

ŞEVLERDE STABİLİTENİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE DEĞERLENDİRİLMESİ

YÜKSEK LİSANS TEZİ

BARIŞ BAŞEREN

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI**

**MERSİN
AĞUSTOS – 2021**

ŞEVLERDE STABİLİTENİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE DEĞERLENDİRİLMESİ

YÜKSEK LİSANS TEZİ

BARIŞ BAŞEREN

ORCID ID: 0000-0001-8522-9645

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI**

Danışman

Doç.Dr. T. Fikret KURNAZ

ORCID ID: 0000-0003-2079-8315

**MERSİN
AĞUSTOS – 2021**

ÖZET

ŞEVLERDE STABİLİTENİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE DEĞERLENDİRİLMESİ

Bu çalışmada, inşaat mühendisliği geoteknik anabilim dalının önemli konularından biri olan şev stabilitesi analizleri için alternatif olarak makine öğrenme yöntemleri kullanılarak stabilite sonuçlarına yönelik tahmin modelleri uygulanmıştır. Makine öğrenme yöntemleri, diğer birçok karmaşık problemin çözümünde olduğu gibi şev stabilite analizlerinde de, zaman ve işgücü tasarrufu sağlamak amacı ile tercih edilmiştir.

Tahmin modellerinde kullanılmak üzere hazırlanan veri setinde 114 adet farklı şev profiline ait veriler ve vaka sonuçları kullanılmıştır. Kullanılan makine öğrenme yöntemlerinde girdi parametreleri olarak şev yüksekliği, şev açısı, içsel sürtünme açısı, kuru birim hacim ağırlığı ve kohezyon kullanılmış olup, çıkış parametresi olarak da şevin stabilite durumu verilmiştir. Elde edilen bulgular doğrultusunda tahmin modellerinde %92,10 - %97,44 arasında değişen performans sonuçları elde edilmiştir.

Çalışma sonunda, makine öğrenme yöntemleri ile şev stabilitesi tespitinde güvenilir sonuçlar elde edilebileceği vurgulanmıştır.

Anahtar Kelimeler: Şev, Şev Stabilitesi, Makine Öğrenme Yöntemleri, Yapay Sinir Ağı.

Danışman: Doç.Dr. T. Fikret Kurnaz, Mersin Üniversitesi, İnşaat Mühendisliği Anabilim Dalı, Mersin.

ABSTRACT

EVALUATION OF STABILITY ON SLOPES BY MACHINE LEARNING METHODS

In this study, predictive models for stability results were applied by using machine learning methods as an alternative for slope stability analysis, which is one of the important topics of civil engineering geotechnical department. Machine learning methods have been preferred in slope stability analyzes as well as in solving many other complex problems, in order to save time and labor.

Data and case results of 114 different slope profiles were used in the data set prepared to be used in forecasting models. In the machine learning methods; slope height, slope angle, internal friction angle, dry unit weight and cohesion were used as input parameters, and the stability of the slope was given as output parameter. In line with the findings obtained, performance results ranging from 92.10% to 97.44% were obtained in the prediction models.

At the end of the study, it was emphasized that reliable results can be obtained in the determination of slope stability with machine learning methods.

Keywords: Slope, Slope Stability, Machine Learning Methods, Artificial Neural Network.

Advisor: Associate Prof. T. Fikret KURNAZ, Department of Civil Engineering, University of Mersin, Mersin.

TEŞEKKÜR

Bu tezin hazırlanmasında; süreci yöneten ve desteğini esirgemeyen saygıdeğer hocam Doç.Dr. T.Fikret KURNAZ ile verdiği desteklerden ötürü saygıdeğer hocam Doç.Dr. Yılmaz KAYA'ya en içten teşekkürlerimi sunarım.

Akademik alanda ilerlemem konusunda beni her zaman teşvik eden sayın Prof.Dr. Akif AKKUŞ, Prof.Dr. Erol YAŞAR ve Prof.Dr. Murat YAKAR'a sonsuz teşekkürlerimi sunarım.

Beni yetiştiren ve bu günlere gelmemi sağlayan ailem ile hayatımın her alanında olduğu gibi bu tezin hazırlanma sürecinde de hep yanımda olan değerli eşim Yük.Mim. Meriç Begüm BAŞEREN'e ve hayat motivasyon kaynağım biricik oğlum Arda BAŞEREN'e en içten dileklerimle teşekkür ederim.



İÇİNDEKİLER

	Sayfa
İÇ KAPAK	İi
ONAY	İii
ETİK BEYAN	İiv
ÖZET	V
ABSTRACT	Vi
TEŞEKKÜR	Vii
İÇİNDEKİLER	Viii
TABLolar DİZİNİ	İx
ŞEKİLLER DİZİNİ	X
KISALTMALAR ve SİMGELER	Xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMALARI	2
2.1. Genel Şev Stabilitesi Kavramları	2
2.2. Şev Stabilite Analizlerinin Amaçları	2
2.3. Doğal Şevler	3
2.4. Mühendislik Yöntemleri İle Oluşturulan Şevler	3
2.5. Heyelanlar	4
2.6. Güvenlik Faktörü Kavramı	5
2.7. Şev Stabilitesi Analiz Metotları	8
2.7.1. Blok Analizi	8
2.7.2. Sonsuz Şev Analizi	9
2.7.2.1. Kuru Kumda Sonsuz Şev Analizi	9
2.7.2.2. Sızma Durumunda Sonsuz Şev Analizi	10
2.7.3. Düzlemsel Yüzey Analizi	11
2.7.4. Dairesel Yüzey Analizi	13
2.7.4.1. Dairesel Yay Yöntemi ($\emptyset u=0$)	14
2.7.4.2. Sürtünme Çemberi Yöntemi	14
2.7.5. Dilim Metotları	16
2.7.5.1. Fellenius Metodu	16
2.7.5.2. Bishop Methodu	17
2.7.5.3. Janbu Metodu	19
2.7.5.4. Spencer Metodu	20
2.7.5.5. Genelleştirilmiş Limit Denge Metodu	23
2.7.5.6. Fan, Frenlund ve Wilson Metodu	25
2.7.5.7. Lowe ve Karafiath Metodu	26
2.7.5.8. Corps of Engineers' Metodu	26
2.7.5.9. Morgenstern – Price Metodu	26
2.7.5.10. Sarma Metodu	27
2.7.6. Sonlu Elemanlar Analizi	27
2.7.7. Plastisite Çözümleri	29
2.7.8. Sonlu Farklar Çözümü	30
2.8. Makine Öğrenme Yöntemleri	31
2.8.1. Yapay Sinir Ağları	33
2.8.1.1. Yapay Nöron	33
2.8.1.2. Algi	34
2.8.1.3. Çok Katmanlı Yapay Sinir Ağı	34
2.8.1.4. Aktivasyon Fonksiyonları	35
2.8.1.5. Sigmoid Fonksiyonu	35
2.8.1.6. Geri Yayılım Mimarisi	36
2.9. Makine Öğrenme Yöntemleri İle Şev Stabilitesi Konusunda Önceki Çalışmalar	37

	Sayfa
3. MATERYAL ve YÖNTEM	45
3.1. Veri Setinin Oluşturulması	45
3.2. Kullanılan Yöntemler	50
3.2.1. Group Method of Data Handling (Grup Veri İşleme Yöntemi) (GMDH)	50
3.2.2. Ensemble GMDH Model (Topluluk Grup Veri İşleme Yöntemi)	52
3.2.3. Extreme Learning Machine (Aşırı Öğrenme Makinesi) (ELM)	53
3.2.4. Ensemble ELM (Topluluk Aşırı Öğrenme Makinesi) (EELM)	55
3.2.5. Performans Ölçütleri	57
4. BULGULAR	58
4.1. ELM ve GMDH Sonuçları	58
4.2. EELM ve EGMDH Sonuçları	62
5. TARTIŞMA ve SONUÇ	66
KAYNAKLAR	67
ÖZGEÇMİŞ	72



TABLÖLAR DİZİNİ

	Sayfa
Tablo 3.1. Çalışmada Kullanılan Veri Seti	45
Tablo 3.2. Parametrelere ait istatistiksel değerler	47
Tablo 4.1. Kullanılan modellere ait bilgiler	58
Tablo 4.2. GMDH ve ELM başarı oranları	59
Tablo 4.3. Veri seti ve GMDH – ELM ile tahmin edilen değerler	59
Tablo 4.4. EGMDH ve EELM başarı oranları	62
Tablo 4.5. Veri seti ve EGMDH – EELM ile tahmin edilen değerler	63
Tablo 5.1. Modellerin karşılaştırılması	66

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Heyelan hareketi türleri	6
Şekil 2.2. Blok analizinde ele alınan göçme yüzeyi	8
Şekil 2.3. Sonsuz şev ve kuvvet poligonu	9
Şekil 2.4. Sızma durumunda sonsuz şev ve kuvvet poligonu	10
Şekil 2.5. Düzlemsel kayma yüzeyi ve kuvvet poligonu	12
Şekil 2.6. Dairesel kayma yüzeyi	14
Şekil 2.7. Sürtünme dairesine ait gösterim	15
Şekil 2.8. Tek dilime etkiyen kuvvetler	17
Şekil 2.9. Dairesel yenilme yüzeyi ile tek dilime etkiyen kuvvetler	17
Şekil 2.10. İtme hattı pozisyonu	18
Şekil 2.11. Janbu'nun basitleştirilmiş yöntemi için düzeltme faktörü	20
Şekil 2.12. Spencer metoduna göre dilim üzerine etkiyen kuvvetler	21
Şekil 2.13. F_m ile F_f 'nin θ ile değişimi	23
Şekil 2.14. Farklı varsayımlarla $F(x)$ fonksiyonu	23
Şekil 2.15. Fan, Frenlund ve Wilson'a göre ampirik yanal kuvvet fonksiyonu	25
Şekil 2.16. Sınıflandırmaya örnek	32
Şekil 2.17. Doğrusal regresyon örneği	33
Şekil 2.18. Algı yapay sinir ağı mimarisi	34
Şekil 2.19. Çok katmanlı yapay sinir ağı mimarisi	34
Şekil 2.20. Normal sigmoid grafiksel gösterimi	35
Şekil 2.21. Gradyan iniş yöntemi	36
Şekil 3.1. Veri Setinde Şev Açısına göre veri sayısı	48
Şekil 3.2. Veri Setinde Şev Yüksekliğine göre veri sayısı	48
Şekil 3.3. Veri Setinde İçsel Sürtünme Açısına göre veri sayısı	48
Şekil 3.4. Veri Setinde Birim Hacim Ağırlığına göre veri sayısı	49
Şekil 3.5. Veri Setinde Kohezyona göre veri sayısı	49
Şekil 3.6. Veri Setinde Stabilite Durumuna göre veri sayısı	49
Şekil 3.7. GMDH ağı mimari yapısı	52
Şekil 3.8. EGMDH algoritması	53
Şekil 3.9. SLFN'nin mimari yapısı	55
Şekil 3.10. EELM algoritması	56
Şekil 4.1. GMDH ve ELM için karışıklık matrisleri	59
Şekil 4.2. EGMDH ve EELM için karışıklık matrisleri	63

KISALTMALAR ve SİMGELER

Kısaltma/Simg	Tanım
α	Dilim tabanının yatayla yaptığı açı
a	Şevin topuk ve tepe yakınlarında eğimin değiştiği yerleri belirten değişken
ANFIS	Uyarlamalı nöro bulanık çıkarım sistemi
AUC	Alıcı çalışma karakteristik eğrisi
b	Dilim genişliği
β	Eğim açısı
BDA	Bayes diskriminant analizi
BPNN	Geri yayılım sinir ağı
c	Kohezyon
c'	Efektif gerilme cinsinden zeminin drenajlı durumdaki kohezyonu
c _c	Arazideki zemin kohezyonu
c _{ort}	İyileştirilen zemin için ortalama kohezyon
c _m	Mobilize olmuş kohezyon değeri
c' _m	Efektif gerilmeler cinsinden mobilize olmuş kohezyon değeri
c _u	Drenajsız kayma mukavemeti
ΔX	Dilimin iki yüzündeki kesme kuvvetleri farkı
e	Hata kareler toplamı
E	Makine öğrenme yöntemlerinde rastgele hata terimi
E _n	Dilimler arası normal kuvvet
EGMDH	Topluluk grup veri işleme yöntemi
ELM	Aşırı öğrenme makinesi
EELM	Topluluk aşırı öğrenme makinesi
EO	Denge optimizasyonu
F _c	Kohezyona göre güvenlik katsayısı
F _s	Güvenlik katsayısı
GMDH	Grup veri işleme yöntemi
GSA	Yerçekimi arama algoritması
$\emptyset$	İçsel sürtünme açısı
$\emptyset'$	Efektif gerilmeler cinsinden içsel sürtünme açısı
$\emptyset_c$	Arazi zemininin içsel sürtünme açısı
$\emptyset_m$	Mobilize olmuş kayma mukavemeti açısı
$\emptyset'_m$	Efektif gerilmeler cinsinden mobilize olmuş kayma mukavemeti açısı
$\emptyset_u$	Zeminin drenajsız kayma mukavemeti açısı
$\emptyset_d$	Zeminin drenajlı kayma mukavemeti açısı
γ	Zeminin birim hacim ağırlığı
γ'	Zeminin su altındaki birim hacim ağırlığı
γ_c	Arazi zemininin birim hacim ağırlığı
γ_{sat}	Zeminin suya doymuş birim hacim ağırlığı
γ_w	Suyun birim hacim ağırlığı
H	Kayma yüzeyi yüksekliği
H _{crit}	Kritik şev tepe yüksekliği
h	Yüzeyden itibaren derinlik
HHO	Harris hawks optimizasyonu
ICA	Empyralist rekabet algoritması
K	Şevin orta noktasında kuvvet fonksiyonunun büyüklüğü
K _A	Aktif toprak basınç katsayısı
K _P	Pasif toprak basınç katsayısı
k _h	Yatay sismik etki
k _v	Düşey sismik etki
L	Kayma yüzeyi uzunluğu

Kısaltma/Simge	Tanım
L_{arc}	Kayma yüzeyini tanımlayan yayın uzunluğu
L_{chord}	Kayma yüzeyini tanımlayan kirişin uzunluğu
LEM	Limit denge yöntemi
LSSVM	En küçük kareler destek vektör makinesi
MAPE	Mutlak yüzde hatası
MLR	Çoklu doğrusal regresyon
MLPNN	Çok katmanlı algılayıcı sinir ağı
MR	Çoklu regresyon
n	Fonksiyon eğrilik değişkeni
N	Normal kuvvet
N'	Efektif normal gerilme
NMSE	Normalleştirilmiş ortalama kare hatası
θ	Kayma yüzeyinin yatay ile yaptığı açı
θ_{crit}	Kayma yüzeyi – yatay arası açının kritik değeri
θ_L	Dilimin solundaki dilimler arası kuvvetin yatayla yaptığı açı
θ_R	Dilimin sağındaki dilimler arası kuvvetin yatayla yaptığı açı
P_a	Kaymayı sağlayan aktif kuvvet
P_p	Kaymayı önleyen pasif kuvvet
R	Kritik daire yarıçapı
R_c	Kuvvetlerin bileşke noktasından merkeze dik uzaklık
R_f	Sürtünme dairesi yarıçapı
r_u	Boşluk suyu basıncı oranı
RMSE	Eğitim kök ortalama kare hatası
σ	Dilim tabanındaki gerilme
σ_n	Dilim tabanındaki normal gerilme
σ_v	Dilim tabanındaki düşey yönde gerilme
σ'_v	Düşey efektif gerilme
S	Sürtünme kuvveti
S_m	Mobilize sürtünme kuvveti
SVM	Destek vektör makinesi
T	Kesme kuvveti
TE	Deneme yanılma
τ_{base}	Dilim tabanındaki kayma gerilmesi
τ_c	Arazi zemininin kayma gerilmesi
τ_m	Mobilize kayma gerilmesi
U	Boşluk suyu basıncı
U_α	Boşluk suyu kuvveti
U_β	Yüzey suyu kuvveti
VSA	Girdap arama algoritması
W	Dilim ağırlığı
W	Makine öğrenme yöntemlerine kuadratik polinomun bilinmeyen ağırlık katsayılarının vektörü
w	Şev orta noktasına göre boyutsuz yer
WOA	Balina optimizasyon algoritması
X	Makine öğrenme yöntemlerinde bağımsız değişken
X_n	Dilimler arası kesme kuvveti
x	Kayan kütleinin kritik daire merkezine göre moment kolu
Y	Makine öğrenme yöntemlerinde bağımlı değişken
YSA	Yapay sinir ağı
Z_L	Dilimin sol kenarındaki dilimler arası kuvvet
Z_R	Dilimin sağ kenarındaki dilimler arası kuvvet

1. GİRİŞ

Gerek yapay gerekse de doğal nedenlerle belirli bir eğimde ve dengedeki kaya veya zemin kütlelerinin stabilitesinin bozularak hareket etmesi ile oluşan şev kayması dünyada ve ülkemizde sıklıkla görülen, yüksek olasılıkla can ve mal kaybıyla sonuçlanan bir olaydır. Şev stabilitesi ve heyelanlar; inşaat mühendisliğinde sürekli olarak güncelliğini her zaman koruyan önemli konulardan biridir [1]. Doğal ya da insan yapımı şevlerde, şev stabilitesinin analiz edilmesi, incelenen şevde herhangi bir düşme, kayma, kopma, akma gibi şev kaymasının gerçekleşip gerçekleşmeyeceği durumlar hakkında bilgi sahibi olmamızı sağlar.

Şev stabilite çalışmalarında mühendislik açısından en ekonomik ve güvenli çözüme ulaşabilmek için arazi ve laboratuvar araştırmaları önem taşımaktadır. Bununla birlikte şev stabilite analizlerinin çeşitli yöntemler ile yapılabiliyor olması ile birlikte günümüz teknolojileri de göz önüne alındığında bilgisayar destekli program ve uygulamalar ile de şev stabilitesi analizleri yapılabilmektedir.

Makine öğrenimi, veri ve algoritmalarından gelen kalıpların otomatik olarak tanınmasıyla ilgilenen bir bilgisayar bilimidir. Makinenin performansını artırmak için verilerden öğrenmek için çeşitli algoritmalar kullanılır ve bu algoritmalar verileri kullandıkça daha kesin modeller üretmek mümkün olur [2].

Modern dünyada, makine öğrenimi arama motorlarında, istenmeyen posta önleme yazılım sistemlerinde ve bilgisayar kodlarında, dijital kameralarda, akıllı telefonlarda, kaza müdahale sistemlerinde, biyoinformatik, tıp, fizik bilimi, bilgisayar mühendisliği gibi bilimsel uygulamalarda insanların hayatını kolaylaştırmak için kullanılmaktadır. Ayrıca psikoloji ve sinirbilimde istatistik, insan ve hayvan öğrenme metodolojileri de makine öğrenmesi ile yakından ilişkili alanlardır. Makine öğrenimi teknikleri, uzay aracı mühendisliği, örüntü tanıma, bilgisayarla görme, finansman, eğlence ve tıbbi uygulamalar gibi farklı alanlarda etkin bir şekilde uygulanmaktadır [3].

Tüm bu dalların yanı sıra makine öğrenme yöntemleri inşaat mühendisliğinde de yerini almıştır. Özellikle geoteknik alanda birçok karmaşık problemin çözümünde geçmişten günümüze kullanılmış ve güncel olarak da kullanılmaktadır [4-23]

Şev stabilite analizlerinde, ilerleyen teknoloji ve zamanın dünya konjonktüründeki önemi birlikte ele alındığında makine öğrenme yöntemlerinin kullanılması da hem zaman hem de işgücü tasarrufu sağlamaktadır.

Bu çalışmanın amacı, geleneksel şev stabilite analizlerine alternatif olarak, teknolojiyen faydalanan makine öğrenme yöntemlerinin şev stabilite analizlerinde kullanılması ile zaman ve işgücünden tasarruf sağlanmasının araştırılmasıdır. Bu amaç doğrultusunda çalışmada güncel makine öğrenme yöntemleri ile denemeler yapılmış ve şev stabilitesi için tahmin modelleri

geliştirilmiştir. Çalışma için hazırlanan veri setinde, farklı bölgelere ait 114 şev profilinin verileri ve vaka sonuçları kullanılmıştır. Çalışma sonucunda, kullanılan tüm makine öğrenme yöntemlerinin tahmin sonuçları karşılaştırmalı olarak verilmiştir.

2. KAYNAK ARAŞTIRMALARI

2.1. Genel Şev Stabilitesi Kavramları

Geoteknik mühendisliğinde şev stabilite analizlerinin evrimi, bir bütün olarak zemin ve kaya mekaniğindeki gelişmeleri yakından takip etmiştir. Şevler ya doğal olarak oluşur ya da insanlar tarafından oluşturulur. Tarih boyunca insanoğlunun veya doğanın doğal toprak şevlerinin hassas dengesini bozduğu zamanlarda şev stabilitesi sorunları ile karşılaşmıştır. Ayrıca, inşaat projelerinde tasarlanmış kesme ve dolgu şevlere yönelik artan talep, yalnızca şev stabilitesi problemlerini çözmek için analitik yöntemleri, araştırma araçlarını ve stabilizasyon yöntemlerini anlama ihtiyacını artırmıştır [24,27].

Jeoloji, hidroloji ve zemin özelliklerinin anlaşılması, şev stabilitesi ilkelerinin uygun şekilde uygulanmasının merkezinde yer alır. Analiz, saha yeraltı koşullarını, zemin davranışını ve uygulanan yükleri doğru bir şekilde temsil eden bir modele dayanmalıdır. Analizlerin sonuçlarını değerlendirmek için kabul edilebilir riskler veya güvenlik faktörü ile ilgili kararlar alınmalıdır [24].

2.2. Şev Stabilite Analizlerinin Amaçları

Çoğu uygulamada, şev stabilite analizinin birincil amacı, kazıların, toprak setlerin, toprak barajların, depolama sahalarının ve atık yığınlarının güvenli ve ekonomik tasarımına katkıda bulunmaktır [24].

Şev stabilitesi değerlendirmeleri, projeyi etkileyecek kritik jeolojik, malzeme, çevresel ve ekonomik parametreleri tanımlamanın yanı sıra potansiyel şev problemlerinin doğasını, büyüklüğünü ve sıklığını anlamakla ilgilenir.

Şev stabilite analizlerinin amaçları aşağıdaki şekilde açıklanabilir :

- Doğal yamaçların gelişimini ve biçimini ve farklı doğal özelliklerden sorumlu süreçleri anlamak.
- Kısa ve uzun vadeli koşullar altında şevin stabilitesini değerlendirmek.
- Doğal veya mühendislikle oluşturulmuş şevler üzerinde heyelan olasılığını değerlendirmek.

- Heyelanları analiz ederken yenilme mekanizmalarını ve çevresel faktörlerin etkisini anlamak.
- Yenilen şevlerin yeniden tasarlanmasını ve gerektiğinde önleyici ve iyileştirici tedbirlerin planlanmasını ve tasarlanmasını sağlamak.
- Sismik yüklerin şevler ve dolgular üzerindeki etkisini incelemek.

Şevlerin analizi, topografya, jeoloji ve malzeme özellikleriyle ilgili çeşitli faktörleri hesaba katar ve genellikle şevin doğal olarak oluşturulup oluşturulmadığı veya mühendislikle oluşturulup oluşturulmadığı ile ilgilidir [24,27].

2.3. Doğal Şevler

Uzun yıllar stabil olan doğal şevler, topografya, depremsellik, yeraltı suyu akışları, dayanım kaybı, stres değişiklikleri ve hava koşullarındaki değişiklikler nedeniyle aniden yenilebilir. Genel olarak, bu yenilmeler iyi anlaşılabilir çünkü bu yenilmeler ile ilgili çok az çalışma yapılır. Birçok durumda, doğal bir şevin stabilitesi hakkında önemli bir belirsizlik mevcuttur [24,27].

Doğal bir şevde eski kayma yüzeylerinin bulunduğunu bilmek şevin davranışını anlamayı ve tahmin etmeyi kolaylaştırır. Bu tür kayma yüzeyleri genellikle önceki heyelanlardan veya tektonik faaliyetlerden kaynaklanır. Bu kayma yüzeyleri boyunca kayma mukavemeti genellikle çok düşüktür, çünkü önceki hareket kayma direncinin doruğa çıkmasına ve kademeli olarak artık değerlere düşmesine neden olmuştur. Heyelan alanlarını tanımak her zaman kolay değildir. Bununla birlikte, ön-kesilmiş tabakalar yerleştirildikten sonra, kararlılık değerlendirmesi güvenle yapılabilir [24].

Doğal şevlerle ilgili problemlerde ilerleyici yenilmenin rolü, zaman geçtikçe daha fazla anlaşılmıştır. Progresif bozulma sergilemesi en muhtemel malzemeler, ayrışma ile kademeli olarak parçalanan kimyasal bağları işleyen killer ve şeyllerdir. Ayrışma, bu bağlarda depolanan enerjinin çoğunu serbest bırakır. Kil ve şeyl yamaçlarını ve dikişlerini içeren heyelanlarla ilgili anlayışımız, Bishop(1966), Bjerrum(1966) ve Skempton(1964)'ın orijinal çalışmaları sayesinde büyük ölçüde artmıştır [27].

2.4. Mühendislik Yöntemleri İle Oluşturulan Şevler

Mühendislik yöntemleri ile oluşturulan şevler; bentler, kazı şevleri ve istinat duvarları olarak üç ana kategoride değerlendirilebilir [24,26].

Sıkıştırılmış toprakları içeren bentler ve dolgulara; yol ve demiryolu setleri, çöp sahaları, toprak barajları ve setler örnek verilebilir. Bu yapılarda kullanılan malzemelerin mühendislik

özellikleri, ariyet kaynağı tane boyutu dağılımı, yapım yöntemleri ve sıkıştırma derecesi ile kontrol edilir. Bentleri ve dolguların stabilite analizleri, genellikle doğal şevler ve yamaçlar ile aynı zorlukları ve belirsizlikleri içermez, çünkü ariyet malzemeleri önceden seçilmiş ve işlenmiştir [24,26,27].

Sığ ve derin kazılar herhangi bir inşaat mühendisliği projesinde önemli yer tutmaktadır. Bir şev tasarımı amaç, ekonomik olan ve makul bir ömür boyunca sabit kalacak bir yükseklik ve eğim belirlemektir. Şev tasarımı; yapılacak kazı amacı, jeolojik özellikler, su basıncı, yapım yöntemi ile birlikte aşırı yağış, sel, donma, erozyon ve depremler gibi doğa olayları tarafından etkilenir. Genellikle geçiş hakkı ve mülkiyet sınırı kısıtlamaları nedeniyle dik kazılar gerekmektedir. Bu gibi durumlarda kazı şev tasarımı, ani yenilmeyi önleyecek ve şevi uzun vadede koruyacak önlemleri dikkate almalıdır. Bazı durumlarda, inşaatın sonundaki kazı şevi stabilitesi, kritik bir tasarım hususu olabilir. Bu durum tersi olarak, kazı şevinde, kısa vadede kararlı olmasına rağmen, uzun yıllar sonra çok fazla uyarı vermeden yenilme gerçekleşebilir.

İstinat yapıları, genellikle dengesiz toprak kütlelerini desteklemek için kullanılır. Ağırlık istinat duvarı, ankrajlı yada zemin çivili yapılar, iksa kazıklı yada palplanşlı yapılar ve geosentetik ve geogrid takviyeli duvarlar dahil mekanik olarak stabilize edilmiş setler gibi farklı istinat yapı türleri kullanılmaktadır. İstinat yapılarının tasarımı üç temel hususu gerektirmektedir. Bunlar; yapının arkasındaki ve altındaki toprağın dış stabilitesi, desteklenen dolgunun iç stabilitesi ve istinat duvarı elemanlarının yapısal mukavemetidir [24,27].

2.5. Heyelanlar

Doğal veya mühendislik yöntemi ile oluşturulmuş bir şevin eğim boyunca hareketine heyelan denir [24].

Kinematik olarak sınıflandırmada beş farklı heyelan hareketi türü vardır;

- Düşme
- Devrilme
- Kayma
- Yayılma
- Akma

Her heyelan türünün bir dizi ortak noktası vardır. Düşme ve devrilme, sıklıkla kaya şevleriyle ilişkilendirilen özellikler olup diğer üçü ise toprak şevleriyle ilgilidir [24].

Kayma, ağırlıklı olarak yırtılma yüzeylerinde veya nispeten ince yoğun kesme gerilmesi bölgelerinde meydana gelen bir toprak kütlelerinin eğim aşağı hareketidir. Hareket genellikle yerel bir yenilme alanından ilerler. Yer hareketinin ilk belirgin işaretleri, genellikle, kaymanın ana eğiminin oluşacağı orijinal zemin yüzeyindeki çatlaklardır. Kayma, öteleme, rotasyonel veya













her ikisinin bir kombinasyonu olarak oluşabilir ve buna bileşik kayma denir. Öteleme kaymaları genellikle, önceden var olan yenilme düzlemleri de dahil olmak üzere, belirgin süreksizlikler veya zayıflık düzlemleri boyunca hareketi içerir. Killi zeminlerde, özellikle bu zayıflık bölgelerinin mevcut eğime kabaca paralel olduğu yerlerde, doymun kum veya silt dikişleri boyunca öteleme kaymaları meydana gelir. Rotasyonel kaymalar, yukarı doğru içbükey olan ve genellikle sağlam bir zemin kütlesi içinde meydana gelen bir kırılma yüzeyine sahiptir. Rotasyonel şev yenilmeleri, en yaygın olarak, inşa edilmiş dolgularda ve dolgularda bulunanlar gibi nispeten homojen malzemelerde meydana gelir. Ek olarak, açılmış kayma döküntüsü doymun hale gelirse, çökmeler, öteleme slaytlarında olduğu gibi akışlara dönüşebilir [24].

Yayılma, kırık kütlenin daha yumuşak altta yatan malzemeye genel bir çökmesi ile birleştirilmiş bir toprak kütlesinin bir uzantısı olarak tanımlanır. Kırılma yüzeyi, yoğun bir kayma yüzeyi değildir. Yayılmalar, granül birikintilerin sıvılaşmasından veya bir eğimdeki zayıf kohezyonlu zeminlerin yenilmesinden kaynaklanabilir. Genellikle sığ yamaçlarda gerçekleşir [24,27].

Akma, kayma yüzeylerinin kısa ömürlü, yakın aralıklı ve genellikle korunmadığı uzamsal olarak sürekli bir harekettir. Yer değiştiren kütledeki hızların dağılımı, viskoz bir sıvınıninkine benzer. Yer değiştiren kütlenin alt sınırı, üzerinde fark edilebilir bir diferansiyel hareketin meydana geldiği bir yüzey olabilir veya kalın bir yayılı kesme bölgesi olabilir. Kaymalar, su içeriği, hareketlilik ve hareketin evrimindeki değişikliklerle kademeli olarak akışlara dönüşebilir. Yer değiştiren malzeme mukavemet kaybedip su kazandıkça veya daha dik eğimlerle karşılaştıkça, döküntü kaymaları hızlı döküntü akışları haline gelebilir [24].

2.6. Güvenlik Faktörü Kavramı

Şevlerin rasyonel tasarımında güvenlik faktörünün rolünün anlaşılması hayati önem taşımaktadır. Güvenlik faktörünün iyi bilinen bir işlevi, belirsizliği hesaba katmak ve böylece dayanım parametreleri, boşluk basıncı dağılımı ve stratigrafi gibi analize giren öğelerin güvenilirliği hakkında belirsizliğe karşı önlem almaktır. Genel olarak, saha araştırmasının kalitesi ne kadar düşükse, özellikle tasarımcının söz konusu malzemelerle sınırlı deneyimi varsa, istenen güvenlik faktörü o kadar yüksek olmalıdır. Güvenlik faktörünün bir başka rolü de, deformasyon stabilite performanslarının ekonomik kısıtlamalar dahilinde tolere edilebilir miktarlarla sınırlı olduğu ampirik bir araç oluşturmaktır. Bu şekilde, güvenlik faktörünün seçimi, belirli bir toprak kütlesi ile birikmiş deneyimlerden büyük ölçüde etkilenir. Alınabilecek risk derecesi de deneyimden büyük ölçüde etkilendiğinden, tasarımda kullanılan güvenlik faktörünün gerçek büyüklüğü malzeme tipine ve performans gereksinimlerine göre değişecektir [24].

Malzeme Hareketin Türü	KAYA	MOLOZ	ZEMİN
DÜŞMELER	 Kaya Düşmesi	 Moloz Düşmesi Scree Debris cone	 Toprak Düşmesi Colluvium Debris cone
DEVİLMELER	 Kaya Devrilmesi	 Moloz Devrilmesi Debris cone	 Taç Çatlakları Toprak Devrilmesi Debris cone
KAYMALAR	 Tek Dairesel Kayma	 Heyelan üstü Çoklu Dairesel Kayma Ayna Taç İkincil ayna	 Ardışık Dönel Kayma
	 Kaya Kayması (*)	 Moloz Kayması	 Toprak Kayması
YAYILMALAR	 Örnek: Bombelenme ve Vadi oluşumu		 Toprak yayılması
AKMALAR	 Kaya Akması Buzul moloz akması	 Moloz Akması	 Toprak Akması Çamur Akması
KARMAŞIK	 Kaya-Toprak akması ile kaya etek döküntüsü		 Örnek: Kompozit, dairesel olmayan, kısmen dönel/kısmen düzlemsel ve eteğe doğru toprak akması şeklinde

Şekil 2.1. Heyelan Hareketi Türleri [25]

Çoğu limit denge analizinde, sadece stabiliteyi korumak için potansiyel bir yenilme yüzeyi boyunca gerekli olan kesme mukavemeti hesaplanır ve daha sonra mevcut kesme mukavemetinin büyüklüğü ile karşılaştırılır. Bu durumda güvenlik faktörünün tüm yenilme yüzeyi için sabit olduğu varsayılır. Örneğin, üst eğimdeki A noktasında, bu ortalama güvenlik faktörü, mevcut olanın gerekli kesme mukavemetine oranı ile verilecektir. Böylece, potansiyel kaymaya direnmek için, yenilme yüzeyinin her noktasında sabit bir oranda mevcut mukavemet harekete geçirilir [24,26].

τ gerekli kesme mukavemeti ise, o zaman

$$\tau_{req} = \frac{s_u}{F} \text{ toplam stres için} \quad (1)$$

$$\tau_{req} = \frac{c'}{F_c} + \frac{\sigma' \tan \emptyset}{F_\emptyset} \text{ efektif stres için} \quad (2)$$

s_u = toplam stres kuvveti

c' ve $\emptyset'$ = efektif stres kuvvet parametreleri

F = toplam streslere göre güvenlik faktörü

F_c ve $F_\emptyset$ = efektif streslere göre güvenlik faktörü

F_c ve $F_\emptyset$ 'nin benimsenmesi, mukavemetin kohezyonlu ve sürtünmeli bileşenlerinin farklı oranlarının kırılma yüzeyi boyunca mobilize olmasına izin verir. Bununla birlikte, çoğu limit denge yöntemi, $F_c = F_\emptyset$ olarak varsayılır ve bu, c' ve $\emptyset'$ bileşenlerinin aynı oranının, kayma kırılma yüzeyi boyunca aynı anda harekete geçirildiğini ifade eder [24].


Güvenlik faktörünün sıklıkla dikkate alınan diğer bir tanımı, düzlemsel kırılma yüzeyleri için toplam direnç kuvvetlerinin toplam itme kuvvetlerine oranı veya dairesel kayma yüzeylerinde olduğu gibi toplam direncin itme momentlerine oranıdır. Bununla birlikte, üç yöntem kullanılarak elde edilen bu farklı güvenlik faktörü değerlerinin, yani mobilize edilmiş mukavemet, kuvvetler oranı veya momentlerin oranı, c - $\emptyset$ zeminler için aynı değerleri vermeyeceği bilinmelidir [27].

Tipik eğim tasarımları için gerekli güvenlik faktörleri (sismik olmayan durumlarda) genellikle 1,25 ila 1,5 aralığındadır. İlgili tasarım parametreleriyle ilgili yüksek bir yaşam kaybı riski veya belirsizlik varsa daha yüksek faktörler gerekebilir. Aynı şekilde, eğer mühendis giriş verilerinin doğruluğundan eminse ve inşaat yakından izleniyorsa, daha düşük bir güvenlik faktörü kullanılabilir [24].

2.7. Şev Stabilitesi Analiz Metotları

2.7.1. Blok Analizi

Dolgu zeminin şevin taban zemininden daha dayanımlı olması durumunda kayma olasılığına karşı güvenlik katsayısının hesaplanması için kullanılan yöntemlerdir. Bu durumlar hem dolgu zeminin kendi içerisinde geçen bir göçme yüzeyinden kayabileceği hem de taban zemininin içerisinde geçen bir göçme yüzeyinden kayma durumudur. İnce ve zayıf bir zemin tabakasında kayma yüzeyi büyük oranda düzlemsel olacaktır. Burada stabilize zayıf zemin tabanına kesme kuvveti uygulayan bir kayma bloğuna göre incelenir [26].



Şekil 2.2. Blok analizinde ele alınan göçme yüzeyi [24]

Şekil 2.2’de kayma yüzeyine bir örnek görülmektedir. Güvenlik katsayısı analizinde potansiyel kayma yüzeyi aktif, pasif ve merkez blok olarak 3 bloğa bölünmüş kabul edilir. Güvenlik katsayısı yatay kuvvetlerin dengesi ile hesaplanır [24,26].

$$F_s = \frac{P_p + c'_m L + (W - u) \tan \phi'_m}{P_a} \quad (3)$$

P_a : kayması sağlayan aktif kuvvet

P_p : kaymayı önleyen pasif kuvvet

L : kayma yüzeyinin kil tabakası boyunca uzunluğu

c'_m ve ϕ'_m : zemin mukavemet parametreleri (efektif ağırlığı $W-u$ olan)


Bu analiz yönteminde aktif ve pasif yan toprak basınçları;

$\sigma_{A/P} = K_{A/P} \sigma'_v \pm 2c_m \sqrt{K_{A/P}}$ formülü ile bulunur. Bu formülde aktif toprak basınç katsayısı K_A , pasif toprak basınç katsayısı K_P , düşey efektif gerilme σ'_v ve mobilize kohezyon değeri c_m olarak tanımlanır.

2.7.2. Sonsuz Şev Analizi

Nispeten uzun bir mesafe boyunca uzanan ve tutarlı bir zemin altı profiline sahip olan bir şev, sonsuz bir şev olarak analiz edilebilir. Bu durumda yenilme düzlemi şevin yüzeyine paraleldir ve limit denge yöntemi kolaylıkla uygulanabilir [24].

2.7.2.1. Kuru Kumda Sonsuz Şev Analizi



Şekil 2.3. Sonsuz şev ve kuvvet poligonu [26]

Serbest cisim diyagramı ile birlikte kuru kumdaki bir eğim için tipik bir dilim şekil 2.3'te gösterilmiştir.

Dilimin ağırlığı yanında normal, N ve harekete geçiren, T , kuvvetler tarafından verilir:

$$N = W \cos \beta \quad (4)$$

$$T = W \sin \beta \quad (5)$$

Yenilme düzlemi boyunca mevcut sürtünme kuvveti $\emptyset$ 'ya bağlı olacaktır ve şu şekilde verilir;

$$S = N \tan \emptyset \quad (6)$$


O halde, F_s 'yi kararlılığı korumak için gereken mevcut gücün oranı olarak düşünürsek, F_s şu şekilde verilecektir;

$$F = \frac{N \tan \phi}{W \sin \beta} = \frac{\tan \phi}{\tan \beta} \quad (7)$$

Güvenlik katsayısı, eğim yüksekliği ve derinliğinden bağımsızdır ve içsel sürtünme açısı (ϕ) ile eğim açısına (β) bağlıdır. Ayrıca $F=1$ 'de maksimum eğim açısı içsel sürtünme açısıyla sınırlı olacaktır.

2.7.2.2 Sızma Durumunda Sonsuz Şev Analizi

Eğer kohezyonlu zeminde doygun bir şev şekil 2.4'te gösterildiği gibi şev yüzeyine paralel bir sızıntıya sahipse, şimdi efektif normal kuvvete bağlı olacak olan güvenlik katsayısını belirlemek için aynı limit denge kavramları uygulanabilir [26].



Şekil 2.4. Sızma durumunda sonsuz şev ve kuvvet poligonu [26]

$$U = (\gamma_w h \cos^2 \beta) \frac{b}{\cos \beta} = \gamma_w b h \cos \beta \quad (8)$$

Yenilme düzlemi boyunca mevcut sürtünme kuvveti ϕ' ve etkin normal kuvvete bağlı olacaktır ve şu şekilde verilir;

$$S = c' b \sec \beta + (N - U) \tan \phi' \quad (9)$$

Bu doğrultuda güvenlik katsayısı;

$$FS = \frac{c' b \sec \beta + (N - U) \tan \phi'}{W \sin \beta} \quad (10)$$

$$W = \gamma_{sat} b h \text{ formülde yerine konduğunda;} \quad (11)$$

$$FS = \frac{c' + h(\gamma_{maks} - \gamma_w) \cos^2 \beta \tan \phi'}{\gamma_{sat} h \sin \beta \cos \beta} \quad (12)$$

$$\gamma' = (\gamma_{sat} - \gamma_w) \quad (13)$$

Kohezyonsuz zeminde sadeleşen denklem;

$$FS = \frac{\gamma' \tan \phi'}{\gamma_{sat} \tan \beta} \quad (14)$$

Denklemden, tanecikli bir malzeme için güvenlik katsayısının hala eğim yüksekliğinden ve derinliğinden bağımsız olduğu, ancak γ'/γ_{sat} faktörü tarafından azaltıldığı görülebilir. Tipik zeminler için bu azalmanın kuru eğimlere kıyasla yüzde 50 civarında olacağı görülmektedir.

Yukarıdaki analiz, sızıntı hattının yenilme yüzeyinin üzerinde bir yükseklikte yer aldığı varsayılırsa genelleştirilebilir. Bu durumda güvenlik katsayısı;


$$FS = \frac{c' + h \cos^2 \beta [(1-m)\gamma_m + m\gamma'] \tan \phi'}{h \sin \beta \cos \beta [(1-m)\gamma_m + m\gamma_{sat}]} \quad (15)$$

γ_{sat} ve γ_m sızıntı çizgisinin altındaki ve üstündeki toprağın doymuş ve nemli birim ağırlıklarıdır. Yukarıdaki denklem, herhangi bir sızıntı durumu ve bir $c'-\phi'$ zemin için yenilme yüzeyinin kritik derinliğini belirlemek üzere kolaylıkla yeniden formüle edilebilir.

2.7.3. Düzlemsel Yüzey Analizi

Düzlemsel yenilme yüzeyleri genellikle, üzerindeki malzemelere kıyasla nispeten düşük mukavemete sahip ince bir zemin tabakasına sahip şevlerde meydana gelir. Ayrıca bu, yapılan kazılara doğru dolabilecek derzli malzemeler için tercih edilen yenilme şeklidir [24,26].

Düzlemsel bir yenilme yüzeyi, yenilme düzlemi boyunca zeminin şev geometrisine ve kesme mukavemeti parametrelerine bağlı olan kapalı biçimli bir çözümle kolaylıkla analiz edilebilir. Şekil 2.5'te gösterilen eğim için, stabiliteyi değerlendirmek için üç kuvvetin - ağırlık, mobilize kesme kuvveti ve normal kuvveti - belirlenmesi gerekir [24].



Şekil 2.5. Düzlemsel kayma yüzeyi ve kuvvet poligonu [26]

Kamanın ağırlığı, aşağıdakiler kullanılarak geometriden belirlenebilir;

$$L = \frac{h}{\sin \beta} \frac{\sin(\beta - \alpha)}{\cos(\theta - \alpha)} \quad (16)$$

$$W = \frac{1}{2} \gamma H^2 \left[\frac{\sin(\beta - \theta) \sin(\beta - \alpha)}{\sin^2 \beta \sin(\theta - \alpha)} \right] \quad (17)$$

Yukarıdaki denklemdaki α açısı, yataya göre şev arkası eğimidir.

Normal kuvvet ve harekete geçirilmiş kayma kuvveti;

$$N = \frac{1}{2} W \cos \theta \quad (18)$$

$$S_m = W \sin \theta \quad (19)$$

Kohezyon ve sürtünmeye göre güvenlik katsayısı, F_c ve F_ϕ ile mobilize edilmiş kesme kuvveti ile kullanılarak oluşan denklemler;

$$c_m = \frac{c}{F_c} \quad (20)$$

$$\tan \phi_m = \frac{\tan \phi}{F_\phi} \quad (21)$$

Yukarıda yer alan denklemler, Mohr-Coulomb kriteri doğrultusunda bulunan mobilize kayma mukaveti ile eşitlendiğinde;

$$W \sin \theta = c_m L + W \cos \theta \tan \phi_m \quad (22)$$

$$c_m = \frac{W}{L} [\sin \theta - \cos \theta \tan \phi_m] \quad (23)$$

$$c_m = \frac{\gamma H^2}{2L} \left[\frac{\sin(\beta-\theta)}{\sin \beta \sin \theta} - [\sin \theta - \cos \theta \tan \phi_m] \right] \quad (24)$$

$$c_m = \frac{1}{2} \gamma H \left[\frac{\sin(\beta-\theta)[\sin \theta - \cos \theta \tan \phi_m]}{\sin \beta} \right] \quad (25)$$

γ , β ve H değerlerinin sabit olduğu varsayımı ile denklemin türevinin alınması durumunda θ 'nın kritik için aşağıdaki eşitlik ortaya çıkar;

$$\theta_{crit} = \frac{\beta + \phi_m}{2} \quad (26)$$

c_m 'nin kritik değer hesabı için denklem de;

$$c_m = \frac{1}{4} \gamma H \left[\frac{1 - \cos(\beta - \phi_m)}{\sin \beta (\cos \phi_m)} \right] \quad (27)$$

Kritik şev yüksekliği de;

$$H_{crit} = \frac{4c}{\gamma} \left[\frac{\sin \beta \cos \phi}{1 - \cos(\beta - \phi)} \right] \quad (28)$$

Tipik bir analiz için, prosedür, kohezyon ve sürtünme ile ilgili güvenlik faktörlerinin eşit olduğu bir $c-\phi$ zemini için bir deneme yanılma çözümü gerektirir. Bu genellikle aşağıdaki adımlar kullanılarak gerçekleştirilir [26]:


- Sürtünme direncine karşı F_ϕ varsayılır.
- ϕ_m değeri bulunur.
- Mobilize kohesif c_m hesaplanır.
- $F_c = c / c_m$ hesaplanır.
- F_c ile F_ϕ eşitleninceye kadar işlemler tekrarlanır.

2.7.4. Dairesel Yüzey Analizi

Homojen malzemelerden oluşan şevlerde dairesel yenilme yüzeylerinin en kritik parametre olduğu bulunmuştur. Bir şevin güvenlik katsayısının hesaplanması için kullanılabilecek dairesel yay yöntemi ve sürtünme çemberi yöntemi olmak üzere iki yöntem vardır [24].

2.7.4.1. Dairesel Yay Yöntemi ($\phi_u=0$)

En basit dairesel analiz, rijit, silindirik bir bloğun merkezi etrafında dönmesiyle göçeceği ve göçme yüzeyi boyunca kesme mukavemetinin drenajsız mukavemet ile tanımlandığı varsayımına dayanır. Drenajsız dayanım kullanıldığında, içsel sürtünme açısının, ϕ , sıfır olduğu varsayılır. Şekil 2.6'da da görüleceği üzere böyle bir şev için güvenlik katsayısı, dairesel yüzeyin merkezi etrafındaki direnç ve devrilme momentlerinin oranı alınarak analiz edilebilir [24].



Şekil 2.6. Dairesel kayma yüzeyi [24]

Devrilme ve direnç momentleri sırasıyla Wx ve $c_u LR$ tarafından verilirse, şev için güvenlik katsayısı şu şekilde verilebilir:

$$FS = \frac{c_u LR}{Wx} \quad (29)$$

Denklemde;

c_u : Drenajsız kesme kuvveti

R : Dairesel yüzeyin çapı

W : Kayan kütle ağırlığı

X : kayan kütlenin merkezi ile dairenin merkezi arasındaki yatay mesafe

Drenajsız kesme mukavemeti yenilme yüzeyi boyunca değişirse, $c_u L$ terimi değiştirilmeli ve yukarıdaki formülasyonda bir değişken olarak ele alınmalıdır.

2.7.4.2. Sürtünme Çemberi Yöntemi

Bu yöntem, kesme dayanımı normal gerilmeye bağlı olacak şekilde $\phi_u > 0$ olan homojen zeminler için kullanışlıdır. Diğer bir deyişle, kesme mukavemeti için hem kohezif hem de

geçirilen kohezyon kuvvetinin değerini elde etmek için kuvvet poligonu kapatılabilir. Yine, nihai güvenlik katsayısı, $F_0=F_c=FS$ varsayımıyla hesaplanır.

Çözüm prosedürü genellikle grafiksel olarak takip edilir, ancak doğrudan cevabı oluşturmak için oluşturulmuş birkaç sayısal şema vardır. Genel kullanım durumu için aşağıdaki modifiye edilmiş prosedür önerilir:

- Kayan kütlenin ağırlığını hesapla, W .
- Ortaya çıkan boşluk suyu kuvvetinin büyüklüğünü ve yönünü hesaplayın, U
- C_m 'nin hareket çizgisine dik mesafeyi hesaplayın
- W ve U kuvvetlerinden elde edilen efektif ağırlık bileşkesi W' ve bunun A noktasındaki C_m hareket çizgisiyle kesişimini bulun.
- Bir F_0 değeri varsayalım.
- Mobilize sürtünme açısını hesaplayın, $\phi_m = \tan^{-1}(\tan \phi / F_0)$
- $R_f = R \sin \phi_m$ yarıçaplı sürtünme çemberini çizin.
- Kuvvet poligonunu W' 'ya uygun şekilde eğimli ve A noktasından geçecek şekilde çizin.
- Sürtünme çemberine teğet olan P yönünü çizin.
- Dairesel kırılma yüzeyinin uç noktalarını birbirine bağlayan kirişin eğimine göre C_m yönünü çizin.
- Kapalı çokgen daha sonra C_m değerini sağlayacaktır.
- Bu C_m değerini kullanarak $F_c = c L_{chord} / C_m$ 'yi hesaplayın.
- 5-12 arası adımları $F_c \approx F_0$ olana kadar tekrarlayın

2.7.5. Dilim Metotları

2.7.5.1. Fellenius Metodu


Bu yöntem, herhangi bir dilim için, kenarlarına etki eden kuvvetlerin, kırılma yayına dik doğrultuda sıfır bileşkesine sahip olduğunu varsayar. Bu yöntem güvenli tarafta hatalara sahiptir, ancak erken kökenleri ve basitliği nedeniyle pratikte yaygın olarak kullanılmaktadır. Şekil 2.8'te görüleceği üzere dilimlere bölünmüş varsayılan dairesel yenilme yüzeyinin üzerindeki bölgeyi ve tüm kuvvetlerin etki ettiği tek bir dilimin serbest cisim diyagramını ve kuvvetlerin bilinmeyen uygulama noktalarını göstermektedir [26-28].

Çözüm elde etmek için çok fazla bilinmeyen olduğundan, 11 kuvvet ve konumları hakkında bazı varsayımlar yapılmalıdır. Dilimler arası kuvvetlerin (X_n ; E_n) eşit olduğu varsayılır ve her dilimin karşısındadır ve bu nedenle birbirlerini iptal ederler. Çemberin


merkezi etrafında momentler alarak ve yenilme yüzeyi boyunca her yerde harekete geçirilen τM kayma gerilimi miktarının mevcut toplam kayma geriliminin aynı fraksiyonu olduğunu varsayarak ($\tau M = (c' + \sigma' \cdot \tan \phi')/F$)

$$F_s = \frac{\sum [c' b \cdot \sec \alpha + (W \cdot \cos \alpha - u b \cdot \sec \alpha) \cdot \tan \phi']}{\sum W \cdot \sin \alpha} \quad (31)$$

c' etkin kohezyon, b dilim genişliği, α dilimin tabanının yataya olan açısı, W dilimin toplam ağırlığı, u dilimin tabanına etki eden su basıncı, ϕ' etkin sürtünme açısıdır ve toplam, tüm dilimler üzerinde bir toplama anlamına gelmektedir [26,27].



Şekil 2.8. Tek dilime etkiyen kuvvetler [27]



Şekil 2.9. Dairesel yenilme yüzeyi ile tek dilime etkiyen kuvvetler [27]

2.7.5.2 Bishop Metodu

Bu yöntem 1955 yılında Bishop tarafından geliştirilmiş ve Fellenius (1936) tarafından geliştirilen dilim yöntemi üzerine geliştirilmiştir. Yöntem, dikey dilimlerden oluştuğu düşünülen kütlelerin istatistiksel analizine dayanmaktadır. Her dilim için düşey doğrultudaki kuvvetlerin

dengesi sağlanır ve her dilim için deneme yayının merkez noktası etrafındaki momentlerin dengesi sağlanır. Deneme yayının üzerindeki tüm dilimlerden oluşan tüm toprak kütlesi için denge de sağlanır. Güvenlik faktörü, direnç momentlerinin toplamının, soruna neden olan momentlerin toplamına bölünmesiyle hesaplanır [28].

Matematiksel olarak doğru bir statik çözüm için, tüm dilimler için olduğu kadar her dilim için de kuvvet ve moment dengesi bulunmalıdır. Bishop'ın titiz formülasyonu, doğrudan bir çözüm sağlamak için çok fazla bilinmeyen içeriyor. Bazı bilinmeyen niceliklerin dağılımı ile ilgili bazı varsayımlar yapılmalıdır ve bu yöntem için X kuvvetinin dağılımı ile ilgili varsayımlar yapılır. Bu X kuvvetlerinin y_t itme hattının konumu (Şekil 2.10), her dilimin moment dengesi korunacak şekilde olmalıdır. Sarma'nın (1979) belirttiği gibi, Bishop dilimin tabanındaki normal kuvvetin etki noktasını dikkate almadı, böylece problem için başka bir bilinmeyen grubunu ortadan kaldırdı [28].


Bishop'un orijinal ve şimdi biraz tanıdık gösterimini kullanarak, kayma hatasına karşı güvenlik faktörü ifadesi şu şekilde ifade edilir:

$$F = \frac{\sum [c' \cdot b + (W - ub + \Delta X) \cdot \tan \phi' / m_\alpha]}{\sum W \cdot \sin \alpha} \quad (32)$$

$$\Delta X = X_n - X_{n+1} \quad (33)$$

$$m_\alpha = \cos \alpha \cdot \left(1 + \frac{\tan \alpha \cdot \tan \phi'}{F} \right) \quad (34)$$

c' etkin kohezyon, b dilim genişliği, α dilimin tabanının yataya olan açısı, W dilimin toplam ağırlığı, u dilimin tabanına etki eden su basıncı, φ' etkin sürtünme açısıdır ve toplam, tüm dilimler üzerinde bir toplama anlamına gelmektedir [28].



Şekil 2.10. İtme hattı pozisyonu [28]

2.7.5.3. Janbu Metodu

50'lerin ortalarından 70'lerin başlarına kadar, Janbu (1973) genelleştirilmiş ve basitleştirilmiş yöntemler geliştirdi [28].

Genelleştirilmiş yöntemde, bir itme çizgisi varsayılır ve denge denklemleri çözülür. Sarma (1979), son dilimin moment dengesi sağlanmadığı için bunun kesin bir çözüm olmadığına işaret etti; bunun, itme hattını etkilediğini ancak güvenlik faktörünü büyük ölçüde etkilemediğini belirtmiştir. Janbu (1973), emniyet faktörünün, makul olduğu sürece, itme hattının konumuyla ilgili varsayıma nispeten duyarsız olduğunu belirtmiştir. Janbu'ya (1973) göre kohezyonsuz zeminler için bindirme hattındaki dilim yüksekliğinin üçte birine yakın olması gerekir. Aktif bölgede bu seviyenin altında, kohezyonlu zeminlerde ise pasif bölgede bu seviyenin üzerinde olmalıdır. Bu yöntem bazen Bishop yöntemi gibi diğer yöntemlerle elde edilenlerden oldukça farklı cevaplar verir. Janbu'nun yöntemi, yalnızca kuvvet dengesinin sağlanmasına dayanır ve dilimler arası kesme kuvvetlerinin sıfır olduğunu varsayar ve moment dengesini sağlamaz. Bununla birlikte, basitleştirilmiş Janbu yöntemi, dikey kuvvet dengesini ve genel yatay kuvvet dengesini sağlar [28].

Her dilimin tabanındaki normal efektif gerilme aşağıdaki denklemlerle belirlenebilir:

$$N' = \frac{-U_\alpha \cos\alpha - S_m \sin\alpha + W(1 - k_v) + U_\beta \cos\beta + Q \cos\delta}{\cos\alpha} \quad (35)$$

Kayma kütlesi için genel yatay kuvvet dengesi aşağıdakilerden belirlenir;


$$\sum_{i=1}^n [F_H]_i = \sum_{i=1}^n [(N' + U_\alpha) \sin\alpha + W k_h + U_\beta \sin\beta] + \sum_{i=1}^n [Q \sin\delta - \frac{C + N' \tan\phi}{F} \cos\alpha] = 0 \quad (36)$$

Ardından Güvenlik Faktörü F aşağıdaki denklemle belirlenebilir:

$$F = \frac{\sum_{i=1}^n [C + N' \tan\phi] \cos\alpha}{\sum_{i=1}^n A_4 + N' \sin\alpha} \quad (37)$$

$$A_4 = U_\alpha \sin\alpha + W k_h + U_\beta + Q \sin\delta \quad (38)$$

Basitleştirilmiş Janbu Metodu, daha önce bahsedildiği gibi, kayma kütlesi için moment dengesini sağlamaz. Bu nedenle, Janbu daha titiz çözümler uyguladı ve sonucu kendi basitleştirilmiş yöntemini kullanarak bulunanlarla karşılaştırdı. Daha sonra, aşırı kararlı çözümünü düzeltmek için Şekil 2.11'da görüldüğü gibi aşağıdaki grafiği sundu [28].



Şekil 2.11 Janbu'nun basitleştirilmiş yöntemi için düzeltme faktörü [28]

$$F_{Janbu} = f_o * F_{calculated} \quad (39)$$

2.7.5.4. Spencer Metodu

Spencer tarafından bu yöntem 1967'de bir deneme kayma yüzeyinde yenilmeye karşı bir şevin güvenlik faktörünü belirlemek için geliştirilmiştir. Analiz efektif stres açılarından. İki denge denkleminde, kuvvet dengesi ve moment dengesine yol açar. Bishop yönteminde olduğu gibi kayma yüzeyindeki zemin kütlesi dikey dilimlere bölünür. Her bir dilimde, kuvvetlerin bileşkesi ve kuvvetlerin momentlerinin toplamı sıfır olmalıdır [28].

Güvenlik faktörü, dengeyi korumak için kayma yüzeyindeki mevcut toplam kesme mukavemeti S 'nin, harekete geçirilen toplam S_m gerilmesine oranı olarak tanımlanır [28].

$$F = \frac{S}{S_m} \quad (40)$$

Şekil 2.12'de kuvvetlerin etki ettiği bir dilim taslağı gösterilmektedir. Kuvvetler aşağıdaki gibidir:

Ağırlık, W_i

Toplam reaksiyon, P dilimin tabanına dik (etkili gerilmeden kaynaklanan P' kuvveti, boşluk basıncından dolayı $ub \cdot \sec \alpha$ kuvveti, u),

Böylece;

$$P = P' + ub \cdot \sec \alpha \quad (41)$$

Harekete geçirilmiş kesme kuvveti,


$$S_m = \frac{S}{F} \quad (42)$$

Böylece;

$$S = c'b \cdot \sec \alpha + P' \cdot \tan \phi' \quad (43)$$

$$S_m = \frac{c'b}{F} \sec \alpha + P' \frac{\tan \phi'}{F} \quad (44)$$

Dilim içi kuvvetleri, Z_n ve Z_{n+1} 'i; dengeden, bu iki kuvvetin bileşkesi Q , diğer üç kuvvetin kesişme noktasından geçmelidir.



Şekil 2.12. Spencer metoduna göre dilim üzerine etkiyen kuvvetler [28]

Şekil 2.12'de normal ve dilimin tabanına paralel olarak gösterilen kuvvetleri çözerek, sonraki dilim kuvvetlerinin ortaya çıkan Q_i 'si yazılabilir:

$$Q_i = \frac{\frac{c'b_i}{F} \sec \alpha_i + \frac{\tan \phi'}{F} (W_i \cos \alpha_i - u_i b_i \sec \alpha_i) - W_i \sin \alpha_i}{\cos(\alpha_i - \theta_i) [1 + \frac{\tan \phi'}{F} \tan(\alpha_i - \theta_i)]} \quad (45)$$

Tüm kütlelerin kuvvet dengesi için, dilimler arası kuvvetlerin hem yatay hem de dikey bileşenlerinin toplamı sıfır olmalıdır;

$$\sum Q_i \cos \theta_i = 0 \quad (46)$$

$$\sum Q_i \sin \theta_i = 0 \quad (47)$$

Ayrıca, moment dengesi için, dilimler arası kuvvetlerin merkez dönüş etrafındaki momentlerinin toplamı da sıfır olmalıdır.

$$\sum [Q_i R \cos(\alpha_i - \theta_i)] = 0 \quad (48)$$

Kayma yüzeyinin dairesel olduğu varsayıldığından,,

$$\sum [Q \cos(\alpha_i - \theta_i)] = 0 \quad (49)$$

Dilimler arası kuvvetlerin paralel olduğunu varsayarsak,

$$\sum Q = 0 \quad (50)$$

Spencer ayrıca F, Q ve θ 'yı çözmek için aşağıdaki prosedürü de tanımlamıştır;

Dairesel bir kayma yüzeyi keyfi olarak seçilir, kayma yüzeyinin içindeki alan eşit genişlikte dikey dilimlere bölünür. Her dilimin ortalama yüksekliği, h ve taban eğimi α grafiksel olarak belirlenir [28].


Birkaç θ değeri seçilir ve her biri için, her iki Denklem (49) ve (50)'yi sağlayan F değeri bulunur. Denklem (50) kullanılarak elde edilen F değeri F_f olarak adlandırılır ve Denklem (49) kullanılarak F_m olarak elde edilir. Moment dengesinden elde edilen ve sıfır alınan güvenlik faktörünün değeri F_m olarak gösterilir [28].

Elde edilen F_f değeri, θ 'ya karşı çizilir. Aynı grafikte, ikinci bir eğri F_m 'ye karşı olarak çizilir. Tipik bir grafik Şekil 2.13'te gösterilmiştir. İki eğrinin kesişimi, hem Denklem (49) hem de (50)'yi karşılayan güvenlik faktörü F'nin değerlerini verir. Dilimler arası kuvvetlerin karşılık gelen eğimi de elde edilir [28].

F ve θ değerleri daha sonra, dilimler arası kuvvetlerin bileşkesinin değerlerini elde etmek için Denklem (45)'te ikame edilir. Daha sonra ilk dilimden son dilime doğru çalışılarak dilimler arası kuvvetlerin değerleri elde edilir [28].

$F_m = F_f = FS$ durumu için gerekli (kritik) güvenlik faktörü elde edilir. Bu güvenlik faktörü $FS = 1,07$ ve dilimler arası kuvvet açısının karşılık gelen değeri $\theta = 22,50^\circ$ daha sonra tüm dilimler arası kuvvetleri ve bunların itme çizgisini belirlemek için kullanılabilir [28].


Spencer'ın yöntemi kullanılarak elde edilen güvenlik faktörü ile Bishop'un yöntemi arasındaki fark büyük değildir. Spencer (1968) tarafından iki yöntem arasındaki farkın %1'i aştığı belirtilmiştir [28].



Şekil 2.13. F_m ve F_f 'nin θ ile değişimi [27]

2.7.5.5. Genelleştirilmiş Limit Denge Metodu

Spencer(1973) metodunun Chugh(1986) tarafından genelleştirilmiş hali olan genelleştirilmiş limit denge metodu $\theta_i = \lambda f(x_i)$ fonksiyonu ile dilimin kuvvet açısını tanımlarken, $f(x_i)$ fonksiyonu 0-1 aralığında değer alır ve kuvvet dağılımının dilimler arası kuvvet açıları değişiminin tanımlanmasıdır. Değişik olasılıklara göre $f(x)$ fonksiyonunu Şekil 2.14'te gösterilmiştir [26].



Şekil 2.14. Farklı varsayımlarla $f(x)$ fonksiyonu [24]

Formülasyonun geliştirilmiş hali sürekli $f(x)$ fonksiyonunun özel bir durumudur. Formülasyon, bölünen her bir dilimde fonksiyonun her iki yanındaki değerleri, θ_R ve θ_L 'yi

hesaplamak için kullanılır. Böylece klasik bir dilimler arası bölge için $\theta_R = \lambda f(x)$ durumuna geçer, eşitlikteki x , dilimin sağ tarafının x -koordinatıdır. Bu dağılım genellikle göçme yüzeyinin yatay genişliğiyle normalize edilen bir fonksiyonla yerine konur. İlk dilimin solundaki (topuk) ve son dilimin sağındaki (tepe) dilimler arası kuvvet açısının “0” olduğu varsayılırsa yatay genişliğin ilk ve son dilimler arası sınır için değiştiği varsayılır [24,26].

Kuvvet Dengesi:

Genelleştirilmiş limit denge metodunda dilimler arası kuvvetler olan Z_L ve Z_R her bir dilimin sağ ve solunda yatayla θ_R ve θ_L açısı yaparlar. Her bir dilimin tabanına paralel kuvvet dengesi ele alınıp Mohr-Coulomb kriterleri kullanıldığında dilimlerin tabanına dik kuvvet dengesi şu şekilde ortaya çıkar [24,26]:

$$Z_R = A_8 Z_L [\cos(\alpha - \theta_L)] + \sin \tan \phi_m + A_8 [W \cos \alpha (1 - k_v)(\tan \phi_m - \tan \alpha) + C_m - U_\alpha \tan \phi_m - W k_h (1 + \tan \phi_m \tan \alpha) + \cos \alpha + U_\beta [\cos \alpha - \beta) \tan \phi_m - \sin(\alpha - \beta)] + Q[\cos(\alpha - \delta) \tan \phi_m - \sin(\alpha - \beta)]] \quad (51)$$

Denklemde;

$$A_s = \frac{1}{\cos(\alpha - \theta_R)[1 + \tan \phi_m \tan(\alpha - \theta_R)]} \quad (52)$$

α : dilim tabanının yatayla yaptığı açı

ϕ_m : mobilize olmuş kayma mukavemeti açısı

U_α : boşluk suyu kuvveti

U_β : yüzey suyu kuvveti

k_h : yatay sismik katsayı

k_v : düşey sismik katsayı

Moment Dengesi:

Tüm dilim kuvvetlerinin, dilim tabanının orta noktasına göre momentinin alınması moment denge koşulunu sağlar. Bulunan denge denklemi kullanıldığında dilimler arası kuvvetin yeri olan h_R bulunur;

$$h_R = \frac{Z_L}{Z_R \cos \theta_R} \left[h_L \cos \theta_L - \frac{b}{2} (\cos \theta_L \tan \alpha + \sin \theta_L) \right] + \frac{1}{Z_R \cos \theta_R} [h(U_\beta \sin \beta + Q \sin \delta) - h_c k_h W] + \frac{b}{2} [\tan \theta_R - \tan \alpha] \quad (53)$$

Kuvvet dengesi denkleminin dilimler arası kuvvetin yerini veren denklem ile beraber iterasyonu moment denge koşulunu verir. Güvenlik katsayısının belirlenmesine müteakip dilim tabanında toplam kayma, normal ve düşey gerilmeler için de aşağıdaki denklem kullanılır:

$$\sigma_n = \frac{1}{b \sec \alpha} \{Z_L \sin(\alpha - \theta_L) - Z_R \sin(\alpha - \theta_R) + U_\beta \cos(\alpha - \beta) - U_a + W[(1 - k_v) \cos \alpha - k_h \sin \alpha] + Q \cos(\alpha - \delta)\} \quad (54)$$

$$\sigma_v = \frac{W + Q \cos \delta + U_\beta \cos \beta}{b \sec \alpha} \quad (55)$$

$$\tau_{base} = c_m + \sigma' \tan \delta_m \quad (56)$$

2.7.5.6 Fan, Frendlund ve Wilson Metodu

Fan, Frendlund ve Wilson sonlu elemanlar analizini kullanarak bilinmeyen dilimler arası kuvvetleri yaklaşık olarak hesaplamış, aynı zamanda değişik geometrik şevlerde gerilme dağılımını belirlemişlerdir. Bu gerilmeler ile dilimi etkileyen kuvvetlerden kaymanın normale oranını hesaplayarak, bu oranın şev boyunca dağılımını gösteren fonksiyon sunmuşlardır [26].

$$f(x) = K^{((-a^n w^n)/2)} \quad (57)$$



K : şevin orta noktasında kuvvet fonksiyonunun büyüklüğü

a: şevin topuk ve tepe yakınlarında eğimin değiştiği yerleri belirten değişken

n: fonksiyon eğrilik değişkeni

w: şev orta noktasına göre boyutsuz nokta

K, a ve n değerleri halihazırda düzenlenmiş grafikler ile tespit edilebilmektedir. Şekil 2.15'de $f(x)$ 'in sonlu elemanlar analizinde yer alan kuvvetler oranlarına oranı görülmektedir.



Şekil 2.15. Fan, Frenlund ve Wilson'a göre ampirik yanal kuvvet fonksiyonu [27]**2.7.5.7. Lowe ve Karafiath Metodu**

Lowe ve Karafiath (1960) varsayımına göre dilimler arası kuvvetler taban zemini ve dilim tabanlarının ortalaması $\bar{\theta} = (\alpha + \beta)/2$ açısı ile eğimlidir. Varsayım doğrultusunda bilinmeyen parametre sayısı $(4n-1)$ 'e düşmekte ve n =denklem sayısı doğrultusunda moment dengesi kurulamamaktadır [26].

2.7.5.8. Corps of Engineers' Metodu

Varsayım Lowe and Karafiath varsayımına benzerlik göstermekte ve moment dengesinin kurulmadığı fazladan tanımlı bir sistem oluşturmaktadır. Metotta dilimler arası kuvvet yönü ile ilgili iki olasılık tanımlanır. Biri yüzeye paralel kuvvet yönleri, diğeri ise göçme yüzeyinin sağ ve sol kısımlarındaki şev açılarının ortalamasına eşitliğidir [26].

2.7.5.9. Morgenstern-Price Metodu

Bu belki de genelleştirilmiş yenilme yüzeylerini analiz etmek için geliştirilmiş en iyi bilinen ve en yaygın kullanılan yöntemdir. Yöntem ilk olarak Morgenstern ve Price (1965) tarafından tanımlanmıştır. Tüm statik denge gereksinimlerini karşılar ve bu nedenle titiz bir yöntemdir, ancak elde edilen çözümün kabul edilebilirliği kontrol edilmelidir. Genel problem, dilimler arası kesme kuvveti ile dilimler arası normal kuvvet arasında fonksiyonel bir ilişki olduğu varsayılarak belirlenir. İşlev $f(x)$ olarak adlandırılır ve yöntemi uygulayan çoğu program bu tür işlevlerin bir seçimini sağlar. Bu şekilde seçilen fonksiyon gerçekte problemi çıkmaza götürdüğü için, çözümün sağlanması için bir ölçekleme faktörünü belirlenmelidir, λ . $f(x)$ fonksiyonu, dilimler arası kuvvetlerin görelî eğimini tanımlarken, onların mutlak büyüklüğünü tanımlar. Böylece dilimin sol tarafındaki dilimler arası kuvvetler aşağıdaki denklemle ilişkilidir [26]:

$$X = \lambda \cdot f(x) \cdot E \quad (58)$$

Morgenstern ve Price (1965) tarafından önerilen çözüm prosedürü, problemin her dilim üzerine entegre edilen diferansiyel denklemler kullanılarak formüle edilmesi bakımından çoğu araştırmacı tarafından benimsenen prosedürden farklıdır. Morgenstern ve Price (1965) yöntemi, her dilimin tabanındaki normal kuvvetin dilimin merkezine etki ettiği varsayımını

yapmaz. Böylece dilim incelirken diğer yöntemlerin doğruluğu artar. Herhangi bir analizde makul sayıda dilim kabul edilmelidir [26].

2.7.5.10. Sarma Metodu

Sarma(1973)'nın geliştirdiği yöntemde esas şev güvenliğinin zemin kütlelerinin limit denge durumuna getirecek yatay ivmedir. Önerilen hesabın elle yapılması ve iterasyon gerektirmemesi diğer yöntemlerden ayırmaktadır. Kabul edilebilir bir güvenlik katsayısının bulunabilmesi için kayma mukavemetinin azaltılması ile 0 yatay ivmeye kadar iterasyon yapılması gerekmekte olup 3 iterasyon ile denge denklemi sağlanmaktadır [26].

2.7.6. Sonlu Elemanlar Analizi

Sonlu elemanlar yöntemi (FEM), şev stabilite analizi için güçlü bir alternatif yaklaşımı temsil eder. Bu yöntem doğru, çok yönlüdür ve özellikle arıza mekanizmasıyla ilgili olarak daha az varsayım gerektirir. FEM, düzensiz sınırlar ve potansiyel ve akış hatlarının karmaşık varyasyonları ile ilgili sorunları çözebilir. Analiz edilecek bölge, düğümlerde birleştirilen elemanlara bölünür. Her düğümdeki bilinmeyen yer değiştirmeler hesaplanabilir ve bunlardan gövde içindeki gerinim ve gerilim alanları bulunabilir [28].

Sonlu elemanlar yöntemi (FEM), uygulanan yüklerin neden olduğu yer değiştirmeleri ve gerilmeleri hesaplamak için kullanılabilir. Ancak, hesaplanan gerilimlerin ek işlenmesi olmadan genel güvenlik faktörü için bir değer sağlamaz. Tasarım için sonlu elemanlar yönteminin başlıca kullanımları şunlardır [28]:

- (1) Sonlu eleman analizleri, yer değiştirmelerin ve inşaat boşluk suyu basınçlarının tahminlerini sağlayabilir. Bunlar, inşaatın saha kontrolü için veya bitişik yapılara zarar verilmesi endişesi olduğunda faydalı olabilir. Sahada ölçülen yer değiştirmeler ve boşluk suyu basınçları hesaplananlardan büyük ölçüde farklıysa, farkın nedeni araştırılmalıdır [28].
- (2) Sonlu eleman analizleri, potansiyel ve muhtemelen karmaşık arıza mekanizmalarını gösterebilen yer değiştirme modeli sağlar. Limit denge analizlerinden elde edilen güvenlik faktörünün geçerliliği, kritik potansiyel kayma yüzeylerinin bulunmasına bağlıdır. Karmaşık koşullarda, özellikle jeotekstiller, beton istinat duvarları veya palplanşlar gibi donatı veya yapısal elemanlar dahil edildiğinde, yenilme modlarını tahmin etmek genellikle zordur. Potansiyel bir yenilme mekanizması tanındığında, bu mod tarafından gelişen bir kesme kırılmasına karşı güvenlik faktörü, geleneksel limit denge prosedürleri kullanılarak hesaplanabilir [28].

(3) Sonlu eleman analizleri, harekete geçirilmiş gerilmelerin ve kuvvetlerin tahminlerini sağlar. Sonlu elemanlar yöntemi, malzemelerin çok farklı gerilme-gerinim ve dayanım özelliklerine sahip olduğu, yani gerinim uyumluluğunun bir sorun olduğu durumlarda hangi dayanımların kullanılması gerektiğine karar vermede özellikle yararlı olabilir. FEM, "aşırı gerilmenin" meydana gelebileceği ve kırılgan ve gerinim yumuşatıcı malzemelerde çatlamaya neden olabileceği yerel bölgelerin belirlenmesine yardımcı olabilir. Ayrıca FEM, setlerde donatının nasıl tepki vereceğini belirlemede yardımcı olur. Sonlu eleman analizleri, yeni donatı türlerinin kullanıldığı veya donatının deneyimin var olduğu yollardan farklı şekillerde kullanıldığı alanlarda faydalı olabilir. Donatılı şevler için stabilite analizlerine önemli bir girdi, donatıdaki kuvvettir. FEM, kullanılacak kuvveti belirlemek için faydalı rehberlik sağlayabilir [28].

Güvenlik faktörlerini hesaplamak için sonlu eleman analizlerinin kullanılabilir. İstenirse, limit denge analizleri kullanılarak hesaplananlara eşdeğer güvenlik faktörleri, sonlu eleman analizlerinin sonuçlarından hesaplanabilir. Güvenlik faktörlerini hesaplamak için FEM'i kullanma prosedürü aşağıdaki gibidir [28]:

- (1) Şev için gerilmeleri belirlemek için FEM'i kullanarak bir analiz gerçekleştirin
- (2) Bir deneme kayma yüzeyi seçin
- (3) Kayma yüzeyini parçalara ayırın
- (4) Varsayılan bir kayma yüzeyi boyunca normal gerilmeleri ve kesme gerilmelerini hesaplayın. Bu, kayma yüzeyinde seçilen noktalarda değerler elde etmek için sonlu elemanlar ağında Gauss noktalarında hesaplanan değerlerden gerilim değerlerinin interpolasyonunu gerektirir. Efektif gerilme analizi yapılıyorsa, kayma yüzeyindeki efektif normal gerilmeleri belirlemek için boşluk basınçlarını çıkarın. Gerilmeleri ve deformasyonları hesaplamak için birleştirilmiş bir analiz yapıldıysa, boşluk basınçları aynı sonlu eleman analizinden belirlenir. Boşluk basınçları, gerilmeleri ve deformasyonları hesaplamak için kuplajsız bir analiz yapıldıysa, ayrı bir sürekli sızıntı analizinden belirlenir.
- (5) Kesme yüzeyi boyunca noktalarda mevcut kesme kuvvetini hesaplamak için normal gerilme ve kesme kuvveti parametreleri c ve ϕ veya c' ve ϕ' kullanın. Toplam gerilme analizi için toplam normal gerilmeler ve toplam gerilme kesme mukavemeti parametrelerini ve etkili gerilme analizleri için 24 efektif normal gerilmeler ve efektif gerilme kesme mukavemeti parametrelerini kullanın.
- (6) Aşağıdaki denklemi kullanarak genel bir güvenlik faktörünü hesaplayın:

$$F_s = \frac{\sum s_i \Delta l_i}{\sum \tau_i \Delta l_i} \quad (59)$$

$$\tau_f = c' + \sigma_n \tan \phi' \quad (60)$$

$$F_s = \frac{\tau_s}{\tau_n} \quad (61)$$

s_i =Adım (4)'te hesaplanan mevcut kesme mukavemeti

τ_i =Adım (3)'te hesaplanan kesme gerilimi

Δl =Kayma yüzeyinin alt bölümlere ayrıldığı her bir parçanın uzunluğu.

Denklemdaki toplamalar, kayma yüzeyinin alt bölümlere ayrıldığı tüm segmentler üzerinde gerçekleştirilir.

Sonlu eleman analizleri, limit denge analizleri ve malzemelerin gerilme-gerinim davranışı ile ilgili ek veriler için gerekenden çok daha fazla zaman ve çaba gerektirir. Bu nedenle, sonlu eleman analizlerinin kullanımı, yalnızca güvenlik faktörlerini hesaplama amacıyla doğrulanmaz [28].

Diğer bir yöntem ise, kayma dayanımını azaltma tekniğinin, şev stabilite analizinde sonlu elemanlar yöntemini kullanmak için yeni bir yöntem olması ve şevin yenilme mekanizmasının, kayma şekil değiştirmesinin gelişimi ile doğrudan ilişkili olduğu varsayılmasıdır. Bu yöntemde, geomalzemenin kesme dayanımı (c, ϕ) kesme dayanımı azaltma oranı F_s ile bölünür ve şevi getirmek için birincil kesme dayanımının yerine azaltılmış kesme dayanımını (c', ϕ') kullanır. Yenilmenin eşiğine gelindiğinde, kayma bölgesindeki gerinim veya yer değiştirme kırılacak ve bu tür kırılma, sonlu eleman kırılmasının yakınsamasına yol açacaktır. İndirgemenin ifadesi şu şekilde tanımlanabilir [28]:

$$c' = \frac{c}{F_s} \quad (62)$$

$$\phi' = \tan^{-1}(\tan \phi / F_s) \quad (63)$$

Burada, c ve ϕ , kesme mukavemeti parametreleridir, c' ve ϕ' , azaltılmış kesme mukavemeti parametreleridir, F_s , kesme mukavemeti azalma oranıdır. Hesaplama sırasında, kesme mukavemeti azaltma oranı, F_s , adım adım arttırılır ve ayrıca geomalzemenin kesme mukavemeti de değiştirilir. Yakınsama başarısız olduğunda, kayma mukavemeti oranı, F_s , şevin güvenlik faktörüdür ve plastik bölge şevin kayma yüzeyine karşılık gelir [28].

2.7.7. Plastisite Çözümleri

Plastisite teorisi şev davranışlarının belirlenmesi için kullanılan yöntemlerden biri olup Booker ve Davis(1972) tarafından kohezyonun şev derinliği ile lineer değişen bir şev için bu çözümü kullanmışlardır. Kullanılan çözümün bir başka yöntem olan kayma dairesi sonucu bulunan sonuçlar ile kıyaslandığında kayma dairesi yönteminde güvenlik katsayısının daha fazla olduğunu bulmuşlardır [26].

2.7.8. Sonlu Farklar Çözümü

Limit denge yöntemlerinin uygulanması, yenilme durumunda şevin stabilitesi hakkında bir fikir verir ve yenilme meydana gelmeden önce ve sonra şevin gerilme - şekil değiştirme geçmişi hakkında hiçbir bilgi vermez. Limit denge yöntemleri genellikle eğimin herhangi bir noktasındaki gerilim dengesini sağlamaz [26].

Herhangi bir zamanda, bu nedenle yöntemler ilerleyici başarısızlık mekanizmalarını modellemek için uygun değildir. Sonlu elemanlar ve fark yöntemleri, yenilme boyunca şevin deformasyonunu ve deformasyonların neden olduğu gerilmeyi modelleyebilir. Bu tür problemleri çözebilen bu yöntemlere dayalı bazı bilgisayar programları bulunmakta, ancak bu yöntemler hala analiz sonuçlarının yorumlanmasını gerektirmektedir. Bu yüzden de genel şev stabilite analizi için yaygın olarak kullanılmamıştır. Bununla birlikte, gelişmiş ile bilgisayar teknolojisi ve bu tür analizlerin sonuçlarının etkileşimli görselleştirilmesi, yöntemler kararlılık analizinde kullanılan genel yöntemler arasında yer almaktadır. Sonlu fark yöntemlerinin içeriği aşağıda verilmiştir [26].

Kesin çözümleri matematiksel olarak karmaşık ve bazı durumlarda imkansız olan birçok sınır değer probleminin yaklaşık çözümlerini elde etmek için yaygın olarak kullanılan sonlu farklar yöntemi, bir yapı sisteminin tepkisi genellikle ana diferansiyel denklemlerle temsil edilir. Bu denklemler, sonlu farklar yaklaşımı kullanılarak fonksiyonların türevlerini içerir, bu türevler ayrı noktalarda kolaylıkla değerlendirilebilir. Kısmi diferansiyel denklemler (PDE) daha sonra, verilen bazı sınır koşullarına göre etki alanında çözülebilir. Cundall (1976), şev stabilitesi problemlerine sonlu farklar yöntemlerinin nasıl uygulanabileceğine dair bir örnek vermiştir. [26].

Sonlu farklar yöntemi, bir fonksiyonun türevlerini belirlemek için yaklaşık bir yöntemdir. Koşullara bağlı olarak, sonlu farklar yöntemi kesin sonuçlar verebilir. Ancak, sıklıkla yalnızca yaklaşık sonuçlar verir. Bir fonksiyonun türevlerini bulmada sonlu farklar yönteminin kullanılmasındaki hatanın kapsamı, türev mertebesi, fonksiyonun türü, sonlu fark ağının türü gibi çeşitli faktörlere bağlıdır [26].

Bu yöntemin geleneksel yöntemlere göre aşağıdaki avantajları vardır: Hata modu doğal olarak gelişir, deneme yüzeyleri belirtmeye gerek yoktur; Girdi olarak herhangi bir parametre verilmesine gerek yoktur. Birden fazla arıza yüzeyi doğal olarak gelişir [26].

2.8. Makine Öğrenme Yöntemleri

Öğrenme, tanımlanması zor olan geniş bir süreç yelpazesidir. Makineler doğası gereği akıllı değildir, ancak makine öğrenimi, makinelerin akıllı yazılım kullanarak üst düzey performans göstermesini sağlar. Makine Öğrenimi, Dünya Sistemlerinin fiziksel modeline alternatif olarak kabul edilen istatistiksel bir yöntemdir ve makine öğrenimi terimi, verilerdeki anlamlı kalıpların otomatik olarak algılanması anlamına gelir [2].


Makine öğrenimi, veri ve algoritmalarından gelen kalıpların otomatik olarak tanınmasıyla ilgilenen bir bilgisayar bilimi dalıdır. Makinenin performansını artırmak için verilerden öğrenmek için çeşitli algoritmalar kullanılır ve bu algoritmalar verileri emdikçe daha kesin modeller üretmek mümkün olur. Makine öğrenimi ihtiyacına, problemin karmaşıklığı ve uyarlanabilirlik ihtiyacı olmak üzere iki açıdan yaklaşılır. Bir makine öğrenimi modeli, algoritma verilerle eğitildiğinde üretilen çıktıdır, ardından girdi sağlandığında, model, modeli eğiten verilere dayalı olarak bir çıktı üretir. Makine öğrenimi modelleri ile, büyük miktardaki örnek girdiler için doğru çıktılar üretmek üzere makinelerin iç yapıları ayarlanabilir, örneklerdeki ilişkiyi ortaya çıkarmak için girdi/çıktı fraksiyonunu sınırlamak, gizli ilişkiler ve büyük veriler arasındaki korelasyonlar çıkarılabilir, belirli görevler hakkında büyük miktarda bilgi elde edilebilir, değişen ortamlar nedeniyle sürekli yeniden tasarım ihtiyacı azaltılabilir ve görevler hakkında yeni bilgiler kolayca izlenebilir. Günümüzde problemlerin özelliklerine göre regresyon, sınıflandırma, kümeleme, kümelemesiz, sinir ağları vb. gibi çeşitli makine öğrenmesi algoritmaları vardır [2]

Modern dünyada makine öğrenimi birçok alanda ve disiplinde kullanılmaktadır. Bu durum sayesinde çeşitli araştırmacılar tarafından birçok tanım yapılmıştır. Tasarımlara ve tümevarım adımına bağlı olarak, bilgisayar çerçevelerinin belirli bir görevi başarılı bir şekilde yerine getirmek için kullandığı hesaplamaların ve olgusal modellerin mantıksal olarak düşünülmesi olarak tanımlanır. Makine öğrenimi, yapay zekanın bir alt kümesi olarak görülüyor [3].

Makine öğrenme yöntemleri denetimli ve denetimsiz yöntemler olarak ikiye ayrılmakta olup, denetimli öğrenme sınıflandırma ve regresyon, denetimsiz öğrenme ise kümeleme olarak tanımlanır [3].

Sınıflandırma, verileri farklı sınıflara ayırma stratejisidir. Sınıflandırma, ait olduğu verilerin kategorizasyonunu tahmin eder. Sınıflandırma, metin kategorizasyonu, doğal dil

işleme, bilişim, dolandırıcılık tespiti, yüz tanıma, pazarlama, optik karakter tanıma ile ilgilenir. Yapay sinir ağları, destek vektör makinesi, en yakın komşu algoritması, naif bayes ve rastgele orman algoritması popüler sınıflandırma algoritmalarıdır. Sınıflandırma, bilgisayarlı görme, ilaç keşfi ve geliştirme, jeostatik, konuşma tanıma, el yazısı tanıma, biyometrik tanımlama, biyolojik sınıflandırma, sinirsel dil işleme, belge sınıflandırma, arama motorları, banka kredi puanlama ve örüntü tanıma gibi birçok uygulama alanına uygulanabilir [3].



Şekil 2.16. Sınıflandırmaya örnek [27]

Şekil 2.16'da gösterildiği gibi, sınıflandırma örnekleri tahmin eder ve bu örnekleri birbirinden ayırmak ve her sınıfın kategorizasyonunu tanımlamak için sınıflandırır.

Regresyon, iki veya daha fazla değişken arasındaki doğrusal ilişkiye dayanır. Sınıflandırmadan farklı olarak, iki veya daha fazla değişken arasındaki ilişkiyi ölçmek için regresyon tahminleri sayısal çıktılarına dayanmaktadır. Analiz tek değişken kullanılarak yapılıyorsa tek değişkenli regresyon, birden fazla değişken kullanılıyorsa çok değişkenli regresyon analizi olarak adlandırılır [3].


$$Y_i = B_0 + B_1X_1 + E_1 \quad (64)$$

Yukarıdaki denklem, X'in bağımsız değişken, Y'nin bağımlı değişken, B₀'ın Y kesişim popülasyonunu, B₁'in popülasyon eğim katsayısını ve son olarak E'nin rastgele hata terimi olarak adlandırıldığı lineer regresyon modelini temsil eder. Bağımsız değişkenli popülasyon eğim katsayısı ve popülasyon y kesişim kısmı doğrusal bileşen olarak adlandırılır ve rastgele hata terimi kısmı rastgele hata bileşenini temsil eder [3].

$$Y = B_0 + B_1X_1 + B_2X_2 + \dots + B_nX_n + E_1 \quad (65)$$

Yukarıda denklem ise, X'lerin bağımsız değişkenler, Y'nin bağımlı değişken, E'nin rasgele hata terimi olarak adlandırıldığı çoklu doğrusal regresyon modelini temsil eder. Regresyon

analizinin amacı, modeldeki bilinmeyen parametreleri tahmin etmektir ve bu süreç, modeli verilere uydurma olarak da bilinir [3].



Şekil 2.17. Doğrusal regresyon örneği [27]

2.8.1. Yapay Sinir Ağları

Yapay Sinir Ağları, insan beyni aktivitesinin biyolojik doğası tarafından sisli bir şekilde modellenen bilgi işlem sistemleridir. Bu tür sistemler, tipik olarak herhangi bir göreve özgü kurallarla programlanmadan, örnekleri dikkate alarak görevleri gerçekleştirmeyi öğrenir. Yapay sinir ağları, insan beynindeki nöronlar gibi birbirine bağlı çeşitli yapay nöronlardan oluşur. Nöronlar arasındaki bağlantı sinapsları temsil eder ve sinyalleri birbirlerine iletebilir ve alabilir. Genel yaklaşımda düğümler arasındaki bağlantı ağırlıklı sayılardır ve her bir nöronun çıktısı, aktivasyon fonksiyonları ile hesaplanan YSA yapısındaki nöronların toplamı ile hesaplanır. Yapay sinir ağı yapısının uygulanmasının temel amacı, çeşitli problem türlerini çözmektir [3].

2.8.1.1. Yapay Nöron


Yapay bir nöron, yapay sinir ağlarının temel birimidir. Her düğümün, ağırlıklı girdiler üretebilen ve çıktıyı ağdaki diğer uçlara aktarabilen bir bağlantı noktası vardır. Biyolojik nöronlarda olduğu gibi, bir girdi alındığında, nöron bir sonraki katmandan geçen çıktıyı girdi olarak göndermeye karar verir. Çıkış sinyali göndermenin belirlenmesi, “önyargı” terimini temsil etmektedir. Genellikle önyargı, sistemin kullandığı aktivasyon fonksiyonu ile doğrudan ilişkilidir. Aşağıdaki denklem, nöronun önyargılı denklemini temsil etmektedir. Y , modelin çıktısını temsil eder. W_j ağırlık bağlantılarını temsil eder, X_j girdi değişkenlerini temsil eder [3].

W_0 , bir modeli daha genel hale getirmek için kesme değeridir; genellikle her zaman +1 olan ekstra bir sapma birimi olan W_0 'dan gelen ağırlık olarak modellenir [3].

$$Y = \sum_{j=1}^d w_j x_j + w_0 \quad (66)$$

2.8.1.2. Algı


Yapay sinir ağlarının en basit ortak dereceli en eski modeli olan algı, ikili tahminler için kullanılan doğrusal bir sınıflandırıcı olabilir. Bu, bilginin doğrusal olarak ayrıştırılabilir olması gerektiği anlamına gelir. Algılayıcı yapısıyla ilgili temel işlem mantığı, hem giriş ağırlık değişkenlerinin hem de bağlantı ağırlık değişkenlerinin çarpımına ilişkin toplam toplama değerlerine ulaşmaktır. Bir sonraki adım, toplam toplama değerlerine eşik değerleri eklemek ve çıktı değerlerine ulaşmak için bir aktivasyon fonksiyonu uygulamaktır [3].



Şekil 2.18. Algı Yapay Sinir Ağı Mimarisi [31]

2.8.1.3. Çok Katmanlı Yapay Sinir Ağı

Çok katmanlı yapay sinir ağı veya çok katmanlı algılayıcı, birbirine bağlı nöron dizilerini içeren organize bir katman sistemidir. Yapısal olarak yapay sinir ağları, giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç bölümden oluşur. Giriş katmanı, sonraki yapay nöron katmanları tarafından herhangi bir işlem için ilk bilgileri sisteme getirir. Gizli katman, değerlerin eğitimi ve öğrenilmesi ile ilgili operasyonel katmandır. Gizli katman, girdi katmanı nöronlarından ağırlıklı girdileri çıktı katmanı nöronlarına aktaran girdi katmanı ile çıktı katmanı arasındadır. Çıktı katmanı, ağ için verilen çıktıları üreten son nöron katmanıdır. Algıdan daha rafine olan Çok Katmanlı YSA, Evrişimli Sinir Ağı gibi, gizli katman(lar)ı nedeniyle birçok gelişmiş sınıflandırma ve regresyon görevini çözme yeteneğine sahiptir [3].




Şekil 2.19. Çok Katmanlı Yapay Sinir Ağı Mimarisi [3]

2.8.1.4. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, yapay nöronlara ait girdilerin ağırlıklı toplamına göre çıktı üreten fonksiyonlardır. Temel olarak, önyargı değerleri ekleyerek ağırlıklı bağlantılarla tüm çarpılan girdi değişkenlerinin sonuçlarını hesaplar; daha sonra, bu sonuç üzerinden doğrusal olmayan işlevi uygulamak ve bu değerleri 0 ile 1 arasında dönüştürür. Doğrusal olmayan fonksiyonun kullanılmasının temel nedeni, her birini türetebilecek türevlenebilir sonuçlar elde etmektir. Bu durum, problemin karmaşık davranışını öğrenmek için doğrusal olmayan hata gradyanını kolayca bulabilen ileri beslemeli sinir ağlarında geri yayılım optimizasyonu gerçekleştirirken önemli bir role sahiptir. Aktivasyon işlevleri, nöronların beyindeki birbirleriyle iletişim kurma şeklini kabaca modeller. Her düğüm etkinleştirilir ve düğüm belirli bir eşik değerine ulaştığında sinyal gönderir. Her katmanda aynı terminoloji ile ileri beslemeli uygulama fonksiyonu uygulanmakta ve tahminin belirlenmesi için çıktı son katmana ulaşana kadar sürekli olarak bir sonraki katmandan geçirilmektedir. Doğrusal olmayan problemleri çözmek için kullanılabilecek birkaç aktivasyon fonksiyonu vardır. En popüler aktivasyon fonksiyonları sigmoid, hiperbolik tanjant fonksiyonu ve doğrultulmuş lineer birim aktivasyon fonksiyonudur [3].

2.8.1.5. Sigmoid Fonksiyonu


Bir sigmoid fonksiyonu, karakteristik S şeklinde bir eğriye veya sigmoid eğriye sahip bir fonksiyon olabilir. Genellikle, sigmoid gerçekleştirme, bir girdi seti ile beslendiğinde sıfır ile bir arasında bir olasılık çıktıları koleksiyonu oluşturan tedarik fonksiyonunun özel durumunu ifade eder. Sigmoid aktivasyon gerçekleştirme, ikili sınıflandırmada yaygın olarak kullanılmaktadır [3].



Şekil 2.20. Normal Sigmoid Grafiksel Gösterimi [3]

2.8.1.6. Geri Yayılım Mimarisi

Geri yayılım, denetimli öğrenmenin istenen çıktılarına ulaşmak için yapay sinir ağı mimarisinde düğümleri eğitmek için kullanılan bir optimizasyon tekniğidir. Sinir ağının tahmin sonuçlarını düzeltmesine yardımcı olur ve her bir düğümün mutlak en iyi ağırlık değerlerini bulur. Geri yayılımın amacı, ağıdaki her bir bireysel ağırlığa göre hata fonksiyonunun kısmi türevlerini bulmaktır. Kısmi türevler, gradyan iniş fonksiyonu ile düğümler arasındaki ağırlıkları güncellemek için önemlidir. Gradyan iniş fonksiyonu, ağı her katmanı için hatayı hesaplar ve daha sonra bu hata değerlerini ağıdaki herhangi bir ağırlığa göre kısmi türev ile gerçek ilgi miktarıyla ilişkilendirir. Geri yayılım basitçe, ağıdaki tüm olası yollar boyunca hesapta zincir kuralının tekrar tekrar uygulanmasından oluşur. Çıktı katmanının hata değerlerini bulduktan sonra, gizli katmanlara ait nöronların hata değerlerini geriye doğru hesaplar. Daha sonra çıkış ve gizli katman bağlantıları arasında yeni ağırlıklı bağlantı değerleri atanır ve giriş katmanına ait nöronların hata değerlerini hesaplar ve tüm yeni ağırlıklı bağlantı değerlerini gizli katman ile giriş katmanı arasında atar [3].



Şekil 2.21. Gradyan İniş Yöntemi [3]

2.9. Makine Öğrenme Yöntemleri ile Şev Stabilitesi Konusunda Önceki Çalışmalar

Sah vd. (1994) çalışmasında şevlerin dairesel (kuru ve ıslak şevler için) ve kama (kuru şev için) yenilmesi için güvenlik faktörünün doğrudan tahmini için basit yeni ampirik denklemler önermiştir. 23 kuru (13 başarısız ve 10 kararlı) ve 23 ıslak (16 başarısız ve 7 kararlı) dairesel göçme vaka çalışmaları ve 14 kuru (8 başarısız ve 6 kararlı) kama arızası verisi toplanmıştır. Yeni denklemler tarafından tahmin edilen güvenlik faktörleri ile limit denge yöntemi kullanılarak elde edilenler arasında iyi bir uyum olduğunu göstermiştir [30].

Cao (2002) çalışması ile kohezyonlu ve kohezyonsuz zeminleri içeren şev stabilitesinin analizi için yarı analitik bir yöntem geliştirmiştir. Önerilen yöntem, dilimler yönteminin bir uzantısı olarak görülebilir, ancak bütünsel bir biçimde temsil edildikleri için kuvvetlerin daha doğru bir şekilde ele alınmasını sağlar. Asgari güvenlik faktörü, yaygın olarak kullanılan bir deneme yanılma yaklaşımı yerine Powell'ın optimizasyon tekniği kullanılarak elde edilir. Bu çalışmada geliştirilen önerilen yarı-analitik yöntemden elde edilen sonuçlar (güvenlik faktörü), Bishop yöntemi (1952) ve sonlu elemanlar yöntemi ile çözümlerle karşılaştırılmış ve tatmin edici anlaşmalar elde edilmiştir. Önerilen yöntem, Bishop yöntemi ve sonlu elemanlar yönteminden daha basittir. Ayrıca, geleneksel şev stabilize analiz yöntemleri kadar veya onlardan daha iyi olduğu bulunmuştur. Bu çalışmasında, şev stabilitesini modellemek için alternatif bir yaklaşım olarak bir yapay sinir ağı da tanıtmıştır. Önerilen sinir ağı modeli, sigmoid gizli katmana ve doğrusal çıkış katmanına sahip iki katmanlı bir tekrarlayan sinir ağıdır (RNN). Model, bu çalışma için toplanan 124 eğimden elde edilen veriler kullanılarak geliştirmiştir. Girdi değişkenleri, bir şev yenilmesine katkıda bulunan parametreleri içerir ve şev yüksekliğini, şev eğimini, su seviyesinin yüksekliğini, şev tepesindeki çekme çatlaklarının yüksekliğini, sağlam temelin derinliğini, yatay ve düşey sismik katsayılar, zeminin birim ağırlığı, zeminin kohezyonu, zeminin sürtünme açısı, her tabakanın kalınlığı ve boşluk suyu basıncının örtü basıncına oranı olarak tanımlanan boşluk suyu basıncı oranıdır. Çıkış katmanı, tek bir lineer nörondur - bir şevin güvenlik faktörü. Yapılan istatistiksel analizler, önerilen RNN modelinden elde edilen sonuçların, Bishop yöntemi ve önerilen yarı analitik yöntemden ziyade sonlu elemanlar yöntemine daha yakın olduğunu göstermiştir. Önerilen sinir ağı modeli, çıkış katmanında üç nöron, yani dairesel kayma yüzeyinin merkezinin koordinatları ve yarıçapı ile yeniden eğitilerek dairesel kayma yüzeylerini belirlemek için ayrı bir RNN modeli geliştirmiştir. Önerilen yarı analitik yöntemle karşılaştırıldığında, önerilen RNN modelinin katmanlı zeminler ve/veya boşluk suyu basınçları ile nispeten karmaşık şevleri temsil etmede daha etkili olduğunu bulmuştur [31].

Lu ve Rosenbaum (2003) çalışmasında şev stabilitesini etkileyen faktörler arasındaki etkileşimlerin karmaşık, çok faktörlü ve genellikle matematiksel olarak tanımlanmasının

zorluğunu, bunun da geleneksel yöntemlerle tahmin için bir zorluk oluşturduğunu belirtmiştir. YSA ve Gri Sistemler yaklaşımlarının gücünün, açık ilişkiler bilgisinden ziyade sistemin davranışını kullanmada yatmakta olduğunu açıklamıştır. Yayımlanmış verileri, şev stabilitesinin durumunu tahmin etmek için bu tekniklerin uygulanmasını göstermek için kullanmıştır. Bunu, jeoteknik özelliklere ve tarihsel davranışa dayalı olarak gelecekteki yer hareketini analiz etmek ve tahmin etmek için bir araç olarak geliştirmiştir [32].

Maccabiani ve Koelewijn (2004) çalışmasında Hollanda'nın büyük bir kısmı nehir setleri tarafından sel baskınlarına karşı korunduğunu ve bu setlerin güvenliğinin Bishop yöntemi gibi iki boyutlu modeller kullanılarak her beş yılda bir değerlendirildiğini belirtmiştir. Bu modellerin güvenilir olarak kabul edildiği, ancak su seviyesinin tasarım seviyesini geçme tehdidinde bulunduğu ve hızlı bir şekilde güvenlik tahmininin yapılması gerektiği durumlarda çok zaman alması dolayısıyla Bishop'un yöntemine yaklaşmak için bir yapay sinir ağı (YSA) modeli yapmıştır. YSA modelinde, açık parametreler kullanılmış ve büyük ölçekli senaryo çalışmaları, herhangi bir nehir suyu seviyesi için gerçek zamanlı şev stabilitesi, stabilizasyon setlerinin yinelemeli tasarımı veya hızlı set şev stabilite analizleri gerektiren diğer herhangi bir uygulama için oldukça otomatikleştirilmiş bir ortamda kullanılabildiğini göstermiştir [33].

Wang vd. (2005) çalışma konusu, Çin'in batı Hubei Eyaletinde yer alan Yudonghe heyelanı, doğu ve batı alt birimlerinin yanı sıra üst ve alt kayma yüzeylerine sahip ana heyelan kütesinden oluşmaktadır. Qing Nehri üzerindeki Shuibuya Barajı yakınında önemli bir heyelan olduğu için, Shuibuya Rezervuarının doldurulmasından kaynaklanan yeraltı suyu seviyesindeki bir değişiklik nedeniyle kayma yeniden etkinleşebileceğinden stabilitesinin çok önemli olduğunu tanımlamıştır. Mevcut zayıflık bölgeleri, kırılmaların büyümesi, jeolojik tabakaların yokuş aşağı tutumu ve kayaların ve toprakların gücünü azaltan su sızıntısının Yudonghe heyelanına katkıda bulunan en önemli faktörler olduğu tespit etmiştir. Heyelan süreçleriyle ilgili olarak, orijinal büyük ölçekli kayma aktivitesinin Qing Nehri'nin neden olduğu erozyondan kaynaklandığı, ikinci kaymanın baş uçurumundan blokların düşmesinden kaynaklandığı ve son aktivitenin büyüme olduğu not etmiştir. Şev kararsızlığını, Qing boyunca heyelan örneklerinden oluşan bir eğitim veri seti kullanarak beş giriş düğümü, iki gizli katman ve iki çıkış düğümü içeren dört katmanlı bir BPNN modeli oluşturarak Geri Yayılım Sinir Ağları (BPNN) yöntemiyle değerlendirmiştir. Bu analizin tahmin edilen sonuçları, güvenlik faktörünün 1.10 olduğunu göstermiş; bu, Yudonghe heyelanının şu anda marjinal olarak istikrarlı bir durumda olduğunu göstermiştir [8].

Sakellariou ve Ferentinou (2005) çalışmasında şev stabilite tahmini için girdi verileri olarak, jeoteknik ve geometrik girdi parametrelerinin değerlerini kullanmıştır. Bir çıktı olarak ağ, bir fonksiyon yaklaşım problemi olarak modellenebilen güvenlik faktörünü (FS) veya bir fonksiyon yaklaşım problemi veya bir sınıflandırma modeli olarak modellenebilen stabilite

durumunu (S) tahmin etmektedir. Ağın performansını ölçmüş ve sonuçları standart analitik yöntemlerle elde edilenlerle karşılaştırmıştır. Ayrıca, ağırlıkların paylaştırılması yöntemini kullanarak parametrelerin göreceli önemini incelemiş ve Endeks Bilgi Teorisi kullanılarak elde edilen sonuçlarla karşılaştırmıştır [7].

Li ve Liu (2005) çalışmasında veri madenciliğinin bu tür şev stabilite verilerinin arşivlerindeki anlamlı yapılara dikkat çekmiştir. Şev stabilitesi üzerinde önemli etkileri olan zemin mekanik özellikleri ve şev şekillerini, sinir ağlarını eğitmek ve test etmek için kullanmıştır. Doğrulama, şev stabilitesinin tahmini için olasılıksal sinir ağlarının etkinliğini göstermek için yapılmış, simülasyon sonuçları, olasılıksal sinir ağı modellerinin geleneksel doğrusal regresyon, limit denge yöntemi ve maksimum olabilirlik tahmininden daha yüksek tahmin kesinliği ürettiğini göstermiştir [34].

Tolon (2007) çalışmasında yapay zeka kullanarak şev stabilitesini incelemiş, bu teknik şevin stabilitesinde deprem etkisi ile sismik durumların irdelenmesine değişik bir pencere açmıştır. Çalışmasında 170 adet bölgeden şev profil verileri kullanılmış ve beş farklı yapay sinir ağı mimarisi kullanarak model oluşturmuştur. Amacı tüm modellerde sismik zemin katsayısı kullanılarak beklenen sismik etkinin önemiyetinin çıkarılmasıdır. Sonucunda %92,5 başarı yüzdesi ile düşey ve yatay sismik zemin katsayılarının şevin yüklüklüğünden, şevin eğiminden ve yer altı suyunun derinliğinden sonra şev stabilitesindeki etkisinin ne denli önemli olduğunu belirtmiştir [28].

Farrokhzad vd. (2008) çalışmasında belirli bir konumdaki şev stabilitesini tahmin etmek için yapay sinir ağları geliştirmiştir. Ardından sonuçları, YSA modelinin geçerliliğini kontrol etmek için eski analiz yöntemleriyle karşılaştırmıştır [35].

Ural ve Tolon (2008) çalışmada yapay zeka yaklaşımı kullanarak 170 adet şevi analiz etmiştir. Geri yayılım sinir ağı mimarisi, genel regresyon sinir ağı, grup veri işleme yöntemi, Kohonen öğrenme paradigması ve olasılıksal sinir ağı mimarileri dahil olmak üzere beş sinir ağı mimarisi kullanmıştır. Geri yayılım sinir ağı mimarisi ve genel regresyon sinir ağı, şev stabilite problemine daha iyi uygulanabilirlik gösterdiği belirtilmiştir. Analizde dokuz giriş parametresi ve bir çıkış parametresi kullanılmıştır. Çıkış parametresi şevlerin güvenlik faktörüdür, giriş parametreleri şev yüksekliği, şev eğimi, su seviyesinin yüksekliği, sağlam temelin derinliği, zeminin kohezyonu, zeminin sürtünme açısı, zeminin birim ağırlığıdır, ancak önemli girdi parametreleri yatay ve dikey sismik katsayılarıdır. Şev stabilite güvenliği için sismik katsayıların önemi sunulmuştur. Eğimin ve dinamik girdi parametrelerinin önemini değerlendirmek için bir duyarlılık çalışması yapılmıştır [36].

Zhou ve Chen (2009) çalışmasında şev stabilitesi tahminini etkileyen faktörlerin rastgeleliği ve belirsizliğine göre, doğrusal olmayan işlemenin iyi fonksiyonunun kullanımını ve

sinir ağının örüntü tanınmasını önermiş ve karşılık gelen sinir ağı modeli oluşturmuştur. Tahmin sonuçlarının, modelin yüksek tahmin isabetine sahip olduğunu belirtilmiştir [37].

Li ve Wang (2010) çalışmasında veri madenciliğinde yaygın olarak kullanılan yapay sinir ağı (YSA) ve destek vektör makinesi (SVM) yöntemlerini tanıtmakta, mühendislik uygulamalarında aralarındaki avantajı ve dezavantajları detaylı olarak tartışmaktadır. YSA ve SVM'ye dayalı iki tahmin modeli, şev stabilitesi ile ana etkileyen faktörler arasındaki doğrusal olmayan ilişkilerin sonlu ampirik verilerden elde edildiği, şev stabilitesi için ana faktörlerden türetmiştir. Sonuçlar maksimum olabilirlik tahmini ile detaylı olarak karşılaştırıldığında, sınırlı veri koşulunda DVM tahmin modelinin YSA modeline göre şev stabilitesi değerlendirmesinde daha avantajlı olduğu sonucuna varmıştır [38].

Erzin ve Çetin (2011) çalışmasında, deprem kuvvetlerine maruz kalan tipik bir yapay şevin kritik güvenlik faktörü (Fs) değerini tahmin etmek için Yapay Sinir Ağı (YSA) ve Çoklu Regresyon (MR) modellerinin geliştirilmesini ele almıştır. Bunu başarmak için, şevin geometrisi ve suni zeminin özellikleri sabit tutulurken, doğal zemin altı özellikleri, yani kohezyon, iç sürtünme açısı, zemin yüzeyinin altındaki katmanın toplu birim ağırlığı ve şev stabilite analizleri sırasında değişen sismik katsayı değişkendir. Daha sonra bu şevin Fs değerleri basitleştirilmiş Bishop yöntemi kullanılarak hesaplanmış ve her bir durum için minimum (kritik) Fs değeri belirlenerek YSA ve MR modellerinin geliştirilmesinde kullanmıştır. Modellerden elde edilen sonuçlar, hesaplamalardan elde edilenlerle karşılaştırmıştır. Ayrıca, geliştirilen modellerin tahmin kapasitesini kontrol etmek için belirleme katsayısı, varyans hesabı, ortalama mutlak hata ve ortalama karekök hata gibi çeşitli performans endeksleri hesaplamıştır. Elde edilen indeksler, YSA modelinin MR modelinden daha yüksek bir tahmin performansı gösterdiğini belirtmiştir [39].

Xioming ve Xibing (2011) yazısında Bayes diskriminant analizi teorisini kullanmış ve açık ocak şevinin stabilitesini tahmin etmek için bir yöntem sunmuştur. Açık ocak şevinin madencilik koşulları ve jeolojik koşullarını göz önünde bulundurarak, birim ağırlığın büyüklüğü, iç sürtünme açısı, kohezyon, şev açısı, şev yüksekliği ve boşluk basıncı oranı dahil olmak üzere açık ocak şevinin stabilitesini yansıtan altı faktör seçmiştir. Bir BDA modeli oluşturup, eğitim ve tahmin örnekleri olarak 33 adet açık ocak şevi örneği kullanmıştır. Her bir kolektivitenin önsel olasılığı, eğitim örneklerinin oranına göre elde edilerek ve modelin kararlılığını doğrulamak için yeniden ikame yöntemi de tanıtmıştır. Destek vektör makinesi (SVM) yöntemi ile karşılaştırıldığında, sonuçların bu Bayes diskriminant analiz modelinin mükemmel performans, yüksek tahmin doğruluğuna sahip olduğunu ve pratik mühendislikte kullanılabileceğini belirtmiştir [40].

Mohamed vd (2012) araştırmasının temel amacı, bulanık mantık, Uyarlamalı Nöro Bulanık Çıkarım Sistemi (ANFIS) ve istatistiksel yöntem olan Çoklu Doğrusal Regresyon (MLR)

kullanarak eğimin kararlılığını tahmin etmektir. Dört limit denge yöntemi (LEM), yani Morgenstern-Price, Janbu, Bishop ve Ordinary, çeşitli eğim tasarımları için güvenlik faktörlerini hesaplamak için kullanmıştır. Tahmin için, girdi olarak eğim yüksekliği, eğim malzemesinin birim ağırlığı, eğim açısı, kohezyon katsayısı ve iç sürtünme açısı gibi beş parametre kullanırken, çıktı parametreleri güvenlik faktörleridir. MLR, Bishop için 0.470, Janbu için 0.459, Morgenstern-Price için 0.470 ve Ordinary Method için 0.468 regresyon karesi (R^2) elde ederken, ANFIS, Bishop için 0.9996, Janbu için 0.9994, Morgenstern-Price için 0.9995 regresyon karesi (R^2) elde etmiştir. Sonuç, ANFIS'in MLR ile karşılaştırıldığında güvenlik faktörlerini yüksek doğrulukla tahmin edebileceğini göstermiştir [41].

Abdalla vd (2012) çalışmasında, Yapay Sinir Ağı (YSA) kullanarak killi zeminlerde şev yenilmesine karşı minimum Güvenlik Faktörünün (FS) tahmini için bir çalışma sunmuştur. İyi bilinen dört analitik yöntemle dayalı olarak minimum güvenlik faktörü oluşturmak için farklı geometrik ve kesme mukavemeti parametrelerine sahip toplam 640 veri seti kullanmıştır. Girdi verileri ve analizden elde edilen sonuçlar, minimum güvenlik faktörünü tahmin etmek için YSA modelini eğitmek ve test etmek için kullanılmıştır. ANN tahminlerinin, %2,49 Ortalama Mutlak Yüzde Hatası (MAPE) ile karşılık gelen analitik yöntemle hesaplanan FS'ye çok yakın olduğu ve rastgele seçilen test verilerinin %99'unun mutlak yüzde hatasının 10'dan az olduğunu gözlemlemiştir. Normalleştirilmiş Ortalama Kare Hatasını (NMSE) 0.01763 olarak bulmuş, böyle bir YSA modelinin, emniyet faktörünü tahmin etmek ve killi zeminin eğimlerinin stabilitesini değerlendirmek için güvenilir, basit ve geçerli bir hesaplama aracı olduğu sonucuna varmıştır [42].

Rashed (2014)'in yaptığı bu çalışma, Po Nehri boyunca nehir kıyılarının çeşitli nehir ve yeraltı suyu sınır koşulları altında stabilite analizi için tahmin modelleri oluşturmak için çok katmanlı yapay sinir ağı (YSA) algılayıcısını sunmaktadır. Bu amaçla, giriş parametrelerinin farklı kombinasyonları kullanılarak bir dizi eşik mantık birimi ağı test edilmiştir. Güvenlik faktörü (FS), şev stabilitesinin bir indeksi olarak, birkaç etkileyen geometrik ve jeoteknik parametre açısından formüle edilmiştir. Kapsamlı bir jeoteknik veri tabanı elde etmek için, çalışma sahasından çeşitli koni penetrasyon testleri yorumlanmıştır. Önerilen modeller, nehir setlerinin farklı temsili kesitleri üzerinde sonlu elemanlar kodu kullanılarak stabilite analizleri üzerine geliştirilmiştir. Geçerlilik doğrulaması için, kalibrasyon veri alanının ötesinde veritabanının bir bölümünün FS değerlerini tahmin etmek için ANN modelleri kullanılır. Sonuçlar, önerilen YSA modellerinin şev stabilitesini değerlendirmek için etkili araçlar olduğunu göstermektedir. YSA modelleri, türetilen çoklu doğrusal regresyon modellerinden belirgin şekilde daha iyi performans gösterdiği belirtilmiştir [43].

Qi ve Tang (2018) çalışmasında, sınıflandırıcı toplulukları ve genetik algoritmayı kullanarak şev stabilitesinin gelişmiş tahmini için bir hibrit topluluk yöntemini önermiştir.

Gauss süreç sınıflandırması, ikinci dereceden diskriminant analizi, destek vektör makinesi, yapay sinir ağları, uyarlanabilir artırılmış karar ağaçları ve k-en yakın komşular, bireysel AI teknikleri olarak seçildi ve kombinasyon yöntemi olarak ağırlıklı çoğunluk oylaması kullanmıştır. Doğrulama yöntemi 10 kat çapraz doğrulama olarak seçilmiştir ve performans ölçütleri doğruluk, alıcı çalışma karakteristik eğrisi ve alıcı çalışma karakteristik eğrisinin (AUC) altındaki alan olarak seçilmiştir. Hiperparametre ayarı ve ağırlık ayarı için sırasıyla grid arama ve genetik algoritma kullanılmıştır. Sonuçlar, önerilen hibrit topluluk yönteminin şev stabilitesinin tahminini geliştirmede büyük bir potansiyele sahip olduğunu göstermiştir. Bireysel sınıflandırıcılarla karşılaştırdığında, optimum grup sınıflandırıcı, test setinde en yüksek AUC değerini (0,943) ve en yüksek doğruluğu (0,902) elde ederek, tahmin performansının iyileştirildiğini göstermiştir. AUC değeri, doğruluk, gerçek pozitif oran ve gerçek negatif oran ile ilgili olarak şev stabilitesi tahmini için Youden's cutoff değerine sahip optimum grup sınıflandırıcısı önermiştir. Bu araştırması ile, ideal bireysel sınıflandırıcıları aramak yerine sınıflandırıcı topluluklarının kullanılmasının, şev stabilitesi tahmininde yardımcı olabileceğini göstermiştir [44].

Gao vd (2020) bu çalışmada, şev stabilite tasarım çizelgeleri problemi için emperyalist rekabet algoritması (ICA) ile yapay sinir ağını (YSA) optimize etmiştir. ANN ve ICA-ANN tahmin modelleri için eğitim ve test veri kümeleri hazırlamak için çok sayıda limit denge analizi modellemesi (örneğin, alt sınır, LB, limit analizi ve üst sınır, UB, limit analizi için) yapmıştır. Analizleri OptumG2 bilgisayar yazılımı kullanarak yapmış ve iki katmanlı kohezyonlu zemin katman setleri üzerinde uygulamıştır. LB ve UB limit analizinin her biri için, veritabanı 320 eğitim veri setinden ve 80 test veri setinden oluşmuştur. Bu, kohezyonlu zeminlerin şev stabilitesi davranışlarını tahmin etmede ICA-ANN modelinin daha iyi bir performansını ve dolayısıyla burada sağlanan daha güvenilir tasarım çözümü çizelgelerini kanıtlamıştır [45].

Foong ve Moayedı (2021) çalışmada, tek katmanlı bir toprak eğiminin güvenlik faktörünü tahmin etmek için kullanılan çok katmanlı algılayıcı sinir ağını (MLPNN) optimize etmek için denge optimizasyonu (EO) ve girdap arama algoritmasının (VSA) kullanımını önermiştir. Normal MLPNN'nin yanı sıra iki hibrit model, sonlu eleman simülasyonlarından elde edilen toplam 630 veriyle beslenmiştir. Sonuçlar öncelikle yapay zekanın bu alanda uygulanabilirliğini göstermiştir. Daha sonra, MLPNN'nin (EO ve VSA tarafından sırasıyla 0,4715'ten 0,3891 ve 0,4383'e) eğitim kök ortalama kare hatasını (RMSE) azaltarak, bu modelin hesaplama zayıflıklarının giderilmesinde kullanılan algoritmaların etkinliğini ortaya çıkarmıştır. Ayrıca, RMSE testi 0,5397'den 0,4129 ve 0,5155'e düşmüş, bu da hibrit modellerin daha yüksek bir genelleme kabiliyetine işaret etmiştir. Ayrıca, EO tabanlı topluluğun daha yüksek doğruluğu nedeniyle, bu algoritma MLPNN'yi optimize etmede VSA'dan daha iyi performans gösterdiğini belirtmiştir [46].

Luo vd (2021) açık ocak madenlerinde şev stabilitesini analiz etmek ve değerlendirmek için yeni bir yapay zeka modeli geliştirmeyi amaçlamıştır. Aslında, şev stabilitesinde güvenlik faktörünü (FS) tahmin etmek için evrimsel bir yöntemle (yani PSO) kübist algoritmanın optimizasyonuna dayanan yeni bir hibrit akıllı teknik, yani PSO CA tekniği geliştirilmiştir. Bir taş ocağı madeninin (Vietnam) FS'si için Geostudio yazılımından 450 simülasyon bu amaç için veri setleri olarak kullanılmıştır. Bu çalışmada FS'yi tahmin etmek için girdi değişkenleri olarak sıra yüksekliği, eğim açısı, iç sürtünme açısı, kohezyon ve birim ağırlığı içeren beş faktör kullanmıştır. Önerilen PSO-CA tekniğinin şev stabilite analizindeki performansını netleştirmek için SVM, CART ve kNN modelleri de geliştirmiş ve değerlendirmiştir. Tahmine dayalı modellerin doğruluğunu değerlendirmek için ortalama mutlak hata (MAE), ortalama kare hata (RMSE) ve belirleme katsayısı (R^2) gibi üç performans indeksi hesaplamıştır. Sonuçlarda, önerilen PSO-CA tekniğinin, şev stabilitesini tahmin etmede 0.009 MAE, 0.025 RMSE ve 0.981 R^2 ile en baskın doğruluk olduğunu netleştirmiştir. Kalan modeller (yani, SVM, CART, kNN), MAE ile 0.014 ila 0.038, RMSE 0.030-0.056 ve R^2 0.917-0.974 arasında daha düşük performans elde etmiştir [47].

Moayedi (2021) temel amacı olarak, katı temellerin varlığında güvenlik faktörünü tahmin etmede geleneksel çok katmanlı algılayıcı tekniğinin doğruluğunu artırmak için Harris hawks optimizasyonu (HHO) adlı yeni bir metasezgisel optimizasyonu tanıtmıştır. Bu şekilde şev açısı, rijit temelin konumu, zeminin mukavemeti ve uygulanan sürşarj olmak üzere dört şev stabilitesi koşullandırma faktörü göz önünde bulundurulmuştur. Dikkat çekici bir şekilde, bu algoritmanın şev stabilitesi sorununa ana katkısı, bu koşullandırma faktörlerinin hesaplama ağırlıklarının ayarlanmasında yatmıştır. Sonuçlar, HHO kullanmanın, görünmeyen koşullara sahip eğimleri analiz etmek için YSA'nın tahmin doğruluğunu arttırdığını göstermiştir. Bu bağlamda, ortalama karekök hata ve ortalama mutlak hata kriterlerinin sırasıyla %20,47 ve %26,97 oranında azaltılmasına yol açmıştır. Ayrıca, güvenlik faktörünün gerçek değerleri ile HHO-ANN çıktıları arasındaki korelasyon ($R^2 = 0.9253$) ANN'den ($R^2 = 0.8220$) daha anlamlı olup son olarak, benzer uygulamalar için kullanılmak üzere HHO tabanlı bir tahmin formülü de sunmuştur [48].

Zeng vd (2021) çalışmanın amacı olarak, optimizasyon algoritmaları ile geliştirilmiş makine öğrenmesi yöntemleri ile eğimlerin SF'sini tahmin etmek için gelişmiş ve doğru modeller sunmuştur. Bu görüşe göre, en küçük kareler destek vektör makinesi (LSSVM) yönteminin uygun kontrol parametrelerini araştırmak için deneme yanılma (TE) yöntemi, yerçekimi arama algoritması (GSA) ve balina optimizasyon algoritması (WOA) olmak üzere üç farklı yöntem kullanmıştır. Oluşturulan LSSVM-TE, LSSVM-GSA ve LSSVM-WOA yöntemlerinde, giriş parametreleri olarak boşluk basıncı oranı ve iç sürtünme açısı gibi SF üzerinde etkili olan altı parametre kullanılmıştır. Hata kriterlerinin sonuçları, hem GSA hem de WOA'nın, SF'yi

tahmin etmede LSSVM yönteminin performans tahminini iyileştirebileceğini göstermiştir. Bununla birlikte, 0,141 ortalama karekök hatasıyla LSSVM-WOA yöntemi, 0,170 ortalama karekök hatasıyla LSSVM-GSA'dan daha iyi performans gösterdiğini belirtmiştir [49].

Zhang vd (2021) çalışmasında İngiltere, İtalya, Yeni Zelanda, Endonezya, Venezuela, ABD ve Japonya'dan veri setleri dahil olmak üzere, şev stabilitesini veya heyelan duyarlılık haritalamasını değerlendirmek için farklı alanlardan/konumlardan killerin sürtünme açısını tahmin etmek için yeni bir geliştirilmiş yapay zeka modeli önermiştir. Modelin tahmininin sağlamlığı ve tutarlılığı, farklı jeolojik ve jeomorfolojik kurulumlara sahip çeşitli veri setleri ile test edilerek kontrol edilmiştir. Buna göre, bu amaçla çalışmaya esas konum ve bölgelerden farklı alanlardan/konumlardan 162 gözlem toplamıştır. Ardından, MLP modelinin hatalarını azaltmak amacıyla çok katmanlı algılayıcı (MLP) sinir ağı modelini (yani DMLP modelini) geliştirmek için derin öğrenme teknikleri uygulamıştır. Daha sonra, HHO-DMLP modeli olarak adlandırılan DMLP modelinden daha iyi bir doğruluk elde etmeyi amaçlayan killerin sürtünme açısını tahmin etmek için DMLP modelinin optimizasyonunu artırmak için Harris Hawks optimizasyonu (HHO) algoritması uygulamıştır. Önerilen HHO-DMLP modeliyle karşılaştırmak için HHO algoritması ve diğer iki geleneksel model (yani, SVM ve RF) optimizasyonu olmayan bir DMLP sinir ağı da kullanılmıştır. Sonuçlar, önerilen HHO-DMLP modelinin killerin sürtünme açısını diğer modellerden daha iyi tahmin ettiğini göstermiştir. Killerin sürtünme açısını farklı konum ve bölgelerden kabul edilebilir doğrulukla yansıtabilmiştir (yani, MSE = 12.042; RMSE = 3.470; R2 = 0.796; MAPE = 0.182; ve VAF = 78.806). HHO algoritmasının optimizasyonu olmadan DMLP modeli biraz daha düşük doğruluk sağlamıştır (yani, MSE = 15.151; RMSE = 3.892; R2 = 0.738; MAPE = 0.202; ve VAF = 73.431). Ayrıca, diğer iki geleneksel model (yani, SVM ve RF) düşük güvenilirlik sağlamıştır, özellikle RF modelinde aşırı uydurma meydana gelmiştir ve killerin sürtünme açısını tahmin etmek için kullanılması tavsiye edilmemiştir (yani, RMSE = 6.325 ve R2). = eğitim veri kümesinde 0.377, ancak test veri kümesinde RMSE = 1.669 ve R2 = 0.961) [50].

3. MATERYAL ve YÖNTEM

3.1. Veri Setinin Oluşturulması

Bu çalışmada farklı bölgelerden oluşan ve şevlerin stabil olup olmadığına ait sonuçların bulunduğu 114 adet şev profil verileri kullanılmıştır (Tablo 3.1.). Bu verilerden 8 adet şev profil verisi Lu ve Rosenbaum (2003) [32]'un çalışmasından, 46 adet şev profili Sah vd. (1994) [30]'nin çalışmasından, 32 adet şev profil verisi Xiaoming ve Xibing (2011) [40]'in çalışmasından ve 28 adet şev profil verisi de Zhou ve Chen (2009) [37]'in çalışmasından alınmıştır. Girdi verileri olarak şevin yüksekliği (m), şev açısı (α), zeminin içsel sürtünme açısı (ϕ), zeminin birim hacim ağırlığı (γ) ve kohezyon (c) çalışmada kullanılan makine öğrenme yöntemleri ile çıktı verisi olarak şevin stabilite durumu kullanılmıştır. Veri setinde yer alan parametrelere ait istatistiksel değerler Tablo 3.2.'de gösterilmiştir. Bununla birlikte veri setinde yer alan parametrelerin veri seti içerisindeki dağılımlarının yer aldığı histogram grafikleri Şekil 3.1., Şekil 3.2., Şekil 3.3., Şekil 3.4., Şekil 3.5. ve Şekil 3.6.'da gösterilmiştir.

Çalışmada kullanılan veri setinde yer alan şev profillerinden 91 adet şev profilinde yer altı suyu bulunmakta olup, 23 adet şev profilinde yer altı suyu bulunmamaktadır. Yer altı suyu bulunmayan 23 adet şev profili Sah (1994) [30]'ın çalışmasından alınan verilerdir.

Tablo 3.1. Çalışmada Kullanılan Veri Seti

No	Şev Yüksekliği (m)	Şev Açısı ($^{\circ}$)	İçsel Sürtünme Açısı ϕ ($^{\circ}$)	Birim Hacim Ağırlık γ (Kn/m ³)	Kohezyon c (Kpa)	Stabilite
1	73	45	33	26,49	150	Stabil
2	130	50	33	26,7	150	Stabil
3	120	52	33	26,89	150	Stabil
4	155	54	38,7	26,78	300	Yenilme
5	138	58	35	26,81	200	Stabil
6	92,2	40	26,6	26,43	50	Stabil
7	170	50	26,6	26,7	50	Stabil
8	108	59	28,8	26,8	60	Stabil
9	8,23	35	15	18,68	26,34	Yenilme
10	3,66	30	0	16,5	11,49	Yenilme
11	30,5	20	25	18,84	14,36	Yenilme
12	30,5	20	20	18,84	57,46	Yenilme
13	100	35	35	28,44	29,42	Yenilme
14	100	35	38	28,44	39,23	Yenilme
15	40	30	26,5	20,6	16,28	Yenilme
16	50	20	17	14,8	0	Yenilme
17	88	30	26	14	11,97	Yenilme
18	120	53	45	25	120	Yenilme
19	200	50	45	26	150,05	Yenilme


20	6	30	0	18,5	25	Yenilme
21	6	30	0	18,5	12	Yenilme
22	10	30	35	22,4	10	Yenilme
23	20	30	30,34	21,4	10	Yenilme
24	50	45	36	22	20	Yenilme
25	50	45	36	22	0	Yenilme
26	4	35	30	12	0	Yenilme
27	8	45	30	12	0	Yenilme
28	4	35	30	12	0	Yenilme
29	8	45	30	12	0	Yenilme
30	214	37	32	23,47	0	Yenilme
31	115	40	20	16	70	Yenilme
32	10,67	22	13	20,41	24,9	Yenilme
33	12,19	22	20	19,63	11,97	Yenilme
34	12,8	28	32	21,82	8,62	Yenilme
35	45,72	16	11	20,41	33,52	Yenilme
36	10,67	25	30	18,84	15,32	Yenilme
37	7,62	20	20	18,84	0	Yenilme
38	61	20	20	21,43	0	Yenilme
39	21	35	28	19,06	11,71	Yenilme
40	30,5	20	25	18,84	14,36	Yenilme
41	76,81	31	30	21,51	6,84	Yenilme
42	88	30	26	14	11,97	Yenilme
43	20	45	30,15	18	24	Yenilme
44	100	20	20	23	0	Yenilme
45	15	45	45	22,4	100	Yenilme
46	10	45	35	22,4	10	Yenilme
47	50	45	36	20	20	Yenilme
48	50	45	36	20	20	Yenilme
49	50	45	36	20	0	Yenilme
50	50	45	36	20	0	Yenilme
51	8	33	40	22	0	Yenilme
52	8	33	40	24	0	Yenilme
53	8	20	24,5	20	0	Yenilme
54	8	20	30	18	5	Yenilme
55	45,7	11	16	20,41	33,52	Yenilme
56	7,62	20	20	18,84	0	Yenilme
57	61	20	20	21,43	0	Yenilme
58	21	28	35	19,03	11,7	Yenilme
59	30,5	25	20	18,84	14,36	Yenilme
60	76,81	30	31	21,51	6,94	Yenilme
61	88	26	30	14	11,97	Yenilme
62	20	30,15	45	18	24	Yenilme
63	100	20	20	23	0	Yenilme
64	10	35	45	22,4	10	Yenilme
65	50	36	45	20	20	Yenilme
66	8	40	33	24	0	Stabil
67	407	40	42	27	50	Stabil
68	366	37	46	31,3	68	Stabil
69	305	37	47	31,3	68,6	Stabil
70	359	35	42	27	35	Stabil

71	320	35	38	27	37,5	Stabil
72	289	33	42	27	32	Stabil
73	110	31	41	27	14	Stabil
74	135	29,7	41	27	32,15	Stabil
75	90,5	28	50	27	16,8	Stabil
76	92	31	50	27	26	Stabil
77	511	39	41	27	10	Stabil
78	470	39	40	27	10	Stabil
79	443	35	47	25	46	Stabil
80	50	36	45	20	20	Yenilme
81	21,19	20	22	19,63	11,97	Yenilme
82	12,8	32	28	21,82	8,62	Yenilme
83	299	36	44	25	55	Stabil
84	480	39	40	27,3	10	Stabil
85	393	35	46	25	46	Stabil
86	330	40	49	25	48	Stabil
87	10	45	35	22,4	10	Yenilme
88	50	45	36	20	20	Yenilme
89	50	45	36	20	0	Yenilme
90	50	45	36	20	0	Yenilme
91	8	33	40	22	0	Yenilme
92	8	33	40	24	0	Yenilme
93	407	42	40	27	50	Stabil
94	359	42	35	27	35	Stabil
95	320	37,8	35	27	37,5	Stabil
96	289	42,4	33	27	32	Stabil
97	110	41	31	27,3	14	Stabil
98	135	41	29,7	27,3	31,5	Stabil
99	90,5	50	28	27,3	16,8	Stabil
100	92	50	31	27,3	26	Stabil
101	511	41	39	27,3	10	Stabil
102	470	40	39	27,3	10	Stabil
103	443	47	35	25	46	Stabil
104	435	44	35	25	46	Stabil
105	432	46	35	25	46	Stabil
106	200	30	45	26	150	Stabil
107	6	30	0	18,5	25	Yenilme
108	6	30	0	18,5	12	Yenilme
109	50	45	36	22	20	Yenilme
110	8	45	30	12	0	Yenilme
111	50	45	36	20	20	Yenilme
112	284	50	35	25	46	Stabil
113	299	44,5	36	25	46	Stabil
114	480	40	39	27,3	10	Stabil


Tablo 3.2. Parametrelere ait istatistiksel değerler

Parametre	En Büyük Değer	En Küçük Değer	Ortalama Değer	Standart Sapma
Şev Yüksekliği	511,00 m	3,66 m	128,60 m	148,8690


Şev Açısı	59°	11°	35,98°	9,9204
İçsel Sürtünme Açısı	50°	0°	31,99°	10,8783
Birim Hacim Ağırlık	31,30 Kn/m ³	12,00 Kn/m ³	22,39 Kn/m ³	4,3936
Kohezyon	300 Kpa	0 Kpa	31,49 Kpa	45,1372




Şekil 3.1. Veri Setinde Şev Açısına göre veri sayısı




Şekil 3.2. Veri Setinde Şev Yüksekliğine göre veri sayısı




Şekil 3.3. Veri Setinde İçsel Sürtünme Açısına göre veri sayısı



Şekil 3.4. Veri Setinde Birim Hacim Ağırlığına göre veri sayısı



Şekil 3.5. Veri Setinde Kohezyona göre veri sayısı



Şekil 3.6. Veri Setinde Stabilite Durumuna göre veri sayısı

3.2. Kullanılan Yöntemler

3.2.1. Group Method of Data Handling (Grup veri işleme yöntemi) (GMDH)

GMDH algoritması, bir dizi çoklu-giriş tek-çıkış veri çiftleri üzerindeki performanslarının değerlendirilmesine dayanarak oluşturulan, kendi kendini organize eden bir yaklaşımdır. GMDH ağı, 1960'larda Ivakhnenko tarafından önerilmiştir.

GMDH modelinde giriş ve çıkış değişkenleri arasındaki genel bağlantı, aşağıdaki gibi bir seri olan Volterra fonksiyonunun karmaşık bir ayrık biçimi ile ifade edilebilir [51-53]

$$y = w_0 + \sum_{i=1}^n w_i x_i + \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n w_{ijk} x_i x_j x_k + \dots, \quad (67)$$

Yukarıdaki denklem Kolmogorov-Gabor polinomu olarak bilinir [54,55]. Burada $X = (X_1, X_2, X_3, \dots, X_n)$ girdi vektörünü, w_i ağırlık katsayıları vektörü ve $\hat{y}$ tahmin değerini belirtir. Denklem 1'deki genel denklem, sadece iki değişkenden oluşan kısmi kuadratik polinom şeklinde ifade edilebilir. Bu fonksiyon aşağıdaki gibi yazılmaktadır [56].

$$\text{Quadratic: } \hat{y} = G(x_i, x_j) = w_0 + w_1 x_i + w_2 x_j + w_3 x_i x_j + w_4 x_i^2 + w_5 x_j^2 \quad (68)$$

GMDH ağı oluşturulurken n adet girdi değişkenlerin olası tüm ikili kombinasyonları kullanılır [57]. Gözlenen $\{(y_i, x_{ip}, x_{iq}), (i=1,2,3,\dots,M)\}$ örneklerden GMDH ağın ilk katmanını $n(n-1)/2$ adet kuadratik polinom nöronları kullanılarak oluşturulur [58]. Polinom denklemlerin katsayıları en küçük kareler yöntemi ile tahmin edilir.

$$e = \sum_{i=1}^M [\hat{y}_i - y_i]^2 \quad (69)$$

Burada e hata kareler toplamını belirtmektedir. Amaç gerçek çıktı değerleri ile tahmin edilen değerler arasındaki farkın diğer bir deyişle hatanın minimum olmasıdır. Bu durum polinom denklemlerde en uygun katsayıların bulunmasını sağlar. Bunun için denklemlerin her değişken için kısmi türevleri alınıp denklemler sıfıra eşitlenir [59].

$$\frac{\partial e}{\partial w_i} = 0 \quad (70)$$

(70) numaralı denklemin çözümü aşağıdaki eşitlikteki ikili değişkenin katsayılarının bulunmasını sağlar.

$$\text{Quadratic: } \hat{y} = G(x_i, x_j) = w_0 + w_1x_i + w_2x_j + w_3x_ix_j + w_4x_i^2 + w_5x_j^2 \quad (71)$$

Burada W, kuadratik polinomun bilinmeyen ağırlık katsayılarının vektörüdür.

$$W = \{w_0, w_1, w_2, w_3, w_4, w_5\}^T \quad (72)$$

Y ise çıkış değerlerin vektörünü belirtir.

$$Y = \{y_1, y_2, y_3, y_4, y_5, \dots, y_M\}^T \quad (73)$$


$$X = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{mp} & x_{mq} & x_{mp}x_{mq} & x_{mp}^2 & x_{mq}^2 \end{bmatrix} \quad (74)$$

Ağırlıklar çoklu regresyon denklemi kullanılarak matris formunda aşağıdaki gibi çözülür.

$$W = (X^T X)^{-1} X^T Y \quad (75)$$

Burada W tahmin edilecek ağırlık vektörü, X giriş matrisi ve Y ise çıkış vektörünü belirtir.

Her giriş vektörü çifti (öznitelikler) bir ikinci kuadratik regresyon polinom denklemi oluşturacaktır. İlk katman için L ($L = m(m-1) / 2$) kadar regresyon polinom denklemi elde edilir. Örneğin giriş değişken sayısı $m=4$ ise 1.katmanda $L=6$ adet regresyon polinom denklemi elde edilecektir. Bu denklemler kullanılarak 1.katmandak sonraki katman için yeni değişkenler elde edilmektedir. Bu şekilde her katmandaki diğer katmanlar için yeni değişkenler elde edilmektedir. Dolayısıyla giriş değişkenlerden çıkış değişkenini en iyi şekilde açıklayan yeni değişkenler üretilmektedir. Geçerli katmandaki minimum hata değeri bir önceki katmandaki hata değerinden büyük ise modeli karmaşık hale getirmektedir. Diğer bir deyişle belli bir katmandaki hata değeri bir önceki katmandaki hata değerinden küçük olması beklenir. Şekil 3.1'de GMDH ağı mimarisi verilmiştir.



Şekil 3.7. GMDH Ağı mimari Yapısı

3.2.2. Ensemble GMDH Model (Topluluk Grup Veri İşleme Yöntemi) (EGMDH)

Bu çalışmada GMDH modeli farklı aktivasyon fonksiyonları için ensemble (topluluk) model haline getirilmiştir. Ensemble (topluluk) sınıflandırmada temel amaç, farklı sınıflandırıcılar tarafından elde edilen değerlerin bir araya getirilerek bir sonuca ulaşılmasıdır. Sınıflandırıcıların birleştirilmesi, yeniden örneklenen eğitim setleri ile sınıflandırıcıların ayrı ayrı eğitilmesi ile ortaya çıkan tahminler doğrultusunda sınıflandırma işleminin gerçekleştirilmesi işlemlerinden oluşur. Genel olarak birleştirme sonucu elde edilen sınıflandırıcı ile yapılan sınıflandırma doğruluğunun her bir sınıflandırıcının tekil olarak kullanılmasından daha iyi sonuç verdiği ifade edilir. Çünkü tek bir sınıflandırıcı daha yüksek test hatasına sahip olabilmekte iken sınıflandırıcıların çeşitliliği, genellikle tek bir sınıflandırıcının hatalarını telafi eder. Bundan dolayı, sınıflandırıcıların kombinasyonu ile daha az test hatası elde edilmektedir [60]. Ensemble (topluluk) sınıflandırmada temel amaç, önceden farklı sınıflandırıcılar tarafından elde edilen değerlerin bir araya getirilmesi ile bir sonuç üretilmesidir. Bu işlem yapılırken diğer sınıflandırıcılara belli ağırlık puanları verilerek hesaplama yapmaya çalışılır. Burada asıl problem farklı sınıflama algoritmalarını birleştirmek ve hangi oranların kullanılacağına karar vermektir. En büyük avantajı diğer yöntemlerin verilerini bir arada kullandığı için daha iyi değerler elde edebilmesidir [61]. GMDH, aynı şartlarda(öğrenme oranı, gizli katman sayısı, ağırlıklar, gizli katmandaki nöron sayısı) farklı aktivasyon fonksiyonları kullanılarak ensemble (topluluk) haline getirilmiştir. Aktivasyon fonksiyonları giriş ile çıkış arasındaki ilişkiyi daha iyi açıklamak için kullanılır [62]. Bu fonksiyonlar aşağıda verilmiştir.

$$\text{Sigmoid} = \frac{1}{1+e^{-y}} \quad (76)$$

$$\text{Radial Basis} = e^{-y^2} \quad (77)$$


$$\text{Polynomial} = y \quad (78)$$

$$\text{Tangent} = \tanh(y) \quad (79)$$

$$\text{Sinus} = \sin(y) \quad (80)$$

Önerilen ensemble (topluluk) GMDH (EMDH) modeline ait diyagram Şekil 3.2’de gösterilmiştir.

Aynı koşullarda çalıştırılan 5 GMDH modelin çıktıları farklı aktivasyon fonksiyonları ile üretilmektedir. Bir örnek veri için her model kendi çıktı kararını vermektedir. Ancak EGMDH’ın çıktısı bu 5 modelin topluluk kararı olmaktadır.



Şekil 3.8. EGMDH Algoritması

3.2.3. Extreme Learning Machine (Aşırı Öğrenme Makinesi) (ELM)

Aşırı öğrenme makinesi (ELM), bir tür tek gizli katmanlı ileri beslemeli ağ (SLFN) modelidir. ELM modelinin girdi ve gizli katmanlarının girdi ağırlıkları ve eşik değerleri rastgele atanır ve çıktı ağırlıkları analitik olarak hesaplanır. ELM modelinde türevlenebilir transfer fonksiyonlarının (sigmodial, sinüs ve hard-limit vb.) yanı sıra diferansiyel olmayan veya kesikli transfer fonksiyonlarının kullanılması da mümkündür [63]. Geleneksel ileri beslemeli sinir ağlarının performansı, momentum, öğrenme hızı vb. gibi bazı parametrelere bağlıdır. Bu tür ağlarda, ağırlık ve eşik değerlerinin gradyan tabanlı öğrenme algoritmaları ile güncellenmesi

gerekir. Ancak iyi bir performans elde etmek için öğrenme süreci uzun zaman alır ve hata yerel bir noktaya sabitlenebilir. Momentum değerinin değiştirilmesi muhtemelen hatanın yerel bir noktaya odaklanmasını engelleyebilir, ancak öğrenme sürecinin uzun süresini etkilemeyecektir. ELM ağı, bir SLFN modelinin özelleştirilmiş bir versiyonudur. Bir SLFN'nin şekli Şekil 3.3'te gösterilmektedir.

Burada $X=(X_1, X_2, X_3 \dots X_N)$ girdi özniteliği ve Y çıktı özniteliğidir, gizli katmanda M nörona sahip ağ matematiksel olarak aşağıdaki gibi ifade edilir [63].

$$\sum_{i=1}^M \beta_i F(W_i X_k + b_i) = O_k, \quad k = 1, 2 \dots N \quad (81)$$

Burada $W_i = (W_{i1}, W_{i2} \dots W_{in})$ girdi katmanındaki çıktıların ağırlıklarını, $\beta_i = (\beta_{i1}, \beta_{i2} \dots \beta_{im})$ gizli katmandaki çıktıların ağırlıklarını, b_i nöronların eşik değerlerini temsil eder. Gizli katmanda ve O_k ağı çıkış değerlerini temsil eder. $F(\cdot)$ transfer fonksiyonudur (Hai-Jun ve diğerleri, 2008). N girişli bir ELM ağındaki amaç, hatanın $\sum_{k=1}^N (O_k - Y_k) = 0$ olması veya $\min \|\sum_{k=1}^N (O_k - Y_k)^2\|$ elde edilmesidir. Bu nedenle, denklem (81) şu şekilde verilebilir (Suresh vd., 2010; Huang vd., 2006).

$$\sum_{i=1}^M \beta_i F(W_i X_k + b_i) = O_k, \quad k = 1, 2 \dots N \quad (82)$$

Yukarıdaki denklemde şunları yazmak mümkündür [64];

$$H\beta = Y \quad (83)$$

Burada H , β ve Y aşağıdaki gibi ifade edilebilir [65];


$$H(W_1, \dots, W_M; b_1, \dots, b_M; X_1, \dots, X_N) = \begin{bmatrix} g(W_1 X_1 + b_1) & \dots & g(W_M X_1 + b_M) \\ \vdots & \ddots & \vdots \\ g(W_1 X_N + b_1) & \dots & g(W_M X_N + b_M) \end{bmatrix} \quad (84)$$

Ve

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times m} \quad (85)$$

Ve

$$Y = \begin{bmatrix} Y_1^T \\ \vdots \\ Y_N^T \end{bmatrix}_{N \times m} \quad (86)$$



Şekil 3.9. SLFN'nin mimari yapısı

H , gizli katmanın çıktı matrisidir. Geleneksel ileri beslemeli YSA'da ağın eğitimi, ELM'de $H\beta = Y$ lineer denkleminde en küçük kareler çözümünü aramaktır. ELM yöntemi aşağıdaki gibi üç adımda verilebilir [64].

İlk adım: (giriş, gizli) katmanlar için $W_i = (W_{i1}, W_{i2} \dots W_{in})$ ağırlıkları ve gizli katmanın b_i eşik değerleri rastgele oluşturulur.

İkinci adım: Gizli katmanın çıktısı (H) hesaplanır.

Üçüncü adım: Çıktı katmanının çıktı ağırlıkları ($\hat{\beta}$), $\hat{\beta} = H^+Y$ denkleminde göre hesaplanır. Burada Y , hedef niteliklerdir.

3.2.4. Ensemble ELM (Topluluk Aşırı Öğrenme Makinesi) (EELM)

Farklı aktivasyon fonksiyonların paralel çalışması ile ELM ensemble (topluluk) model haline getirilebilir. Ensemble (topluluk) sınıflandırmada temel amaç, farklı sınıflandırıcılar tarafından elde edilen değerlerin bir araya getirilerek bir sonuca ulaşılmasıdır. Genel olarak birleştirme sonucu elde edilen sınıflandırıcı ile yapılan sınıflandırma doğruluğunun her bir sınıflandırıcının tekil olarak kullanılmasından daha iyi sonuç verdiği ifade edilir. ELM Ensemble (topluluk) sınıflandırmada amaç, farklı aktivasyon fonksiyonlar tarafından elde edilen değerlerin bir araya getirilmesi ile bir sonuç üretilmesidir. Bu işlem yapılırken tüm aktivasyon fonksiyonların çıkış değerlerine göre belli ağırlık puanları verilerek çıkış üretilmektedir. ELM, aynı şartlarda (gizli katman sayısı, ağırlıklar, gizli katmandaki nöron sayısı) farklı aktivasyon fonksiyonları kullanılarak ensemble (topluluk) haline getirilmiştir. Aktivasyon fonksiyonları

giriş ile çıkış arasındaki ilişkiyi daha iyi açıklamak için kullanılır [62]. ELM için kullanılan fonksiyonlar aşağıda verilmiştir.

$$Sigmoid = \frac{1}{1+e^{-y}} \quad (87)$$


$$Radial\ Basis = e^{-y^2} \quad (88)$$

$$Sinus = \sin(y) \quad (89)$$

$$tri = \Lambda(y) = \begin{cases} 1 - |y|, & |x| < 1; \\ 0, & otherwise; \end{cases} \quad (90)$$

$$hardlim(a) = \begin{cases} 1, & y \geq a; \\ 0, & y < a; \end{cases} \quad (91)$$

Önerilen ensemble (topluluk) ELM(EELM) modeline ait diyagram Şekil 3.4'te verilmiştir. Aynı koşullarda çalıştırılan 5 ELM modelin çıktıları farklı aktivasyon fonksiyonları ile üretilmektedir. Bir örnek veri için her model kendi çıktı kararını vermektedir. Ancak EELM'in çıktısı bu 5 modelin topluluk kararı olmaktadır.



Şekil 3.10. EELM Algoritması

3.2.5. Performans Ölçütleri

Çalışmada önerilen yöntemlerin performansını göstermek için doğruluk, hassaslık, hatırlatma ve f-ölçütleri kullanılmıştır. Bu başarı ölçütleri aşağıdaki Denklem (92 - 95)'te olduğu gibi hesaplanmaktadır.

$$\text{Doğruluk}(\text{Accuracy}) = \frac{TP+TN}{TP+TN+FP+FN} \quad (92)$$

$$\text{Kesinlik}(\text{Precision}) = TP/(TP + FP) \quad (93)$$

$$\text{Duyarlılık}(\text{Recall}) = TP/(TP + FN) \quad (94)$$

$$F - \text{Ölçütü}(F - \text{Measure}) = 2(\text{Recall} * \text{Precision})/(\text{Recall} + \text{Precision}) \quad (95)$$

Bu denklemlerde T, F, P ve N sırasıyla doğruyu, yanlış, pozitif ve negatif ifade etmektedir. Örneğin, TP doğru sınıflandırılan pozitif örnek sayısını; FN ise yanlış sınıflandırılan negatif örnek sayısını göstermektedir.

Doğruluk, başarının tespiti için kullanılan en popüler ve basit yöntemdir ve bu oran doğru sınıflandırılmış (TP+TN) örnek sayısının, toplam örnek sayısına (TP+TN+FP+FN) oranı olarak tanımlanmaktadır.

Kesinlik: Sınıflandırıcı sonucunun kesinlik derecesini verir. Pozitif olarak etiketlenen örneklerin sayısının (TP) pozitif olarak sınıflandırılmış toplam örneklerle (TP+FP) oranıdır.

Duyarlılık: Pozitif olarak etiketlenmiş örneklerin (TP) gerçekten pozitif olan örneklerin (TP+FN) toplam sayısına oranıdır.

F-Ölçütü: Kesinlik ve duyarlılık metrikleri kullanılarak hesaplanmaktadır. Sistemin, kesinlik ve ya duyarlılık yönüne doğru optimize edilmesinde kullanılmaktadır.

4. BULGULAR

4.1. ELM ve GMDH Sonuçları

Bu çalışmada şev stabilite analizi durum bilgisi tahmininde öncelikle GMDH ve ELM makine öğrenmesi yöntemleri kullanıldı. Tahmin modellerinde Şev Yüksekliği (m), Şev Açısı ($^{\circ}$), İçsel Sürtünme Açısı ϕ ($^{\circ}$), Birim Hacim Ağırlık γ (Kn/m^3) ve Kohezyon c (Kpa) değişkenleri kullanılmıştır. Sınıflandırma işlemi K-katlı çapraz geçerlilik testine göre gerçekleştirilmiştir. K-katlı çapraz doğrulamasında, verilerimizi k farklı alt kümeye böleriz. Verilerimizi eğitmek için k-1 alt kümelerini kullanırız ve son alt kümeyi test verileri olarak bırakırız. k deney sonucunda elde edilen ortalama sınıflandırma değeri modelimizin geçerliliğini göstermektedir. Bu çalışmada, tüm deneylerde, veri setine 10 kat çapraz doğrulama uygulanmıştır. Veri seti çapraz doğrulama işlemine göre 10 kümeye ayrılmıştır. Bu çalışmada, tüm deneylerde, veri setine 10 kat çapraz doğrulama uygulanmıştır. Veri seti çapraz doğrulama işlemine göre 10 kümeye ayrılmıştır. Çapraz doğrulamada, modelin eğitimi için 9 küme geriye kalan 1 küme ise test için kullanılır. Bu işlem 10 defa sürekli test kümesi değiştirilerek devam eder. İşlem sonucunda 10 farklı başarı sonucu elde edilecektir. Bu 10 başarı sonucun aritmetik ortalaması sınıflandırma modelin başarısı olarak alınmaktadır. Bu yöntemler farklı mimarilerde kullanılabilirler. GMDH modeli farklı aktivasyon fonksiyonları, farklı sayıda katman sayısı ve her katmanda farklı nöron sayılarda mimariler şeklinde olabilir. Aynı şekilde ELM modeli de farklı aktivasyon fonksiyonları ve tek gizli katmanda farklı sayıda nöron sayıları ile kullanılabilir. Bu çalışmada bu iki model için değişik mimariler denenmiştir. Kullanılan parametrelere yönelik bilgiler Tablo 4.1'de verilmiştir. GMDH modeli ile farklı aktivasyon fonksiyonları, farklı katman sayıları ve her katmanda farklı nöron sayıları ile deneyler yapılmıştır. En yüksek başarı oranları sigmoid aktivasyon fonksiyonu, 6 katmanlı yapı ve gizli katmanlarda 10 nöron kullanılması durumunda elde edilmiştir. ELM modeli için ise sigmoid aktivasyon fonksiyonu ile gizli katmanda 100 nöron kullanılması durumunda elde edilmiştir.

Tablo 4.1. Kullanılan modellere ait bilgiler


Parametre	GMDH	ELM
Aktivasyon fonksiyonu	Sigmoid, radial basis, polinomiyal, tanjant ve sinus	Sigmoid, sinus, radial basis, rringular basis, hardlimit
Gizli Katman Sayısı	3-6	1
Katmanlardaki Nöron Sayısı	8-12	80-120

Yapılan denemelerin performansını belirtmek için doğruluk, kesinlik, duyarlılık ve F-ölçütü performans ölçütleri kullanılmıştır. GMDH ve ELM için elde edilen başarı oranları Tablo 4.2’de verilmiştir.

Tablo 4.2. GMDH ve ELM başarı oranları

Model	Accuracy(%) (Doğruluk)	Precision (Kesinlik)	Recall (Duyarlılık)	F-Measure (F-Ölçütü)
GMDH	94,82	0,947	0,946	0,947
ELM	92,10	0,921	0,922	0,921

Tablo 4.2’ye bakıldığında şev stabilite durumu tahmininde en yüksek %94,82 başarı oranı elde edilmiştir. GMDH modeli ELM modeline göre daha yüksek başarı sağlamıştır. GMDH modeli veri setindeki 114 örneğin 108’i doğru sınıflandırılmıştır. ELM ise 105 örneği doğru sınıflandırmıştır. GMDH ve ELM ile elde edilen sınıflandırmalara ait karışıklık matrisleri Şekil 4.1’de verilmiştir. Çalışmada kullanılan veri seti örneklerine ait giriş, çıkış değişkenleri Tablo 4.3’te verilmiştir. Tabloda ayrıca GMDH ve ELM ile tahmin edilen çıkış değişkenleri de verilmiştir. Tabloya bakıldığında GMDH için 4, 13, 19, 66, 75 ve 76’ncı örnekler için yanlış tahmin gözlenmiştir. ELM modeli için ise 4,6,13, 19, 66, 75, 76, 97 ve 99 örnekler yanlış sınıflandırılmıştır.



Şekil 4.1. GMDH ve ELM için karışıklık matrisleri

Tablo 4.3. Veri seti ve GMDH-ELM ile tahmin edilen değerler

No	Şev Yüksekliği (m)	Şev Açısı (°)	İçsel Sürtünme Açısı ϕ (°)	Birim Hacim Ağırlık γ (Kn/m ³)	Kohezyon c (Kpa)	Stabilite	GMDH	ELM
1	73	45	33	26,49	150	Stabil	Stabil	Stabil

2	130	50	33	26,7	150	Stabil	Stabil	Stabil
3	120	52	33	26,89	150	Stabil	Stabil	Stabil
4	155	54	38,7	26,78	300	Yenilme	Stabil	Stabil
5	138	58	35	26,81	200	Stabil	Stabil	Stabil
6	92,2	40	26,6	26,43	50	Stabil	Stabil	Yenilme
7	170	50	26,6	26,7	50	Stabil	Stabil	Stabil
8	108	59	28,8	26,8	60	Stabil	Stabil	Stabil
9	8,23	35	15	18,68	26,34	Yenilme	Yenilme	Yenilme
10	3,66	30	0	16,5	11,49	Yenilme	Yenilme	Yenilme
11	30,5	20	25	18,84	14,36	Yenilme	Yenilme	Yenilme
12	30,5	20	20	18,84	57,46	Yenilme	Yenilme	Yenilme
13	100	35	35	28,44	29,42	Yenilme	Stabil	Stabil
14	100	35	38	28,44	39,23	Yenilme	Yenilme	Yenilme
15	40	30	26,5	20,6	16,28	Yenilme	Yenilme	Yenilme
16	50	20	17	14,8	0	Yenilme	Yenilme	Yenilme
17	88	30	26	14	11,97	Yenilme	Yenilme	Yenilme
18	120	53	45	25	120	Yenilme	Yenilme	Yenilme
19	200	50	45	26	150,05	Yenilme	Stabil	Stabil
20	6	30	0	18,5	25	Yenilme	Yenilme	Yenilme
21	6	30	0	18,5	12	Yenilme	Yenilme	Yenilme
22	10	30	35	22,4	10	Yenilme	Yenilme	Yenilme
23	20	30	30,34	21,4	10	Yenilme	Yenilme	Yenilme
24	50	45	36	22	20	Yenilme	Yenilme	Yenilme
25	50	45	36	22	0	Yenilme	Yenilme	Yenilme
26	4	35	30	12	0	Yenilme	Yenilme	Yenilme
27	8	45	30	12	0	Yenilme	Yenilme	Yenilme
28	4	35	30	12	0	Yenilme	Yenilme	Yenilme
29	8	45	30	12	0	Yenilme	Yenilme	Yenilme
30	214	37	32	23,47	0	Yenilme	Yenilme	Yenilme
31	115	40	20	16	70	Yenilme	Yenilme	Yenilme
32	10,67	22	13	20,41	24,9	Yenilme	Yenilme	Yenilme
33	12,19	22	20	19,63	11,97	Yenilme	Yenilme	Yenilme
34	12,8	28	32	21,82	8,62	Yenilme	Yenilme	Yenilme
35	45,72	16	11	20,41	33,52	Yenilme	Yenilme	Yenilme
36	10,67	25	30	18,84	15,32	Yenilme	Yenilme	Yenilme
37	7,62	20	20	18,84	0	Yenilme	Yenilme	Yenilme
38	61	20	20	21,43	0	Yenilme	Yenilme	Yenilme
39	21	35	28	19,06	11,71	Yenilme	Yenilme	Yenilme
40	30,5	20	25	18,84	14,36	Yenilme	Yenilme	Yenilme
41	76,81	31	30	21,51	6,84	Yenilme	Yenilme	Yenilme
42	88	30	26	14	11,97	Yenilme	Yenilme	Yenilme
43	20	45	30,15	18	24	Yenilme	Yenilme	Yenilme
44	100	20	20	23	0	Yenilme	Yenilme	Yenilme
45	15	45	45	22,4	100	Yenilme	Yenilme	Yenilme
46	10	45	35	22,4	10	Yenilme	Yenilme	Yenilme
47	50	45	36	20	20	Yenilme	Yenilme	Yenilme
48	50	45	36	20	20	Yenilme	Yenilme	Yenilme
49	50	45	36	20	0	Yenilme	Yenilme	Yenilme
50	50	45	36	20	0	Yenilme	Yenilme	Yenilme
51	8	33	40	22	0	Yenilme	Yenilme	Yenilme
52	8	33	40	24	0	Yenilme	Yenilme	Yenilme

53	8	20	24,5	20	0	Yenilme	Yenilme	Yenilme
54	8	20	30	18	5	Yenilme	Yenilme	Yenilme
55	45,7	11	16	20,41	33,52	Yenilme	Yenilme	Yenilme
56	7,62	20	20	18,84	0	Yenilme	Yenilme	Yenilme
57	61	20	20	21,43	0	Yenilme	Yenilme	Yenilme
58	21	28	35	19,03	11,7	Yenilme	Yenilme	Yenilme
59	30,5	25	20	18,84	14,36	Yenilme	Yenilme	Yenilme
60	76,81	30	31	21,51	6,94	Yenilme	Yenilme	Yenilme
61	88	26	30	14	11,97	Yenilme	Yenilme	Yenilme
62	20	30,15	45	18	24	Yenilme	Yenilme	Yenilme
63	100	20	20	23	0	Yenilme	Yenilme	Yenilme
64	10	35	45	22,4	10	Yenilme	Yenilme	Yenilme
65	50	36	45	20	20	Yenilme	Yenilme	Yenilme
66	8	40	33	24	0	Stabil	Yenilme	Yenilme
67	407	40	42	27	50	Stabil	Stabil	Stabil
68	366	37	46	31,3	68	Stabil	Stabil	Stabil
69	305	37	47	31,3	68,6	Stabil	Stabil	Stabil
70	359	35	42	27	35	Stabil	Stabil	Stabil
71	320	35	38	27	37,5	Stabil	Stabil	Stabil
72	289	33	42	27	32	Stabil	Stabil	Stabil
73	110	31	41	27	14	Stabil	Stabil	Stabil
74	135	29,7	41	27	32,15	Stabil	Stabil	Stabil
75	90,5	28	50	27	16,8	Stabil	Yenilme	Yenilme
76	92	31	50	27	26	Stabil	Yenilme	Yenilme
77	511	39	41	27	10	Stabil	Stabil	Stabil
78	470	39	40	27	10	Stabil	Stabil	Stabil
79	443	35	47	25	46	Stabil	Stabil	Stabil
80	50	36	45	20	20	Yenilme	Yenilme	Yenilme
81	21,19	20	22	19,63	11,97	Yenilme	Yenilme	Yenilme
82	12,8	32	28	21,82	8,62	Yenilme	Yenilme	Yenilme
83	299	36	44	25	55	Stabil	Stabil	Stabil
84	480	39	40	27,3	10	Stabil	Stabil	Stabil
85	393	35	46	25	46	Stabil	Stabil	Stabil
86	330	40	49	25	48	Stabil	Stabil	Stabil
87	10	45	35	22,4	10	Yenilme	Yenilme	Yenilme
88	50	45	36	20	20	Yenilme	Yenilme	Yenilme
89	50	45	36	20	0	Yenilme	Yenilme	Yenilme
90	50	45	36	20	0	Yenilme	Yenilme	Yenilme
91	8	33	40	22	0	Yenilme	Yenilme	Yenilme
92	8	33	40	24	0	Yenilme	Yenilme	Yenilme
93	407	42	40	27	50	Stabil	Stabil	Stabil
94	359	42	35	27	35	Stabil	Stabil	Stabil
95	320	37,8	35	27	37,5	Stabil	Stabil	Stabil
96	289	42,4	33	27	32	Stabil	Stabil	Stabil
97	110	41	31	27,3	14	Stabil	Stabil	Yenilme
98	135	41	29,7	27,3	31,5	Stabil	Stabil	Stabil
99	90,5	50	28	27,3	16,8	Stabil	Stabil	Yenilme
100	92	50	31	27,3	26	Stabil	Stabil	Stabil
101	511	41	39	27,3	10	Stabil	Stabil	Stabil
102	470	40	39	27,3	10	Stabil	Stabil	Stabil
103	443	47	35	25	46	Stabil	Stabil	Stabil

104	435	44	35	25	46	Stabil	Stabil	Stabil
105	432	46	35	25	46	Stabil	Stabil	Stabil
106	200	30	45	26	150	Stabil	Stabil	Stabil
107	6	30	0	18,5	25	Yenilme	Yenilme	Yenilme
108	6	30	0	18,5	12	Yenilme	Yenilme	Yenilme
109	50	45	36	22	20	Yenilme	Yenilme	Yenilme
110	8	45	30	12	0	Yenilme	Yenilme	Yenilme
111	50	45	36	20	20	Yenilme	Yenilme	Yenilme
112	284	50	35	25	46	Stabil	Stabil	Stabil
113	299	44,5	36	25	46	Stabil	Stabil	Stabil
114	480	40	39	27,3	10	Stabil	Stabil	Stabil

4.2. EELM ve EGMDH Sonuçları


Bu çalışmada şev stabilite durumu tahmininde GMDH ve ELM tabanlı iki yaklaşım önerilmiştir. GMDH ve ELM algoritmaları değiştirilerek ensemble (topluluk) modeller haline getirilmiştir. Giriş değişkenler ile çıkış değişkenler arasındaki ilişkiyi en iyi şekilde açıklamak için farklı aktivasyon fonksiyonlu tabanlı iki yeni ensemble (topluluk) GMDH (EGMDH) ve ensemble (topluluk) ELM (EELM) modeller geliştirilmiştir. Sigmoid, radial basis, sinüs, Tangent ve Polynomial fonksiyonlarının her biri için bir GMDH model çalıştırılmıştır. Daha sonra her aktivasyon fonksiyonlu GMDH sınıflandırıcı modeller birleştirilerek ortak bir çıktı elde edilmiştir. Genel olarak birleştirme sonucu elde edilen sınıflandırıcı ile yapılan sınıflandırma doğruluğunun her bir sınıflandırıcının tekil olarak kullanılmasından daha iyi sonuç verdiği ifade edilir. Çünkü tek bir sınıflandırıcı daha yüksek test hatasına sahip olabilmekte iken sınıflandırıcıların çeşitliliği, genellikle tek bir sınıflandırıcının hatalarını telafi eder. Benzer şekilde ELM modeli için sigmoid, radial basis, sinus, Tringular basis ve hardlim aktivasyon fonksiyonları kullanılarak ensemble (topluluk) model oluşturulmuştur. EGMDH modeli 6 katmanlı ve gizli katmandaki nöron sayıları 10 olarak kullanılmıştır. EELM ise tek gizli katmanda 100 nöron kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. EGMDH ve EELM için elde edilen sınıflandırma başarı oranları Tablo 4.4'te verilmiştir.

Tablo 4.4. EGMDH ve EELM başarı oranları

Model	Accuracy(%) (Doğruluk)	Precision (Kesinlik)	Recall (Duyarlılık)	F-Measure (F-Ölçütü)
EGMDH	95,60	0,956	0,956	0,956
EELM	97.44	0,976	0,975	0,975

Tablo 4.4'e bakıldığında şev stabilitesi durumu tahmininde en yüksek %97.44 başarı oranı elde edilmiştir. EELM modeli EGMDH modeline göre daha yüksek başarı sağlamıştır.

EGMDH modeli veri setindeki 114 örneğin 109'unu doğru sınıflandırmıştır. EELM ise 111 örneği doğru sınıflandırmıştır. EGMDH ve EELM ile elde edilen sınıflandırmalara ait karışıklık matrisleri Şekil 4.2'de verilmiştir. Çalışmada kullanılan veri seti örneklerine ait giriş, çıkış değişkenleri Tablo 4.5'te verilmiştir. Tabloda ayrıca EGMDH ve EELM ile tahmin edilen çıkış değişkenleri de verilmiştir. Tabloya bakıldığında EGMDH için 4, 14, 19, 66 ve 76'ncı örnekler için yanlış tahmin gözlenmiştir. EELM modeli için ise 14, 19 ve 76 örnekler yanlış sınıflandırılmıştır.



Şekil 4.2. EGMDH ve EELM için karışıklık matrisleri

Tablo 4.5. Veri seti ve EGMDH-EELM ile tahmin edilen değerler

No	Şev Yüksekliği (m)	Şev Açısı (°)	İçsel Sürtünme Açısı ϕ (°)	Birim Hacim Ağırlık γ (Kn/m ³)	Kohezyon c (Kpa)	Stabilite	EGMDH	EELM
1	73	45	33	26,49	150	Stabil	Stabil	Stabil
2	130	50	33	26,7	150	Stabil	Stabil	Stabil
3	120	52	33	26,89	150	Stabil	Stabil	Stabil
4	155	54	38,7	26,78	300	Yenilme	Stabil	Stabil
5	138	58	35	26,81	200	Stabil	Stabil	Stabil
6	92,2	40	26,6	26,43	50	Stabil	Stabil	Yenilme
7	170	50	26,6	26,7	50	Stabil	Stabil	Stabil
8	108	59	28,8	26,8	60	Stabil	Stabil	Stabil
9	8,23	35	15	18,68	26,34	Yenilme	Yenilme	Yenilme
10	3,66	30	0	16,5	11,49	Yenilme	Yenilme	Yenilme
11	30,5	20	25	18,84	14,36	Yenilme	Yenilme	Yenilme
12	30,5	20	20	18,84	57,46	Yenilme	Yenilme	Yenilme
13	100	35	35	28,44	29,42	Yenilme	Yenilme	Yenilme
14	100	35	38	28,44	39,23	Yenilme	Stabil	Stabil
15	40	30	26,5	20,6	16,28	Yenilme	Yenilme	Yenilme

16	50	20	17	14,8	0	Yenilme	Yenilme	Yenilme
17	88	30	26	14	11,97	Yenilme	Yenilme	Yenilme
18	120	53	45	25	120	Yenilme	Yenilme	Yenilme
19	200	50	45	26	150,05	Yenilme	Stabil	Stabil
20	6	30	0	18,5	25	Yenilme	Yenilme	Yenilme
21	6	30	0	18,5	12	Yenilme	Yenilme	Yenilme
22	10	30	35	22,4	10	Yenilme	Yenilme	Yenilme
23	20	30	30,34	21,4	10	Yenilme	Yenilme	Yenilme
24	50	45	36	22	20	Yenilme	Yenilme	Yenilme
25	50	45	36	22	0	Yenilme	Yenilme	Yenilme
26	4	35	30	12	0	Yenilme	Yenilme	Yenilme
27	8	45	30	12	0	Yenilme	Yenilme	Yenilme
28	4	35	30	12	0	Yenilme	Yenilme	Yenilme
29	8	45	30	12	0	Yenilme	Yenilme	Yenilme
30	214	37	32	23,47	0	Yenilme	Stabil	Yenilme
31	115	40	20	16	70	Yenilme	Yenilme	Yenilme
32	10,67	22	13	20,41	24,9	Yenilme	Yenilme	Yenilme
33	12,19	22	20	19,63	11,97	Yenilme	Yenilme	Yenilme
34	12,8	28	32	21,82	8,62	Yenilme	Yenilme	Yenilme
35	45,72	16	11	20,41	33,52	Yenilme	Yenilme	Yenilme
36	10,67	25	30	18,84	15,32	Yenilme	Yenilme	Yenilme
37	7,62	20	20	18,84	0	Yenilme	Yenilme	Yenilme
38	61	20	20	21,43	0	Yenilme	Yenilme	Yenilme
39	21	35	28	19,06	11,71	Yenilme	Yenilme	Yenilme
40	30,5	20	25	18,84	14,36	Yenilme	Yenilme	Yenilme
41	76,81	31	30	21,51	6,84	Yenilme	Yenilme	Yenilme
42	88	30	26	14	11,97	Yenilme	Yenilme	Yenilme
43	20	45	30,15	18	24	Yenilme	Yenilme	Yenilme
44	100	20	20	23	0	Yenilme	Yenilme	Yenilme
45	15	45	45	22,4	100	Yenilme	Yenilme	Yenilme
46	10	45	35	22,4	10	Yenilme	Yenilme	Yenilme
47	50	45	36	20	20	Yenilme	Yenilme	Yenilme
48	50	45	36	20	20	Yenilme	Yenilme	Yenilme
49	50	45	36	20	0	Yenilme	Yenilme	Yenilme
50	50	45	36	20	0	Yenilme	Yenilme	Yenilme
51	8	33	40	22	0	Yenilme	Yenilme	Yenilme
52	8	33	40	24	0	Yenilme	Yenilme	Yenilme
53	8	20	24,5	20	0	Yenilme	Yenilme	Yenilme
54	8	20	30	18	5	Yenilme	Yenilme	Yenilme
55	45,7	11	16	20,41	33,52	Yenilme	Yenilme	Yenilme
56	7,62	20	20	18,84	0	Yenilme	Yenilme	Yenilme
57	61	20	20	21,43	0	Yenilme	Yenilme	Yenilme
58	21	28	35	19,03	11,7	Yenilme	Yenilme	Yenilme
59	30,5	25	20	18,84	14,36	Yenilme	Yenilme	Yenilme
60	76,81	30	31	21,51	6,94	Yenilme	Yenilme	Yenilme
61	88	26	30	14	11,97	Yenilme	Yenilme	Yenilme
62	20	30,15	45	18	24	Yenilme	Yenilme	Yenilme
63	100	20	20	23	0	Yenilme	Yenilme	Yenilme
64	10	35	45	22,4	10	Yenilme	Yenilme	Yenilme
65	50	36	45	20	20	Yenilme	Yenilme	Yenilme
66	8	40	33	24	0	Stabil	Yenilme	Stabil

67	407	40	42	27	50	Stabil	Stabil	Stabil
68	366	37	46	31,3	68	Stabil	Stabil	Stabil
69	305	37	47	31,3	68,6	Stabil	Stabil	Stabil
70	359	35	42	27	35	Stabil	Stabil	Stabil
71	320	35	38	27	37,5	Stabil	Stabil	Stabil
72	289	33	42	27	32	Stabil	Stabil	Stabil
73	110	31	41	27	14	Stabil	Stabil	Yenilme
74	135	29,7	41	27	32,15	Stabil	Stabil	Stabil
75	90,5	28	50	27	16,8	Stabil	Stabil	Stabil
76	92	31	50	27	26	Stabil	Yenilme	Yenilme
77	511	39	41	27	10	Stabil	Stabil	Stabil
78	470	39	40	27	10	Stabil	Stabil	Stabil
79	443	35	47	25	46	Stabil	Stabil	Stabil
80	50	36	45	20	20	Yenilme	Yenilme	Yenilme
81	21,19	20	22	19,63	11,97	Yenilme	Yenilme	Yenilme
82	12,8	32	28	21,82	8,62	Yenilme	Yenilme	Yenilme
83	299	36	44	25	55	Stabil	Stabil	Stabil
84	480	39	40	27,3	10	Stabil	Stabil	Stabil
85	393	35	46	25	46	Stabil	Stabil	Stabil
86	330	40	49	25	48	Stabil	Stabil	Stabil
87	10	45	35	22,4	10	Yenilme	Yenilme	Yenilme
88	50	45	36	20	20	Yenilme	Yenilme	Yenilme
89	50	45	36	20	0	Yenilme	Yenilme	Yenilme
90	50	45	36	20	0	Yenilme	Yenilme	Yenilme
91	8	33	40	22	0	Yenilme	Yenilme	Yenilme
92	8	33	40	24	0	Yenilme	Yenilme	Yenilme
93	407	42	40	27	50	Stabil	Stabil	Stabil
94	359	42	35	27	35	Stabil	Stabil	Stabil
95	320	37,8	35	27	37,5	Stabil	Stabil	Stabil
96	289	42,4	33	27	32	Stabil	Stabil	Stabil
97	110	41	31	27,3	14	Stabil	Stabil	Yenilme
98	135	41	29,7	27,3	31,5	Stabil	Stabil	Stabil
99	90,5	50	28	27,3	16,8	Stabil	Stabil	Yenilme
100	92	50	31	27,3	26	Stabil	Stabil	Stabil
101	511	41	39	27,3	10	Stabil	Stabil	Stabil
102	470	40	39	27,3	10	Stabil	Stabil	Stabil
103	443	47	35	25	46	Stabil	Stabil	Stabil
104	435	44	35	25	46	Stabil	Stabil	Stabil
105	432	46	35	25	46	Stabil	Stabil	Stabil
106	200	30	45	26	150	Stabil	Stabil	Stabil
107	6	30	0	18,5	25	Yenilme	Yenilme	Yenilme
108	6	30	0	18,5	12	Yenilme	Yenilme	Yenilme
109	50	45	36	22	20	Yenilme	Yenilme	Yenilme
110	8	45	30	12	0	Yenilme	Yenilme	Yenilme
111	50	45	36	20	20	Yenilme	Yenilme	Yenilme
112	284	50	35	25	46	Stabil	Stabil	Stabil
113	299	44,5	36	25	46	Stabil	Stabil	Stabil
114	480	40	39	27,3	10	Stabil	Stabil	Stabil

5. TARTIŞMA VE SONUÇ

Bu çalışmada şev stabilitesi durumu tahmininde GMDH ve ELM gibi klasik yöntemler ensemble (topluluk) modeller haline getirilerek tahmin modelleri önerilmiştir. Önerilen tahmin modellerinin şev stabilite durumu tahminindeki başarısını belirtmek için sonuçlar ELM ve GMDH modellerinin sonuçları ile de karşılaştırılmıştır. Tüm modellere ait performans değerleri Tablo 5.1’de gösterilmiştir. Tabloya bakıldığında en yüksek başarı oranı %97.44 olarak EELM ile elde edilmiştir. Daha sonra en başarılı model EGMDH olarak gözlenmiştir. En kötü performans gösteren model ise ELM olarak gözlenmiştir. Genel olarak, ensemble (topluluk) modeller ile diğer klasik modellere göre daha yüksek başarılar elde edilmiştir.

Tablo 5.1. Modellerin Karşılaştırılması

Model	Accuracy(%) (Doğruluk)	Precision (Kesinlik)	Recall (Duyarlılık)	F-Measure (F-Ölçütü)
EGMDH	95,60	0,956	0,956	0,956
EELM	97.44	0,976	0,975	0,975
GMDH	94,82	0,947	0,946	0,947
ELM	92,10	0,921	0,922	0,921

Tüm bu sonuçlar birlikte ele alındığında, elde edilen bulgular doğrultusunda, şev stabilite analizlerinde teknolojiye dayanarak makine öğrenme yöntemlerinin geleneksel şev stabilite analiz yöntemlerine alternatif olabileceği görülmüştür.

Sonuç olarak bu çalışma göstermiştir ki şev stabilite analizleri için yapılan uzun ve zahmetli laboratuvar çalışmalarına kıyasla uygun makine öğrenme yöntemlerinin kullanılması hem işgücü hem de zamandan tasarruf sağlamış olacaktır.

KAYNAKLAR

- [1]. Halilođlu, S. B. (1997). *Heyelan analizinde kullanılan yntemler ve sayısal czmleri*. Yksek lisans tezi, Karadeniz Teknik niversitesi, Trabzon.
- [2]. Koç, M. (2020). *Investigation of urban climate and built environment relations by using machine learning*. Yksek lisans tezi, TOBB Ekonomi ve Teknoloji niversitesi, Ankara.
- [3]. Çimen, E. A. (2019). *Prediction of the football match results with using machine learning algorithms*. Yksek lisans tezi, Çankaya niversitesi, Ankara.
- [4]. Nejad, F. P., Jaksa, M. B., Kakhi, M., McCabe, B. A. (2009). Prediction of pile settlement using artificial neural networks based on standard penetration test data. *Computers and Geotechnics*, 36(7), 1125–1133.
- [5]. Lee, I., Lee, J. (1996). Prediction of pile bearing capacity using artificial neural networks. *Computers and Geotechnics*, 18(3), 189–200. [https://doi.org/10.1016/0266-352X\(95\)00027-8](https://doi.org/10.1016/0266-352X(95)00027-8)
- [6]. Kiefa, M. A. A. (1998). General regression neural networks for driven piles in cohesionless soils. *Journal of Geotechnical and Geoenvironmental Engineering*, 124(12), 1177–1185.
- [7]. Sakellariou, M.G., Ferentinou, M. (2005). A study of slope stability prediction using neural networks. *Geotechnical and Geological Engineering*, 24(3), 419–445.
- [8]. Wang, H. B., Xu, W. Y., Xu, R. C. (2005). Slope stability evaluation using back propagation neural networks. *Engineering Geology*, 80, 302–315.
- [9]. Kuo, Y. L., Jaksa, M. B., Lyamin, A. V., Kaggwa, W. S. (2009). ANN-based model for predicting the bearing capacity of strip footing on multilayered cohesive soil. *Computers and Geotechnics*, 36(3), 503–516. <https://doi.org/10.1016/j.compgeo.2008.07.002>
- [10]. Abdalla, J. A., Attom, M. F., Hawileh, R. (2015). Prediction of minimum factor of safety against slope failure in clayey soils using artificial neural network. *Environmental Earth Sciences*, 73(9), 5463–5477.
- [11]. Chenari, R. J., Tizpa, P., Rad, M. R. G., Machado, S. L., Fard, M. K. (2015). The use of index parameters to predict soil geotechnical properties. *Arabian Journal of Geosciences*, 8(7), 4907–4919.
- [12]. Kalinli, A., Acar, M. C., Gunduz, Z. (2011). New approaches to determine the ultimate bearing capacity of shallow foundations based on artificial neural networks and ant colony optimization. *Engineering Geology*, 117(1–2), 29–38. <https://doi.org/10.1016/j.enggeo.2010.10.002>
- [13]. Sulewska, M. J. (2011). Applying artificial neural networks for analysis of geotechnical problems. *Computer Assisted Methods in Engineering and Science*, 18,231–241.
- [14]. Chik, Z., Aljanabi, Q. A., Kasa, A., Taha, M. R. (2014). Tenfold cross validation artificial neural network modeling of the settlement behavior of a stone column under a highway embankment. *Arabian Journal of Geosciences*, 7(11), 4877–4887. <https://doi.org/10.1007/s12517-013-1128-6>
- [15]. Goh, A. T. C. (2002). Probabilistic neural network for evaluating seismic liquefaction potential. *Canadian Geotechnical Journal*, 39, 219–232.

- [16]. Juang, C. H., Chen, C. J. (1999). CPT-based liquefaction evaluation using artificial neural networks. *Computer Aided Civil Infrastructure Engineering*, 14(3), 221–229.
- [17]. Rahman, M. S., Wang, J. (2002). Fuzzy neural network models for liquefaction prediction. *Soil Dynamics and Earthquake Engineering*, 22, 685–694.
- [18]. Kim, Y. S., Kim, B. T. (2006). Use of artificial neural networks in the prediction of liquefaction resistance of sands. *Journal of Geotechnical and Geoenvironmental Engineering ASCE*, 132(11), 1502–1504. <https://doi.org/10.1061/asce1090-02412006132111502>
- [19]. Hanna, A. M., Ural, D., Saygili, G. (2007). Neural network model for liquefaction potential in soil deposits using Turkey and Taiwan earthquake data. *Soil Dynamics and Earthquake Engineering*, 27(6), 521–540.
- [20]. Chern, S. G., Lee, C. Y., Wang, C. C. (2008). CPT-based liquefaction assessment by using fuzzy-neural network. *Journal of Marine Science and Technology*, 16(2), 139–148.
- [21]. Samui, P., Sitharam, T. G. (2011). Machine learning modelling for predicting soil liquefaction susceptibility. *Natural Hazards and Earth System Sciences*, 11, 1–9.
- [22]. Xue, X., Xiao, M. (2016). Application of genetic algorithm-based support vector machines for prediction of soil liquefaction. *Environmental Earth Sciences*, 75, 874. <https://doi.org/10.1007/s12665-016-5673-7>
- [23]. Hoang, N. D., Bui, D. T. (2018). Predicting earthquake-induced soil liquefaction based on a hybridization of kernel Fisher discriminant analysis and a least squares support vector machine: a multi-dataset study. *Bulletin of Engineering Geology and the Environment*, 77(1), 191–204.
- [24]. Abramson, L. W., Lee, T. S., Sharma, S., Boyce, G. M. (2002). *Slope stability and stabilization methods*. 2nd edition, New York: John Wiley & Sons.
- [25]. URL-1. (2019). *Heyelen nedir? Heyelan çeşitleri ve sınıflandırılması*. 22 Mayıs 2021 tarihinde <https://insapedia.com/heyelan-nedir-heyelan-cesitleri-ve-siniflandirilmasi/> adresinden erişildi.
- [26]. Konuk, Ç. (2005). *Şev stabilitesi analizi ve şevlerde deprem etkisinin incelenmesi*. Yüksek lisans tezi, İstanbul Teknik Üniversitesi, İstanbul.
- [27]. Bromhead, E. N. (1992). *The stability of slopes*. 2nd edition, New York: Taylor & Francis Group.
- [28]. Tolon, M. (2007). *Artificial neural network approaches for slope stability*. Yüksek lisans tezi, İstanbul Teknik Üniversitesi, İstanbul.
- [29]. URL-2. *Neural Network-Perceptron*. 15 Haziran 2021 tarihinde <https://www.programmersought.com/article/31885064114/> adresinden erişildi.
- [30]. Sah, N. K., Sheorey, P. R., Upadhyaya, L. N. (1994). Maximum likelihood estimation of slope stability. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 31(1), 47–53.

- [31]. Cao, J. (2002). *Neural network and analytical modeling of slope stability*. Doktora tezi, University of Oklahoma, Norman.
- [32]. Lu, P., Rosenbaum, M. S. (2003). Artificial neural networks and grey systems for the prediction of slope stability. *Natural Hazards*, 30, 383-398.
- [33]. Maccabiani, J., Koelewijn, A. R. (2004). Rapid and accurate embankment slope stability analysis using artificial neural networks. London: Taylor & Francis Group.
- [34]. Li, S. ve Liu, Y. (2005). Data mining techniques for slope stability estimation with probabilistic neural networks. *Dalian University of Technology State Key Laboratory of Structural Analysis for Industrial Equipment*, 491-498.
- [35]. Farrokhzad, F., JanAliZadeh, A. ve Barari, A. (2008). Prediction of Slope Stability Using Artificial Neural Network (Case Study: Noabad, Mazandarani Iran). *International Conference on Case Histories in Geotechnical Engineering*. (paper no. 2.86). Missouri University of Science and Technology.
- [36]. Ural, D., F., Tolon, M. (2008). Slope Stability During Earthquakes: A Neural Network Application, *GeoCongress 2008 bildiriler kitabı içinde* (ss. 878- 885). New Orleans.
- [37]. Zhou, K., Chen, Z. (2009). Stability Prediction of Tailing dam Slope Based on Neural Network Pattern Recognition, *2009 Second International Conference on Environmental and Computer Science* (ss. 380-383). Dubai: IEEE. doi: 10.1109/ICECS.2009.55
- [38]. Li, J., Wang, F. (2010). Study on the forecasting models of slope stability under data mining. *Earth and Space 2010: Engineering, Science, Construction, and Operations in Challenging Environments*, 765-776.
- [39]. Erzin, Y., Çetin, T. (2012). The use of neural networks for the prediction of the critical factor of safety of an artificial slope subjected to earthquake forces. *Scientia Iranica*, 19 (2), 188-194. doi:10.1016/j.scient.2012.02.008
- [40]. Xiaoming, Y., Xibing, L. (2011). Bayes discriminant analysis method for predicting the stability of open pit slope, *2011 International Conference on Electric Technology and Civil Engineering (ICETCE) bildiriler kitabı içinde* (ss. 147-150). Lushan: IEEE. doi:10.1109/ICETCE.2011.5776304
- [41]. Mohamed, T., Kasa, A., Mukhlisin, M. (2012). Prediction of slope stability using statistical method and fuzzy logic. *The Online Journal of Science and Technology*, 2 (4), 68-73.
- [42]. Abdalla, J. A., Attom, M., Hawileh, R. (2012). Artificial neural network prediction of factor of safety of slope stability of soils, *14th International Conference on Computing in Civil and Building Engineering*. Moscow.
- [43]. Rashed, A. (2014). *A new prediction model for slope stability analysis*. Doktora tezi, Alma Mater Studiorum, Bologna.
- [44]. Qi, C., Tang, X. (2018). hybrid ensemble (topluluk) method for improved prediction of slope stability. *International Journal for Numerical and Analytical Methods in Geomechanics*, 1-17. doi:10.1002/nag.2834

- [45]. Gao, W., Raftari, M., Rashid, A.S.A., Muazu, M. A., Jusoh, W.A.W. (2020). A predictive model based on an optimized ANN combined with ICA for predicting the stability of slopes. *Engineering with Computers*, 36, 325-244.
- [46]. Foong, L.K., Moayedi, H. (2021). Slope stability evaluation using neural network optimized by equilibrium optimization and vortex search algorithm. *Engineering with Computers*, 1-15.
- [47]. Luo, Z., Bui, XN., Nguyen, H., Moayedi, H. (2021). A novel artificial intelligence technique for analyzing slope stability using PSO-CA model. *Engineering with Computers*, 37, 533-544. doi:10.1007/s00366-019-00839-5
- [48]. Moayedi, H., Osouli, A., Nguyen, H., Rashid, A.S.A. (2021). A novel Harris hawks' optimization and k-fold cross-validation predicting slope stability. *Engineering with Computers*, 37, 369-379. doi:10.1007/s00366-019-00828-8
- [49]. Zeng, F., Nait Amar, M., Mohammed, A.S., Motahari, M.R., Hasanipanah, M. (2021). Improving the performance of LSSVM model in predicting the safety factor for circular failure slope through optimization algorithms. *Engineering with Computers*. doi:10.1007/s00366-021-01374-y
- [50]. Zhang, H., Nguyen, H., Bui, XN., Pradhan, B., Asteris, P.G., Costache, R. ve diğerleri. (2021). A generalized artificial intelligence model for estimating the friction angle of clays in evaluating slope stability using a deep neural network and Harris Hawks optimization algorithm. *Engineering with Computers*. doi: 10.1007/s00366-020-01272-9
- [51]. Ivakhnenko, A.G. (1976). The group method of data handling in prediction problems. *Sov Autom Control Avtomatika*, 9, 21-30.
- [52]. Abdolrahimi, S., Nasernejad, B., Pazuki, G. (2014). Prediction of partition coefficients of alkaloids in ionic liquids based aqueous biphasic systems using hybrid group method of data handling (GMDH) neural network. *Journal of Molecular Liquids*, 191, 79-84.
- [53]. Naeini, S.A., Moayed, R.Z., Kordnaeij, A., Mola-Abasi, H. (2018). Elasticity modulus of clayey deposits estimation using group method of data handling type neural network. *Measurement*, 121, 335-343.
- [54]. Eichengreen, B., Park, D., Shin, K. (2014). Growth Slowdowns Redux. *Japan and the World Economy*, 32, 65-84.
- [55]. De Giorgi, M.G., Malvoni, M., Congedo, P.M., Comparison of strategies for multi-step ahead photovoltaic power forecasting models based on hybrid group method of data handling networks and least square support vector machine. *Energy*, 107, 360-373.
- [56]. Lambert, R.S.C., Lemke, F., Kucherenko, S.S., Song, S., Shah, N. (2016). Global sensitivity analysis using sparse high dimensional model representations generated by the group method of data handling. *Mathematics and Computers in Simulation*, 128, 42-54.
- [57]. Astakhov, V.P., Galitsky, V.V. (2005). Tool life testing in gundrilling: an application of the group method of data handling (GMDH). *International Journal of Machine Tools & Manufacture*, 45, 509-517.
- [58]. Bayat, H., Neyshabouri, M.R., Mohammadi, K., Nariman-Zadeh, N. (2011). Estimating water retention with pedotransfer functions using multi-objective group method of data handling and ANNs. *Pedosphere*, 21(1), 107-114.

- [59]. Najafzadeh, M., Barani, G.A., Hessami Kermani, M.R. (2013). Abudment scour in live-bed and clear-water using (GMDH). *Netw Water Sci Technol*, 67(5), 1121-1128.
- [60]. Pal, M., Mather, P.M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sens Environ*, 86, 554–565.
- [61]. Augusty, S.M., Izudheen, S. (2013). Ensemble classifiers a survey: evaluation of ensemble classifiers and data level methods to deal with imbalanced data problem in protein–protein interactions. *Rev Bioinform Biom*, 2(1), 1–9.
- [62]. Kondo, T., Ueno, J. (2012). Feedback GMDH-type neural network and its application to medical image analysis of liver cancer. 42th ISCIE International Symposium on Stochastic Systems Theory and Its Applications bildiriler kitabı içinde (ss. 81–82).
- [63]. Suresh, S., Saraswathi, S., Sundararajan, N. (2010). Performance enhancement of extreme learning machine for multi-category sparse data classification problems. *Engineering Applications of Artificial Intelligence*, 23, 1149–1157.
- [64]. Huang, G.B., Zhu, Q.Y., Siew, C.K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70, 489-501.
- [65]. Hai-Jun, R., Yew-Soon, O., Ah-Hwee, T., Zhu, Z. (2008). A fast prunedextreme learning machine for classification problem. *Neurocomputing*, 72, 359–366.