekli çakma profil | 1 | 1 | 1 | 1 | 1 |
| Yukarıdan aşağıya + Kazıklı duvar | 3 | 3 | 3 | 3 | 3 |
| Yukarıdan aşağıya ankrajlı duvar | 1 | 1 | 1 | 1 | 1 |
| Yukarıdan aşağıya diyafraam duvar | 10 | 10 | 10 | 10 | 10 |
| Yukarıdan aşağıya perde duvar | 1 | 1 | 1 | 1 | 1 |
| Yukarıdan aşağıya çakma profil | 2 | 2 | 2 | 2 | 2 |
| Yukarıdan aşağıya çok sıra destekli duvar | 15 | 15 | 15 | 14 | 12 |
| Çakma kazıklı duvar | 1 | 1 | 1 | 1 | 1 |
| Çakma profil + Tek sıra destek | 1 | 1 | 1 | 1 | 1 |
| Çok sıra ankrajlı diyafraam duvar | 8 | 8 | 8 | 8 | 8 |
| Çok sıra ankrajlı kazıklı duvar | 4 | 4 | 4 | 4 | 4 |
| Çok sıra ankrajlı çakma profil | 8 | 8 | 8 | 8 | 8 |
| Çok sıra destek - 'Arbed' | 1 | 1 | 1 | 1 | 1 |
| Çok sıra destekli diyafraam duvar | 11 | 11 | 11 | 11 | 11 |
| Çok sıra destekli kazıklı duvar | 2 | 2 | 2 | 2 | 2 |
| Çok sıra destekli kesişen kazık | 2 | 2 | 2 | 2 | 2 |
| Çok sıra destekli palplanş perde | 3 | 3 | 3 | 3 | 3 |
| Çok sıra destekli perde duvar | 14 | 14 | 14 | 14 | 13 |
| Çok sıra destekli sürekli kazıklı duvar | 8 | 8 | 8 | 8 | 8 |
| Çok sıra destekli çakma profil | 6 | 6 | 6 | 6 | 6 |

Şekil 5.1: Ham Veri Setinin Destekleme Sistemi Tipine Göre Dağılımı

Tablo 4. 4 'de Model1 ve Model2 arasındaki farkın sadece gizli katmanda(hidden_layer_size) nöronlar sayılarında olduğu görülmektedir. Tablo 5. 1'de de Model1 ve Model2'nin metrikleri görülmektedir. r_2_score 'lar göz önüne alındığında Model1 ve Model2 sırasıyla %47.1 ve %58,66 dır. Burada gizli katmanın nöron sayılarının uygun seçilmesinin önemi görülmektedir. Gizli katman parametresi girdi ve çıktı katmanları haricindeki katmanlardır. Bu katmanlarda nöron sayısı belirlenirken herhangi bir kural olmamaktadır ve deneme yanılma yöntemiyle belirlenmektedir. Bu tez kapsamında gizli katman sayısının katlarınca nöron sayısı belirlendiğinde maksimum genellenebilirlik oranlarına ulaşıldığı görülmektedir.

Tablo 4. 4 'de Model3 'ün Model2'den farkı β_1 birincil momentlerin tahminlerinin üssel olarak değişirir. Ve ağırlıklar bu etkiye dağıtıldığı için β_1 'deki artış olumlu yansımatadır. Ancak bir çok parametrede olduğu gibi optimum bir durum β_1 de de geçerlidir β_1 bir 'e yaklaştıkça Model iyileşir demek doğru olmamaktadır.

Tablo 4. 4 'de Model5 'in Model6'dan farkı eğitim sırasındaki verileri paylaşımıdır. Onun dışındaki hiperparametrelerin aynı olduğu görülmektedir. Model5 ve Model6'da sırasıyla validasyon için ayrılacak altı ve sekiz adet veri rassal seçim sayısının yani random_state sayısının farklılaşması ile seçildiği görülmektedir. Bu anlamda random_state'in değişmesinin önemli etkisini Tablo 5. 2'de gözlemlemektedir. Veriler eğitime girmeden önce y değeri olan yatay deplasman ölçümün istatistiksel durumu Şekil 4. 23'de 27.019 olarak okunmaktadır. Bu bilgiler ışığında Model_6'nın Model_5'den daha iyi bir tahmin sonucu verdiğini, Tablo 5. 1'de sırasıyla %82,61 ve %74,38 değerleri ile gözlemlenmektedir. Aynı durum Model_7 ve Model_8 için de gözlemlenmektedir. Model_5 ve Model_6 için; Tablo 5. 2'de veri seti eğitim, doğrulama ve test olarak ayrıldığı durumlarda gözlemlenebilmektedir. Bu ayrımların veri seti içerisinde tutarlı ve birbirine yakın betimsel istatistiksel değerler alması gerekmektedir.


Tablo 5.1: Değerlendirme Ölçütleri - Metrikler

| Metrikler | np.sqrt(mean_absolute_error) | np.sqrt(mean_squared_error) | r2_score | score |
|-----------|------------------------------|-----------------------------|----------|----------|
| Model1 | 3,24980 | 14,86000 | 0,47110 | 0,85004 |
| Model2 | 3,02796 | 13,14546 | 0,58664 | 0,95531 |
| Model3 | 3,35722 | 14,05982 | 0,33434 | 0,95209 |
| Model4 | 2,83382 | 11,16837 | 0,70163 | 0,95532 |
| Model5 | 2,85265 | 10,34991 | 0,74376 | 0,93328 |
| Model6 | 2,45463 | 8,07956 | 0,82605 | 0,94723 |
| Model7 | 2,17287 | 7,53513 | 0,84045 | 0,93680 |
| Model8 | 3,78941 | 20,40136 | 0,11686 | 0,94851 |
| Model9 | 3,51595 | 17,01434 | 0,18650 | -0,00931 |
| Model10 | 2,28510 | 6,86642 | 0,86751 | 0,89702 |
| Model11 | 3,88433 | 23,82516 | -0,59513 | -0,85823 |

Tablo 4. 4’de Model10 ile Model11 kıyaslandığında sırasıyla relu ve tanh aktivasyon fonksiyonlarının değiştiği görülmektedir. Tablo 5. 1’de bu değişimin ölçümü incelendiğinde, Model_10 ve Model_11 için sırasıyla r2_score metrikleri %86,75 ve eksi(-) %59,51’dir. Ve yine sırasıyla score metrikleri %89,70 ve eksi(-)%85,82 değerlerindedir. r2_score ve score metriklerinin negatif çıkması Bölüm 4’de de anlatıldığı üzere kurulan modelin yapmış olduğu tahminlerin veri setini anlamlandıramadığını göstermektedir. Bu doğrultuda diğer parametrelerin öneminin de olacağı gibi bu iki model özelinde aktivasyon fonksiyonlarından uygun olanının seçilmesi büyük önem taşıdığı görülmektedir.

Şekil 5. 1’de görülen her bir düğüm noktası sol baştan sağ başa sırasıyla Model_1-Model_11’dir. En yüksek r2_score oranını veren model Model_10’dur ve en az ortalama kare hatasını veren beklenildiği gibi yine Model_10’dur. Ancak ortalama mutlak hata değerince en az hatayı veren Model ise Model_7’dir(bkz. Tablo 5.1). Bu bağlamda Şekil 5. 1’de hata metrikleri kare köklerinin grafiksel değişimi

görülmektedir. Ortalama mutlak hata dağılımındaki eğiri ortalama kare hatasına nazaran lineere daha yakın bir uyum göstermektedir. Bu iki hata metriğinin $r2_score$ eğirisi üzerindeki ilişkisi incelendiğinde ortalama kare hatasındaki değişimin $r2_score$ ile ters orantısı daha iyi gözlemlenmektedir. Buradan sonuçla $r2_score$ değerlendirmesi yapılırken hata metriği olarak ortalama kare hatası kullanılması daha doğrulanabilir genellemeler yapmamızı sağlayacaktır.



Şekil 5.2: Hata Metrikler ve $r2_score$ Oranı –Test Seti

Tablo 5.1 ve Şekil 5. 2’de eğitim setindeki öğrenmedeki genellenebilirliğinin en iyi olduğu modelin Model_4 olduğu görülmektedir.


Şekil 5. 1 ve Şekil 5. 2 incelendiğinde eğitim setindeki başarının test setlerine yansımadağı özellikle de Model_4 için gözlemlenmektedir. Bunun temel nedeni Model_5 ve Model_6 için elde edilen sonuç gibi, eğitim sırasında random olarak seçilen veri havuzundan kaynaklanmaktadır.

Bu tez kapsamında yapay sinir ağı Modeli kurulurken geoteknik mühendisliği verileri kullanılmıştır. Çalışmada hedeflenen durum kazı destekleme elemanlarının yatay deplasman tahimidir. Yapı çukurunun güvenliği için önemli bir parametre olan yatay deplasmanı, yapay sinir ağıları modeli kullanarak %86,75 ‘lik

açıklanabilirlik ile elde edilmiştir. Bu durum, modelin %13,25'lik hata ile yatay deplasman tahmini yapabildiği anlamına gelmektedir.

Tablo 5.2: Eğitim Aşamasındaki Çıktı Verilerinin Ortalama Hedef Değer Dağılımları - Model5 ve Model6

| | Model5 | Model6 |
|--------------|-----------|-----------|
| y_train | 28.730645 | 27.295 |
| y_test | 23.792308 | 26.346154 |
| y_validasyon | 16.333333 | 26.05 |



Şekil 5.3: Score - Metrik

Denklem (4.6) ve Tablo 4. 3 'deki değerler RidgeReg Modeli çok daha iyi genellenebilirlik oranı vermediğinden bu katsayılar kullanılabilir olmamaktadır. Ancak buradan sonuçla daha uygun verilerle kazı alanlarında zeminin yanıl deplasman hareketi için baskın parametre tayini yapılabileceği öngörülebilmektedir.

Tablo 4. 7 ve Tablo 4.8 incelendiğinde Model_10'un ve Model_10s'den daha iyi genellenebilirlik vermesinin sebebi aykırı verilerin analizine dayanmakla birlikte bir adet bağımsız değişkenin hesap dışında kalmasıdır. Ayrıca Model_10s'in veri setinin asla anlamlandırmadığı görülmektedir. Bunun nedeni genellenebilirlikle ilgili olan r^2_score ve $score$ değerleri negatif çıkmasıdır.

Tablo 4. 7 'den anlaşılacağı üzere Model_10m'de veri seti aykırı değerlerce işlenmediği için artık Model_10 ve Model_10m'in veri kümelerinin betimsel istatistikleri değişmiştir. Bu bağlamda modellerin hiperparametrelerinin en iyi değerleri de değişmektedir.

Tablo 4. 7 'de Model_10a'nın Model_10'dan daha başarısız sonuçlanması sebebi aradaki tek fark Model_10 'da verilerin işlenmesidir. Buradan sonuçla doğrudan diyebiliriz ki verilerin işlenmesi makine öğrenmesinde kurulan her modele doğrudan olumlu etkiye sahip olmaktadır. Bu işleme yönteminin uzman kişilerce yapılması ve düzgün yürütülmesi gerekmektedir. Model_10a'nın eğitim setinde test setine göre daha iyi başarı gösterme sebebi iki temel durumdan kaynaklanmaktadır. Birincisi; verilerin betimsel istatistiklerinin eğitim setinde genel veri havuzuna daha çok uyması. İkincisi; eğitim sırasında algoritmaların test sırasına kıyasla daha çok veriden öğrenmesidir.

Tablo 4. 7 de Model_10c ve Model_10s arasındaki bu farklılaşmanı nedeni optimum parametrelerdir. Aykırı verilerin ayıklanmaması ve işlem görmemesine rağmen Model_10c 'nin hem eğitim hem de test sırasında başarısının %80'lerin üzerinde olmasının nedenleri şu şekildedir:

- Eğitim ve test ayrımı parametrelerinde betimsel istatistiklerin dağılımını kontrol eden parametreler. Tablo 4. 7'deki fark $random_state$ parametresi ile meydana gelmiştir.
- Eğitim test ayrımı bittikten sonra modelin hiperparametrelerinin tahmini üzerinde çalışılıp en iyi değerler elde edilmektedir. Tablo 4.7'de de görülebileceği üzere en iyi hiperparametrelerde farkı $hidden_layer_sizes$, $random_state$, max_iter , $alpha$, $beta_1$, $beta_2$ parametreleri ile sağlamıştır.

Model_10c'nin Model_10'dan daha etkin bir sonuç verememesinin nedeni temel olarak aykırı verilerinin işlem görmemesinden kaynaklanmaktadır.

Tablo 4. 7 'de Model_10m ve Model_10a arasındaki fark görülmektedir. Buna göre bu fark hiperparametre seçimlerinden kaynaklanmaktadır. Buna göre doğrudan hiperparametre seçimlerinin en uygun yapılması olumlu etki vermektedir.

Yukarıda izah edilen sonuçlar ve yorumlamalar sonrasında anlaşılan odur ki veri işleme süreci, veri görselleştirme süreci, verinin betimsel istatistiksel olarak dağılımı ve hiper parametrelerin seçiminin doğru yapılması ile birlikte makine öğrenmesi aracılığı ile kazı alanlarındaki zeminlerin yatay deplasmanlarının tahminlerini elde edilebilmektedir. Bu tez kapsamında geliştirilen Model_10 ile bir kazı sırasında meydana gelebilecek yatay deplasmanları destekleme tipine, yanal rijitliğe, düşey deplasmana, kazı derinliğine bağlı olarak %86,73'lük bir doğrulama ile bulunabilmektedir.

6. TARTIŞMA VE TAVSİYELER

Gelecekte yapay zeka teknolojileri kullanılarak kazısı yapılan bir zemin için yatay deplasman tahmini yaptırılabilir. Bu tez kapsamında kurulan Modelin sonucundan farklı olarak Özgür Yıldız, (2019) “kazı destek yapılarının veri madenciliği ilkeleri ile incelenmesi” adlı doktora çalışmasında; R, korelasyon katsayısını 0,91005 bulmuştur. Buradaki farklılaşmanın en temel durumu veri setinde gözlemlenmektedir. Özgür Yıldız, (2019) tez çalışmasında kategorik veri olarak zemin tipini seçmiştir. Bu tez kapsamında ise elde edilen verilerde sadece destekleme sisteminin var olmasından dolayı destekleme sistemi seçilmiştir. İki tez kapsamında, verilerin işlenmesinin düzgün yapılması ve yapay sinir ağ modellerinin doğru kurulması sonucunda yatay deplasmanların yüksek doğruluklarda hesaplandığı görülmektedir.

Verilerin betimsel istatistiksel dağılımının önemi anlaşılmaktadır. Bununla birlikte betimsel istatistik aralığında olmayan verilerle kurulan yapay sinir ağı modelinin doğru tahmin işlemini ön görülebilir doğrulukta gerçekleştiremeyeceği gözlemlenmektedir. Başarısı ispatlanmış bir modelden doğru tahminler elde etmek için betimsel istatistiklerle uyumlu örneklerin modele gösterilmesi gerekmektedir. Bu bağlamda aykırı verilerin verinin betimsel istatistiğini olumsuz yönde kendi tarafına çekeceğini unutmamak gerekir. Bunun içindir ki aykırı verilerin işlenmesinde seçilecek yöntem önem arz etmektedir. Aynı zamanda en yüksek r2_score değeri her zaman en doğru model olmamaktadır. Doğrulaması en iyi model r2_score değeri en yüksek olmasa bile genellemesi en doğru model olduğu için tercih edilen model olmaktadır. Modellerin başarı oranları asla %100 veya buna çok yakın değerler almamalıdır. Bu tarz durumlarda modelin aşırı öğrenme yaptığı düşünülmelidir ve sebepleri öncelikle veri setin de sonrasın da algoritmalar ve onların parametrelerinin içinde aranmalıdır.

Geliştirilebilecek makine öğrenmesi modelleri sayesinde baskın parametre seçimi ile

model girdi ve çıktı deęişkenlerinden oluşturulacak regresyon denklemi ile parametrelerin problemlerdeki önem katsayılarıda bulunabilecektir. Bu durum biz inşaat mühendisleri ve dięer disiplinler için büyük kolaylıkları ve tartışmaları beraberinde getirecektir. Öyle ki belki de doğru bildiğimiz yanlışlarımız olacaktır. O yüzden yapay zekanın mühendislik uygulamalarına doğrudan dahil edilmeden önce bu tarz durumların akademi ve bilim severlerce araştırılması gerekmektedir. Çok yakın zamanda bu tartışmaların yerini yapay zeka uygulamaları alacağı ön görülebildiği için bir an önce bu alandaki en büyük ihtiyaç ve önemli konu olan verilere ulaşabilmenin önü açılmalıdır.

Arazi, laboratuvar ve uygulama alanlarında işlerin doğru gittiğiden emin olmamız gerekmektedir. Çünkü elde edilecek verilerin güvenilirliği makine öğrenmesinde en önemli durumların başında gelmektedir. Aksi halde öğrenme doğru bir şekilde gerçekleşemez.

Veri setimizde yer alan parametrelerin seçimi tartışma konusu olabilmektedir. Farklı parametre girdileri ile farklı doğrulanabilirlik oranı yakalandığı için bu tarz girdi parametrelerinin de doğru seçilmesi ve problemi tanımlıyor olması gerekmektedir. Bu anlamda düzenlenen geoteknik rapor ve veri raporu belirli bir standarta oturtulmalı ve açık kaynak olarak paylaşılmalıdır. Böylelikle daha güvenilir ve yeterli adet de veri ile en iyi makine öğrenmesi modellerini oluşturabiliriz.

Tüm bunlarla birlikte uzun süreçler alan literature dayalı geleneksel mühendislik hesaplarını daha hızlı bir şekilde sonuçlandırmış ve zaman kazanmış olmaktadır. Böylelikle; tasarım süreçlerinde karar alma hızı artacak ve tasarım mühendislerinin dięer başka detaylarla ilgilenmesi kolaylaşacaktır. Daha güvenli ve daha ekonomik mühendislik yapıları inşaa edilecektir. Özellikle zemin davranışları ile ilgili bilinmezlikler düşünüldüğünde geoteknik yapıları için makine öğrenmesinin önemi daha da belirginleşmektedir.

Bu tarz çalışmalarla hata oranlarının minimize edilmesi maliyetlerin düşürülmesi ile optimum tasarımlar gerçekleşecek ve daha enerji harcanması ile karbon ayak izi azalacaktır. Çağımızın en büyük problemlerinden biri olan iklim krizi düşünüldüğünde daha sürdürülebilir bir dünya için optimum tasarımların yeri büyük

önem arz etmektedir.

Yapay zeka uygulamalarının yakın bir gelecekte tasarım mühendisleri tarafında yardımcı bir kaynak ve asistan olarak kullanılacakları bu tarz çalışmaların sıklığıyla mümkün olabilecektir.



KAYNAKLAR

- Abbas A. S., Chunling, S., Emma, Z., Stefan, L.,** (2021). Spatial distribution Modeling of subsurface bedrock using a developed automated intelligence deep learning procedure: A case study in Sweden. *Journal of Rock Mechanics and Geotechnical Engineering*. 2021 September.
- Akar Bakhtiyar Abdullah.,** (2019). Investigating Geotechnical Properties Of Soils Using Ground Granulated Blast Furnace Slag, Fly Ash, And Lignosulfonates. Hasan Kalyoncu University, Ph.D. Thesis.
- Akın, Önalp., Ersin, Arel.,** (2018). Geoteknik Bilgisi- I Zeminler ve Mekaniği, İstanbul, Birsen Yayınevi.
- Aktaş, R.,** (2003), "Mali başarısızlığın öngörülmesi: İstatistiksel yöntemler ve yapay sinir ağı karşılaştırılması", Ankara Üniversitesi SBF Dergisi, 58(04).
- American Geological Institute.,** (1976). Dictionary of Geological Terms, Revised Ed., Anchor Books.
- Anderson, J. A.,** (1995), "An Introduction to Neural Networks", Massachusetts. Wilson, R.L. and Sharda, R., (1994), "Bankruptcy Prediction Using Neural Networks" Decision Support System, 13(5), 545-557.
- Ataseven, B.** (2013). Yapay Sinir Ağları ile Öngörü Modellemesi. Öneri, 10(39), 101-115.
- Bahadır E., Özdemir A.Ş.,** (2016), "Akademik Başarı Tahmininde Yapay Sinir Ağları", 1. Baskı, Burç Yayınevi.
- Bahar, M.,** (2009). Diyafram Duvarlı İksa Perdelerinde Ölçülen ve Tahmin Edilen Deplasmanların Karşılaştırılması. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı, İstanbul.
- Belciug, S., & Gorunescu, F.** (2014). Error-correction learning for artificial neural networks using the Bayesian paradigm. Application to automated medical diagnosis. *Journal of biomedical informatics*, 52, 329-337.
- Birand, A.,** (2006). Duvarlar. Teknik Yayınevi Mühendislik ve Mimarlık Yayınları, Ankara.
- Bowles, J.E.,** (1990). Foundation Engineering and Design, John Wiley and Sons, New York.
- Caner, M., & Akarşlan, E.** (2009). Mermer Kesme İşleminde Spesifik Enerji Faktörünün ANFIS ve YSA Yöntemleri ile Tahmini. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 15(2), 221-226.
- Çelik, B.** (2008). YSA Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama, Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler

Enstitüsü, İstanbul.

- Clough, G.W., and O'Rourke, T.D.,** (1990). Construction Induced Movements of Insitu Walls, *Design and Performance of Earth Retaining Structures*, ASCE, pp. 439-470, 1990
- Clough, G.W., ve O'Rourke, T.D.,** (1990). "Construction Induced Movements of Insitu Walls", *Design and Performance of Earth Retaining Structures*, ASCE, pp. 439-470, 1990.
- Coast, P.K.ve Fant, L.F.,** (1991), "A Neural Network Approach to Forecasting Financial Distress", *Journal of Business Forecasting*, 10(4), 9-12.
- Coduto, D.P.,** (2001). *Foundation Design: Principles and Practices*, PrenticeHall, Inc.Upper Saddle River.
- Collins, A. ve Evans, A.,** (1994), "Aircraft Noise and Residential Property Values"., *Journal of Transport Economics and Policy*, 28(2), 175-197.
- Du, H., Chi, S., and Wang, F.,** (2006). Using an Improved Particle Swarm Optimization for Back Analysis of Geotechnical Parameters of Concrete Face Rock-fill Dams. *In 2006 Sixth International Conference on Hybrid Intelligent Systems (HIS'06)* (pp. 66-66). IEEE.
- Dunn, I. S., Anderson, L. R., ve Kiefer, F. W.,** (1980), *Fundamentals of Geotechnical Analysis*, John Wiley, New York.
- Engin, E.,** (2008). Destekli Kazılarda Yapılan İnklinometrik Ölçümleri ile Sonlu Elemanlar Analizini Karşılaştırılması, Yüksek Lisans Tezi, YTÜ, İstanbul.
- Ermanlar, L.,** (2009). Derin Kazılar Sonucu Çevre Yapılarda Oluşan Deformasyonların Tahmini, Yıldız Teknik Üniversitesi, Yüksek Lisans Tezi, İstanbul
- Fatih, Büyükgökçe.,** (2018). Derin Kazılarda Yanal Yüke Maruz İksa Sistemlerinin Parametrik Analizi, Sakarya Üniversitesi, Yüksek Lisans Tezi, Sakarya.
- Finno R.J., ve Harahap IS.,** (1991). Finite element analyses of HDR-4 excavation. *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE 1991; 117(10):1590–1609.
- Finno, R. J., ve Calvello, M.,** (2005). Supported excavations: Observational method and inverse Modeling. *Journal of Geotechnical and Geoenvironmental Engineering*, 131, 826–836.
- Gökhan, Demir.,** (t.y). Derin Kazılar ve İksa Yöntemleri Zemin Mekaniği Ders Notları. On Dokuz Mayıs Üniversitesi.
- Goldberg, D. T., Jaworski, W. E., and Gordon, M. D.,** (1976). Lateral support systems and underpinning.
- Köse, H. K.,** (2011). Derin Kazılar Ve Derin Kazı Uygulamasına Bir Örnek: Hilton Garden Inn Sütlüce Derin Temel Kazısı (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Harrington, P. B.** (1993). Transfer functions in artificial neural networks. Center for Intelligent Chemical Instrument, Department of Chemistry, Ohio University, Athens, OH.
- Haykin, S.,** (1999), "Neural Networks- A Comprehensive Foundation", Prentice Hall, 2. Edition, New Jersey.

- Hebb, D. O.**, (1949), "The Organization of Behavior: A Neuropsychological Theory", New York: Wiley and Sons.
- Hu, C.**, (2002), "Advanced Tourism Demand Forecasting: ANN and Box-Jenkins Modelling", Doktora Tezi, Purdue University, MI, USA. İstanbul, İstanbul Technical University, Master Thesis.
- Kaftan, İ.** (2010). Batı Türkiye gravite ve deprem katalog verilerinin yapay sinir ağları ile değerlendirilmesi (Doctoral dissertation, DEÜ Fen Bilimleri Enstitüsü).
- Karaatlı, M., Güngör, İ., Demir, Y., & Kalaycı, Ş.** (2005). Hisse senedi fiyat hareketlerinin yapay sinir ağları yöntemi ile tahmin edilmesi. Yönetim ve Ekonomi Araştırmaları Dergisi, 3(3), 38-48.n
- Keller I.**, (2011). Improvement Of Weak Soils By The Deep Soil Mixing Method, Keller Brochure: 23-30.
- Keskenler, M. F., & Keskenler, E. F.** (2017). "Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi". Takvim-i Vekayi, 5(2), 8-18.
- Kormaz, M.**, (2020). Thermoelastic Stress Analysis with Python Programming Language, Master Thesis, Gazi University Institute of Science and Technology, Ankara.
- Mana, A. I., ve Clough, G. W.** (1981). Prediction of movements for braced cuts in clay. *Journal of Geotechnical and Geoenvironmental Engineering*, 107(ASCE16312 Proceeding).
- Marulanda, C.**, (2005). Integration of numerical Modeling and field observations of deep excavations. University of Illinois at Urbana-Champaign.
- Mehra, P., & Wah, B. W.**, (1992), "Artificial Neural Networks: Concepts and Theory", Los Alamitos IEEE Computer Society Press, 680.
- Müller-Breslau, H.**, (1906). Erddruk auf Stützmauern, Alfred Kroner Verlag, Stuttgart (in German).
- Mustafa, S.**, (2010). A Case Study: A Deep Retaining System Construction With Prestressed Anchors, Dokuz Eylül University, Master Thesis.
- N. Hussey., A. Cerato., J. Grasmick., E. Holderby., G. Miller and W. Tabet.,** (2010). An Assessment Of Soil Parameters Governing Soil Strength Increases GeoFlorida 2010: Advances In Analysis, Modeling & Design, ASCE 2010.
- Nabiyev, V. V.**, (2016), "Yapay Zeka", 5. Baskı, Seçkin Yayıncılık, Ankara.
- Nilsson, N. J.**, (1998), "Artificial intelligence: a new synthesis", Elsevier.
- Orhan, H., ve Kaşıkçı, D.**, (2002). Path, korelasyon ve kısmi regresyon katsayılarının karşılaştırılması olarak incelenmesi. Hayvansal Üretim, 43(2), 68-78.
- Özgür, Yıldız.**, (2019). Kazi Destek Yapılarının Veri Madenciliği İlkeleri İle İncelenmesi. İstanbul, İstanbul Yıldız Teknik Üniversitesi, Doktora Tezi.
- Öztemel E.**, (2012), "Yapay Sinir Ağları", 3. Baskı, Papatya Yayıncılık, İstanbul.
- Öztemel, E.**, (2003), Yapay Sinir Ağları (1. Baskı). İstanbul: Papatya Yayıncılık.
- Pham, D. T., & Öztemel, E.**, (1995), "An Integrated Neural Network and Expert System Tool for Statistical Process Control. Proceedings Of The

- Institution Of Mechanical Engineers", Part B: Journal of Engineering Manufacture, 209(2), 91-97.
- Puller, M.**, (2003). Deep Excavations: A Practical Manual (2nd ed.). Great Britain: Thomas Telford.
- R. Buhler and A. Cerato.**, (2007). Stabilization Of Oklahoma Expansive Soils Using Lime And Class C Fly Ash, Geo-denver 2007: New Peaks In Geotechnics, ASCE 2007.
- Rankine, W. J. M.**, (1857), On the Stability of Loose Earth, *Philosophical Transactions of the Royal Society*, Vol. 147, London.
- Rojas, R.**, (2013), "Neural Networks: A Systematic Introduction", Springer Science & Business Media. Rumelhart, D. E., & Zipser, D. (1985). Feature discoveriby competi- tive learning. *Cognitive science*, 9(1), 75-112.
- Sedat, S., Ertan, B., Aşkın, Ö.**, (2018). İNM305 Zemin Mekaniği Ders Notları. Sakarya Üniversitesi.
- Seyfullah, Şengün.**, (2021). Derin Kazi İksa Yapısında Tasarımının Ve Deformasyonlarının İncelenmesi. Zonguldak, Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- Şen Z.**, (2004), "Yapay Sinir Ağları İlkeleri", Su Vakfı Yayınları, İstanbul.
- Sherwood P.**, (1993). Soil Stabilization With Cement And Lime.
- Sinan, Uğuz.**, (2021). Makine Öğrenmesi Teorik Yönleri Ve Python Uygulamaları İle Bir Yapay Zeka Ekolü. Nobel Yayıncılık. Ankara.
- Smith, M. R., ve Martinez, T.**, (2011). Improving Classification Accuracy By Identifying And Removing Instances That Should Be Misclassified. *In The 2011 International Joint Conference on Neural Networks* (pp. 2690-2697). IEEE.
- Steinberg M.**, (2000). Expansive Soils And The Geomembrane Remedy. In: Geo-Denver 2000.ASCE; 2000.
- Terzaghi, K., Peck, R.B.**, (1948). Soil Mechanics in Engineering Practice. John Wiley.
- Terzaghi, Karl.**, (1925a). Erdbaumechanik auf bodenphysikalischer Grundlage, Deuticke, Vienna (in German) (Forward translated into English in From Theory to Practice in Soil Mechanics, John Wiley, New York, 1960, pp. 58-61). Ayrıca bkz. Clayton et al., (1995).
- Terzaghi, Karl.**, (1925b). "Principles of Soil Mechanics," *Engineering News Record*, Vol. 95, No. 19-23 and 25-27, pp. 742-746, 796-800, 832-836, 874-878, 912-915, 987-990, 1026-1029, 1064-1068.
- Terzaghi, Karl.**, (1925c). "Modern Conceptions Concerning Foundation Engineering," *Journal of the Boston Society of Civil Engineers*, Vol. 12, No. 10, pp. 397-39.
- Terzaghi, Karl.**, (1929). "The Mechanics of Shear Failures on Clay Slopes and the Creep of Retaining Walls," *Public Roads*, Vol. 10, No. 10, pp. 177-192.
- Terzaghi, Karl.**, (1934a). "Die Ursachen der Schiefstellung des Turmes von Pisa," *Der Bauingenieur*, Vol. 15, No. 1/2, pp. 1—4 (Reprinted in From Theory to Practice in Soil Mechanics, L. Bjerrum et al., Eds, pp. 198-201, John Wiley, New York, 1960) (in German).
- Terzaghi, Karl.**, (1934b). "Large Retaining Wall Tests," a series of articles in

- Engineering News-Record, Vol. 112; 2/1/34, 2/22/34, 3/8/34, 3/29/34, 4/19/34, and 5/17/34.
- Terzaghi, Karl.**, (1936), "Discussion on Instruction in Soil Mechanics," Proceedings, International Conference on Soil Mechanics and Foundation Engineering, Vol. III, pp. 261-263.
- Terzaghi, Karl.**, (1939). "Soil Mechanics — A New Chapter in Engineering Science," Journal of the Institution of Civil Engineers, Vol. 12, pp. 106-141.
- Terzaghi, Karl.**, (1943). Theoretical Soil Mechanics, John Wiley, New York.
- Terzaghi, Karl.**, ve **Peck, Ralph B.**, (1967). Soil Mechanics in Engineering Practice, 2nd ed., John Wiley, New York.
- Tolon, M.** (2007). Artificial Neural Network Approaches For Slope Stability.
- Tolon, M.** (2013). A Comparative Numerical Analysis For Liquefaction. İstanbul, İstanbul Technical University, Ph.D. Thesis.
- Trippi, R.R. ve Turban, E.**, (1993), "Neural Network in Finance and Investment: Using Artificial Intelligence to Improve Real- Word Performance", Chicago.
- Tschebotarioff, Gregory P.**, (1951). Soil Mechanics, Foundations, and Earth Structures, McGraw Hill, New York.
- United States U.S. Department of Transportation Federal Highway Administration.**, (1999). *Geotechnical Engineering Circular No. 4: Ground Anchors And Anchored Systems*, Technical Manual, Publication No: FHWA-IF-99-015.
- Vogl, T.P., J.K. Mangis, A.K. Rigler, W.T. Zink, ve D.L. Alkon.** (1988). "Accelerating the convergence of the backpropagation method," Biological Cybernetics, Vol. 59, pp. 257-263
- Voorhees, W. R.** (2006), "Neural Networks and Revenue Forecasting: A Smarter Forecast?", International Journal of Public Policy, 1(4), 379-388.
- Wang, J. H., Xu, Z. H., and Wang, W. D.**, (2009). Wall and ground movements due to deep excavations in Shanghai soft soils. *Journal of Geotechnical and Geoenvironmental Engineering*, 136(7), 985-994.
- Whittle, A. J., Hashash, Y. M., and Whitman, R. V.**, (1993). Analysis of deep excavation in Boston. *Journal of geotechnical engineering*, 119(1), 69-90.
- Yetkin, M.** (2015). Tanker-şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğiyle Optimizasyonu (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Youssef M. A. Hashash., Camilo Phillips., David R. Groholski.**, (2010). Recent Advances In Non-Linear Site Response Analysis. Fifth international Conference on Recent Advances in Geotechnical Earthquake Engineering and Soil Dynamics and Symposium in Honor of Professor I.M. Idriss. 2010 May.
- Zhang, G., Patuwo, B. E., & Hu, M. Y.**, (1998), "Forecasting with Artificial Neural Networks", The State of The Art. International Journal Of Forecasting, 14(1), 35-62.

İnternet Kaynakları

https://acikders.ankara.edu.tr/pluginfile.php/2154/mod_resource/content/2/konu8a.pdf, alındığı tarih: 25.12.2021

https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcQUapUtto9FZYF0IrcgRSfPcNgnUSrR6Xhl-1R7LW_atSkODByk2HQzJCLbJ9RnjtWhKKc&usqp=CAU, alındığı tarih: 28.12.2021

https://towardsdatascience.com/beware-of-the-dummy-variable-trap-in-pandas-727e8e6b8bde_, alındığı tarih: 27.12.2021

<https://www.sciencedirect.com/science/article/pii/S009830041930679X>

Amir Ali Shahmansouri., Maziar Yazdani., Mehdi Hosseini., Habib Akbarzadeh Bengar., Hamid Farrokh Ghatte., (2022) The Prediction Analysis Of Compressive Strength And Electrical Resistivity Of Environmentally Friendly Concrete Incorporating Natural Zeolite Using Artificial Neural Network, Construction And Building Materials, Volume 317, 2022, 125876, ISSN 0950-0618. Alındığı tarih: 20.12.2021, adres:

<https://www.sciencedirect.com/science/article/pii/S0950061821036096>

<https://jupyter.org/>

Jon Sáenz., Juan Zubillaga., Jesús Fernández., (2002). Geophysical Data Analysis Using Python, Computers & Geosciences, Volume 28, Issue 4, 2002, Pages 457-465, ISSN 0098-3004. Alındığı tarih: 18.12.2021, adres:

<https://www.sciencedirect.com/science/article/pii/S0098300401000863>

L. Shawn Matott., K. Leung., Junyoung Sim., (2011). Application of MATLAB and Python optimizers to two case studies involving groundwater flow and contaminant transport Modeling, Computers & Geosciences, Volume 37, Issue 11, 2011, Pages 1894-1899, ISSN 0098-3004. Alındığı tarih: 17.12.2021, adres:

<https://www.sciencedirect.com/science/article/pii/S0098300411001312>

Pranshu, Sharma., (2021). Exploratory Data Analysis : Iris Dataset. Nisan 2021. Alındığı tarih: 19.12.2021, adres: <https://medium.com/analytics-vidhya/exploratory-data-analysis-iris-dataset-4df6f045cda>

Qian, He., Hongfei, Zheng., Xinglong, Ma., Lu, Wang., Hui, Kong., ve Ziyue Zhu (2022). Artificial Intelligence Application In A Renewable Energy-Driven Desalination System: A Critical Review, School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081, China. Alındığı tarih: 18.12.2021, adres: <https://www.sciencedirect.com/journal/energy-and-ai> 18 October 2021.

S. Memari, T., ve Prabhakar Clement., (2021). PySWR- A Python Code For Fitting Soil Water Retention Functions, Computers & Geosciences, Volume 156, 2021, 104897, ISSN 0098-3004. Alındığı tarih: 22.12.2021 adres:

<https://www.sciencedirect.com/science/article/pii/S0098300421001898>

Url-1

<<https://imb.cu.edu.tr/storage/Ders%20Notlar%C4%B1%20ve%20Yara>

- rl%C4%B1%20D%C3%B6k%C3%BCmanlar/Zemin%20%C4%B0yile
%C5%9Firme%20Y%C3%B6ntemleri.pdf>, alındığı tarih: 17.12.2021
- Url-2** <<http://www.dunyazemin.com/tuna-taksim-otel-iksa-projesi>>, alındığı tarih: 17.12.2021
- Url-3** <<http://www.dunyazemin.com/vadipark-seyrantepe-rezidans-iksa-projesi>>, alındığı tarih: 18.12.2021
- Url-4** <<http://imoistanbul.org/imoarsiv/geoteknik-kurs-notlari-2016/2.hafta/ozercinicioglu-Toprak%20bas%C4%B1n%C3%A7lar%C4%B1%20ve%20dayanma%20yap%C4%B1lar%C4%B1.pdf>>, alındığı tarih: 08.11.2021
- Url-5** <<https://docplayer.biz.tr/docs-images/93/113420618/images/5-3.jpg>>
- Url-6** <<https://santiyede.com/wp-content/uploads/2020/06/Diyafram-Perde-Avantaj-ve-Dezavantajlari-2.jpg>>, alındığı tarih: 22.12.2021
- Url-7** <<https://santiyede.com/wp-content/uploads/2020/06/zemin-ankraj%C4%B1-bile%C5%9Fenleri.jpg>>, alındığı tarih: 19.12.2021
- Url-8** <<http://www.dunyazemin.com/kasimpasa-pi-house-rezidans-iksa-projesi>>, alındığı tarih: 11.11.2021
- Url-9** <https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcQUapUtto9FZYF0IrcgRSfPcNgnUSrR6Xhl-1R7LW_atSkODByk2HQzJCLbJ9RnjtWhKKc&usqp=CAU>, alındığı tarih: 02.11.2021
- Url-10** <<http://naturalzemin.com/wp-content/uploads/2016/04/zemin-civisi-2.jpg>>,alındığı tarih: 28.10.2021
- Url-11** <<https://1.bp.blogspot.com/-Yih5AXIFhYw/YE-qzZ1AfPI/AAAAAAAAeNE/VduOApe5GIUOCv8u3tMs19hS4gcpFIVQCLcBGAsYHQ/w629-h376/Batardo-300x232.jpg>>, alındığı tarih: 11.11.2021
- Url-12** <https://santiyede.com/palplans-perde-nedir-ve-cesitleri/>, alındığı tarih: 11.11.2021
- Url-13** <<https://i1.wp.com/www.zeminarastirma.com/wp-content/uploads/2017/12/fore-kazik-nasil-yapilir-yapim-asamalari.jpeg?fit=1600%2C780>>, alındığı tarih: 31.12.2021
- Url-14** <<http://www.dunyazemin.com/umraniye-okan-sokak-yani-zemin-alti-otopark-iksa-projesi>>, alındığı tarih: 19.12.2021
- Url-15** <https://www.imo.org.tr/resimler/dosya_ekler/dcc1e1c41f0506a_ek.pdf?tipi=79&turu=X&sube=3>, alındığı tarih: 19.12.2021
- Url-16** <<https://www.analytichouse.com/aykiri-deger-analizleri-1/> ve <https://ichi.pro/tr/her-veri-bilimcisinin-ihiyac-duyugu-3-basit-aykiri-deger-anormallik-algilama-algoritmaları-254103469205810>>, alındığı tarih: 12.12.2021
- Url-17** <<https://www.turhost.com/blog/2020nin-en-populer-programlama-dilleri/#serp>>, alındığı tarih: 28.12.2021
- Url-18** <https://acikders.ankara.edu.tr/pluginfile.php/2154/mod_resource/content/2/konu8a.pdf>, alındığı tarih: 12.12.2021

- Url-19** <<https://ayyucekizrak.medium.com/derin-%C3%B6%C4%9Frenme-i%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9Ft%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd>> alındığı tarih: 08.01.2022
- Url-20** <https://miro.medium.com/max/724/1*a2e-ozEcNCm_s0trFzf-DA.jpeg>, alındığı tarih: 21.12.2021
- Url-20** <<https://www.researchgate.net/profile/Arthur-Jacobs/publication/326279910/figure/fig1/AS:675145723162632@1537978692947/Hyperbolic-tangent-activation-function.png>>, alındığı tarih: 21.12.2021
- Url-21** <<https://numpy.org/>>, alındığı tarih: 01.04.2022
- Url-22** <<https://pandas.pydata.org/>>, alındığı tarih: 18.12.2021
- Url-23** <<https://matplotlib.org/>>, alındığı tarih: 01.01.2022
- Url-24** <<https://seaborn.pydata.org/>>, alındığı tarih: 02.01.2022
- Url-25** <<https://scikit-learn.org/stable/>>, alındığı tarih: 17.12.2021
- Url-26** <https://scikit-learn.org/stable/auto_examples/neighbors/plot_lof_outlier_detection.html#sphx-glr-auto-examples-neighbors-plot-lof-outlier-detection-py>, alındığı tarih: 24.12.2021
- Url-27** <<https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.LocalOutlierFactor.html>>, alındığı tarih: 20.12.2021
- Url-28** <<https://ravenfo.com/2021/02/11/aykiri-deger-analizi/>>, alındığı tarih: 15.12.2021
- Url-29** <https://scikit-learn.org/stable/modules/generated/sklearn.Model_selection.train_test_split.html?highlight=train_test_split#sklearn.Model_selection.train_test_split>, alındığı tarih: 19.12.2021
- Url-30** <<https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>>, alındığı tarih: 16.12.2021
- Url-31** <https://scikit-learn.org/stable/modules/Model_evaluation.html#r2-score>, alındığı tarih: 16.12.2021
- Url-32** <https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPRegressor.html#sklearn-neural-network-mlpregressor>, alındığı tarih: 28.12.2021
- Url-33** <https://scikit-learn.org/stable/modules/generated/sklearn.Model_selection.GridSearchCV.html>, alındığı tarih: 18.12.2021
- Url-34** <https://scikit-learn.org/stable/modules/Model_evaluation.html#regression-metrics>, alındığı tarih: 23.12.2021
- Url-35** <<https://www.veribilimiokulu.com/basit-regresyon-python-ile-uygulama/>>, alındığı tarih: 15.01.2022

EKLER

EK-A: Kodlar



1. `import pandas as pd`
2. `import numpy as np`
3. `import seaborn as sns`
4. `import matplotlib.pyplot as plt`
5. `dosya= pd.read_excel("Doktora_Tez_Verileri_15.12.xlsx")`
6. `data=dosya.copy()`
7. `data.head()`
8. `data.tail()`
9. `data.shape`
10. `data.info()`
11. `data.describe().T`
12. `data.dropna(axis=0, how='any', inplace= True)`
13. `data.isnull().sum()`
14. `from sklearn.neighbors import LocalOutlierFactor`
15. `clf= LocalOutlierFactor(n_neighbors=20, contamination=0.2)`
16. `clf.fit_predict(data.iloc[:,1:])`
17. `data_scores= clf.negative_outlier_factor_`
18. `pd.DataFrame(np.sort(data_scores)).plot(stacked= True, xlim= [0,35], style= ".-");`
19. `esik_deger= np.sort(data_scores)[5]`

```
20. outlier_lof_index= data[data_scores < esik_deger].index

21. data.drop(index=outlier_lof_index, inplace= True)

22. data.shape

23. data.index= np.arange(0,116)

24. std= data["δh_Olcum(mm)"].std()

25. mean= data["δh_Olcum(mm)"].mean()

26. alt_2sigma= mean - 2*std

27. ust_2sigma= mean + 2*std

28. print(data[data["δh_Olcum(mm)"] < alt_2sigma].index)

29. print(data[data["δh_Olcum(mm)"] > ust_2sigma].index)

30. aykırı_ust_index= data[data["δh_Olcum(mm)"] > ust_2sigma].index

31. data.drop(index=aykırı_ust_index, inplace= True)

32. data.shape

33. data.index= np.arange(0,90)

34. for column in data.iloc[:,1:]:

35. sns.boxplot(data= data[column], orient= "h" );

36. plt.xlabel(column)

37. plt.show()

38. # δv_Olcum(mm) boxplot:

39. Q1= data["δv_Olcum(mm)"].quantile(0.25)
```

```

40. Q3= data["δv_Olcum(mm)].quantile(0.75)

41. IQR= Q3 - Q1 # Interquartile Range - Çeyrekler açıklığı (IQR)

42. alt_sinir_δv_Olcum= Q1 - 1.5*IQR

43. ust_sinir_δv_Olcum= Q3 + 1.5*IQR

44. print(Q1)

45. print(Q3)

46. print(IQR, "\n")

47. print(alt_sinir_δv_Olcum)

48. aykırı_alt_δv_Olcum_index=data[data["δh_Olcum(mm)"]<alt_sinir_δv_Olcu
    m].index

49. print(aykırı_alt_δv_Olcum_index)

50. aykırı_ust_δv_Olcum_index=data[data["δv_Olcum(mm)"]>ust_sinir_δv_Olc
    um].index

51. print(aykırı_ust_δv_Olcum_index)

52. data[data["δv_Olcum(mm)"] > ust_sinir_δv_Olcum]

53. aykırı_ust_δv_Olcum= data["δv_Olcum(mm)"]>ust_sinir_δv_Olcum

54. data["δv_Olcum(mm)"][aykırı_ust_δv_Olcum] = ust_sinir_δv_Olcum

55. data.drop(index=[58, 68, 71, 78, 79, 81], inplace=True)

56. data_one_hot=pd.get_dummies(data,columns=["Destekleme_Sistemi"],
    prefix= ["Tip:"], drop_first=True)

57. df= data_one_hot.copy()

58. from sklearn.Model_selection import train_test_split

```

```

59. X = df.drop(["δh_Olcum(mm)"], axis=1)

60. df.describe().T

61. X_train, X_test, y_train, y_test = train_test_split(X,y,test_size=0.15,
    random_state=9)

62. X_train, X_validasyon, y_train, y_validasyon = train_test_split(X_train,
    y_train, test_size=11 ,random_state=16)

63. pd.DataFrame(y_train).mean()

64. pd.DataFrame(y_validasyon).mean()

65. pd.DataFrame(y_test).mean()

66. from sklearn.preprocessing import StandardScaler

67. scaler = StandardScaler()

68. X_test_scaled=scaler.transform(X_test)

69. from sklearn.neural_network import MLPRegressor

70. mlp_Model= MLPRegressor().fit(X_train_scaled,y_train)

71. mlp_Model= MLPRegressor().fit(X_train_scaled,y_train)

72. y_pred= mlp_Model.predict(X_test_scaled)

73. np.sqrt(mean_absolute_error(y_test, y_pred))

74. np.sqrt(mean_squared_error(y_test, y_pred))

75. r2_score(y_test, y_pred)

76. mlp_params= {"alpha": [1.3,0.001,0.09,0.9], "random_state":
    np.arange(1,101), "hidden_layer_sizes": [(13, 26, 13, 26, 13, 26, 13),
    (100), (13,13,26,13,13)], "activation": ["relu","identity", "logistic", "tanh"],

```

```
"solver": ["adam","lbfgs","sgd"], "learning_rate": ["constant","invscaling",  
"adaptive"], "momentum": [0.26,0.71,0.75,0.80], "beta_1":[0.881,0.92,0.74],  
"max_iter": [200,300,400,650,800]}
```

```
77. from sklearn.Model_selection import GridSearchCV
```

```
78. mlp_cv_Model= GridSearchCV(mlp_Model, mlp_params, cv=3)
```

```
79. mlp_cv_Model.fit(X_train_scaled,y_train)
```

```
80. mlp_cv_Model.best_params_
```

```
81. np.sqrt(mean_absolute_error(y_test, y_pred))
```

```
82. np.sqrt(mean_squared_error(y_test, y_pred))
```

```
83. r2_score(y_test, y_pred)
```

```
84. mlp_Model.score(X_train_scaled,y_train)
```

ÖZGEÇMİŞ

Ad-Soyad : Caner KARABULUT

ÖĞRENİM DURUMU:

Lisans : 2013, Sakarya Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü.

Yükseklisans : 2016, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, İş Sağlığı ve Güvenliği Programı (TYL).

MESLEKİ TECRÜBE VE ÖDÜLLER:

İstanbul Gedik Üniversitesi'nde 2017 Eylül'den bu yana İnşaat Teknolojisi Programı'nda öğretim görevlisi olarak devam etmekteyim.

İnşaat mühendisliği yapılarında teknik ofis ve saha olarak yaklaşık 5 yıl çalıştım. Bu çalışmanın yaklaşık 3 yılını Adana 33.000 Seyirci Kapasiteli Stadyum Projesi Şantiyesinde kaba işler şefi olarak çalıştım.

Makine öğrenmesi eğitimlerinden çeşitli sertifikalar aldım ve öğrenmeye devam ediyorum.

TEZDEN OLUŞTURULAN YAYINLAR, SUNUMLAR VE PATENTLER: