

CELAL BAYAR ÜNİVERSİTESİ * FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARININ GEOTEKNİK ALANINDA
KULLANIMI**

YÜKSEK LİSANS TEZİ

İnşaat Mühendisi Yeşim TUSKAN

Anabilim Dalı : İnşaat Mühendisliği

Programı : Geoteknik

MANİSA 2012

CELAL BAYAR ÜNİVERSİTESİ * FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARININ GEOTEKNİK ALANINDA
KULLANIMI**

YÜKSEK LİSANS TEZİ

İnşaat Mühendisi Yeşim TUSKAN

Tezin Enstitüye Verildiği Tarih : 11 Ocak 2012

Tezin Savunulduğu Tarih : 18 Ocak 2012

Tez Danışmanı : Yrd.Doç.Dr. Yusuf ERZİN

Diğer Jüri Üyeleri : Yrd.Doç.Dr. Mehmet SÖYLEMEZ

:Yrd.Doç.Dr. Ayşegül ALAYBEYOĞLU

MANİSA 2012

İÇİNDEKİLER.....	i
SEMBOL LİSTESİ.....	iv
ŞEKİL LİSTESİ.....	vi
ÇİZELGE LİSTESİ.....	x
KISALTMALAR LİSTESİ.....	xii
TEŞEKKÜR.....	xiii
ÖZET.....	xiv
ABSTRACT.....	xv
1.GİRİŞ.....	1
2.YAPAY ZEKA VE ÇALIŞMA ALANLARI.....	3
2.1 ZEKA.....	3
2.2 YAPAY ZEKA.....	4
2.3 BİLGİSAYAR-YAPAY ZEKA-ZEKA İLİŞKİSİ.....	5
2.4 YAPAY ZEKA TESTLERİ.....	6
2.4.1 Turing Testi.....	6
2.4.2 Çin Odası Testi.....	7
2.5 YAPAY SİNİR AĞLARI VE BİLEŞENLERİ.....	7
2.5.1 İnsanda Sinir Sistemi.....	9
2.5.2 Matematik Sinir Yapısı (Nöronun Matematik Modeli).....	10
2.5.3 Yapay Sinir Hücresi (İşlem Elemanı).....	11
2.5.4. İnsanda Sinir Sistemi ve Matematik Sinir Yapısı Özdeşlikleri.....	14
3.YAPAY SİNİR AĞLARININ ÖZELLİKLERİ.....	16
3.1. YAPAY SİNİR AĞLARININ GENEL ÖZELLİK VE AVANTAJLARI.....	17
3.2. YAPAY SİNİR AĞLARININ ÖNEMLİ DEZAVANTAJLARI.....	18
4.YAPAY SİNİR AĞLARININ KULLANIM ALANLARI.....	19
5.YAPAY SİNİR AĞLARININ HESAP YAPI VE MİMARİLERİ.....	23

5.1 YAPAY SİNİR AĞLARI HESAP ESASLARI.....	23
5.1.1 Öğrenme.....	23
5.1.2 Hatırlama.....	24
5.2. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI.....	24
5.2.1 Yapay Sinir Ağlarının Mimari Yapılarına Göre Sınıflandırılması.....	24
5.2.2 Yapay Sinir Ağlarının Öğrenme Yaklaşımlarına Göre Sınıflandırılması.....	28
5.3. YAPAY SİNİR AĞI YAPILARI.....	29
5.3.1 İleri Beslemeli Ağlar.....	30
5.3.1.1 Tek Katmanlı İleri Beslemeli YSA.....	30
5.3.1.2 Çok Katmanlı İleri Beslemeli YSA.....	31
5.3.1.3 Radyal Tabanlı İleri Beslemeli YSA.....	32
5.3.2 Geri Beslemeli Yapay Sinir Ağları.....	33
5.3.3 Bazı YSA Çeşitleri.....	33
5.4. YAPAY SİNİR AĞI MİMARİSİ.....	44
5.4.1 Ağ Katmanları.....	44
5.4.1.1 Tek Katmanlı Ağlar.....	44
5.4.1.2 Çok Katmanlı Ağlar.....	45
6. İNŞAAT MÜHENDİSLİĞİ SİSTEMLERİNDE YAPAY ZEKA TEKNİKLERİ İLE YAPILAN ÇALIŞMALAR.....	46
6.1 BULANIK MANTIK İLE YAPILAN ÇALIŞMALAR.....	46
6.2 SİNİRSEL BULANIK MANTIK İLE YAPILAN ÇALIŞMALAR.....	47
6.3 GENETİK ALGORİTMA İLE YAPILAN ÇALIŞMALAR.....	47
6.4 YAPAY SİNİR AĞLARI İLE YAPILAN ÇALIŞMALAR.....	48
7.GEOTEKNİK ALANINDA YAPAY SİNİR AĞLARININ KULLANIMI.....	49
7.1 KAZIK TAŞIMA GÜCÜ KAPASİTESİ.....	52
7.2 TEMELLERİN OTURMASI.....	71
7.3 ZEMİN ÖZELLİKLERİ VE DAVRANIŞI.....	85
7.4 SIVILAŞMA.....	96

8. SIVILAŞMA ANALİZLERİ.....	119
8.1.SIVILAŞMA POTANSİYELİ HESAP YAKLAŞIMLARI VE ÇEVİRİMLİ GERİLME YAKLAŞIM	119
8.1.1 Sismik Gerilme Oranının Bulunması.....	119
8.2 SIVILAŞMAYA TESİR EDEN ÖNEMLİ PARAMETRELERİN SEÇİMİ.....	120
8.2.1 SPT.....	121
8.2.2 DEPREM MAGNİTÜDÜ VE KAYMA DALGASI HIZI	122
8.2.3 İNCE TANE ORANI.....	123
8.2.4 MAKSİMUM DEPREM YÜZEY İVMESİ.....	123
8.2.5 YER ALTI SU SEVİYESİ.....	123
8.2.6 ZEMİN DERİNLİĞİ.....	123
 9.SIVILAŞMA POTANSİYELİ TAHMİNİNDE YAPAY SİNİR AĞININ KURULMASI.....	124
9.1. TRANSFER FONKSİYONU SEÇİMİ	124
9.2. SIVILAŞMA POTANSİYELİ TAHMİNİ İÇİN YAPAY SİNİR AĞININ EĞİTİLMESİ.....	125
 10. SONUÇLAR	128
10.1. MODEL KURULUMLARI.....	128
10.2. MODEL KARŞILAŞTIRMASI VE DUYARLILIK ANALİZLERİ.....	136
 KAYNAKLAR.....	138

SEMBOL LİSTESİ

a_{max}	:Yüzeydeki maksimum ivme
b	:Bias değerleri
C_R	:Sondaj takımı çubuğu düzeltme faktörü
C_S	:Numune elde etme yöntemine göre düzeltme
C_B	:Sondaj çukuru çapı düzeltme faktörü
C_E	:Tokmağın enerji oranının düzeltme faktörü
C_N	:Deney yapıları derinlikteki gerilmeyi normalize etmek için kullanılan faktör.
D_r	:Sıkılık derecesi
e	:Boşluk oranı
e_{max}	:Maksimum boşluk oranı
e_{min}	:Minimum boşluk oranı
ϕ	:İçsel sürtünme açısı
$G.S_{sıvılaşma}$	:Sıvılaşmaya karşı güvenlik sayısı
$\dot{I}TO$	: ince tane oranı
γ_n	:Zeminin doğal birim hacim ağırlığı
γ_d	:Zeminin doygun birim hacim ağırlığı
ρ_n	:Zeminin doğal yoğunluğu
ρ_d	:Zeminin doygun yoğunluğu
M	: Moment Magnitüdü
N	:Standart penetrasyon deneyi darbe sayısı
$N_{1,60}$	:Düzeltilmiş standart penetrasyon darbe sayısı
σ_{vo}'	:Düşey efektif gerilme
σ_v	:Toplam düşey gerilme

r_d	:Derinlik azalım faktörü
τ_{max}	:Maksimum kayma gerilmesi
τ_{ort}	:Ortalama kayma gerilmesi
$\tau_{eş}$	:Eşdeğer kayma gerilmesi
τ_r	:Yük boşalımındaki gerilme
V_s	:Kayma dalgası hızı
W	:Ağırlık vektörü
X	:Girdi vektörü
Y	:Çıkış vektörü
YASS	:Yer altı su seviyesi

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1. Basit bir YSA modeli.....	8
Şekil 2.2. Biyolojik sinir sisteminin blok gösterimi.....	9
Şekil 2.3. Nöronun biyolojik modeli.....	10
Şekil 2.4. Doğrusal aktivasyon fonksiyonu.....	13
Şekil 2.5. Sigmoid aktivasyon fonksiyonu.....	14
Şekil 2.6. Tanjant hiperbolik aktivasyon	14
Şekil 5.1. İleri beslemeli bir yapay sinir ağı yapısı.....	25
Şekil 5.2. Geri beslemeli bir yapay sinir ağı yapısı.....	26
Şekil 5.3. Eğitici öğrenme.....	28
Şekil 5.4. Eğitici öğrenme.....	28
Şekil 5.5. Destekleyici öğrenme.....	29
Şekil 5.6. İleri beslemeli ağ blok diyagramı.....	30
Şekil 5.7. Tek katmanlı ileri beslemeli yapay sinir ağı.....	31
Şekil 5.8. Çok katmanlı ileri beslemeli yapay sinir ağı.....	31
Şekil 5.9. Radyal tabanlı ileri beslemeli yapay sinir ağı.....	32
Şekil 5.10. Geri beslemeli ağ blok diyagramı.....	33
Şekil 5.11. Elman ağı.....	34
Şekil 5.12. Jordan ağı.....	34
Şekil 5.13. Hopfield ağı.....	35
Şekil 5.14. Uyarlanır Rezonans ağı genel yapısı.....	36
Şekil 5.15. Som ağı.....	37
Şekil 5.16. Öğrenme Vektör Nicelendirmesi (LVQ) İleri Beslemeli Yapay Sinir Ağı.....	38
Şekil 5.17. Öğrenme Vektör Nicelendirmesi (LVQ) İleri Beslemeli YSA topolojik yapısı.....	39
Şekil 5.18. Kohonen ağı.....	42
Şekil 5.19. Bir tek katmanlı lineer ağ.....	44
Şekil 5.20. Çok katmanlı katmanlı ağ.....	45

Şekil 7.1. YSA-Meyerhof denklemi kazık nihai taşıma gücü tahmini karşılaştırması.....	54
Şekil 7.2. Teorik oturma ve yapay sinir ağı tahmini karşılaştırması.....	55
Şekil 7.3. Kohezyonsuz zeminlerdeki çakma kazıkların kapasitesinin tahmininde YSA GRNNM1 ve diğer yöntemlerin karşılaştırması	57
Şekil 7.4. Kohezyonsuz zeminlerdeki çakma kazıkların kapasitesinin tahmininde YSA GRNNM2 ve diğer yöntemlerin karşılaştırması.....	58
Şekil 7.5. Kohezyonsuz zeminlerdeki çakma kazıkların kapasitesinin tahmininde YSA GRNNM3 ve diğer yöntemlerin karşılaştırması.....	58
Şekil 7.6. Kazık temelli yapılarda okyanus tabanı oyulma tahmininde kullanılan bir YSA mimarisi.....	59
Şekil 7.7. (a) Kazık grubu yerleşimi (b) okyanus tabanı oyulması.....	60
Şekil 7.8. Farklı tolerans değerlerinde YSA ve geleneksel yöntemlerin doğruluğu.....	61
Şekil 7.9. YSA ve diğer yöntemler için ölçülen karşısında tahmin edilen çekme yükleri.....	64
Şekil 7.10. Yapay sinir ağı mimarisi.....	65
Şekil 7.11. Bağlantı ağırlıklarını gösteren aksonlar ve girdilerin Q_v üzerindeki etkisini gösteren şema.....	65
Şekil 7.12. Farklı yöntemlerle elde edilen tahmini yük kapasitesi karşılaştırması.....	66
Şekil 7.13. $ANNM_{NFIK1}$ model mimarisi.....	67
Şekil 7.14. $ANNM_{NFIK1}$ model tahmini.....	68
Şekil 7.15. $ANNM_{NFIK}$ model tahmini.....	68
Şekil 7.16. Kazık birim yanal direnci için GMDH yapısı.....	68
Şekil 7.17. Ölçülen ve tahmin edilen kazık direnci karşılaştırması.....	69
Şekil 7.18. Tahmin edilen-ölçülen kazık yanal direncinin farklı yöntemlerle ifadesi.....	69
Şekil 7.19. (a) BPN-eğitim verisi (b) BPN-test verisi (c) HON-eğitim verisi (d) HON-test verisi ölçülen ve tahmin edilen değer karşılaştırması.....	70
Şekil 7.20. Yapay sinir ağı ve teorik oturma karşılaştırması.....	72
Şekil 7.21. Tahmin edilen ve gözlemlenen oturmaların farklı yöntemlerle irdelenmesi.....	73

Şekil 7.22. Tahmin edilen ve gözlemlenen oturmaların YSA yöntemi ile irdelenmesi.....	74
Şekil 7.23. Optimum yapay sinir ağı mimarisi.....	75
Şekil 7.24. Ölçülen ve tahmin edilen noktalar arasındaki karşılaştırma.....	75
Şekil 7.25. k Değeri Gamma Dağılımı.....	78
Şekil 7.26. Tünel projesi tipik yerleşim diyagramı (a)Tipik plan görünüş;(b)A-A kesiti;(c)B-B kesiti.....	79
Şekil 7.27. Yüzey oturmaları tahmini için iki tabakalı sinir ağı modeli yapısı.....	80
Şekil 7.28. Oturma tahmini geri beslemeli sinir ağı modeli yapısı.....	81
Şekil 7.29. Oturma tahmini sinir ağı modelinde hata-epoch gösterimi.....	81
Şekil 7.30. Tahmin modelleri için ölçülen-tahmin edilen RCS karşılaştırmaları.....	82
Şekil 7.31. Kazık örneğinde en iyi YSA modeli, Poulos ve Davis, Vesic, Das ve lineer olmayan t-z yöntemleri için tahmin edilen-ölçülen oturma değerleri.....	83
Şekil 7.32. Test veri setine göre tek gizli katmanlı YSA modeli için tahmin edilen-ölçülen oturma değerleri (a) 7 gizli katman nöronlu YSA, (b) 8 gizli katman nöronlu YSA.....	84
Şekil 7.33. (a) AC1 deneyi için eğitilmiş verilerle ACU deney sonuçlarının tekrarlı yapay sinir ağı modeli (RNN) ile simülasyonu, (b) IC2 deneyi için eğitilmiş verilerle ICU deney sonuçlarının tekrarlı yapay sinir ağı modeli (RNN) ile simülasyonu.....	87
Şekil 7.34. Tipik MLP tabanlı zemin temel modeli.....	91
Şekil 7.35. Silindirik, düzlem ve kama kayma mekanizmaları.....	92
Şekil 7.36. Bağlantı ağırlıklarının ϕ_r üzerindeki etkisinin gösterimi.....	94
Şekil 7.37. Ölçülen düşey şişme basıncı-YSA ile tahmin edilen düşey şişme basıncı ilişkisi.....	95
Şekil 7.38. YSA modeli.....	95
Şekil 7.39. Test sonuçlarının ve modellemenin karşılaştırılması.....	96
Şekil 7.40. CRR modelleri uygulanark türetilmiş haritalama fonksiyonu.....	104
Şekil 7.41. 1976 Tangshan Depremi sivilaşma sınırları ($M=7.8$, $a_{max}=0.2$, $\sigma_o'=100$ kPa).....	106
Şekil 7.42. YSA-2003 modeli ve MLR modeli arasındaki karşılaştırma(toplam 1 veri seti ile)..	108

Şekil 7.43. Figueroa ve diğ. Değerlendirmesi kapasite enerjisi modeli, (veri tabanındaki tüm elemanların test verisi olarak kullanılarak geliştirilmiş).....	110
Şekil 7.44. MLR-tabanlı kapasite enerjisi modeli, (veri tabanındaki tüm elemanların test verisi olarak kullanılarak geliştirilmiş).....	110
Şekil 7.45. Deneysel çalışmada kullanılan rezonans kolon test düzeneğinin basitleştirilmiş diyagramı.....	111
Şekil 7.46. Leighton Buzzard kum mika karşımı SEM fotoğrafı.....	112
Şekil 7.47. Sönümleme oranı (D) için en iyi YSA modeli.....	113
Şekil 7.48. Kesme modülü (G) için en iyi YSA modeli.....	113
Şekil 7.49. Hesaplan (FEM-QUAD4M) – tahmin edilen (YSA) en büyük ivmeye bağlı simik değerler 5 farklı PGA'ya göre grafikleştirilmesi.....	115
Şekil 7.50. Takip eden zaman periyodundaki en büyük sismik durumun magnitüd değerinin tahmini için oluşturulan PNN mimarisi.....	116
Şekil 7.51. Dalga-deniz tabanı etkileşim tanımı.....	116
Şekil 7.52. Dalga kaynaklı sıvılaşma tahmini için önerilen YSA mimarisi.....	117
Şekil 7.53. (a) BPN-eğitim verisi, (b) BPN-test verisi, (c) HON1-eğitim verisi, (d) HON2 test verisi.....	118
Şekil 8.1. Her hangi bir deprem durumunda sıvılaşmanın zor olduğu SPT değerleri.....	124
Şekil 10.1. Çalışmada kullanılan YSA'nın Yapısı.....	128
Şekil 10.2. Çalışmada kullanılan YSA'nın Yapısı ve parametreler.....	128
Şekil 10.3. Sıvılaşma potansiyeli güvenlik sayısı tahmininde, program ve YSA ile elde edilen değerlerin 4 deneme için ayrı ayrı karşılaştırması.....	133
Şekil 10.4. Sıvılaşma potansiyeli güvenlik sayısı tahmininde, program ve YSA ile elde edilen değerlerin 4. deneme için eğitim-test ve doğrulama karşılaştırması.....	135

ÇİZELGE LİSTESİ

Sayfa No

Çizelge 2.1. Aktivasyon Fonksiyonları ve Açıklamaları.....	12
Çizelge 2.2. Sinir Sistemi-YSA Sistemi Karşılaştırması.....	15
Çizelge 5.1 Yapay Sinir Ağı Çeşitleri.....	30
Çizelge 7.1. Kazık kapasitesi tahmini regresyon analiz sonuçlarının özeti.....	52
Çizelge 7.2. Kazık kapasitesi tahmini regresyon analiz sonuçlarının özeti(Hiley ,Janbu;YSA)..	53
Çizelge 7.3. ANOVA deney sonuçları.....	62
Çizelge 7.4. YSA girdi ve çıktı parametreleri.....	63
Çizelge 7.5. Garson algoritmasında farklı girdilerin göreceli önemi ve bağlantı ağırlıkları yaklaşımı.....	66
Çizelge 7.6. YSA model mimarileri.....	67
Çizelge 7.7. Hata oranlarının YSA ve diğer yöntemlerde karşılaştırması.....	74
Çizelge 7.8. k Değeri Gamma Dağılımı	78
Çizelge 7.9. Çok katmanlı yapay sinir ağı (MLP) modeli girdi ve çıktıları.....	90
Çizelge 7.10. Sakellariou ve Hlias YSA modeli ile Bayezyen YSA modelinin karşılaştırılması....	93
Çizelge 7.11. YSA modellerinde test ve eğitim setlerinin istatistiksel parametreleri.....	96
Çizelge 7.12. Sembol dizini ve açıklamaları.....	113
Çizelge 9.1. YSA modelinde kullanılan girdi parametreleri sınır değerleri.....	125
Çizelge 9.2. Sıvılaşma potansiyelini tahminde geliştirilen YSA modeli için Ağırlık ve Bias değerleri (1. Deneme).....	126

Çizelge 9.3. Sıvılaşma potansiyelini tahminde geliştirilen YSA modeli için Ağırlık ve Bias değerleri (2. Deneme).....	126
Çizelge 9.4. Sıvılaşma potansiyelini tahminde geliştirilen YSA modeli için Ağırlık ve Bias değerleri (3. Deneme).....	127
Çizelge 9.5. Sıvılaşma potansiyelini tahminde geliştirilen YSA modeli için Ağırlık ve Bias değerleri (4. Deneme).....	127
Çizelge 10.1. Sıvılaşma potansiyeli güvenlik sayısı tahmininde kullanılan değişkenlere göre program ve YSA ile elde edilen değerlerin karşılaştırması.(Eğitim -1. Deneme).....	129
Çizelge 10.2. Sıvılaşma potansiyeli güvenlik sayısı tahmininde kullanılan değişkenlere göre program ve YSA ile elde edilen değerlerin karşılaştırması.(Eğitim -2.Deneme).....	130
Çizelge 10.3. Sıvılaşma potansiyeli güvenlik sayısı tahmininde kullanılan değişkenlere göre program ve YSA ile elde edilen değerlerin karşılaştırması.(Eğitim -3.Deneme).....	131
Çizelge 10.4. Sıvılaşma potansiyeli güvenlik sayısı tahmininde kullanılan değişkenlere göre program ve YSA ile elde edilen değerlerin karşılaştırması.(Eğitim -4.Deneme).....	132
Çizelge 10.5. Duyarlılık analizi ile parametrelerin etkinliğinin ölçülmesi.....	137
Çizelge 10.6. Performans parametreleri.....	137

KISALTMALAR LİSTESİ

ADALİNE	:Adaptif Lineer Nöron
ANOVA	:Tek Değişkenli Varyans Analizi
CPT	:Koni Penetrasyon Deneyi
CPU	:Merkezi İşlem Birimi
İTO	:İnce Tane Oranı
MADALİNE	:Çoklu Adaptif Lineer Nöron
MAE	:Ortalama Mutlak Hata
MLP	:Çok Katmanlı Algılayıcı
MSE	:Ortalama Hata Kareleri
RMSE	:Ortalama Hata Kareleri Kökü
SPT	:Standart Penetrasyon Deneyi
VAF	:Varyans
YASS	:Yer Altı Su Seviyesi
YSA	:Yapay Sinir Ağı

TEŞEKKÜR

Bu çalışma Celal Bayar Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Ana Bilim Dalı'nda, yüksek lisans tezi olarak hazırlanmıştır.

Bu tez çalışmasında beni yönlendiren, her türlü eksikliklerimi tamamlayan ve araştırmalarımda bana her zaman yol gösteren Danışman Hocam Sayın Yrd. Doç. Dr. Yusuf ERZİN'e teşekkürlerimi ve saygılarımı sunarım.

Eğitim hayatım boyunca hayatımın her alanında olduğu gibi desteklerini esirgemeyen aileme ve dostlarıma sonsuz teşekkürlerimi ve saygılarımı sunarım.

YAPAY SİNİR AĞLARININ GEOTEKNİK MÜHENDİSLİĞİNDE KULLANIMI

ÖZET

Sıvılaşma, döngüsel boşluk suyu basıncı mekanizmasına dayalı kesme kuvvetindeki azalmanın dış etkisi olarak ortaya çıkan bir durumdur. Sismik bir olay etkileşimi sırasında, doymuş ince taneli kohezyonsuz zeminlerde geçici olmakla birlikte, toplam sonuç açısından zemin kütlelerinin taneler arası boşluklarını dolduran suyun ani yükselişine bağlı taneler arası gerilme kaybı gerçekleşmektedir (ASCE, Kartam, Flood, 1997).

Bu çalışmada Seed ve Idriss tarafından önerilen Seed Yöntemi sıvılaşma potansiyelini tahminde kullanılmıştır. Bu SPT-N tabanlı sıvılaşan ve sıvılaşmanın olmadığı durumları ayıran güvenlik sayısı kullanan yöntemde, zemin döngüsel direnç oranına (CRR) bağlı olarak, çevrimsel gerilme oranı (CSR) hesaplanır. Zemin ince oranı (İTO), deprem magnitudu (M), yüzeydeki maksimum ivme (a_{max}), doymuş birim hacim ağırlık (γ_d) ve doğal birim hacim ağırlık (γ_n) ile yeraltı su seviyesi CRR tahmininde birlikte düşünülmektedir. Derinlik azalım faktörü (r_d) için Seed ve Idriss tarafından önerilen ve farklı derinlik sınırları için kullanılan bağıntı uygulanmıştır ($z \leq 9.15m$, $9.15 m < z \leq 23m$).

Hasar göstergesi olarak güvenlik katsayısı (G.S.) olgusu, inşaat mühendisliğinde çokça başvurulmuş bir uygulamadır. Güvenlik katsayısı $G.S.=CRR/CSR$ şeklinde hesaplanır. $G.S.\leq 1$ olması durumunda sıvılaşmanın gerçekleşeceği, $G.S.>1$ durumunda ise sıvılaşmanın gerçekleşmeyeceği söylenmektedir.

Zeminlerin yüksek derecedeki doğrusal olmayan davranışları için kullanılan çeşitli sayısal modelleme tekniklerinin sınırlamaları, geoteknik yaklaşımlar için aynı zamanda karmaşık ve zaman alıcı olarak da nitelendirilir. YSA ile karmaşık girdi/çıkı ilişkilerini temsil edebilecek güçlü bir veri modelleme aracıdır. YSA iki yönüyle insan beyniyle benzerlik gösterir; ilk olarak YSA öğrenme yoluyla bilgi edinir ve ikinci olarak elde ettiği bilgiyi sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantılarla saklarlar (Baykasoğlu ve diğerleri, 2009). Bu çalışmada YSA sıvılaşma güvenlik katsayısını tahminlemede kullanılmıştır. Levenberg-Marquardt algoritmaları ileri beslemeli geri yayımlı bir yapay sinir ağı modeli çevrimsel gerilme oranı yardımıyla hesaplanan sıvılaşma potansiyeli güvenlik sayısı tahmini için geliştirilmiştir. Transfer fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. ayrıca çeşitli performans belirleme araçları olarak, determinasyon katsayısı (R^2), varyans hesabı (VAF), ortalama mutlak hata (MAE) ve ortalama hata kareleri kötü (RMSE) kapasite kontrolü için kullanılmıştır. Elde edilen verilerle YSA modelinin yüksek tahmin performansı gösterdiği açıkça gözlemlenmektedir. Duyarlılık analizi de, sıvılaşma potansiyeli tahminini etkileyen faktörlerin görece önemini incelemek için uygulanmıştır.

Anahtar Kelimeler: Yapay sinir ağları, Sıvılaşma potansiyeli, Standart penetrasyon deneyi

THE USE OF NEURAL NETWORKS IN GEOTECHNICAL ENGINEERING

ABSTRACT

Liquefaction is an external manifestation of decrease in shear strength, due to the cyclic pore-pressure generation mechanism. During a seismic event agitation of saturated fine grained cohesionless soils can result transient, but total, loss of intergranular stress due to a sudden rise in the water filling the intergranular voids of the soil mass (ASCE, Kartam, Flood, 1997).

In this study, Seed's method proposed by Seed and Idriss used to estimate liquefaction potential. This SPT-N based method using factor of safety for separate liquefaction and non-liquefaction situations, compute the cyclic stress ratio (CSR) due to the cyclic resistance ratio (CRR) of soils. The effects of fines content (FC), earthquake magnitude (M), Horizontal peak ground acceleration, (a_{max}), saturated unit weight (γ_d) and natural unit weight (γ_n) of soil with ground water level incorporated in the CRR estimation. For the stress reduction factor (r_d) the relationship suggested by Seed and Idriss used in different depth limits ($z \leq 9.15\text{m}$, $9.15\text{ m} < z \leq 23\text{m}$).

The concept of factor of safety (FS) against damage was commonly employed in the design in civil engineering. Then the factor of safety (FS) can be calculated as $FS = CRR/CSR$. Liquefaction is said to occur if $FS \leq 1$, and no liquefaction occurs if $FS > 1$.

The limitations of various numerical modeling techniques, for highly non-linear behavior of soils is also considered to be complex and time-consuming for geotechnical approaches. ANN is a powerful data modeling tool that is able to capture and represent complex input/output relationships. ANNs resemble the human brain in two aspects; firstly an ANN acquires knowledge through learning and secondly an ANN's knowledge is stored within inter-neuron connection strengths known as synaptic weights (Baykasoğlu et al., 2009). In this study, ANN were used to predict the liquefaction factor of safety. a feed forward with Levenberg–Marquardt algorithm, back propagation neural network model is developed to predict the liquefaction potential due to factor of safety calculated by cyclic stress ratio (CSR). The sigmoid function is used as the transfer function. Moreover, several performance indices such as determination of coefficient (R^2), variance account for (VAF), mean absolute error (MAE), and root mean square error (RMSE) were calculated to check the prediction capacity of the ANN model. The obtained indices make it clear that the developed ANN model has shown high prediction performance. Sensitivity analyses were also carried out to examine the relative importance of the factors affecting liquefaction potential prediction.

Key Words: Artificial neural networks, Liquefaction potential, Standard penetration test

1.GİRİŞ:

“Yapay Zeka” isminin ortaya atıldığı Dartmouth Konferansı öncesi, 1950 yılında, “Mind” adlı felsefe dergisinde Turing tarafından yayınlanan “Computing Machinery and Intelligence” adlı bir makalede “Makineler düşünebilir mi?” sorusu felsefi tartışma ortamına taşınmıştır.

1936 yılında yine Turing, bilgisayar tasarımının mantıki temelleri ile ilgili yazmış olduğu makalede matematiksel mantıkta soyut bir problem ile ilgilenmiştir. Turing makinesi olarak adlandırılan ve program depo eden genel amaçlı bilgisayarın icadı da yine aynı dönemde gerçekleşmiştir. Turing makinesi kuramsal bir hesap makinesi olarak tasarlanmıştır. Hesaplar ise, karelere bölünmüş ve her karede yalnızca bir sembol içerebilen bir bant aracı ile yapar. Bu sistemde, bir karedeki sembol okunduğu zaman içinde bulunduğu durum ve sembolün ne olduğuna göre durumu değişebilmektedir. Turing’in yapay zeka konusunda sinir ağları ile kesişimi ise Turing testi ile gerçekleşmektedir.

Alan Turing, Turing testi olarak adlandırılan ve bir bilgisayarın veya başka bir sistemin insanlarla aynı zihinsel yetiye sahip olup olmadığını ölçen bir test geliştirmiştir. İleriki bölümlerde makine ve insan performansını karşılaştırma da bu yöntemle değinilecek ayrıca, ‘yapay sinir ağı’ konusuna geçiş değerlendirmesi yapılacaktır (Turing, 1950).

Yapay Zeka araştırmaları Turing makinesiyle başlamış, bir bilim dalı olarak kabul edilmesi ise, Newel ve Simon’un mantık teoristi ile sağlanmıştır. 1950’lerde ilk yapay zeka programları; Samuel’in kontrol edici programı, Newell ve Simon’un mantık teoristi ve Gelernter’in geometri motorudur. Yapay zeka, yapılan araştırmalardan da anlaşılacağı üzere, bilgisayar biliminin, insan beyninin otomasyonunu, çalışma şeklini, bilgi saklama ve işleme yeteneklerini araştıran ve kullanan dallarından biridir. Yapay zekada temel olarak sembolist ve bağlantıcı olarak adlandırılan iki yaklaşım bulunmaktadır. Sembolist yaklaşımda kavramların, olayların sembollerle temsil edildiği zeki sistemler üzerinde çalışılırken, bağlantıcı yaklaşımda nöron adı verilen temel işleme birimleri ve bu birimlerin birbirine yoğun bir biçimde bağlanmasından oluşan yapay sinir ağları kullanılmaktadır. (Halıcı, Akman, Leloğlu, 1993)

Temelde yapay sinir ağları, insan beyninin mimarisinden yola çıkılarak düzenlenmektedir. Bu konudaki ilk teoriler Mc Culloch ve Pitts tarafından 1943 yılında ortaya atılmıştır. Daha sonra Hebb’in çalışması (Hebb’in öğrenme teorisi, 1949) insan beyninin nöronlarının nasıl öğrendiklerini ortaya koymaya çalışmıştır. 1958 yılında Rosenblatt algılama üzerinde durmuştur.

Yapay sinir ağıları hakkında en başarılı uygulamalar 1960'lı yıllarda Widrow ve Hoff tarafından geliştirilmiştir. Paul Werbos 1974 yılında Widrow – Hoff prosedürü için karşıt hata görevleri yapısını teklif etmiş, böylece daha önceki tek-katman kısıtı elemine edilmiş ve pek çok kısıtlı süreç hesaplanabilmiştir. Diğer gelişmeler büyük ölçüde Kolmogorov'un (1957) süper durum teoreminden esinlenmiştir. Bu bize sürekli fonksiyonların doğrusal olmayan sonuçlarla doğrusal sonuçların bütünleştirilmesiyle hesaplanabileceğini göstermiştir (Krycha, Wagner, 1999).

Başlıca bilişsel süreçler; algılama, öğrenme, seçici dikkat, hedef belirleme olarak ifade edilebilir. Ortamdaki nesneler ve sistemin gereksinimleri ile beraber içsel durum tarafından belirlenen süreçlerin anlaşılması ve modellenmesi, nörobiyoloji, psikoloji, matematik, elektrik mühendisliği veya bilgisayar mühendisliği gibi değişik alanların ortak konusu olan bir multidisipliner yapıdır. Bu süreçlere benzerliklerden yararlanılarak geliştirilen yapay sinir ağı sistemlerinde ise amaç çok genel olarak, sistemin ortamda bulunan birçok nesne ve uyarının arasında kendi gereksinimine ve içsel durumuna göre bazılarını öncelikle algılamasıdır. Yapay sinir ağının bilişsel süreçleri izleyerek; algılanan durumlar arasında bağlantılar kurması, beklentiler oluşturması, iç ve dış uyarıların durumuna göre hedefler belirleyip bunlarla ilgili eylemlerde bulunması ve eylemlerin ortam üzerindeki sonuçlarına göre yeni hedefler belirlemesidir.

Gerçek dünyadaki problemlerin çözümü için de problemi çözecek en uygun hesap modeli seçilir. Modelleme amacıyla kullanılan hesap yöntemlerini genel olarak matematik eşitlikler, modelden bağımsız yöntemler ve bulanık sistemler olarak üç ana gruba ayırabiliriz. Bunlardan kapalı formdaki matematik eşitlikler, çok az karmaşıklık ve belirsizlik içeren sistemlerde sistem tanımlama için çok elverişlidir. Biraz daha karmaşıklık içeren fakat anlamlı sayısal verilere dayalı sistemler için, yapay sinir ağıları gibi modelden bağımsız yöntemler öğrenme yoluyla belirsizliği azaltarak güçlü ve sağlam sonuçlar üretebilmektedir. Son olarak az sayıda sayısal verinin, eksik ve belirsizlik içeren bilgilerin bulunduğu en karmaşık sistemlerin tanımlanmasında ise bulanık ilişkilendirme giriş ve çıkış bilgileri arasında belli esaslara bağlı olarak ifade edilen dönüşüm ile sistemin davranışı hakkında bilgi edinmemizi sağlarlar (Akyılmaz, 2005).

Son yıllarda yapay zeka konusunda yapılan araştırmalar, insan beyninin öğrenme ve karar verme fonksiyonlarını taklit eden Yapay Sinir Ağları (Artificial Neural Networks, ANN) üzerinde yoğunlaşmıştır.

2.YAPAY ZEKA VE ÇALIŞMA ALANLARI

2.1.Zeka

Yapay zeka ve yapay zekanın inşaat mühendisliği geoteknik alanındaki alt çalışma alanları ile sınılaşma probleminin irdelendiği tez çalışmasına, ilk bölümde zeka kavramını açıklayarak başlamak daha uygun olacaktır. İnsanoğlu yeni buluşlarının büyük bir kısmında doğadaki izlenimlerinden yararlanmıştır. İnsanoğlunun son yüzyıldaki en büyük buluşlarından biri olan bilgisayarlar dahi insanın bilişsel yapısı ve sinir sistemi taklit edilerek geliştirilmiştir. İnsan ve bilgisayarın bilgiyi işleme sistemlerinde bile birçok benzerliğe rastlamak mümkündür. Miller'ın (1956) ortaya koyduğu "Bilgiyi İşleme Teorisi"ne göre bireyin belleğinde bir bilginin depolanabilmesi için dikkat, algı ve kodlama gibi bir takım süreçlerden geçmesi gerekmektedir. Bu kurama göre insanda üç tür bellek bulunmaktadır (Miller, 1956).

Bunlar (1) Duyusal Kayıt, (2) Kısa Süreli Bellek ve (3) Uzun Süreli Bellektir. Bir bilgisayarın işlem süreci incelendiğinde de RAM (Random Access Memory / Rasgele Erişilebilir Bellek), CPU (Central Processing Unit / Merkezi İşlem Birimi), ve Harddisk (Sabit Disk) gibi donanımların insan bilişsel sistemine benzer bir yapıda organize edildikleri görülmektedir.

Kavramlar ve algılar yardımıyla soyut ya da somut nesneler arasındaki ilişkiyi kavrayabilme, soyut düşünme, muhakeme etme ve bu zihinsel işlevleri uyumlu şekilde bir amaca yönelik olarak kullanabilme yetenekleri zeka olarak adlandırılmaktadır (Koçer 2006). Bu tanım günümüzde en sık olarak kullanılan zeka tanımıdır. Bir çok filozof ve psikolog tarafından ise farklı şekillerde zeka tanımlamaları yapılmıştır.

Binet ve arkadaşları ilk kez 1905 yılında Fransa'daki okullarda öğrenme zorluğu çeken öğrencileri diğerlerinden ayırt etmek amacıyla bir zeka testi geliştirmeye başlamışlar ve bu teste Binet-Simon adı verilmiştir. Binet'e göre zeka, bellek alanı, duyum keskinliği ve tepki hızı gibi basit zihni öğelerle değil, kavrama, hüküm verme, akıl yürütme ve düşünceye belirli bir yön verme, düşünceyi arzu edilen bir gayenin gerçekleşmesine intibak ettirme ile kendi kendini eleştirme, kendi yanlışlarını bulup düzeltme gibi karmaşık işlemlerde kendini gösterir. Bu yıllardan sonra bu testler geliştirilerek farklı yaş gruplarına uygulanır hale getirilmiştir. Ancak bu testlerin en büyük özelliği zekayı sayısal bir değerle ölçmeleri ve zekayı tek boyutta ele almalarıdır. Zeka daha bir çok bilim adamı tarafından farklı şekillerde tanımlanmıştır. Hepsinde ortak görüş ise zekanın kalıtım ve çevrenin ortak ürünü olmasıdır. Tüm bunlarla birlikte zekanın iyileştirilebilir, geliştirilebilir ve değiştirilebilir olduğu, çeşitli yollarla sergilenebildiği, gerçek hayat

durumlarından veya koşullarından da soyutlanamayacağı belirtilmektedir(Gardner,1993; Erkoç,2008). Belirtilen bu tanımlarla birlikte zekanın daha birçok tanımı yapılmaktadır.

2.2. Yapay Zeka

Yapay zeka, birçok insan için farklı çağrışımlar yaratabilmektedir. Kimine göre, insan beynine benzer yapıda bir elektronik cihaz, kimine göre ise insanın düşünme yeteneklerine sahip ve insanın yerini alabilecek elektromekanik bir robotu çağrıştırmaktadır. Fakat yapay zeka alanı ile ilgilenen ya da konu hakkında fikri olan insanlar makineler ile insan arasında kesin bir farklılığın olduğu bilincindedir. 2000'li yılların en önemli kavramlarından biri haline gelen yapay zeka, akıllı makineler veya makinelerin akıllanması gibi kavramların da ortaya çıkmasına ortam hazırlamıştır. Geliştirilen tüm yapay zekaya sahip makineler robotiğin 3 kuralına göre tasarlanmaktadır. Nöroloji ve psikoloji alanlarında yapılan çalışmaların sinir hücrelerinin yapısı ve sinir ağlarının çalışma biçimlerindeki bilinmeyenleri aydınlatmada kat edilen yol, yapay sinir ağlarının gelişimine önemli katkılar yapmıştır (Erkoç, 2008).

Basit mantık önermelerini semboller ile gösteren ingiliz matematikçi George Boole, 1847' de yayımladığı "Mathematical Analysis of Logic"adlı eserinde, mantığa cebir yöntemlerinin uygulanabilirliğini göstermiştir. Daha sonra gerek sibernetik ve otomat ve gerekse yapay zeka tekniği konusunda yoğun çalışmalar başlamıştır. Bu çalışmalar içerisinde, insan beyninin simülasyonuna dayanan yapay sinir ağları geniş bir uygulama alanı bulmuştur (Hertz at al., 1991).

İnsan beyninin; öğrenme, hatırlama, karar verme ve sonuç çıkarma gibi özellikleri teorisyenlerin her zaman ilgisini çekmiştir. Bu amaçla 20. yüzyılın ortalarında, klasik Von-Neumann ilkesiyle seri olarak çalışan bilgisayarların yerine, bilgiyi daha esnek ve daha hızlı işleyen bilgisayarlar yapmak için araştırmacılar yoğun bir çalışma başlatmıştır. Bu çalışmaların hemen hepsindeki temel amaç, beynin paralel olarak çalışma, öğrenme, karar verme, esneklik ve yeni duruma adaptasyon özelliklerinin modellenmeye çalışılmasıdır.

1940'dan önce Helmholtz, Pavlov, Poincare gibi bazı bilim adamlarının yapay sinir ağları kavramı üzerinde çalıştıkları bilinmektedir, ancak bu çalışmaların matematiksel bir tabanı yoktur. 1940'lı yıllarda McCulloch ve Pitts, Hebb, Rosenblatt gibi bilim adamlarının bu konudaki çalışmaları yapay sinir ağlarının çalışmalarının mühendislik alanına kayması ve günümüzdeki yapay sinir ağlarının temelini oluşturmasına neden olmuştur.

1958 yılında Frank Rosenblatt tarafından geliştirilen “Perceptron” yapay sinir ağlarındaki çalışmaları hızlandırmıştır. Perceptron tek katmanlı, eğitilebilen ve tek çıkışa sahip olan bir yapay sinir ağıdır. Perceptronun daha sonra geliştirilecek ve yapay sinir ağları çalışmalarında devrim kabul edilen çok katmanlı yapay sinir ağlarının temelini oluşturması açısından tarihsel önemi vardır.

1959 yılında Bernard Widrow ve öğrencisi Marcian Hoff, ADALINE (ADaptive LInear NEuron) modelini ortaya atmışlardır. Yapay sinir ağlarının mühendislik uygulamalarında kullanılmaya başlanması için atılan ilk adımlardan biri olan bu model, 1970'lerin sonlarında ortaya çıkan ve ADALINE modelinin çok katmanlı hali olan MADALINE'nın temelini oluşturur. Telefon hatlarında oluşan yankıları yok eden bir sistem olarak kullanılması ile de gerçek dünya sorunlarına uyarlanmış ilk yapay sinir ağı unvanını alır (Öztemel, 2003).

2.3. Bilgisayar - Yapay Zeka ve Zeka İlişkisi

Yapay zeka daha önceki tanımlamalarda da yapıldığı gibi basit anlamda insan zekasını taklit eden sistemlerdir. Zeka yetisine sahip olan tek organ da beyin olduğuna göre kabaca beyin yapısına bir göz atmak uygun olacaktır. Beyin, birbiriyle karmaşık ilişkiler içinde bulunan sinir hücreleri (nöron) kitlesinden oluşmaktadır. En genel manada bakıldığında beyin, aktivitelerin bir kontrol merkezi durumundadır. İnsan zekasını, duyarlar tarafından alınan uyarıcıların yorumlanarak tepkilerin oluşturulmasını ve bu tepkilerin kontrolünü sağlamaktadır. Beynin küçücük yapısı altında çok fazla bilinmeyeninin olması, birçok disiplini barındıran nörolojik bilimler alanında çalışmaların yoğunlaşmasına neden olmaktadır. En basit şekilde düşünüldüğünde beyin 1 cm^3 'lük bir bölgesinde bir trilyon bağlantıya sahip, 100 milyar sinir hücresi bulunmaktadır. Bu 100 milyar sinir hücresi arasında saniyede 10 milyon x milyar kere uyarı iletimi olmaktadır. Sadece bu kadar bilgiden bile anlaşılacağı gibi, insan beyni hiç bir bilgisayarla karşılaştırılamayacak kadar karmaşık ve üstün bir sisteme sahiptir (Erkoç, 2008).

Yapay zeka araştırmalarının ana amacı insan bilgi işleme prensiplerinin anlaşılması ve biyolojik sinir sistemlerinin çalışma mekanizmalarının çözülmesidir. Bu mekanizmaların gerek araştırılması gerekse geliştirilmesinde bilgisayarlar önemli bir yer tutmaktadır (Sağıroğlu ve diğerleri, 2003).

Bilgisayarların geliştirilmesi yapay zeka alanındaki çalışmaların hız kazanmasına, yapay zekanın gelişmesi de bilgisayar bilimlerindeki gelişmelere zemin hazırlamıştır. Yapay zekanın çalışma alanının genişlemesi özellikle beyin daha iyi anlaşılması için nöropsikolojik, psikolojik ve buna benzer davranışların üç boyutlu olarak algılanabilmesini sağlamıştır. Bu katkılar da

doğal olarak yapay zeka tekniklerini gelişmesine katkıda bulunacaktır (Sağıroğlu ve diğerleri, 2003).

Bilgisayarların hızı, işlemci, bellek ve depolama birimlerinin hız ve kapasiteleri ile yapay zeka sistemleri ise hesaplama gücü, problem çözümünde kullanılan yöntem ve hafıza ile değerlendirilmektedir. İnsan beyinde ise sinir hücrelerinin birbirleri ile iletişim hızları hesaplama gücünü ortaya koymaktadır. İşlemci hızı yapay zeka da işlem hızını, dolayısıyla hesaplama gücünü belirtir. Yapay zeka sistemlerinde karşılaşılan bir problem için geliştirilen yöntem ve yol, insan zekası için algılama, çözümleme ve tepki verme psikolojisini ortaya koymaktadır. İnsan için öğrenilen bilgiyi depolayan bellek, yapay zeka sistemlerinde bilgisayarın depolama elemanı ile ölçülür (Erkoç, 2008).

Yapay sinir ağları, insan beyninin çalışma mekanizması taklit edilerek geliştirilen ve beynin gerçekleştirdiği temel işlemlere belirli bir yazılımla ulaşmayı amaçlayan bir mantıksal programlama tekniğidir, (Civalek,1998).

Yapay zeka tekniklerinden biri olan yapay sinir ağları (YSA), insan beyindeki sinirlerin çalışmasına benzetip sistemleri öğrenme, ilişkilendirme, sınıflandırma, genelleme yapma, tahmin etme, özellik belirleme, hatırlama, optimizasyon gibi yetenekler kazandırmayı amaçlayan bir bilgi işleme sistemidir. İnşaat mühendisliğinin birçok alanında olduğu gibi, geoteknik mühendisliğindeki problemlere de YSA uygulanmış ve oldukça yüksek oranda başarı elde edilmiştir.

2.4 Yapay Zeka Testleri

Yapay zeka tanımı yapılırken insan zekasını taklit eden sistemler olduğundan bahsedilmişti. İnsan zekasının bir özelliği olan düşünebilme, yapay zeka sistemlerinde gerçekleştirilebilme ideallerinden birisidir. “Bilgisayarlar gerçekten insanlar gibi düşünebilirler mi?” sorusu değişik boyutları ile incelenmiştir.

2.4.1 Turing Testi

“Bilgisayarlar düşünebilir mi?” sorusuna açıklık getirmek için, trajik bir hayat süren ünlü İngiliz matematikçi Alan Turing (1912-1954), bir taklit oyununu önermekteydi. 1950 senesinde “Mind” (Us) dergisinde basılmış “Computing Machinery and Intelligence” başlıklı makalesinde Turing, bir makinenin düşünmesi ile ilgili açıklamaların mantıksal olarak mümkün olup olmasını amaçlamaktaydı. “Turing Testi” olarak bilinen bu oyunda bilgisayar, oyuncu ve sorgulayıcı (savcı) olmak üzere üç oyuncu iştirak etmektedir. İki farklı haberleşme kanalı üzerinden savcı insan ve bilgisayarla iletişim kurmaktadır. Savcı görmediği insan ve bilgisayara

sorular yönelmektedir. Sorulara verilen yanıtlara göre savcı yanıtların sahibinin bilgisayar mı yoksa insan mı olduğunu anlamaya çalışmaktadır. Merak edilen makinenin bir insan kadar anlamlı yanıtlar verebilmesini mümkünlüğünü test etmektir (Nabiyev 2005). Turing testine göre her iki kaynaktan gelen yanıtlar arasında bir seçim yapılamıyorsa makine zekidir denilebilir (Erkoç, 2008).

Bir bilgisayarın insan zekasını taklit etmesi aslında çok kolay bir konu değildir. Bilgisayar kendisine üst üste tekrarlanan sorulara dürüstlikle hep aynı cevabı vermeye çalışır. Oysa insan akıl sahibi ve düşünen bir varlık olduğundan kendisine üst üste tekrarlanan sorulara farklı şekillerde cevap verecek ve bir süre sonra da mantığını kullanarak tekrarlanan sorulardan rahatsızlığını dile getirecektir. Turing testi birçok açıdan bir takım zaaflara sahipti. Söylenenleri doğru şekilde yaparak Turing testini geçse bile, makinelerin düşünüp anlama yeteneğine sahip olamayacağını savunan John Searle, Çin Odası Testi'ni önermekteydi (Nabiyev, 2005).

2.4.2 Çin Odası Testi

Çin odası testi Turing testine alternatif olarak John Searle tarafından önerilmiştir. Kapalı bir odada Çince bilmeyen birisi, üzerine Çince yazılar yazılmış tabelaları ve bu tabelaları açıklayan bir kural kitabı bulundurmaktadır. Kurallar Çinceyi tamamen biçimsel olarak, yani söz dizimlerine göre açıklamaktadır. Sonra kapının altından soru biçiminde Çince yeni tabelalar iletilmektedir. Bunlara yanıt olarak hangi tabelanın dışarıya verilmesi gerektiği var olan simgeleri karıştırarak bulunabilir. İçerideki kişi dışarıda bulunan gözlemciye göre sanki Çince anlayan bir insan gibidir. Çince anlamak için en uygun kurallar bile aslında Çince anlamayı sağlamıyorsa, bir bilgisayar programının da Çince anlaması olanaklı değildir. Bilgisayarda da insan da olduğu gibi, açıklanmamış Çince simgeleri içeren biçimsel bir program vardır ve bir dili anlamak, yalnız biçimsel simgeleri ve yapıları bilmek değildir (Nabiyev, 2005).


Bazı programlar basit bir biçimde de olsa Turing testini geçebilmiştir. Bunlara örnek olarak, 1969-1970 yıllarında M.I.T 'de Yapay zeka alanında çalışan Terry Winograd tarafından yazılan ve doğal dilde verilen emirleri anlayan SHRDLU (Winograd, Erişim:25.12.2006) veya Joseph Weizenbaum tarafından yazılan ve psikiyatri görevini yapan ELIZA (Weizenbaum 1966) gösterilebilir. Ancak ELIZA kullanıcıdan aldığı cümlelerdeki anahtar kelimeleri belirler ve bu anahtar kelimeleri kullanarak cevaplar oluşturur. Yani aslında kullanıcıyı anlamamakta sadece simgeler ve yapıları kullanarak zekaya sahipmiş gibi davranmaktadır (Erkoç, 2008).

2.5 YAPAY SİNİR AĞLARI VE BİLEŞENLERİ:

Yapay zeka, insanların halihazırda bilgisayarlardan daha iyi, daha çabuk, daha üstün yaptıkları işleri bilgisayarların yapabilmesini sağlamaya çalışan bir bilim dalıdır. Bu amaçla, insan beyninin çalışma şekli ve fonksiyonlarının modellenmesine çalışılmakta, insanların

öğrenmedeki metotları incelenmekte ve bunlar bilgisayara uyarlanıp uzman sistemler geliştirilmektedir.

Yapay sinir ağları (YSA), insan sinir hücrelerinin çalışmasına benzeyen algoritmalardır. Oldukça basit ve küçük boyuttaki YSA, insan beyniyle karşılaştırıldığı zaman bile, insan beynine benzerliğinden dolayı bilgi ve bilgi işlemede birtakım güçlü özelliklere sahiptir. Bu yüzden, YSA mühendislik uygulamalarında güçlü bir araç olabilmektedir. YSA üzerindeki ilk çalışmalarını 1943 yılında başladığı kabul edilir. Yapay sinir ağı tanımı ilk olarak aşağıdaki gibi yapılarak bir hücre modeli geliştirilmiştir.



Şekil 2.1. Basit bir nöron modeli (Öztemel, 2003)

Bir yapay sinir hücresi; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş ana kısımdan (Şekil 2.1) oluşmaktadır.

Girdiler, diğer hücrelerden ya da dış ortamlardan hücreye giren bilgilerdir. Girişler tarafından bir yapay sinir hücresine bir başka yapay sinir hücresinden bilgi akışı yapılır. Bu girdiler, ağırlık öğrenmesi istenen örnekler tarafından belirlenir.

Ağırlıklar, girdi seti veya kendinden önceki tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir.

Toplama fonksiyonu, girdiler ve ağırlıkların tamamının bu işlem elemanına etkisini hesaplayan bir fonksiyondur. Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Tüm bu bileşenler ileriki bölümlerde geniş olarak ele alınacaktır.

2.5.1 İnsanda Sinir Sistemi

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinden ya da dış ortamlardan algıladıkları uyarıları, beyine bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyinin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekilde bir sinir sisteminin blok gösterimi verilmiştir. Biyolojik sinir ağlarının temel elemanı sinir hücreleridir ve insan beyinin korteks kısmında yer alan nöron (sinir hücresi) sayısı yaklaşık olarak 1011 olup her hücre sayısı, 1000-10000 arasında değişen başka hücrelerle karşılıklı ilişki içerisinde. Bir sinir hücresinin temel elemanları hücre gövdesi, dendrit ve aksondur (Harvey, 1994).


Sinir hücresine diğer sinir hücrelerinden gelen uyarımlar, dendritler aracılığıyla hücre gövdesine taşınır ve hücre içi aktivasyonun/kararlılık halinin bozulmasıyla oluşan bir kimyasal süreç içerisinde diğer hücrelere aksonlarla iletilir; uyarıların diğer sinir hücrelerine taşınabilmesinde akson uçları ile dendritler arasındaki sinaptik boşluklar (sinaps) rol oynar. Sinaptik boşluk içinde yer alan “sinaptik kesecikler” gelen uyarıların diğer hücrelere dendritler aracılığıyla geçmesini sağlayan elemanlardır. Sinaptik boşluğa, “sinaptik kesecikler” tarafından sağlanan nöro-iletken maddenin dolması uyarıların diğer hücrelere geçişini sağlar. Hücrelere gelen uyarılarla uyumlu olarak hücreler arasındaki mevcut sinaptik ilişkilerin değişimi veya hücreler arasında yeni sinaptik ilişkilerin kurulması “öğrenme” sürecine karşılık gelir (Demir, 1997).



Şekil 2.2. Biyolojik sinir sisteminin blok gösterimi (Demir, 1997)

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler (Şekil 2.2) üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin karakteristiklerini (Şekil 2.3) taşır. Merkezi sinir sisteminin temel işlem elemanı, sinir hücresi (nöron) dur. Sinir hücresi; hücre gövdesi, dendritler ve aksonlar olmak üzere 3 bileşenden meydana gelir. Dendritler, diğer hücrelerden aldığı bilgileri hücre gövdesine

bir ağaç yapısı şeklinde ince yollarla iletir. Aksonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan daha uzun bir yoldur. Aksonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için dendritleri oluşturur (Demir, 1997).



Şekil 2.3. Nöronun biyolojik modeli (Demir, 1997)

Yapay sinir ağları, insan biyolojik sinir sistemini temel alarak geliştirilen bir yöntemdir. YSA, karmaşık mühendislik problemlerinin çözümüne yeni yaklaşımlar geliştirmiştir. Genel olarak bir YSA, tek katmanlı ya da çok katmanlı olarak düzenlenebilen ve paralel olarak çalışan çok sayıda doğrusal olmayan yapay hücreden meydana gelen bir sistem olarak tanımlanır (Nasr at al., 2003).

2.5.2. Matematik Sinir Yapısı (Nöronun Matematik Modeli)

Nöronlar sinir ağlarını oluşturan, tek başlarına ele alındıklarında çok basit bir işleve sahip işlemcilerdir. Bir nöron yapısı içerisinde üç ana bölüm bulunur. Bunlar sırasıyla sinapslar, toplayıcı ve aktivasyon fonksiyonudur. Denklem üzerinde bir nöronun matematiksel modeli gösterilmektedir. Bu denklemden de görüleceği gibi, nöron girdileri sinaptik bağıntılar üzerindeki ağırlıklar ile çarpılarak bir toplayıcıya uygulanmakta ve elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar hesaplanmaktadır.

$$O_i = \psi(S(u)) = \psi(W_1U_1 + W_2U_2 + \dots + W_nU_n - \theta) = \psi(\sum_{i=1}^n W_iU_i - \theta) \quad (2.1)$$

Bu denklemde,

S; Toplam fonksiyonu

$\psi(S)$; Aktivasyon fonksiyonu

θ ; Eşik değeri

u_i ; Giriş fonksiyonu

W_i ; Ağırlık fonksiyonu

O ; Çıkış fonksiyonu

Her bir girdideki değişim, nöron çıkışında belirli bir değişime neden olmakta ve bu değişimin genliği, girdinin etki derecesini belirleyen bağlantı kazançlarına, toplayıcının eşik değerine ve nöron aktivasyon fonksiyonunun tipine bağlıdır. Eşik değerinin kullanımı, pratikte (-1) ya da (+1) değerine sahip sabit bir girdinin (θ) ağırlığına sahip bir bağlantı ile toplayıcıya girdiği şeklinde ele alınır (Efe ve Kaynak, 2000).

Her nöron gelen sinyalin seviyesine göre açık ya da kapalı duruma geçerek basit bir tetikleyici görev üstlenir. Bu işlemleri yaparken nöronlar giriş bilgilerini ağırlandırarak bunları lineer toplar ve bir eşik, doğrusal veya doğrusal olmayan bir fonksiyonda işleyerek çıktısını verir. Bu çıktıyı hücreye bağlantısı olan diğer nöronlar giriş bilgileri olarak alırlar.

2.5.3.Yapay Sinir Hücresi (İşlem Elemanı)

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde işlem elemanları olarak da adlandırılmaktadır. Bir yapay sinir hücresi, girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş ana kısımdan oluşur.

a. Girdiler: Bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bunlar ağın öğrenmesi istenen örnekler tarafından belirlenir.

b. Ağırlıklar: Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir.

c. Toplama Fonksiyonu: Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur. Aşağıdaki şekilde formül ifade edilebilir.

$$net = \sum_{i=1}^n G_i A_i \quad (2.2)$$

Burada G girdileri, A ise ağırlıkları, n ise bir hücreye gelen toplam girdi sayısını gösterir. Yalnız yapay sinir ağlarında daima bu formülün kullanılması şart değildir.

d. Aktivasyon Fonksiyonu: Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak için de değişik formüller kullanılır. Günümüzde en yaygın olarak kullanılan çok katmanlı algılayıcı modelinde genel olarak aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılır ve şöyle formalize edilir:

$$f(net) = \frac{1}{1+e^{-net}} \quad (2.3)$$

Çizelge 2.1. Aktivasyon Fonksiyonları (Öztemel, 2003)

Aktivasyon fonksiyonu	Açıklama
Lineer fonksiyon $f(net) = net$	Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step fonksiyonu $f(x) = \begin{cases} 1 & net > \theta \\ 0 & net \leq \theta \end{cases}$	Gelen net girdi değerinin belirlenen bir eşik değerinin (θ) altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alır.
Sinus fonksiyonu $f(net) = \sin(net)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.
Eşik değer fonksiyonu $f(net) = \begin{cases} 0 & net \leq 0 \\ net & 0 < net < 1 \\ 1 & net \geq 1 \end{cases}$	Gelen bilgilerini 0 veya 1'den büyük veya küçük olmasına göre bir değer alır. 0 ve 1 arasında değerler alabilir. Bunların dışında değerler almaz.
Hiperbolik tanjant fonksiyonu $f(net) = (e^{net} - e^{-net}) / (e^{net} + e^{-net})$	Gelen net girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.


Transfer fonksiyonu olarak da geçen aktivasyon fonksiyonu, birleştirme fonksiyonundan elde edilen net girdiyi bir işlemde geçirerek hücre çıktısını belirleyen ve genellikle doğrusal olmayan bir fonksiyondur. Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir.

Aktivasyon fonksiyonları sabit parametrelili ya da uyarlanabilir parametrelili seçilebilir. En uygun aktivasyon fonksiyonu tasarımcının denemeleri sonucunda belli olur. Aktivasyon fonksiyonunun seçimi büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Geçiş fonksiyonları içinde en çok kullanılanı sigmoid ve tanjant hiperbolik fonksiyonlardır. Aktivasyon fonksiyonları bir YSA' da nöronun çıkış genliğini, istenilen değerler

arasında sınırlar. Bu değerler genellikle $[0,1]$ veya $[-1,1]$ arasındadır. YSA' da kullanılacak aktivasyon fonksiyonlarının türevi alınabilir olması ve süreklilik arz etmesi gereklidir. Lineer veya doğrusal olmayan transfer fonksiyonlarının kullanılması YSA' ların karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır. (Saraç, 2004)

Doğrusal Aktivasyon Fonksiyonu

Doğrusal bir problemi çözmek amacıyla kullanılan doğrusal hücre ve genellikle katmanlı YSA' nın çıkış katmanında kullanılan doğrusal fonksiyon, hücrenin net girdisini doğrudan hücre çıkışı olarak verir. Doğrusal aktivasyon fonksiyonu matematiksel olarak $y=Av$ şeklinde tanımlanabilir. "A" sabit bir katsayıdır.




Şekil 2.4. Doğrusal Aktivasyon Fonksiyonu (Sağıroğlu ve diğerleri, 2003)

Sigmoid Aktivasyon Fonksiyonu

Uygulamalarda nöron cevabının, girdilerin sürekli bir fonksiyonu olmasını gerektiren durumlarda kullanılır. Geriye yayma modeli her yerde diferansiyeli alınabilen aktivasyon fonksiyonu gerektirir (Kang ve Yoon,1994).

Sigmoid Aktivasyon Fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle uygulamada en çok kullanılan aktivasyon fonksiyonudur. Bu fonksiyon, girdinin her değeri için sıfır ile bir arasında değer üretir.


Sigmoid fonksiyonunun denklemi; $y = \frac{1}{1 + e^{-v}}$ 'dir.



Şekil 2.5. Sigmoid Aktivasyon Fonksiyonu (Sağıroğlu ve diğerleri., 2003)

Tanjant Hiperbolik

Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonunun biraz farklı şeklidir. Giriş uzayının genişletilmesinde etkili bir aktivasyon fonksiyonudur. Hiperbolik tanjant fonksiyonunun çıktısı -1 ve 1 aralığında oluşmaktadır. Formülü, $y = \frac{1-e^{-2v}}{1+e^{2v}}$ dir.



Şekil 2.6. Tanjant Hiperbolik Aktivasyon Fonksiyonu (Sağıroğlu ve diğerleri., 2003)

e. Hücrenin Çıktısı: aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendine girdi olarak da gönderebilir (Öztemel, 2003).

2.5.4. İnsanda Sinir Sistemi ve Matematik Sinir Yapısı Özdeşlikleri:

YSA, birbirine paralel bir şekilde bağlanmalı ve doğrusal olmayan bir yapıya sahip olan nöron olarak adlandırılan birçok elemandan oluşmaktadır (Jang at al, 1997). Literatürde farklı yapay sinir ağ yapıları kullanılmaktadır. Bunlar, ileri beslemeli, geri beslemeli ve radyal tabanlı sinir ağlarıdır (Luk at al., 2001).

Öğrenme süreci, arzu edilen amaca ulaşmak için YSA ağırlıklarının yenilenmesini sağlayan öğrenme algoritmalarını ihtiva etmektedir (Kaya ve Engin, 2003). Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanmaktadır. Alıcı sinirler (receptor)

organizma içerisinden ya da dış ortamlardan algıladıkları uyarıları, beyine bilgi ileten elektriksel sinyallere dönüştürmekte, tepki sinirleri (effector) ise, beyinin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürmektedir.

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilmektedir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin karakteristiklerini taşımaktadır. Merkezi sinir sisteminin temel işlem elemanı, sinir hücresidir (nöron) ve insan beyinde yaklaşık 10 milyar sinir hücresi olduğu tahmin edilmektedir. Sinir hücresi; hücre gövdesi, dendritler ve aksonlar olmak üzere 3 bileşenden meydana gelmektedir. Dendritler, diğer hücrelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletir. Aksonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan daha uzun bir yoldur. Aksonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için dendritleri oluşturur. Akson-dendrit bağlantı elemanı sinaps olarak tanımlanır.

İnsan beyinin 10 milyar sinir hücresinden ve 60 trilyon sinaps bağlantısından oluştuğu düşünülürse son derece karmaşık ve etkin bir yapı olduğu anlaşılmaktadır. Diğer taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuşal bilgileri son derecede hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilmektedir (Yüce, 2005).

Çizelge 2.2. Sinir Sistemi-YSA Sistemi Karşılaştırması (Yüce, 2005)

SİNİR SİSTEMİ	YSA SİSTEMİ
Neuron	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Synapslar	Ağırlıklar

Yapay sinir ağları, insanlar tarafından gerçekleştirilmiş örnekleri (gerçek beyin fonksiyonlarının ürünü olan örnekleri) kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üreteceğini belirleyen bilgisayar sistemleridir. Çizelge 2.2. İnsan sinir sistemi ile YSA sistemini karşılaştırmakta ve benzerliklerini ortaya koymaktadır. İnsan beyinin fonksiyonel özelliklerine benzer şekilde,

- Öğrenme
- İlişkilendirme
- Sınıflandırma
- Genelleme
- Özellik belirleme
- Optimizasyon, gibi konular da başarılı bir şekilde uygulanmaktadır.

Yapay sinir ağı özellikle doğrusal olmayan sistemlerde öngörüler açısından istatistik tekniklere göre daha kolaylık sağlayan bir özelliğe sahiptir. Bundan dolayı başta işletmecilik ve finans olmak üzere birçok değişik alanlarda kullanım olanağı bulur.

3.YAPAY SİNİR AĞLARININ ÖZELLİKLERİ

Paralellik: Alışılmış bilgi işlem yöntemlerinin çoğu seri işlemlerden oluşmaktadır. Bu da hız ve güvenilirlik sorunlarını beraberinde getirmektedir. Seri bir işlem gerçekleşirken herhangi bir birimin yavaş oluşu tüm sistemi doğruca yavaşlatırken, paralel bir sistemde yavaş bir birimin etkisi çok azdır. Nitekim seri bir bilgisayarın bir işlem elemanı beyine göre binlerce kez daha hızlı işlemesine rağmen, beynin toplam işlem hızı seri çalışan bir bilgisayara göre kıyaslanamayacak kadar yüksektir (Haykin, 1994).

Gerçeklenme Kolaylığı: Yapay sinir ağlarında basit işlemler gerçekleyen türden hücrelerden oluşması ve bağlantıların düzgün olması, ağların gerçeklenmesi açısından büyük kolaylık sağlamaktadır.

Yerel Bilgi İşleme: Yapay sinir ağlarında her bir işlem birimi, çözülecek problemin tümü ile ilgilenmek yerine, sadece problemin gerekli parçası ile ilgilenmektedir ve problemin bir parçasını işlemektedir. Hücreler çok basit işlem yapmalarına rağmen, sağlanan görev paylaşımı sayesinde, çok karmaşık problemler çözülebilmektedir (Haykin, 1994).

Hata Toleransı: Sayısal bir bilgisayarda, herhangi bir işlem elemanını yerinden almak, onu etkisiz bir makineye dönüştürmektedir. Ancak yapay sinir ağlarında bir elemanda meydana gelebilecek hasar çok büyük önem oluşturmaz. Yapay sinir ağlarının (YSA) paralel çalışması, hız avantajı ile birlikte yüksek hata sağlamaktadır. Seri bilgi işlem yapan bir sistemde herhangi bir birimin hatalı çalışması, hatta bozulmuş olması tüm sistemin hatalı çalışmasına veya bozulmasına sebep olacaktır. Paralel bilgi işleme yapan bir sistemde ise, sistemin ayrı ayrı işlem elemanlarında meydana gelecek olan hatalı çalışma veya hasar, sistemin performansında keskin bir düşüşe yol açmadan, performansın sadece hata birimlerinin bir oranınca düşmesine

sebepler olur. YSA, çok sayıda hücrenin çeşitli şekillerde başlanmasıyla oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir (Haykin, 1994).

Genelleme: YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir (Haykin, 1994).

Uyarlanabilirlik: YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

Donanım ve Hız: YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.

Analiz ve Tasarım Kolaylığı: YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, bütün YSA yapılarında yaklaşık olarak aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'ları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirir (Haykin, 1994).

3.1.Yapay Sinir Ağlarının Genel Özellik ve Avantajları:

Yapay sinir ağlarının karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Burada bütün modeller için geçerli olan genel karakteristik özellikler aşağıdaki gibi sıralanmıştır.

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler.
- Programları çalışma stili bilinen programlama yöntemlerine benzememektedir.
- Bilginin saklanması sağlanmaktadır.

- Yapay sinir ağıları örnekleri kullanarak öğrenirler.
- Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekir.
- Görülmemiş örnekler hakkında bilgi üretebilirler.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler.
- Örüntü tamamlama gerçekleştirebilirler.
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.
- Eksik bilgi ile çalışabilmektedirler.
- Hata toleransına sahiptirler.
- Belirsiz, tam olmayan bilgileri işleyebilirler.
- Dereceli bozulma (Graceful Degradation) gösterirler.
- Dağıtık belleğe sahiptirler.
- Sadece nümerik bilgiler ile çalışabilmektedirler.

Yukarıda belirtilen özelliklere ek olarak geliştirilmiş olan her modelin kendisine özgü özellikleri olabilmektedir (Öztemel, 2003).

3.2. Yapay Sinir Ağlarının Önemli Dezavantajları

Yapay sinir ağlarının yukarıda belirtilen avantajlarının yanı sıra bazı dezavantajları da vardır. Bunları şöyle sıralayabiliriz.

- Yapay sinir ağlarının donanım bağımlı çalışmaları önemli bir sorun olarak görülebilir. Ağların temel var oluş nedenlerinden birisi de paralel işlemciler üzerinde çalışabilmeleridir.
- Probleme uygun ağ yapısının belirlenmesi genellikle deneme yolu ile yapılmaktadır. Bu önemli bir problemdir. Çünkü eğer problem için uygun bir ağ oluşturulamaz ise çözümü olan bir problemin çözülemez veya düşük çözümlerin elde edilmesi söz konusu olabilir.
- Bazı ağlarda ağın parametre değerinin (öğrenme katsayısı vb.), her katmanda olması gereken işlem elemanı (yapay hücrelerin) sayısı, katman sayısı vb. belirlenmesinde bir kural olmaması da bir problem oluşturur.
- Ağın öğreneceği problemin ağa gösterimi de çok önemli bir problemdir.
- Ağın eğitiminin ne zaman bitirileceğine dair karar vermek için de geliştirilmiş bir yöntem yoktur.
- Bir diğer sorun ise, belki de yukarıdakilerin en önemlisi daha önce açıklandığı gibi ağın davranışlarının açıklanamamasıdır (Öztemel, 2003).

4. YAPAY SİNİR AĞLARININ KULLANIM ALANLARI

Yapay sinir ağlarının günümüzde birçok kullanım alanı mevcut olup bunları şu şekilde sıralayabiliriz:

- Veri madenciliği
- Optik karakter tanıma ve çok okuma
- Bankalardan kredi isteyen müracaatları değerlendirme
- Ürünün pazardaki performansını tahmin etme
- Kredi kartı hilelerini saptama
- Zeki araçlar ve robotlar için optimum rota belirleme
- Güvenlik sistemlerinde konuşma ve parmak izi tanıma
- Kalite kontrolü
- Radar ve sonar sinyalleri sınıflandırma
- Beyin modellemesi çalışmaları
- Kanserin saptanması ve kalp krizlerinin tedavisi
- Üretim planlama ve çizelgeleme
- Mekanik parçaların ömürlerinin ve kırılmaların tahmini

Bunların çoğaltılması mümkündür. Bu sistemi hemen her alanda görmek mümkündür. Çünkü bu sistem doğrusal olmayan modellemeler gerektirmektedir

Yapay zeka, insanın düşünme yapısını anlamak ve bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışmak olarak tanımlanır. Yani programlanmış bir bilgisayarın düşünme girişimidir. Daha geniş bir tanıma göre ise, yapay zekâ, bilgi edinme, algılama, görme, düşünme ve karar verme gibi insan zekasına özgü kapasitelerle donatılmış bilgisayarlardır. Yapay zekâ konusundaki ilk çalışma McCulloch ve Pitts tarafından yapılmıştır. Son yıllarda gelişen bilgisayar teknolojisi ile beraber geniş bir kullanım alanı bulan yapay zeka teknikleri, mühendislik alanında en çok optimizasyon amaçlı olarak kullanılmakta ve diğer klasik yöntemlere göre daha iyi sonuç vermektedir.

Hızlı hesaplama yönelik YSA çalışmaları 1950'li yıllarda başlamıştır. Basit nöron modellerine dayalı bir hesaplama modeli, Rosenblatt (1959) tarafından önerilmiş ve ardından perceptron diye bilinen tek katmanlı ilk YSA modeli ortaya çıkmıştır.

Widrow ve Hoff (1960), bu basit nöron modelini kullanarak öğrenebilen ilk adaptif sistemler üzerinde çalışmış ve delta kuralı diye bilinen; gerçek çıkış ile istenen çıkış arasındaki farka eşit

bir hata terimi kullanarak bağ ağırlıklarının değiştirildiği bir öğrenme kuralını ortaya koymuşlardır. Bilgisayar ortamında, beynin yaptığı işlemleri yapmaya çalışan, karar verebilen, sonuç çıkarabilen, yetersiz veri durumunda var olan mevcut verilerden yola çıkarak sonuca ulaşabilen, sürekli yeni veri girişini kabul eden, öğrenen, hatırlayan bir algoritma “Yapay Sinir Ağları” (YSA) olarak adlandırılır (Kaltakçı ve Dere, 1997).

Grossberg (1986), Uyarlanabilir Rezonans Teorisi (Adaptive Resonance Theory, ART) adında bir YSA yapısını geliştirmiştir. ART çok gelişmiş bir YSA modeli olmakla beraber henüz çok fazla probleme uygulanmamıştır. Aynı zamanda Kohonen (1984)’de “kendi kendini düzenleyen nitelik haritasını (self - organizing maps) geliştirmiştir. Bu YSA modeli, nümerik aerodinamik akış hesaplamaları için çoğu algoritmik yöntemden daha etkili olmuştur.

Yapay sinir ağları (YSA) örneklerden öğrenme ve genelleme yeteneğine sahip bağlantılı sistemlerdir, hatalı veya uygun olmayan girdi verileri içeren problemlerde bile anlamlı çözümler üretebilmektedirler, geoteknik mühendisliğini de içeren inşaat mühendisliği uygulamalarında birçok karmaşık problemin çözümünde kullanılmaktadır. Geoteknik mühendisliğindeki problemler, probleme neden olan faktörlerin ve olayların yeterince anlaşılabilmesi ve buna ilaveten mevcut bilgilerin bir bütün halinde değerlendirilmemesine bağlı olarak sınırlı sayıda olması, YSA’ların kullanımı için uygun bir alan oluşturmaktadır (Mohamedzein at al., 2007).

Yapay sinir ağları (YSA), insan sinir hücrelerinin çalışmasına benzeyen algoritmalarlardır. Oldukça basit ve küçük boyuttaki YSA, insan beyniyle karşılaştırıldığı zaman bile, insan beynine benzerliğinden dolayı bilgi ve bilgi işlemede birtakım güçlü özelliklere sahiptir. Bu yüzden, YSA mühendislik uygulamalarında güçlü bir araç olabilmektedir. YSA üzerindeki ilk çalışmaların 1943 yılında başladığı kabul edilir (Anderson, 1983).

Bir yapay sinir hücresi; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş ana kısımdan oluşmaktadır. Girdiler, diğer hücrelerden ya da dış ortamlardan hücreye giren bilgilerdir. Ağırlıklar, girdi seti veya kendinden önceki tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Toplama fonksiyonu, girdiler ve ağırlıkların tamamının bu işlem elemanına etkisini hesaplayan bir fonksiyondur. Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar (Anderson, 1983).

Girdi bileşenlerindeki ağırlıkların tümü (net); Denklem 1 kullanılarak toplanır (Liu at al., 2002).

$$(net)_j = \sum_{i=1}^n W_{ij} X_i + b \quad (4.1)$$

Genel olarak çok tabakalı algılayıcı modellerde aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılır. Sigmoid aktivasyon fonksiyonu kullanılarak hesaplanan sinir hücresinin çıktısı Denklemdeki gibi gösterilmektedir (Hopfield, 1982).

$$(out)_j = f(net)_j = \frac{1}{1 + e^{-\alpha(net)_j}} \quad (4.2)$$

Sigmoid işlemcisi, sürekli bir fonksiyonu gösterdiğinden dolayı özellikle doğrusal olmayan tasvirlerde kullanılır. Bunun nedeni, $(net)_j$ değişkeni bünyesinde bulunan parametrelere göre türevinin kolayca alınabilmesidir. Yapay sinir ağları özel denklem biçimi gerektirmeyip, bunun yerine yeterli girdi-çıkı verisine ihtiyaç duyar (Hopfield, 1982).

En genel anlamda yapay sinir ağları ileri beslemeli ve geri beslemeli ağlar şeklinde iki ana grupta düşünülebilir. İleri beslemeli ağlarda nöronlar; girdi, saklı ve çıktı olarak adlandırılan katmanlar vasıtasıyla organize edilir. Her bir katmandaki nöronlar; bir sonraki katman nöronları ile bağlantı ağırlıkları vasıtasıyla ilişkilidir. Ancak katmanların kendi aralarında her hangi bir bağlantı yoktur. Bilgi, girdi katmanından çıktı katmanına doğru ilerler. Buna aktivasyon yönü de denilir. Bu tür yapay sinir ağına örnek olarak tek ve çok katmanlı perceptron verilebilir. Bu tür ağlar denetimli öğrenme teknikleriyle eğitilir (Fu, 1994).

Geri beslemeli ağların en belirgin özelliği; katmanlar arasındaki nöronlar biri biriyle bağlantılı olup ayrıca bir dinamik hafızaya sahiplerdir. Bu ağlara örnek olarak kendi kendini düzenleyen öz örgütlenme haritası özelliğine sahip Kohonen ağı (Kohonen, 1977) ve ağ iç enerjisinin minimizasyonuna dayanan Hopfield ağı verilebilir. Bu tür ağların eğitilmesi takviyesiz öğrenmeye bir örnek oluşturur. Hopfield ağları daha çok bir içerikli adreslenebilir bellek olarak veya optimizasyon tipi problemlerde başarılıdır (Hopfield, 1982).

Yapay sinir ağlarındaki işleme elemanları biyolojik olarak insan beynindeki nöronlara karşılık gelmektedir. Dendrit olarak adlandırılan yapı, diğer hücrelerden bilgiyi alan nöron girişleri olarak görev yapar. Diğer hücelere bilgiyi transfer eden eleman aksonlardır. Dolayısıyla aksonlar nöron çıkışları olarak görev yaparlar. Akson ile dendrit arasındaki bağlantı ise sinapslar tarafından gerçekleştirilir (Rojas, 1996).

Yapay sinir ağları konvansiyonel programlama gibi belirli bir algoritma çerçevesinde programlanmazlar. Sinir ağları insanlar gibi örnekler ile eğitilirler. Yapay sinir ağları; mevcut örnek kümesi üzerinde girdi ile çıktı arasındaki bağıntının ağırlıkların değiştirilmesiyle eğitilirler. Sunulan girdi kümesi için; transfer fonksiyonu tarafından sağlanan değerlere cevap olarak bağlantı ağırlıklarının tamamının veya bir kısmının istenen çıktı ile ağ çıktısı arasındaki farkın

belirli bir değere düşünceye kadar değiştirilmesidir. Günümüze kadar çeşitli öğrenme algoritmaları geliştirilmiştir. Bunlar temel olarak denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olarak üç ana gruba ayrılır (Fu, 1994).

Denetimli öğrenmede sinir ağına hem girdi hem de çıktı değerleri sunulur. Ağın ürettiği çıktı ile istenen çıktı arasındaki fark sıfır veya ona yakın bir değere gelinceye kadar ağırlıklar değiştirilir. Bu tür öğrenme modelini kullanan ağlar; Perceptron ve ilişkili hafızalar, takviyeli öğrenme, stokastik öğrenme, vektör nicelik öğrenmesi, delta ve genelleştirilmiş delta kuralı, geri yayılma algoritması, bu grup öğrenmede kullanılan etkin metotlardır.

Denetimsiz öğrenmede ağa sadece girdi vektörü uygulanır. Girdi değerlerine uygun bir çıktı üretilinceye kadar bağlantı ağırlıkları değiştirilir. Bu metot görüntü işleme, işaret işleme ve kontrol problemlerinde etkin olarak kullanılır. Kohonen'in kendini düzenleyen uzaylar, ve adaptif rezonans teorisi (ART) denetimsiz öğrenmeye örnek olarak verilebilir. Takviyeli öğrenmede ise giriş değerlerine karşılık gelecek uygun çıktıların elde edilmesi sırasında ağırlıkların en uygun değerlerinin bulunmasında genetik algoritmalar veya tabu en iyilime yöntemleri kullanılır. Böylece ağırlıklar optimize edilmektedir. Bunların dışında hibrit öğrenme algoritmaları da geliştirilmiştir. Yapay sinir ağlarındaki ağırlıklar sabit değildir. Öğrenme kuralı giriş işaretlerine ve transfer fonksiyonu tarafından sağlanan değerlere cevap olarak, yerel bellekteki ağırlıkların hepsini veya bazılarını değiştiren bir denklem olarak bilinir. Öğrenme kuralı giriş işaretlerinin doğasına bağlı olarak işleme elemanının cevabının zamanla değişmesine imkan sağlar. Bu şekilde ağ, kendisini istenen cevaplara uyarlayabilir ve kendi içinde bilgiyi düzenleyebilir, yani öğrenir (Civalek ve Calayır, 2007).

Eğitim yeterli sayıda giriş-çıkış örnek kümesi için yapılmalıdır. Eğitim sonucunda ağ hem eğitime örnek kümesine ait veriyi tanımalı hem de interpolasyon ve ekstrapolasyon yapabilmelidir. Yani eğitim kümesinde olmayan örnek için uygun çıktılar vermelidir. Aslında eğitilmiş bir yapay sinir ağından beklenen de budur.

Yapay sinir ağının eğitimi iki aşamalı bir işlemdir. İlk adımda, ağa bir giriş vektörü uygulanarak, ağ içindeki her birim için toplam giriş ve çıkış hesaplanır ve her birimin çıkışı daha sonraki ağırlık düzenlenmesi için saklanır. Çıkış vektörü oluşturulduktan sonra, eğitime işlemi çıkış hatasını hesaplar ve bu hatanın geriye doğru yayılımını sağlar. Birimlerin ağırlıkları bu hata işaretine göre ayarlanır. Bu iki adımlı işlem ağ istenilen cevapları üretinceye kadar, eğitime vektör çiftçileri ile tekrarlanır. Çıkış katmanını eğitmek kısmen daha basittir. Eğitimin nispeten zor olduğu aşama, ara katmanının eğitilmesidir. Bunu aşmak için, hata işaretinin çıkıştan daha iç katmanlara yayılımını sağlamakla bulunur. Yani, bir iç veya ara katman birimi kendisinden

sonraki katmanın hata işaretlerinin ağırlıklı toplamı olan bir hat işareti alır. Bu hata işareti her birimin ağırlıklarını eğitmek için kullanıldıktan sonra, eğitime işlemi oluşturulan yeni hata işaretinin daha önceki katmanlara doğru yayılımını sağlar (Civalek ve Calayır, 2007).

Yapay sinir ağların öğrenme mekanizması, girdi vektörü ve transfer fonksiyonu tarafından sağlanan değerlere karşılık olarak bağlantı ağırlıklarının hepsinin veya bir kısmının değiştirilmesidir. Yapay sinir ağları ne kadar çok örnekle eğitilirse hem öğrenebilecekleri olay ve tanıyabilecekleri obje sayısı artar, hem de hata oranı azalarak daha hassas sonuçlar elde edilir.

5.YAPAY SİNİR AĞI HESAPLAMA VE YAPILARI

Yapay sinir ağları hesaplamaları öğrenme ve hatırlama olmak üzere iki safhadan oluşur.

5.1.Yapay Sinir Ağı Hesap Esasları:

5.1.1.Öğrenme

Yapay sinir ağları insan zekası gibi örneklerle eğitilirler. Ağlar ne kadar çok örnekle eğitilirse problem üzerindeki teşhisi o kadar doğru olur. Eğitime belirli kabul edilebilir bir hata ile yapılır. Bir yapay sinir ağında öğrenme ağırlık matrisinde değişme olarak düşünülür. Öğrenme genel olarak iki grup içinde kategorize edilir. Bunlar denetimli öğrenme ve denetimsiz öğrenme olarak verilebilir.

Denetimli Öğrenme

Denetimli öğrenme, giriş vektörlerinin data setini ve ağı eğitmek için çıkış vektörlerinin cevabını kullanır. Ağırlık matrisi, toplam ağ hatasının kabul edilebilir hatadan daha büyük olduğu sürece güncelleştirilir. Örneğe ait çıkış değeri ile ağ çıkış değeri karşılaştırılarak ağın hatası bulunur. Bu hata kabul edilebilir seviyeye gelinceye kadar, yapay sinir ağı nöronlar arasındaki ağırlıkları değiştirerek iterasyona devam edilir. Ağın eğitilmesine olanak sağlayan veri setine “eğitim seti” denir. Bir ağın eğitilmesi sırasında, bağlantı ağırlıklarını ayırmadan çoğu zaman veri setinin aynısı işlenir.

Denetimsiz Öğrenme

Bu tür öğrenmede, ağa sadece giriş veri grubu verilir, çıkış değerleri verilmez. Ağdan bu veri grubuna uyumlu bir çıkış değeri üretecek şekilde kendisini uygun ağırlıklarla düzenlemesi istenir. Bu eğitimde nöron ağının ortam ile karşılıklı ilişkisi minimuma indirilir.

5.1.2.Hatırlama

Ağın öğrenmesi sonucu elde edilen ağırlık grubu kullanılarak ağ belirli bir probleme ait giriş değerleri verilir ve bu probleme çözüm getirmesi istenir. Burada verilen giriş değerleri daha önceden ağa verilmeyen değerler olmalıdır.

5.2.Yapay Sinir Ağlarının Sınıflandırılması:

Yapay sinir ağları, biyolojik sinir sisteminden etkilenecek geliştirilmiştir. Biyolojik sinir hücreleri yukarıda da açıklandığı üzere birbirleriyle sinapslar vasıtası ile iletişim kurarlar. Bir sinir hücresi işlediği bilgileri aksonlar vasıtası ile diğer hücrelere gönderir (Öztemel, 2003). Yapay sinir ağları ile değişik öğrenme stratejileri kullanılmaktadır. Öğrenmeyi gerçekleştirecek olan sistem ve kullanılan öğrenme algoritması bu stratejilere bağlı olarak değişmektedir. Genel olarak dört öğrenme stratejisi uygulanmaktadır.

Katmanların değişik şekilde bir birleriyle bağlanmaları, öğrenme kuralları ve transfer fonksiyonlarına göre yapay sinir ağları farklılaşmaktadır ve sınıflandırılmaktadır.

5.2.1. Yapay Sinir Ağlarının Mimari Yapılarına Göre Sınıflandırması:


- İleri beslemeli: İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir.
- Geri beslemeli: En az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterir.

a) İleri Beslemeli Sinir Ağ Yapıları

İleri beslemeli yapay sinir ağlarının en tipik şekli nöron modeli oluşturulan katmanların ardışık biçimde bir araya getirilmesi sonucu kurulabilir. İleri beslemeli YSA' da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Bu yapısı ile ileri beslemeli ağlar doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli 3 katmanlı YSA' nın, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaşılabileceği gösterilmiştir.

Aşağıdaki şekilde gösterildiği gibi girdilerin uygulandığı katmana giriş katmanı, çıkışların alındığı katmana çıkış katmanı denir ve bu katmana dış dünyadan erişebilir. Giriş ve çıkış katmanlarının

arasında gizli katmanlar bulunur. Giriş ve çıkış katmanlarındaki nöron sayıları ele alınan problemin gereklerine göre belirlenir. Dolayısıyla gizli katman sayısındaki ve bu katmanların nöron sayılarındaki belirsizlikleri aşabilmenin tek yolu deneme yanılma yöntemidir.



Şekil 5.1. İleri beslemeli bir yapay sinir ağı yapısı (Arslan ve İnce, 1996)

Giriş katmanı

Giriş veri gruplarının ağı sunulduğu terminallerdir. Bu tabakadaki nöron sayısı, giriş veri sayısı kadardır ve her bir giriş nöronu bir veri alır. Burada veri işlemeyen bir sonraki tabakaya yani gizli tabakaya geçer.

Gizli katman

Ağın temel işlevini gören tabakadır. Bazı uygulamalarda ağda birden fazla saklı tabaka bulunabilir. Gizli tabaka sayısı ve tabakalardaki nöron sayısı probleme göre değişir, tamamen ağ tasarımcısının kontrolündedir ve onun tecrübesine bağlıdır. Bu tabaka girdi tabakasından aldığı ağırlıklandırılmış veriyi probleme uygun bir fonksiyonla işleyerek bir sonraki tabakaya iletir. Bu tabakada gereğinden az sayıda nöron kullanılması giriş verilerine göre daha az hassas çıkış elde edilmesine sebep olur. Aynı şekilde, gerektiğinden daha çok sayıda nöron kullanılması durumunda da aynı ağda yeni tip veri gruplarının işlenmesinde zorluklar ortaya çıkar.

Çıkış katmanı


Ağın en uç tabakasıdır. Gizli tabakadan aldığı veriyi ağın kullandığı fonksiyonla işleyerek çıktısını verir. Çıkış tabakasındaki nöron sayısı, ağı sunulan her verinin çıkış sayısı kadardır. Bu tabakadan elde edilen değerler yapay sinir ağının söz konusu problem için çıkış değerleridir. Üretilen çıktı dış dünyaya veya aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir.

başka bir hücreye gönderilir. Hücre kendi çıktısını kendine girdi olarak da gönderebilir (Öztemel, 2003).

İleri besleme safhasında, giriş tabakasındaki nöronlar, veri değerlerini doğrudan gizli tabakaya iletir. Gizli tabakadaki her bir nöron kendi giriş değerlerini ağırlandırarak toplam değer hesap ederler ve bunları bir taşıma fonksiyonu ile işleyerek bir ileri tabakaya veya doğrudan çıkış tabakasına iletirler. Tabakalar arasındaki ağırlıklar rastgele küçük rakamlardan seçilir.

b) Geri Beslemeli Sinir Ağ Yapıları

En az bir hücre sonraki katmanlardaki hücrelerce de beslenir (Karlık, 2003). Geri beslemeli ağlarda çıkıştan girişe doğru ters yönlü ilişkiler mevcuttur. Ağın girişine vektör verildikten sonra nöronların durumları belirlenir, sonra çıkış nöronları girişe bağlı olduğundan dolayı, yeni giriş vektörü olarak ağı etkiliyor ve durum yeniden düzenleniyor. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır (Sağıroğlu ve diğerleri, 2003).



Şekil 5.2. Geri beslemeli bir yapay sinir ağı yapısı (Das at al., 2005)

Geri beslemeli yapay sinir ağları genellikle danışmasız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Geri beslemeli ağlarda bir tür geri besleme işlemi vardır. Bu ağ yapılarında sinyalin yönü girdi katmanından çıktı katmanına doğrudur. Ancak aynı zamanda, bir katman üzerinde yer alan sinirler, kendisinden, katmandaki diğer sinirlerden ya da diğer katmanlardaki sinirlerden sinyal alabilmektedir. Bu sebeple geri beslemeli ağlarda bir sinirin

çıkışı, sinirin o andaki girdileri ve ağırlık değerleriyle belirlenmesinin yanında bazı sinirlerin bir önceki süredeki çıkış değerlerinden de etkilenmektedir (Güneri ve Apaydın, 2004; Elmas, 2003).

Geri beslemeli ağları ileri beslemeli ağlardan ayıran temel özellik; bu tip mimariyle oluşturulan ağların dinamik doğrusal olmayan sistemleri, özellikle de doğrusal olmayan diferansiyel denklemleri modelleyebilmeleridir (Cichocki at al., 1993).

5.2.2. Yapay Sinir Ağlarının Öğrenme Yaklaşımlarına Göre Sınıflandırması:


Danışmanlı öğrenme: YSA' ya örnek olarak bir doğru çıktı verilir. Bu öğrenmede ağın çıktısı ile hedef çıktılar arasındaki fark hata olarak ele alınır ve bu hata en aza indirilmeye çalışılır. Bunun için, bağlantıların ağırlıkları en uygun çıkışı verecek şekilde değiştirilir.

Danışmansız öğrenme: Ağa sadece girdiler verilir. Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirir.

Takviyeli öğrenme: İstenilen çıkışın bilinmesine gerek duymaz. Ağa hedef çıktılar yerine, ağın çıktılarının ne ölçüde doğru olduğunu belirten bir skor veya derece bildirilir.

a) Eğitici öğrenme


Bu tür stratejide öğrenen sistemin olayı öğrenebilmesine bir eğitici yardımcı olmaktadır. Eğitici sisteme öğrenilmesi istenen olay ile ilgili örnekleri Girdi/Çıktı seti olarak verir. Yani, her örnek için hem girdiler hem de girdiler karşılığında oluşturulması gereken çıktılar sisteme gösterilirler. Sistemin görevi girdileri eğiticinin belirlediği çıktılara haritalamaktır. Bu sayede olayın girdileri ile çıktıları arasındaki ilişkiler öğrenilmektedir. Çok katmalı algılayıcı bu stratejiyi kullanan ağlara örnek olarak verilebilir.



Şekil 5.3. Eğitici öğrenme (Öztemel, 2003)

b) Eğitici öğrenme


Bu tür stratejide sistemin öğrenmesine yardımcı olan herhangi bir eğitici yoktur. Sisteme sadece girdi değerleri gösterilir. Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendisine öğrenmesi beklenir. Bu, daha çok sınıflandırma problemleri için kullanılan bir stratejidir. Yalnız sistemin öğrenmesi bittikten sonra çıktıların ne anlama geldiğini gösteren etiketlenmenin kullanıcı tarafından yapılması gerekmektedir.



Şekil 5.4. Eğitici öğrenme (Öztemel, 2003)

c) Destekleyici öğrenme

Bu tür stratejide de öğrenen sisteme bir eğitici yardımcı olur. Fakat eğitici her girdi seti için üretilmesi gereken çıktı setini sisteme göstermek yerine sistemin kendisine gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Sistem, eğiticiye gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir.



Şekil 5.5. Destekleyici öğrenme (Öztemel, 2003)

d) Karma stratejiler

Yukarıdaki üç stratejiden birkaçını birlikte kullanarak öğrenme gerçekleştiren ağlarda vardır. Burada kısmen eğitici, kısmen ise eğitici olarak öğrenme yapan ağlar kastedilmektedir.

Radyal tabanlı yapay sinir ağları ve olasılık tabanlı ağlar buna örnek olarak verilebilir (Öztemel, 2003). Bir yapay sinir ağında sinir hücrelerinin bağlanması sonucu oluşan topoloji, sinir hücrelerinin sahip oldukları toplam ve aktivasyon fonksiyonları, öğrenme stratejisi ve kullanılan öğrenme kuralı ağın modelini belirlemektedir. Günümüzde çok sayıda model geliştirilmiştir. Bu modellerden tek tabakalı ve çok tabakalı algılayıcı ağları aşağıda anlatılmıştır (Terzi, 2004).


e) Tek Tabakalı Algılayıcı Yapay Sinir Ağları

Yapay sinir ağları ile ilgili çalışmalar tek tabakalı yapay sinir ağları ile başlamıştır. Tek tabakalı yapay sinir ağları sadece girdi ve çıktı tabakalarından oluşur. Her ağın bir veya daha fazla girdisi ve çıktısı vardır. Çıktı nöronları bütün girdi nöronlarına bağlanmaktadır (Öztemel, 2003).


5.3. Yapay Sinir Ağı Yapıları:

Yapay sinir ağları, hücrelerin birbirleri ile çeşitli şekillerde bağlanmalarından oluşur. Hücre çıkışları, ağırlıklar üzerinden diğer hücelere ya da kendisine giriş olarak bağlanabilir ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli YSA yapıları geliştirilmiştir.

Yapay sinir ağları, yapılarına göre, ileri beslemeli (*feed forward*) ve geri beslemeli (*feed back*) ağlar olmak üzere iki şekilde sınıflandırılırlar. Çizelge 5.1.'de Yapay sinir ağı çeşitleri gösterilmiştir.

Çizelge 5.1 Yapay Sinir Ağı Çeşitleri**5.3.1 İleri Beslemeli Ağlar:**


İleri beslemeli bir ağda işlemci elemanlar (İE) genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İE' ler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Şekil 5.6.'da ileri beslemeli ağ için blok diyagramı gösterilmiştir.



Şekil 5.6. İleri Beslemeli Ağ Blok Diyagramı (Sağıroğlu ve diğerleri, 2003)

5.3.1.1. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı:


Tek katmanlı ileri beslemeli yapay sinir ağı en basit ağ yapısıdır. Bir giriş katmanı ve bir çıkış katmanı vardır. Bu tip bir ağda bilgi girişten çıkışa doğru ilerler yani ağ ileri beslemedir. Tek katmanlı (Şekil 5.7.) olarak isimlendirilmesinin sebebi, giriş katmanının veri üzerinde hiçbir işlem yapmadan veriyi çıkış katmanına iletmesidir.



Şeki5.7. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı (Öztemel, 2003)

5.3.1.2. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı:


Çok katmanlı sinir ağı modeli, Şekil 5.8 'de gösterilmiştir. Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Birçok öğretim algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir. Bir MLP modeli, bir giriş, bir veya daha fazla ara ve bir de çıkış katmanından oluşur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemler giriş sayısına bağlıdır.



Şekil 5.8. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı (Öztemel, 2003)

5.3.1.3. Radyal Tabanlı İleri Beslemeli Yapay Sinir Ağı:

Çok değişkenli modelleme ve yakınsamalarda kullanılan YSA yapılarından. Gizli katmandaki işlemci elemanlar girişlerin ağırlıklandırılmış şeklini kullanmamakta ve gizli katmandaki işlemci elemanların çıkışları YSA girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenmektedir. RTYSA yapısı Şekil 5.9.'da gösterildiği gibi en genel anlamıyla radyal olarak simetrik olan gizli katman işlemci elemanları içeren bir yapıdadır.




Şekil 5.9. Radyal tabanlı ileri beslemeli yapay sinir ağı (Sağıroğlu, 2003)

Radyal olarak simetrik olan ara katman işlemci elemanı için üç bileşen vardır. İlki giriş uzayındaki bir merkez vektörüdür. Bu vektör, giriş ve gizli katmanlar arasındaki ağırlık vektörü olarak saklanır. İkincisi, bir giriş vektörünün merkezden ne kadar uzak olduğunu belirlemek için uzaklık ölçütüdür. Tipik olarak bu ölçüt standart Öklit uzaklığı olarak alınmaktadır. Sonuncusu ise, tek değişkenli olan ve uzaklık fonksiyon çıkışını giriş olarak alan işlemci elemanın çıkış değerini belirleyen bir aktivasyon fonksiyon yapısıdır. İlk katmandaki işlemci elemanlar girişlerin ağırlıklandırılmış şeklini kullanmaz. İlk katmandaki işlemci elemanların çıkışları YSA girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenir. RTYSA yapılarının son katmanı doğrusaldır ve ilk katmanın çıkışlarından ağırlıklandırılmış toplam çıkışı üretir.(Sağıroğlu ve diğerleri., 2003)

5.3.2. Geri Beslemeli Ağlar

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 5.10'da bir geri beslemeli ağ görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır.



Şekil 5.10. Geri Beslemeli Ağ Blok Diyagramı (Sağiroğlu, 2003)

5.3.3. Bazı YSA Çeşitleri


- Elman Ağı

Elman ağı daha önce anlatılan çok katmanlı algılayıcı ağının öğrenme kuralına göre öğrenmektedir. Elman ağının yapısı Şekil 5.11'de gösterilmiştir. Şekilde görüldüğü gibi Elman ağının 4 çeşit işlemci elemanı vardır:

- Girdi elemanları,
- Ara katman elemanları,
- Çıktı elemanları,
- İçerik elemanları

Bunlardan giriş ve çıkış elemanları dış dünya ile etkileşim halindedir. Giriş elemanları dış dünyadan bilgileri alır ara katmanlara iletirler. Çok katmanlı algılayıcılarda olduğu gibi, Elman ağında da giriş elemanlarının bilgi işleme özelliği yoktur. Girişleri olduğu gibi ara katman elemanlarına gönderirler. Çıkış elemanları ise, ağın çıkışını dış dünyaya iletirler. Çıkış birimlerinin bilgi işleme fonksiyonları doğrusaldır. Sadece kendilerine gelen bilgileri toplarlar. Ara katman elemanları ise, hem doğrusal hem doğrusal olmayan aktivasyon fonksiyonlarına sahip olabilirler. İçerik elemanları ara katman elemanlarının önceki aktivite değerlerini hatırlamak için


kullanılmaktadır. Bu elemanlar bir adım gecikmeyi (one step time delay) içermektedirler. Bir önceki iterasyondaki aktivasyon değerlerini bir sonraki iterasyona giriş olarak taşırlar. Şekildeki ileri beslemeli bağlantıların ağırlıkları eğitim sırasında değiştirilebilirler.



Şekil 5.11. Elman Ağı (Kröse, van der Smagt, 1996)

- **Jordan Ağı**


Elman ve Jordan Ağları, çok katlıdır. Her iki ağda da gizli tabakaya ek olarak diğer bir “durum” tabakası denilen özel bir gizli tabaka daha vardır. Bu tabaka gizli tabakadan veya çıkış tabakasından geri besleme işaretleri alır. Jordan ağının Şekil 5.12’de gösterildiği gibi aynı zamanda durum tabakasındaki her işlemci elemandan kendisine bağlantıları vardır. Her iki ağda da durum tabakasındaki işlemci elemanların çıkışları ileriye doğru gizli tabakaya verilmektedir. Eğer sadece ileri doğru bağlantılar göz önüne alınır ve geri besleme bağlantılarına sabit değerler verilirse, bu ağlar sıradan ileri beslemeli ağlar haline gelirler.



Şekil 5.12. Jordan Ağı (Kröse, van der Smagt, 1996)

- **Hopfield Ağı**

Hopfield ağı (Şekil 5.13.), John Hopfield tarafından 1982 yılında geliştirilmiştir. En çok optimizasyon problemleri için kullanılır. Hopfield ağı tek katmanlı ve geri dönüşümlü bir ağıdır. (Şekil 9.2.2)'de bir Hopfield ağı şekli gösterilmiştir. Bu ağı genellikle ikili (0 veya 1) ve bipolar (+1 veya -1) girişler kabul eder. Tek katmandaki işlemci elemanlarının her biri bir diğerine bağlanmıştır. Ayrıca her hücrenin çıkışı, bir ağırlıkla işleme tabi tutularak diğer hücrelere giriş değeri olarak dönmektedir. Ağı bağlantı değerleri bir enerji fonksiyonu olarak saklanır.




Şekil 5.13. Hopfield Ağı (Fröhlich, 1997)

- **Uyarlanır Rezonans (ART) Ağı**

ART ağları 1976 yılında Grossberg tarafından geliştirilmiştir. Birçok farklı ART ağı vardır. (Şekil 5.14)'te bir ART-1 ağı verilmektedir. ART-1 ağının giriş ve çıkış olmak üzere iki katmanı vardır. İki katman birbirleriyle tamamen bağlantılıdır ve bağlantılar ileri ve geri yöndedir. İleri çıkış işlemci elemanının ileri yöndeki bağlantılarının ağırlıklarının oluşturduğu W vektörü, temsil ettiği sınıfın bir örneğini oluşturur. İleri bağlantılarının W_i vektörlerinin toplamı ART ağının uzun-dönem (long-term) hafızasını oluşturur. Bu vektörler, giriş desenine benzerlikleri ölçüsünde, çıkış işlemci elemanlarını belirlerler. Çıkış işlemci elemanlarının geri bağlantılarının V_i vektörleri ise, giriş deseninin, hafızadaki desene yeterince benzeyip benzemediğini (o sınıfa ait olup olmadığını) kesin olarak belirlemek amacıyla kullanılır. Bu test vektörleri diyebileceğimiz V_i vektörleri ART ağının kısa-dönem (short-term) hafızasını oluştururlar. W_i , V_i 'nin normalize

edilmiş halidir. Bu ağlar belli giriş verisini analiz eder, olası özellikleri kontrol eder veya giriş vektörü içindeki bu özellikleri sınıflandırır. Birçok ağın temelini oluşturur.



Şekil 5.14. Uyarlanabilir Rezonans Ağı Genel Yapısı (Kröse, van der Smagt, 1996)


Grossberg (1986), Uyarlanabilir Rezonans Teorisi (Adaptive Resonance Theory, ART) adında bir YSA yapısını geliştirmiştir. ART çok gelişmiş bir YSA modeli olmakla beraber henüz çok fazla probleme uygulanmamıştır. Aynı zamanda Kohonen (1984)'de "kendi kendini düzenleyen nitelik haritası"nı (self - organizing maps) geliştirmiştir. Bu YSA modeli, nümerik aerodinamik akış hesaplamaları için çoğu algoritmik yöntemden daha etkili olmuştur.

Rumelhart ve diğ. (1986) "Parallel Distributed Processing" (paralel dağılımlı işleme) adlı kitaplarında, ileri beslemeli (feedforward) ağlarda yeni öğrenme modeli olan hatanın geriye yayılması algoritmasını (backpropagation algorithm) geliştirerek, daha önce bu konuda Minsky ve arkadaşları tarafından iddia edilen aksaklıkların aşılabileceğini göstermişlerdir. Bugün endüstride birçok YSA uygulamasında bu öğrenme yöntemi ile bunun değişik varyasyonları kullanılmaktadır. Backpropagation algoritması, kullanımı çok yaygın olan ve öğrenilmesi kolay bir ağıdır. Ayrıca biyolojik işaretlerin sınıflamalarında tercih edilen bir ağ yapısıdır. İç içe girmiş konveks yapıdaki kümelerin sınıflamasını rahatlıkla yapmaktadır.

- **Som Ağı**

SOM tipi ağlar Kohonen tarafından geliştirilmiştir. Şekil 5.15'te bir SOM ağı gösterilmiştir.⁵⁹ Bu ağlar bir giriş ve bir çıkış katmanından oluşur. Ancak diğer ağlardan farklı olarak çıkış katmanı 2 boyutlu bir düzlemdir. Som tipi ağlarda yarışmayı kazanan işlemci elemanı 1 değerini alırken, diğer elemanlar 0 değerini alır. Sadece 1 değerini alan işlemci ve komsularının ağırlıkları

degisir. Genellikle sınıflandırma amaçlı kullanılırlar. Bu aglar öğrenmek için öğretmene ihtiyaç duymazlar. Yani çıktıların bilinmesi zorunlu degildir.



Şekil 5.15. SOM Ağı (Fröhlich, 1997)

- **Olasılık Tabanlı Yapay Sinir Ağı:**


Olasılık tabanlı YSA yapıları 1990 yılında Donald Specht tarafından önerilmiştir. Bu tip sinir ağları da birçok sınıflandırma probleminin çözümünde kullanılmaktadır. Bu yapı, giriş, patern, toplama ve çıkış olmak üzere dört katmandan oluşur. Giriş nöron sayısı diğer ağlarda olduğu gibi problem girişi sayısına bağlıdır. Ara katman sayısı ise, örnek sayısı kadardır. Saklı katmanda bulunan veri işleme elemanları K toplam mevcut sınıfı göstermek üzere K alt gruba ayrılır. Her veri işleme elemanı karşı geldiği sınıfı ifade eden bir Parzen penceresini gösterir. Sahip olduğu ağırlık değeri söz konusu pencerenin ağırlık merkezini ifade eder. Toplama katındaki nöron sayısı, çıkış sayısının bir fazlasıdır. OTY yapılarında öğrenme hızlıdır ve az sayıdaki veri ile etkin olarak kullanılabilirler. Buna karşı, OTY yapıları hafızayı yoğun olarak kullanırlar. Kompleks veri kümeleri kullanıldığında ve kısmen de bu veriler bir sınıflandırma yarıçapı kullanılarak azaltıldığında problemlerle karşılaşılabilir.

- **Öğrenme Vektör Nicelendirmesi (Learning Vector Quantization) Ağı:**

Learning Vector Quantization (LVQ) ağı 1984 yılında Kohonen tarafından tasarlanmıştır. Bu nedenle Kohonen ağı olarak da bilinir. Sekilde bir LVQ ağı verilmiştir. Şekilde görüldüğü gibi bir giriş, bir çıkış ve bir Kohonen katmanından oluşur. Giriş katmanındaki nöronlar ara katmandaki

tüm nöronlarla bağlıdır. Ancak ara katmandaki farklı sayıdaki nöron grupları çıkış katmanındaki her bir nörona bağlıdır. Bu ağın temel prensibi n boyutlu bir vektörü, bir vektörler setine haritalamaktır. Bu ağın öğrenme işlemi, girdi vektörünün hangi vektör seti tarafından temsil edileceğinin bulunmasını sağlamaktadır. Bu model ve Kohonen'in LVQ ağından önce geliştirdiği SOM (Self-Organizing Maps) modeli Kohonen katmanı denilen bir yapı üzerine temellendirilmiştir. Kohonen katmanı n boyutlu bir vektörü bir vektörler setine uydurmaktadır (mapping) (Anderson ve McNeill, 1992). Burada amaç, bir vektörün belirli sayıda vektör ile gösterilmesidir. LVQ ağının öğrenmesi ile de girdi vektörünün hangi vektör seti tarafından temsil edilmesi gerektiğinin bulunması kastedilmektedir. Bu vektör setine referans vektörleri denirse LVQ ağının görevi, öğrenme yolu ile bu referans vektörleri belirlemektir. Yani, girdi vektörlerinin üyesi olabilecekleri vektör sınıfını belirlemektir (Öztemel, 2003).


LVQ ağları özellikle sınıflandırma problemleri olmak üzere, sınıflandırma ve görüntü işleme problemlerinin çözümünde kullanılır.



Şekil 5.16. Öğrenme Vektör Nicelendirmesi (LVQ) İleri Beslemeli Yapay Sinir Ağı (Kohonen, 1988)

Çok katmanlı perceptronlar gibi LVQ ağları da 3 katmandan (Şekil 5.16.) oluşmaktadır. İlk katman olan girdi katmanında bilgi işleme olmamaktadır. Dış ortamdan gelen bilgiler bu katmandan ağı giriş yaparlar. Gelen bilgiler girdi katmanını oluştururlar. İkinci katman, Kohonen katmanı da denilen ara katmandır. Bu katmanda girdi setine en yakın olan ağırlık vektörü belirlenir. Bu katmandaki her eleman bir referans vektörünü gösterir. Girdi vektörü, girdi katmanı ile Kohonen katmanı arasındaki ağırlıkların oluşturduğu referans vektörlerine uydurulmaktadır. Üçüncü katman olan çıktı katmanında ise girdinin ait olduğu sınıf belirlenir.

LVQ ağı, girdi ve Kohonen katmanları arasında tam bağlantılı, Kohonen ve çıktı katmanları arasında ise kısmi bağlantılı olmaktadır. Yani girdi katmanındaki her işlemci eleman Kohonen katmanındaki tüm işlemci elemanlarla bağlantılıdır. Kohonen katmanındaki işlemci elemanlar ise çıktı katmanındaki bir tek işlemci elemanla bağlantılıdır. Kohonen katmanı ile çıktı katmanı arasındaki ağırlıklar (α) sabit olup 1'e eşittir ve bu ağırlıklar değişmez. Ağın eğitimi sadece Kohonen katmanı ile girdi katmanı arasındaki ağırlıkların yani referans vektörlerin değerlerinin değiştirilmesi ile gerçekleştirilir.



Şekil 5.17. Öğrenme Vektör Nicelendirmesi (LVQ) İleri Beslemeli Yapay Sinir ağının topolojik yapısı (Kohonen, 1988)

LVQ ağı, öğrenme kuralı olarak Kohonen öğrenme kuralını kullanmaktadır. Danışmansız öğrenmenin bir alt türü olan yarışmacı öğrenme (competitive learning) sınıfına giren ağda, eğitim sırasında girdi vektörü ile referans vektörü arasındaki en kısa mesafe aranmakta ve girdi vektörünün en kısa mesafede bulunan vektör grubuna ait olduğu varsayılmaktadır. Ağı ağırlıkları değiştirilerek girdileri doğru sınıflara ayıracak referans vektörleri belirlenmektedir. Çıktı değerlerinin belirlenmesinde “*kazanan herşeyi alır (winner takes all)*” stratejisi uygulanır. Ağ eğitilirken her iterasyonda ağın ürettiği çıktının değeri yerine sadece doğru olup olmadığı belirlenir. Sadece girdi vektörüne yakın olan vektörün (kazanan vektör) değerleri (ağın bu vektöre ait ağırlıkları) değiştirilir (Kröse, van der Smagt, 1996).

LVQ ağlarında öğrenme hızı çok katmanlı perceptron gibi ağlara göre daha hızlı gerçekleşmektedir. Hem Kohonen katmanındaki hem de çıktı katmanındaki her işlemci elemanın çıktıları ikili (binary) değerler almaktadır ve sadece bir işlemci elemanın çıktı değeri 1 diğerleri ise 0 olmaktadır. Çıktı değerinin 1 olması girdinin, ilgili çıktının temsil ettiği sınıfa ait olduğunu göstermektedir.

LVQ ağıının eğitilmesindeki amaç her iterasyonda girdi vektörüne en yakın referans vektörünü bulmaktır. Referans vektörleri daha önce de belirtildiği gibi Kohonen katmanındaki işlemci elemanları girdi katmanındaki işlemci elemanlara bağlayan ağırlık değerleridir. Öğrenme esnasında sadece referans vektörlerinin ağırlık değerleri değiştirilmektedir. Bu işlem Kohonen öğrenme kuralı kullanılarak yapılmaktadır. Kohonen öğrenme kuralı, Kohonen tabakasındaki işlemci elemanların birbirleriyle yarışması ilkesine dayanmaktadır. Yarışma kriteri, girdi vektörü ile ağırlık vektörleri (referans vektörler) arasındaki öklid (euclid) mesafesine bağlıdır. Hangi işlemci elemanın referans vektörü girdi vektörüne en yakın ise yarışmayı o kazanır. Girdi vektörü X ile referans vektörü w arasındaki mesafe d ile gösterilirse; i işlemci elemanın mesafesi,

$$d_i = \|w_i - X\| = \sqrt{\sum (w_{ij} - x_j)^2} \quad (5.1)$$

ile hesaplanır. Burada ij , *ağırlık* vektörünün w_j , j ise girdi vektörünün j . değerini gösterir. Girdi vektörü ile referans vektörlerinin hepsinin aralarındaki mesafe tek tek hesaplandıktan sonra hangi işlemci elemanın referans vektörü girdi vektörüne en yakın ise yarışmayı o kazanır. Öğrenme sırasında, sadece girdi katmanını bu işlemci elemana bağlayan ağırlık değerleri değiştirilir. Kazanan işlemci eleman için iki durum söz konusu olmaktadır.

İlk durumda kazanan işlemci eleman doğru sınıfın bir üyesidir. Bu durumda ilgili ağırlıklar girdi vektörüne biraz daha yaklaştırılmaktadır. Bu, aynı örnek ağı tekrar gösterildiğinde yine aynı işlemci elemanın kazanması için yapılır. Bu durumda ağırlıkların değiştirilmesi,

$$w_n = w_o + \lambda(X - w_o) \quad (5.2)$$

kullanılarak gerçekleştirilir. Burada λ , öğrenme katsayısıdır. Öğrenme katsayısı zaman içinde 0 değerini alacak şekilde monoton olarak azalır. Bunun nedeni, girdi vektörünün referans vektörüne çok yaklaştığında durması ve aksi yönde tekrar uzaklaşmamasıdır. Aksi takdirde ters yönde tekrar uzaklaşma meydana gelecektir. Kazanan işlemci elemanın ikinci durumunda ise, kazanan işlemci eleman yanlış sınıftandır. Bu durumda ağırlık vektörü girdi vektöründen uzaklaşmaktadır. Bunun amacı, bir daha aynı örnek geldiğinde aynı işlemci elemanın kazanmamasıdır. Bu durumda ağırlıklar,

$$w_n = w_o - \lambda(X - w_o) \quad (5.3)$$

kullanılarak değiştirilir. Öğrenme katsayısının zaman içinde azalması burada da geçerli olmaktadır. Kohonen katmanı ile çıktı katmanı arasındaki ağırlıklar (α) eğitim sırasında değiştirilmemektedir. Kohonen katmanındaki her işlemci elemanın çıktısı y_k ise,

$$y_i^k = \begin{cases} 1 \\ 0 \end{cases} \quad (5.4)$$

Eğer i . işlemci eleman yarışı kazanırsa Aksi halde; Kohonen katmanındaki işlemci elemanların çıktıları, bu işlemci elemanları çıktı katmanına bağlayan ağırlık değerleri ile çarpılarak ağın çıktısı hesaplanmaktadır. Yani,

$$y_i = \sum_j y_j^k \alpha_{ki} \quad (5.5)$$

olmaktadır. Bu Kohonen katmanında yarışmayı kazanan işlemci elemana bağlı olan çıktı elemanın değerinin 1, diğerlerinin değerinin 0 olması anlamına gelmektedir. Ağın çıktıları belirlendikten sonra çıktının doğru sınıflandırılıp sınıflandırılmadığı sorgulanır. Bu sorunun cevabına göre Kohonen katmanındaki yarışmayı kazanan işlemci elemanı girdi katmanına bağlayan ağırlıklar değiştirilmektedir. Eğitim setindeki tüm örnekler doğru sınıflandırılınca kadar bu işlemler tekrarlanır. Hepsi doğru sınıflandırılınca öğrenme gerçekleştirilmiş olur. Anlatılan bu model standart bir LVQ modelidir.

LVQ modelinin bazı dezavantajları bulunmaktadır. Bunlardan ilki öğrenme katsayısının zamanında 0 değerini almaması durumunda ağın doğru ağırlık değerlerinden uzaklaşmasıdır. Ayrıca bazı problemlerde sürekli aynı referans vektörü yarışmayı kazanmaktadır. Bu durum da ağın esnekliğini ortadan kaldırmaktadır. Diğer dezavantaj ise sınıflandırmayı yaparken iki sınıfın tam ortasında veya sınırlara çok yakın bulunan vektörlerin hangi sınıfa gireceklerinin belirlenememesidir. Bu sorunları ortadan kaldırmak için LVQ ağının farklı modelleri geliştirilmiştir. Bu modellerden LVQ2 ağı yine Kohonen tarafından, sınır değerlerindeki yanlış sınıflandırmayı önlemek amacıyla geliştirilmiştir. Standart LVQ metodunun aksine LVQ2 ağı eğitim sırasında aynı anda 2 referans vektörünü değiştirmeyi önermektedir. Bu iki vektöre W_1 ve W_2 ve denirse, bu vektörlerin ağırlıklarının değiştirilmesi için iki koşulun sağlanması gerekmektedir. Bu koşullar;

1. W_1 girdi vektörüne en yakın ağırlık vektörü, W_2 ise ondan sonraki en yakın ağırlık vektörü olmak üzere W_1 yanlış, W_2 ise doğru sınıftandır.

2. Girdi vektörü W_1 ve W_2 vektörlerinin arasında merkezi olarak belirlenmiş bir aralık içerisinde kalmaktadır.

Bu iki koşulun sağlanması durumunda W_1 ve W_2 vektörlerinin ikisinin de ağırlıkları değiştirilir. Bu ağırlık vektörlerinin yeni değerleri (W_{1n} ve W_{2n}) şu şekilde hesaplanır.


$$W_{1n} = W_{1o} - \lambda(X - W_{1o}) \quad (5.6)$$

$$W_{2n} = W_{2o} - \lambda(X - W_{2o}) \quad (5.7)$$

Burada (W_{1o} ve W_{2o}) ağırlık vektörlerinin değişmeden önceki değerlerini göstermektedir. LVQ ağıları özellikle sınıflandırma problemlerinin çözümünde kullanılır.

- **Kohonen Ağı**

SOM (Self Organization Feature Map Network-Özörgütlemeli Özellik Haritası) olarak da adlandırılan Kohonen ağı, beynin Neocortex tabakasında yaygın olan duysal haritalardan esinlenilerek 1972 yılında Kohonen tarafından geliştirilmiştir. Genel olarak sınıflandırma yapmak için kullanılan Kohonen ağının, girdi vektörlerini sınıflandırma ve girdi vektörlerinin dağılımını öğrenebilme yetenekleri oldukça yüksektir. Eğitimi sırasında herhangi bir danışmana veya beklenen çıktıya gerek duymayan bu yapay sinir ağı girdi ve çıktı katmanı olmak üzere iki katmandan oluşur. Çıktı katmanı iki boyutlu bir düzlemi, işlemci elemanlar ise bu düzlem üzerine dağılmış vektörleri gösterirler. Girdi elemanları çıktı elemanlarının tamamıyla bağlantılıdır. Yarışmacı öğrenmeyi kullanan Kohonen ağında kazanan işlemci eleman 1 diğer elemanlar ise 0 değerini alır. Eğitimi sırasında hem yarışmayı kazanan işlemci elemanın hem de komşusu olan işlemci elemanların ağırlıkları değiştirilir.



Şekil 5.18. Kohonen Ağı (Fröhlich, 1997)

Çok katmanlı algılayıcılar (ÇKA) modeli giriş katmanı, gizli katman ve çıktı katmanı olmak üzere üç ana katmandan oluşmaktadır. Ara katman sayısının kaç olması gerektiğin gösteren bir yöntem yoktur. Girdi katmanına giren bilgiler ağırlık ve eşik değerleri kullanılarak çıktıya dönüştürülürler. Ağırlıklandırmadan sonra, bu değiştirilmiş girdiler toplama fonksiyonuna gönderilirler. Toplama fonksiyonunda. Toplama fonksiyonu, basit çarpımlar toplamına ek olarak, minimum, maksimum, mod, çarpım veya çeşitli normalizasyon işlemlerinden birisi olabilir. Girdileri birleştirecek olan algoritma genellikle seçilen ağ mimarisine de bağlıdır. Bu fonksiyonlar farklı şekilde değerler üretebilir ve sonra bu değerler ileri doğru gönderilir. Ek olarak, uygulamacı kendi fonksiyonunu oluşturup toplama fonksiyonu olarak kullanabilir. Bazı toplama fonksiyonları, transfer fonksiyonuna ilemeden önce, sonuçları üzerinde ilave işlemler yaparlar. Bu işlem aktivasyon fonksiyonu olarak adlandırılan işlemdir. Bir aktivasyon fonksiyonu kullanmanın amacı toplama fonksiyonu çıktısının zamana bağlı olarak değişmesini sağlamaktır (Yurtoğlu, 2005). Son aşamada toplama fonksiyonu çıktısı transfer fonksiyonuna gönderilir. Bu fonksiyon, aldığı değeri bir algoritma ile gerçek bir çıktıya dönüştürür. Transfer fonksiyonu genellikle doğrusal olmayan bir fonksiyondur. Doğrusal fonksiyonlar genelde tercih edilmez çünkü doğrusal fonksiyonlarda çıktı, girdi ile orantılıdır.

Bu çalışmada oluşturulan ağ yapısını eğitmek için Levenberg Marquart (LM) (Marquardt, 1963) algoritması kullanılmıştır. Gauss Newton ve Steepest Descent algoritmasının değişik bir uyarlaması olan LM algoritması, son yıllarda kullanılan en yaygın yöntemlerden biridir. Levenberg-Marquardt algoritması için ağırlıklar aşağıdaki eşitlik kullanılarak güncelleştirilir.

Burada W_{ij} ağırlıkları, J Jakobiyen matrisi, μ bir sabit, I birim matris ve $E(w)$ hata fonksiyonudur. Jakobiyen matrisi ağda yer alan ağırlık ve biaslara ait hataların ilk türevlerini içerir ve standart geri yayılım algoritması kullanılarak hesaplanabilir. Her başarılı adımda μ değeri azalırken hataların karelerinin toplamının arttığı adımlarda μ değeri artırılır. Bu metotda μ parametresi hesaplama süresince otomatik olarak güncellenmekte ve böylece yavaş yakınsama probleminden etkilenmediği için hızlı bir yaklaşım elde edilmektedir. Yaklaşım oranı hızlanması ile eğitim kısa sürmektedir. Ancak fazla işlem yapmakta ve sonucunda çok fazla hafıza kullanmayı gerektirmektedir (Haykin at al.,1990).

Yapay sinir ağları, çok sayıda nöronun birbirleri ile paralel olarak bağlı olduğu yapılardır ve sinyallerin iletim yönüne bağlı olarak ikiye ayrılır: *ileri beslemeli* ve *geri beslemeli*. İleri beslemeli ağlarda, sinyal iletimi, bir katmandaki nöronlardan, bir sonraki katmandaki nöronlara doğru yapılır ve aynı katmandaki nöronlar arası bağlantı bulunmaz. Geri beslemeli ağlarda ise, sinyal iletimi iki yönlü (ileri ve geri) olarak da mümkündür ve bir çıkış sinyali, giriş ve çıkış değerlerini dinamik bir şekilde kontrol edebilmektedir.

5.4. YAPAY SİNİR AĞI MİMARİSİ


5.4.1 AĞ KATMANLARI

Yapay sinir ağının en ortak tipi 3 gruba, katman ya da birime, dayanır. “ Giriş “, “Gizli”, “Çıkış” biriminin katmanına bağlanmıştır.

- Giriş biriminin aktivitesi, ağda beslenen ham bilgiyi temsil eder.
- Her gizli ünitenin aktivitesi, giriş ve gizli üniteler arasındaki bağlantılar üzerindeki ağırlıklar ve giriş ünitelerinin aktiviteleri tarafından belirlenir.
- Çıkış ünitelerinin davranışı gizli ünitelerin aktivitesine ve gizli ünitelerle çıkış üniteleri arasındaki ağırlığa dayanır.

5.4.1.1. Tek Katmanlı Ağlar

Bir tek katmanlı yapay sinir ağı, bir katmanda organize edilmiş birim gruplarından meydana gelir. Her U_i ünitesi W_{ij} ile X_j girişini alır. Şekil 5.19’ da m girişli ve n çıkışlı bir tek katmanlı lineer modeli gösterilmektedir..



Şekil 5.19. Bir Tek Katmanlı Lineer Ağ (Öztemel, 2003)

$X=(X_1, X_2, X_3, \dots, X_m)$ giriş vektörü olsun. Aktivasyon fonksiyonu f basitçe olsun. Aktivasyon enerjisi sadece birimin net toplamıdır. $m \times n$ matrisi:

$$W = \begin{bmatrix} W_{11} & \dots & W_{1n} \\ W_{21} & \dots & W_{2n} \\ \vdots & & \vdots \\ W_{m1} & \dots & W_{mn} \end{bmatrix} \quad (5.8)$$

Bu sonuçla U birimindeki y_i çıkışı:

$$Y_t = (W_{1t}, W_{2t} \dots W_{mt}) \cdot \begin{bmatrix} X_1 \\ X_2 \\ X_3 \end{bmatrix}, \quad (5.9)$$

V çıkış vektörü:

$$\vec{V} = (y_1, y_2 \dots y_n)^T \quad (5.10)$$

$$y_{n \times t} = \vec{W}_{n \times m} \vec{X}_{n \times m} \quad (5.11)$$


Çıkış vektörü:

$$y = (y_1, y_2 \dots y_n)^T \quad (5.12)$$

$$y = (WT \times X) \text{ şeklinde gösterilir.} \quad (5.13)$$

5.4.1.2.. Çok Katmanlı Ağlar

Birçok katmanlı ağ, 2 ya da daha fazla birim katmanına sahiptir. Giriş olarak bir katman servisinde bir diğerine çıkış ile harici çıkış bağlantıları olmayan katmanlar saklı katmanlar olarak açıklanırlar.



Şekil 5.20. Çok katmanlı ağ (Öztemel, 2003)

Bununla birlikte lineer aktivasyon fonksiyonuna sahip sabit ağırlıklarıyla, herhangi bir çok katmanlı sistem; bir tek katmanlı lineer sisteme eşittir. Örneğin iki katmanlı bir lineer sistemin durumunu ele alalım. İlk katman için giriş vektörü X , ilk katmanın $Y = W_2 * X$ çıkışı 2. katman için giriş olarak verilmiştir ve 2. katman $Z = W_2 * Y$ çıkışı üretmiştir. Bu nedenle;

$$Z = W_2 * (W_1 * X) = (W_2 * W_1) * X \quad (5.14)$$

Sonuç olarak; birçok katmanlı sistem $W=W_2*W_1$ ağırlık matrisiyle bir tek katmanlı ağı eşittir. Tümevarım ile bir n katmanlı sistem ağırlık matrisi n orta ağırlıktaki matrisin ürünü olan bir tek katmanlı lineer sisteme eşittir.

Başka bir deyişle, birçok katmanlı sistem (lineer olmayan), bir tek katmanlı sistemden daha çok hesaplanabilme yeteneği sağlayabilir. Örneğin algılayıcı tarafından karşılaşılan problemler, saklı katmanların eklenmesiyle üstesinden gelinebilir. Çok katmanlı ağların çok güçlü olduğu kanıtlanmıştır.

6. İNŞAAT MÜHENDİSLİĞİNDE YAPAY ZEKA TEKNİKLERİ İLE YAPILAN ÇALIŞMALAR

Yapay zeka tekniklerinin inşaat mühendisliği alanında kullanımı ile ilgili çalışmalar incelendiğinde, araştırma alanı çok büyük boyutlu ve karmaşık ise, matematik analiz ile çözüm mümkün değilse veya geleneksel araştırma yöntemleri ile başarısız olunmuş veya iyi sonuç alınamamış ise en iyi çözüme ulaşmak için yapay zeka tekniklerinden faydalandığı görülmüştür. İncelenen literatürlerden önemli olanları aşağıda özetlenmiştir.

6.1. Bulanık Mantık İle Yapılan Çalışmalar

İnşaat mühendisliği sistemlerinde Fuzzy denetleyicisinin temel avantajı içsel bağımlılık ve yapının herhangi bir doğrusal olmayan davranışını tanıtabilme yeteneğinin olmasıdır.

- Aldawod ve arkadaşları yaptıkları çalışmada bulanık mantık yöntemini kullanarak gökdelenlerin rüzgar etkisi karşısındaki davranışının kontrol edilmesini amaçlamışlardır. Çalışmada yazarlar, Avustralya'daki Melbourne şehrinde bulunan 76 katlı ve 306 metre uzunluğundaki betonarme ile inşa edilmiş gökdeleni dikkate almışlardır. Çalışma sonucunda, fuzzy kontrol aracının klasik kontrol araçlarına göre daha avantajlı ve güvenilir olduğu ifade edilmiştir.

- Samali ve arkadaşı, deprem yüklerini algılamak için aktif ayarlı kütle amortisörü kullanarak beş katmanlı değerlendirme modeli oluşturmuş ve bu modeli fuzzy'le kontrol etmiştir. Bu çalışmadaki fuzzy kontrol aracının avantajını, yapının herhangi bir non-lineer davranışının ve sağlamlığının belirlenebilmesi olarak ifade etmişlerdir.

- Uygunoğlu ve arkadaşları yaptıkları çalışmada çimento ile belirli oranlarda ikame edilen uçucu külün betonun basınç dayanımı üzerindeki etkisini bulanık mantık yaklaşımı ile modellemeye çalışmışlardır. Bulanık mantık yaklaşımı ile deneysel olarak elde edilmiş veriler karşılaştırılmış

ve sonuçların çok yakın olduğu görülmüştür. Çalışma sonunda bulanık mantık yaklaşımı ile betona en iyi basınç dayanımını kazandıracak optimum uçucu kül miktarı belirlenmiştir.

- Yurtçu ve arkadaşları bu çalışmada, bağımsız değişkenler olarak, yağış, akış ve buharlaşmanın etkisiyle, bağımlı değişken olan yeraltı su seviyesindeki (YSS) değişimin, bulanık mantık ile modellenmesini araştırmışlardır. Çalışma sonunda bulanık mantık yaklaşımından elde edilen sonuçlar ile istasyonlardan alınan verilerin aylık ortalama değerlerinin birbirine çok yakın olduğu görülmüştür.

- Juang ve diğerleri (1999) bulanık küme teorisi yardımıyla çalışan bir YSA eğitime tekniği sundular. Teknik, girdi parametrelerinin ön işleme ve çıktıların ağda geri işleme süreci için modüller geliştirmiştir. Bu araştırmacılar, bulanık küme tabanlı yapay sinir ağlarının yüksek verimde eğitilebileceğini göstermişlerdir. Bu çalışma, denetimli sınırlı bellek kullanan ve derin kazılarda duvar hareket diyagramını tahmine yönelik bir model oluşturmuştur(Broydon-Fletcher-Goldfarb-Shanno (L-BFGS)). (Hung ve Lin, 1994).

6.2. Sinirsel – Bulanık Sistem (Neuro Fuzzy) İle Yapılan Çalışmalar

- Dixon, yapmış olduğu çalışmasında Coğrafi bilgi sistemiyle nöro fuzzy kümelerinin birleşimini kullanarak yer altı suyu davranışını incelemiştir. Çalışma sonucunda belirsiz olan verilerin yerine bu modelle geliştirdiği verileri kullanarak bölgesel ve kıtasal ölçekli çevresel modelleme gerçekleştirmiştir.

- Akbulut ve arkadaşları, geliştirdikleri sinirsel bulanık sistem ile betonarme inşaatlarında kullanılan kumların nemlilik dereceleri ve kesme modüllerinin tahmin edilmesinde kullanılmışlardır. Uygulamada yapay sinir ağları için klasik geri beslemeli sistem kullanmışlardır. Çalışma sonucunda sinirsel bulanık sistem (SBS) ile çoklu regresyon analiz sonuçlarını karşılaştırmışlar ve SBS'in daha iyi olduğunu belirtmişlerdir.

6.3. Genetik Algoritmalar İle Yapılan Çalışmalar

- Sahab ve arkadaşları, yapılan çalışmada binalarda düz plaka betonarme betonu için genetik algoritma değişimine dayanarak iki aşamalı melez optimizasyon algoritması kullanmışlardır. İlk aşamada yüzey araştırma tasarımı, ikinci aşamada Jeeves ve Hooke metotlarının genetik algoritma ile çözümünü kritiğe tabi tutulmuştur. Sonuç olarak optimum çözüm için genetik algoritma ile çözümden önce yeterli miktarda değerlendirme fonksiyonu sağlanması gerektiğine karar verilmiştir.

- Sedki vd. (2008), günlük yağış- akış ilişkisinin gerçek genetik algoritmalarının yapay sinir ağları metoduyla elde etmeye çalışmışlardır. Fas'ta yapılan çalışmanın sonucu olarak genetik algoritma ile oluşturulan modellemede, geleneksel ve geri yayımlı modellemeye göre daha iyi sonuçlar verdiğini göstermişlerdir.
- Kaya çalışmasında, yüksek kırışlerde donatı çaplarının optimum tasarımını gerçekleştirmek üzere kesit özellikleri pratikte hazır olan standart kesitlerden seçebilen bir genetik yaklaşım sunulmaktadır. Değerlendirme, seçim, kopyalama, çaprazlama ve mutasyon operatörlerinden oluşan genetik algoritma kullanılarak yüksek kırış elemanları için üzerlerine etki eden yükleri belli bir emniyetle taşıyacak şekilde yatay ve düşey ortogonal donatı çapları belirlenmiştir. Yüksek kırışlerin ACI' da belirtilen koşullara göre analizi yapılarak ACI' nin yüksek kırışlerin analizinde uygulamada karşılaşılan güçlükler ve sınırlamalar ortaya konmuştur. Aynı problemlerin geliştirilen bilgisayar programı ile de analizi yapılarak bu programın ne derece kullanışlı olduğu ortaya konmuştur.
- Morcoux ve arkadaşları çok büyük boyutlu ve karmaşık bir yapıya sahip olan alt yapı şebeke sistemlerinin bakım optimizasyonu için genetik algoritmaları başarılı bir şekilde uygulamışlardır.
- Fairbairn ve arkadaşları, kütle beton yapılarının inşasında (malzeme cinsi, ortam sıcaklığı, pompa yüksekliği vb. kriterleri kullanarak) optimum inşaat maliyetini elde etmek için genetik algoritmaları başarıyla uygulamışlardır.

6.4. Yapay Sinir Ağları İle Yapılan Çalışmalar

- Lee ve arkadaşları beton basınç dayanımının belirlenmesi üzerine yapmış olduğu çalışmada, beton basınç dayanımının tahmin edilmesi için yapay zeka sistemi geliştirmiştir. Bu amaçla yapay sinir ağlarından faydalanmıştır. Geliştirdiği model yardımıyla deneysel verilere etkili bir şekilde yakın sonuçlar elde edebilmesinin yanı sıra yeni değerler de üretebilmesinin de önemli bir avantaj olduğunu vurgulamıştır.
- Özsoy ve arkadaşları kırışsız döşemeli betonarme bir binada çeşitli parametrelere bağlı olarak meydana gelen yatay ötelenme değerinin yapay sinir ağları (YSA) ile tahmin edilmesi üzerine bir çalışma gerçekleştirmişlerdir. YSA ile yapılan yatay yerdeğiştirme tahminleri, SAP2000 programından alınan yatay deplasman verileri ile karşılaştırılmış ve elde edilen sonuçların birbirine çok yakın olmasından dolayı YSA ile yatay deplasmanların başarılı bir şekilde tahmin edilebileceği vurgulanmıştır.

- Yurdusev ve diğerleri. (2007), YSA metodunu kullanarak Akarçay kapalı havzasındaki aylık akımların, yağış ve akım gözlemlerinden tahmin edilmesini ele almışlardır. Havzada mevcut bulunan yağış gözlem istasyonlarının yerleşimi, gözlem aralığı gibi parametreler bağlı olarak 4 ayrı kategoride model tasarlamışlardır. Elde edilen sonuçlar çok değişkenli regresyon analizi sonuçları ile kıyaslayarak Yapay Sinir Ağları metodunun, akım ve yağış gözlemlerinden, akış tahmini problemine başarılı bir şekilde uygulanabileceği ve güvenli tahminler ürettiğini belirtmişlerdir.

- Erzin ve diğerleri. (2007), kil, silt, siltli kum, ince ve kaba kumlardan deneysel olarak elde edilmiş termal rezistivite değerlerine dayanan yapay sinir ağı modelleri geliştirmişleridir. Bu zeminler birbirinden tamamen farklı özellikler göstermeleri ve doğada en sık karşılaşılan zeminler olmaları nedeniyle çalışmalarda araştırılma gereği görülmüştür. Farklı kompaksiyon aşamalarındaki bu zeminlerin termal dirençleri laboratuvar ortamında termal prob yardımıyla ölçülmüş ve elde edilen değerler tek tek YSA modeli ile elde edilenlerle karşılaştırılmıştır.

7. GEOTEKNİK ALANINDA YAPAY SİNİR AĞLARININ KULLANIMI

Son yıllar içerisinde, yapay sinir ağlarının (YSA) kullanımı birçok mühendislik alanında artış göstermiştir. Özellikle, YSA birçok geoteknik mühendisliği problemine uygulanmış ve yüksek derecede başarı göstermiştir. Literatür derlemesi göstermektedir ki; kazık kapasitesi tahmini, zemin davranışı modellemesi, yapılarda oturma sorunu, şev stabilitesi, yer altında inşa edilecek yapı ve tünellerin tasarımı ve karşılaşılan oturma problemleri, sıvılaşma, zemin geçirimsizliği ve hidrolik iletkenliği, zemin kompaksiyonu, şişme ve sınıflandırılmasında YSA başarılı olarak uygulanmıştır. Geoteknik problemlerinin yukarıda sayılan ve bu konulara benzer problemlerini çözmek ve yapay sinir ağları hakkında genel bir görüş geliştirmek için bu çalışma yapılmıştır. Ayrıca tüm çalışmaların incelenmesi yoluna gidilmemiş bunun yerine bazı detayların kuvvetle çözüme yardımcı olabileceği düşünülen, konulara ait seçilmiş çalışmalar; benzerlerine referans gösterebilecek biçimde derlenmiş ve yorumlanmıştır. Yazı daha çok YSA'nın kullanımdaki güç ve sınırlamalarını diğer modelleme yaklaşımlarına kıyaslayarak da tartışmaya açacaktır.

Zemin ve kayaların mühendislik özellikleri, kendilerini meydana getiren malzemelerin karmaşık ve kesin olmayan fiziksel süreçlerine bağlı çeşitli ve belirsiz davranışlar sergilemektedirler (Jaksa, 1995). Bu durum; çelik, beton ve ahşap gibi çok daha büyük homojenlik ve izotropi gösteren inşaat mühendisliği malzemelerinin tam tersi özellik göstermektedir. Geoteknik davranışın karmaşıklığı ile başa çıkmak amacıyla, mühendislik tasarımı modellerinin geleneksel

yapısı haklı olarak basitleştirilmiştir. Başarılı sonuçlar almış olarak gösterilen, alternatif bir yaklaşım, modelin parametrelerini ve yapısını belirlemek üzere tek başına verilere dayanmaktadır.

Bu teknik, Model değişkenleri arasındaki ilişkinin bilinmediği karmaşık problemleri ideal olarak modelleyen ve yapay sinir ağları (YSA) olarak bilinen bir yaklaşımdır (Hubick 1992). Bu çalışma, yapay sinir ağlarına aşina olmayanlar için de açıklanmış ve konular bu düşünceye dayanarak aktarılmıştır. Çalışma, geoteknik mühendisliğinde yer bulan yapay sinir ağlarının bazı kullanımlarına ait derleme çerçevesinde YSA'nın bazı özelliklerini detaylandırmayı hedeflemektedir.

Geoteknik dalının ana inceleme konusu olan zemin ve kayaların mühendislik özellikleri, bu malzemelerin oluşumları ile bağlantılı olarak karmaşık ve kesin olmayan fiziksel işlemlerden dolayı değişken ve kararsız davranışlar sergilemektedir (Jaksa, 1995). Bu durum, inşaat mühendisliğindeki çelik, beton ve ahşap gibi büyük oranda homojen davranışlar gösteren diğer bir çok malzemeye göre farklılık göstermektedir (Shahin, 2001).

Geoteknik davranışların karmaşıklığı ile başa çıkabilmek için çeşitli yaklaşımlar benimsenmektedir. Bunlardan biri, mühendislik tasarım modellerinin basitleştirilmesidir. Bir diğer alternatif yaklaşımda, modelin yapı ve parametrelerini belirlemek için sadece verilere dayanmaktır. Bu teknik, YSA 'dır. Bilindiği üzere YSA, model değişkenleri arasındaki ilişkilerin bilinmediği karmaşık model problemleri için oldukça uygundur (Hubick, 1992).

Geoteknik alanındaki literatürde 1994 yılından itibaren çalışılan konular taranmış ve şu çalışma grupları ile karşılaşılmıştır:

1) Kazıklar taşıma gücü kapasitesi ve hasar tahminleri: Yeh ve diğ. (1993), Kang ve Yoon (1994), Chan ve diğ. (1995), Goh (1994a, 1995b), Goh (1996b), Lee ve Lee (1996), Teh ve diğ. (1997), Abu-Kiefa (1998), Nawari ve diğ. (1999), Kim ve Kim (2002), Kambekar ve Deo (2003), Hanna ve diğ. (2004), M.A. Shahin ve M.B. Jaksa (2005), Goh ve diğ. (2005), Das ve Bashudhar (2006), Ahmad, Naggar ve Khan (2007), Ardalan, Eslami ve Narima-Zadeh (2009), Ismail ve D.S. Jeng (2011), kazık kapasitelerinin ve kazıklarla ilgili hasarların tahminlenmesinde, çalışmalarında YSA'dan yararlanmışlardır.

2) Oturmalar: Goh (1994), Sivakugan vd. (1998), Kim, Bae, Hong ve diğ. (2001), Shahin vd. (2002), Shahin vd. (2002b), Goh ve Kulhawy (2003), Shahin vd. (2003b), Shahin vd. (2004a), Suwansawat (2004), M.A. Shahin, M. B. Jaksa ve H.R. Maier (2005), Suwansawat ve Einstein (2006), Wang, Li ve Shen (2007), Kim ve Kim (2008), Nejad ve diğ. (2009), temeller, temellerdeki oturmaların tahminlenmesi ve konsolidasyon basıncının belirlenmesi, tünel, derin kazı ve otoyol kazı yüzü etkilerinin modellenmesi konularında çalışmışlardır.

3) Zemin Davranışları: Agrawal (1994), Gribb (1994), Goh (1995a), Cal (1995), Najjar ve diğ. (1996a), Najjar ve Basheer (1996b), Şenol (1997), Penumadu ve Jen-Lou (1997), Sıdarta ve Ghaboussi (1998), Zhu ve diğ. (1998a, 1998b), Basheer (1998), Basheer ve Najjar (1998), Najjar ve Ali (1999), Najjar ve diğ. (1999), Penumadu ve Zhao (1999), Karagöz (1999), Wang (1999), Turk, Logar ve Majes (2001), Hurtada ve diğ. (2001), Chen ve diğ. (2002), Habibagahi ve Bambad (2003), Basma ve diğ. (2003), Najjar (2004), Banimahd ve diğ. (2005), Moosavi ve diğ. (2006), Zhai ve diğ. (2006), Erzin ve diğ. (2007), Ferentinou ve Sakellariou (2007), Das ve Basudhar (2008), He ve Li (2009), İkizler ve diğ. (2010), Çevik ve diğ. (2010); zemin kayma gerilmelerinin analizi ve kayma dayanım parametrelerinin belirlenmesi; zemin ve malzeme davranışlarının incelenmesi; zemin şişmesi ve emme davranışı belirlenmesi konularında çalışmışlardır.

4) Sıvılaşma: Masri ve diğ. (1993), Goh (1994b), Goh (1995), Chen ve diğ. (1995), Goh (1996a), Rahman ve Zahaby (1996b), Ural ve Saka (1998), Tien ve Chen (1999), Wang ve Rahman (1999), Juang ve diğ. (2000), Juang ve diğ. (2001), Goh (2002), Wang ve Rahman (2002), Baziar (2003), Baziar ve Ghorbani (2004), Chen ve diğ. (2004), Chen ve diğ. (2005), Dihoru ve diğ. (2005), Hanna ve diğ. (2007), Baziar ve Jafarian (2007), Cabalar ve Çevik (2008), Baykasoğlu ve diğ. (2009), Lee ve Hsiung (2009), Tsompanakis ve diğ. (2009), Adeli ve Panakkat (2009), Zhang ve diğ. (2010), Farrokhzad ve diğ. (2010), İsmail ve diğ. (2011) sıvılaşma potansiyelini belirleme, sismik hareketlere göre zemin sıvılaşma potansiyeli hesaplama konularında çalışmışlardır.

Zeminin yapısını ve davranışını anlamamıza yarayan bazı özelliklerinin, deneyler sonucu bulunan değerleri kesin olmayıp yaklaşık değerlerdir. Bu değerlerin tam bir kesinlikle bulunamaması numune hazırlamadaki güçlüklerden, hazırlanan numunenin, alındığı zemin tabakasının küçük bir modeli olması ve bunun sonucu doğan hatalardan ve şartların deneyden deneye değişmesinden kaynaklanır. Bu hatalar, her bir numune üzerinde eşit şartlarda, aynı şekilde deney yapılması ile azaltılabilir. Böylece farklı yapıdaki zeminlerin özellikleri birbiri ile karşılaştırılabilir. Farklı zeminlerin çeşitli mühendislik özellikleri de farklı olacaktır. Zeminin yapısındaki homojenlikten sapmalara göre ihtiyaç duyulan mühendislik özelliklerinin tayini için matematiksel bir işlem yoktur. Deney sonuçlarından elde edilen bilgiye dayanarak, bir özelliğin matematiksel karakterini belirleyebilmek için istatistiksel yöntemler kullanılır (Güneş, 1986).

Geoteknik mühendisliği problemlerinin bir diğer özelliği çok gerçekli karar verme durumudur. Yani problemin çözümü için birden çok kabul edilebilir metodun bulunmasıdır. Bu tür durumlarda kesin veri isteyip ona göre kesin sonuç isteyen problemlerin çözümü zorlaşmaktadır. Ancak yapay sinir ağları kullanarak bu tür problemlere daha gerçekçi bir şekilde yaklaşmak mümkündür. Bu amaçla sunulan bu çalışmada, normal konsolide haldeki zeminlerin

kayma mukavemetlerinin, elde edilmesine çalışılmıştır. Yapay sinir ağları genellikle problemin türüne göre belirli oranlarda hata ile sonuca ulaşabilmektedir. Ancak bu hata düzeyi güvenlik katsayılarının oldukça büyük seçildiği geoteknik problemlerinde önemsiz mertebede kalmaktadır.

Kullanılan malzemenin zemin gibi heterojen, daneli ve lineer davranış göstermeyen bir malzeme olduğu gerçeği ve projenin tatbiki sırasında yapılan hatalar göz önüne alınırsa problemin çözümünde yapılan %5-10 mertebesindeki hataların birçok problemde önemli olmadığı ortaya çıkar.

7.1 Kazık Taşıma Gücü Kapasitesi:

Kazık taşıma gücü kapasitesi tahmini, özellikle de kazık çakma verilerine dayananları, birçok farklı YSA araştırmacıları tarafından incelenmiştir.

Yeh ve diğ. (1993) geri yayılma algoritmasını bilgi edinme aracı olarak, ön gerilmeli beton kazıklarda hasar teşhisi (beton yüzeyinde dökülmeler, kazıktaki enine çatlak veya kırılmalar) yapan bilgi tabanlı sistem şeklinde kullanmıştır.

Kang ve Yoon (1994) tarafından geri yayılma algoritması temel alınarak yapay sinir ağları yardımı ile basit kafes sistem tasarımları yapılmıştır. Hoit ve diğ. (1994) ise yapıların sonlu eleman analizlerinde profil ve dalga yüzü karakteristiklerini geliştirmede sinir ağından faydalanmışlardır.

Goh (1994a; 1995b), killerde kazık yanal sürtünme kapasitesi tahmini yürüten bir sinir ağı sunmuştur. Yapay sinir ağı, mevcut vaka kayıtlarından elde edilen arazi verisi ile eğitilmiştir. Modelin girdi parametreleri; kazık uzunluğu, kazık çapı, ortalama efektif gerilme ve drenajsız kesme kayma mukavemeti olarak kabul edilmiştir. Yüzey sürtünme direnci oluşturulan modelin tek çıktısıdır. Yapay sinir ağı kullanılarak elde edilen sonuçlar, Semple ve Rigden (1986) yönteminden elde edilen sonuçlar ve $\hat{\sigma}$ yöntemi (Burland, 1973) ile karşılaştırılmıştır. Yöntemler regresyon analizi kullanımıyla karşılaştırılmış ve hata oranı Çizelge 7.1.'de gösterilmiştir.

Çizelge 7.1. Kazık kapasitesi tahmini regresyon analiz sonuçlarının özeti (Goh, 1994)

Yöntem	Korelasyon Katsayısı		Hata Oranı (kPa)	
	Eğitim	Test	Eğitim	Test
Yapay Sinir Ağı	0.985	0.956	1.016	1.194
Semple ve Rigden (1986)	0.976	0.885	1.318	1.894
$\hat{\sigma}$ Yöntemi	0.731	0.704	4.824	3.096

Tablodan da takip edilebileceği üzere, yapay sinir ağı, geleneksel yöntemlere göre daha iyi bir performans sergilemektedir. Çalışma ayrıca, yapay sinir ağının metodolojisinin, girdilerden çıktılara ulaşma yolunda nasıl bir mantık izlediğinin açıklaması ve izlenimindeki yetersizliğine de işaret etmektedir.

Goh (1995a; 1996b) kısa bir süre sonra, kohezyonsuz zeminlerde çakma kazıkların nihai yük kapasitesini tahmin etmek üzere bir başka yapay sinir ağı geliştirmiştir. Bu çalışmasında, kullanılan veri ahşap, prefabrike beton ve kumlu zemine çakılı çelik kazık üzerinde yapılan mevcut yük deneylerinden elde edilmiştir. YSA'da daha fazla anlam ifade eden model girdileri; çekiç ağırlığı, , kazık uzunluğu, kazık kesit alanı, kazık grubu, kazık elastisite modülü ve çekiç tipidir. Model çıktısı, kazık yük kapasitesidir.

Model, test setleri ile incelendiğinde; yapay sinir ağının kazık yük kapasitesi modellenmesinde başarılı olduğu görülmektedir. Bağlantıdaki ağırlıklar incelendiğinde en önemli veri faktörlerinin kazık grubu, çekiç ağırlığı ve çekiç tipi olduğu görülmektedir. Çalışma yapay sinir ağlarından elde edilen sonuçları, aşağıdaki çalışmalarla olan ortak ilişkileri münasebetiyle karşılaştırmaktadır: Engineering News formülü (Wellington, 1982), Hiley formülü (Hiley, 1992) ve Janbu formülü (Janbu, 1953). Regresyon analizi, yapay sinir ağı ve geleneksel yöntemlerden elde edilen tahmin edilen-ölçülen sonuçların korelasyon katsayısını etmek için yapılmıştır. Aşağıdaki Çizelge 7.2., diğer yöntemlerden elde edilenlere göre, yapay sinir ağı tahminlerinden elde olunan çakma kazık yük kapasitesinin en iyi sonucu verdiğini belirtmektedir.


Çizelge 7.2. Kazık kapasitesi tahmini regresyon analiz sonuçlarının özeti (Goh, 1996)

Yöntem	Korelasyon Katsayısı	
	Eğitim Verisi	Test Verisi
Yapay Sinir Ağı	0.96	0.97
Engineering News	0.69	0.61
Hiley	0.48	0.76
Janbu	0.82	0.89

Chan ve arkadaşları (1995), kazık çakma formülüne bir alternatif olarak bir yapay sinir ağı geliştirmişlerdir. Bu sinir ağı, kazık çakma enerjisi ve kazık grubu, zemin ve kazığın elastik sıkışmasını içeren basitleştirilmiş Hiley formülünde sıralanan (Broms ve Lim, 1988) aynı girdi parametreleriyle eğitilmektedir. Modelden elde edilen çıktı ise, kazık kapasitesi olarak kabul görmektedir. Eğitim sürecinde kullanılan, kazık kapasitesi istenilen çıktı değeri, piyasa bilgisayar yazılımlarından CAPWAP (Rausche at al., 1972) ya da CASE yöntemi (Goble at al., 1975) kullanılarak hesaplanmıştır. Yapay sinir ağının ortalama hata kareleri yüzdesi, eğitim seti için %13.5 ve test seti için ise %12.0'dir.

Lee ve Lee (1996), nihai kazık taşıma gücünü tahmin için yapay sinir ağları kullanmıştır. Problem, kalibrasyon odası kullanılarak modellenen kazık yükleme deneylerinden ve arazide yapılan kazık yükleme testi sonuçlarından elde edilen verileri kullanarak benzetim yapılmasına dayanmaktadır. Model kazık yük deney verisi kullanılarak yapılan simülasyon için, model girdileri; penetrasyon derinlik oranı (kazık penetrasyon derinliği/kazık çapı), kalibrasyon odası ortalama normal gerilmesi ve darbe sayısıdır. Nihai taşıma gücü modelin verdiği çıktıdır. YSA model tahmini göstermektedir ki, maksimum hata %20'den fazla değildir ve toplam karekök hatası ise %15'ten azdır. Arazi kazık yükleme deney verileri kullanılarak geliştirilen simülasyon için, penetrasyon derinlik oranı, kazık gövdesi boyunca ortalama standart penetrasyon sayısı, kazık ucu yakınındaki ortalama standart penetrasyon sayısı, kazık grubu ve çekiç enerjisini tanımlayan beş girdi değişkeni kullanılmıştır. İki yapay sinir ağı modeli geliştirilmiştir.


Bu modellerden elde edilen sonuçlar, ortalama standart penetrasyon değerine dayalı Meyerhof denklemi (Meyerhof, 1976) ile karşılaştırılmıştır. Aşağıdaki şekil, Meyerhof denklemi ve yapay sinir ağı modellerinden elde edilen tahmini değerlerin karşılığında ölçülen sonuçları Şekil 7.1. üzerinde resmetmektedir. Aynı şekil göstermektedir ki; yapay sinir ağı ile tahminlenen değerler, Meyerhof denkleminde elde edilenlerden daha fazla ölçülen sonuçlarla örtüşmektedir.



Şekil 7.1. YSA-Meyerhof denklemi kazık nihai taşıma gücü tahmini karşılaştırması (Lee ve Lee, 1996)

Teh ve diğ. (1997) prefabrike kare kesitli beton kazık için, dinamik gerilme-dalga verilerinden tahmin sağlayan bir statik kazık kapasitesi yapay sinir ağı modeli ortaya koymuşlardır. Sinir ağları, gerilme-dalga girdilerinden ilişkilendirme yaparak CAPWAP bilgisayar koduyla elde edilen kapasite verileri ile eğitilmektedir (Rausc at al., 1972). Bu çalışma CAPWAP tahmini

kapasite ile gerçek kazık taşıma gücü kapasitesini karşılaştırmak amacını gütmektedir. Yapay sinir ağı eğitim seti verilerini neredeyse mükemmel bir biçimde ve statik toplam kazık kapasitesini 0,0003'ten daha düşük bir ortalama karekök hata ile öğrenmektedir. Eğitilen yapay sinir ağı, test verileri seti ile genellemeye varılabilecek bir biçimde olduğu için değerlendirilmeye alınmıştır. On tane içerisinde en iyi yedi tahmini sağlayan kazıklar Şekil 7.2.'de gösterilmiştir.



Şekil 7.2. Teorik oturma ve yapay sinir ağı tahmini karşılaştırması (Teh ve dig., 1997)

Derin kazı ile ilgili yapılan çalışmada Peck (1969), derin kazı problemini yatay olarak desteklenmesi gereken bir düşey kenarlı kazık problemi olarak nitelendirmiştir. Yapılan çalışmada; derin kazıya etkiyecek ve tasarımında kullanılacak yanal hareketler ele alınmış, zeminde karşılaşılan oturmalar ve kabarmalar bu konu dahilinde ortaya çıkacak deformasyonlar olarak incelenmiştir. Kazı etrafındaki oturmaların alt düzeylere çekilmesi için gereken zemin basınç diyagramları ve kriterler belirlenmiştir. Çalışmanın temeli ise arazi gözlemleri ve konu hakkında oluşan kişisel deneyime dayanmaktadır.

Dolaylı yöntemlerin aksine direkt CPT yöntemlerinde; ortalama efektif gerilme, zeminin sıkışabilirliği ve sertliği koniyi ve kazığı benzer biçimde etkiler. Dolayısıyla, bu durum saha verilerini laboratuvar testleriyle tamamlama gereğini ortadan kaldırırken; zemin basınç katsayısı, K_s , ve yatak kapasitesi, N_q , gibi ara değerlerin hesaplanmasını da ortadan kaldırır. Direkt CPT yöntemleri az ya da çok ölçülen koni direncini kazık birim uç direncine eşitler. Bazı CPT direkt yöntemleri koni kılıf direncini kazık birim gövde direncini belirlemek için kullanır. Diğer yöntemlerde ise kazık birim gövde direnci, koni direncine oranlanarak hesaplar yapılır (Eslami ve Fellenius, 1997).

Piezocone (CPT_u) gelişimi ile, penetrasyon sürecinde boşluk suyu hareketinin ölçümü de mümkün olmaktadır. Campanella ve Robertson'un mevcut çalışmaları, Eslami ve Fellenius; geleneksel CPT yöntemlerine göre CPT_u yönteminin avantajlı olduğunu göstermiştir. Eslami ve Fellenius tarafından yürütülen araştırmalar, kazık gövde direncinin, koni kılıf sürtünmesi (f_s) ve efektif koni uç direncinin, q_E ($q_E = q_t - u_2$), burada u_2 koni uç noktası hizasında ölçülen boşluk suyudur) bir fonksiyonu olarak tanımlanabileceğine dikkat çekmişlerdir. Birbirine bağımlı faktörlerin ilişkileri bazı problemlerde, regresyon analizi kullanımını engellemektedir ve daha geniş, karmaşık yöntemlere talebi yönlendirir. Bu konu hakkında bir araştırma yaklaşımı, yapay sinir ağları uygulamasıdır ve büyük başarı dereceleri elde edilmiştir. Bu teknik, model değişkenleri arasında var olan bilinmeyen ilişkilerin olduğu karmaşık problemlerin, modellenmesinde uygundur.

Birçok araştırmada çabalar, sistem nitelemek için gelişmiş yöntemlerin etkili araçlar olarak kullanılmasının üzerine yoğunlaşmıştır (Kristinson ve Dumont, 1992). Bu yöntemler arasında veri işleme grup yöntem (GMDH) algoritması kendini aşamalı karmaşık modellerle ve çoklu-girdi ve tek-girdi veri çiftleri (x_i, y_i) seti üzerinde performansların değerlendirilmesi baz alınarak oluşturulmasıyla organize eden bir yaklaşımdır ($i = 1, 2, \dots, M$). GMDH ilk olarak, Ivakhnenko tarafından, sistem üzerinde özel bilgiye sahip olmaksızın karmaşık sistemlerin modellenmesi için kullanılabilen, karmaşık sistem modellenme ve tanımlanması için bir çoklu analiz yöntemi olarak geliştirilmiştir (Ivakhnenko, 1971). GMDH'nin ana fikrinde, katsayıların regresyon tekniği ile elde edildiği karesel düğüm transferine dayanan ileri beslemeli ağda analitik bir fonksiyon inşa etmek yatmaktadır (Farlow, 1984).

Abu-Kiefa (1998), kohezyonsuz zeminlerdeki çakma kazıkların kapasitesinin tahmini için üç yapay sinir ağı modeli (GRNNM1, GRNNM2 ve GRNNM3) ortaya koymuştur. İlk model toplam kazık kapasitesinin tahmini için geliştirilmiştir. İkinci model, kazık uç kapasitesi tahmini işine yararken; son model ise kazık yan kapasitesini tahmin için kullanılmıştır. İlk modelde model girdileri olarak beş değişken seçilmiştir.


Bu değişkenler; kazık gövdesi boyunca uzanan zeminin kayma direnci açısı, kazığın uç kısmındaki kayma direnci açısı, kazık ucu efektif gerilme, kazık uzunluğu ve eşdeğer kazık kesit alanıdır. Modelin toplam kazık kapasitesini tanımlayan tek bir çıktısı vardır.

Kazık uç dayanımını belirlemek için kullanılan modelde de yukarıda sözü edilen değişkenler kullanılmıştır. Kazığın yanal dayanımını tahmin için kullanılan girdi verileri ise, kazık gövdesi boyunca ortalama standart penetrasyon sayısı, gövde boyunca kayma dayanımı açısı, kazık uzunluğu ve kazık çapı olmak üzere dört tanedir.


Bu çalışmadaki yapay sinir ağından elde edilen sonuçlar, diğer dört deneysel teknik ile karşılaştırılmaktadır.

Bu teknikler, Meyerhof (1976), Coyle ve Castello (1981), Amerikan Petrol Enstitüsü (1984) ve Randolph (1985) tarafından önerilmiştir. Diğer yöntemlerde 0.52 ile 0.63 arasında değişen değerler gösterirken, yapay sinir ağı modelinden elde edilen tüm veri sonuçları için, toplam kazık kapasitesi sonuçları 0.95 gibi yüksek bir determinasyon katsayısı göstermektedir. Aşağıdaki şekiller, tüm veri kayıtlarında sırasıyla; kazık kapasitesi, kazık uç kapasitesi ve kazık yanal kapasitesi için ölçülen karşılığında tahmini değerleri göstermektedir.


Şekil 7.3-7.4 v3 7.5'ten de görülebileceği gibi, yapay sinir ağı modeline bağlı tahminler diğer yöntemlerle yapılanlarına göre daha az doğrultudan sapma ve yayılım göstermektedir ve bu da kazık yük kapasitesi, kazık uç ve yanal dayanımı için en iyi tahmini üretmektedir.



Şekil 7.3. Kohezyonsuz zeminlerdeki çakma kazıkların kapasitesinin tahmininde YSA GRNNM1 ve diğer yöntemlerin karşılaştırması (Abu-Kiefa, 1998)



Şekil 7.4. Kohezyonsuz zeminlerdeki çakma kazıkların kapasitesinin tahmininde YSA GRNNM2 ve diğer yöntemlerin karşılaştırması (Abu-Kiefa, 1998)




Şekil 7.5. Kohezyonsuz zeminlerdeki çakma kazıkların kapasitesinin tahmininde YSA GRNNM3 ve diğer yöntemlerin karşılaştırması (Abu-Kiefa, 1998)

Nawari ve diğ. (1999) yaptıkları diğer bir çalışma ise, ön gerilmeli ve güçlendirmeli beton kazıklar ve H profili çelik ve çelik kazıklar için yanal yük ve eksenel yük kapasitesi tahminini içermektedir.

Kim ve Kim (2002) kazık gruplarındaki yatay yük- sehim ilişkisini tahmin etmek için geri yayımlı (BPNN) ve sıralı (SNN) sinir ağı geliştirmiştir.


Kambekar ve Deo (2003), okyanus ortamı ile kazık temelli yapılar arasındaki etkileşim, genel ve doğru bir biçimde oyulma derinliği ve geometrisini tahmin niteliğinde prototip çalışmaları ve laboratuvar çalışmalarına rağmen halen karmaşık ve zor bir problemdir. Bu belirsizliğin altında yatan nedenlerden biri de, genel olarak bu probleme ait toplanan verileri de analiz etmede yaygın olarak kullanılan istatistiki eğri uydurma sınırlandırmalarıdır. Bu nedenle Kambekar ve Deo yaptıkları çalışmada oyulma verilerini başka bir veri madenciliği tekniği kullanarak “Yapay Sinir Ağları” ile analiz etmişlerdir. Nonlineer yönlü regresyon yöntem modelinden farklı olarak, yapay sinir ağlarının rasgele girdi vektörünü rasgele çıktı vektörü ile eşleştirme yeteneği mevcuttur. Oyulma derinliği gibi oyulma genişliğini de tahmin etmeye yarayan farklı yapay sinir ağları geliştirilmiştir. Japonya kapalı kıyı konumunda bulunan iskeleyi destekleyen kazık gruplarında girdi değişkenleri olarak; dalga yüksekliği, dalga periyodu, su derinliği ve kazık çapı hem de kazık Reynold sayısı, maksimum dalga zerresi hızı, maksimum kayma hızı Shield parametresi ve Keulegan-Carpenter sayısı kullanılmıştır. Yapay sinir ağları ileri beslemelidir. Geri yayılım ve kaskat korelasyon algoritmaları kullanılarak eğitilmiştir. Test sonuçları ise yapay sinir ağlarının, istatistiksel doğru uydurma yöntemine alternatif ve çok daha iyi bir yöntem olduğunu göstermektedir. Gruplandırılmış kombinasyonlarına nazaran tekil girdi parametreleri daha iyi sonuçlar vermektedir.



Şekil 7.6. Kazık temelli yapılarda okyanus tabanı oyulma tahmininde kullanılan bir YSA mimarisi (Kambekar ve Deo, 2003)

H, T ve su derinliği, d, gibi etkin ham değişkenlerden oluşan girdi parametrelerinden eğitilen bir yapay sinir ağında (Şekil 7.6.) bu değişkenler, belirli bir lokasyonda zaman zaman değişirken;

D; S; ϕ ; and, f ise sabit kalmaktadır. Bir kazık grubu etrafındaki oyulma deliğinin boyutları, Ağustos 1984- Eylül 1989 dönemleri arasında yapılan 56 haftalık gözlem enketleri yoluyla elde edilen çevresel parametrelere bağlı olarak kayıtlarda mevcut durumdadır. Bahsi geçen kazık grubu, salınım dalgalarının hakim olduğu ve kırılan dalgaların etkisinden uzak iskele sonunda bulunmaktadır. Oyulma boyutları, denge dönemine tekabül etmekteyken; dalga yüksekliği ve periyot değerleri haftalık ortalamalara dayanmaktadır. Tortu tabakasında ortalama tane boyutu 0.2 mm'dir. Her ne kadar kazıklar arasında merkezden merkeze uzaklık büyük (tekil kazık çapından yaklaşık 4.5 kat) olsa da, Şekil 7.7'de görüldüğü gibi grup boyutlarında 's' (derinlik) ve 'L_w' (genişlik) değerleri ortak olarak düşünülmüştür.



Şekil 7.7. (a) Kazık grubu yerleşimi (b) okyanus tabanı oyulması (Kambekar ve Deo, 2003)

Hanna, G. Morcous ve M. Helmy (2004), eksenel yükleme maruz ve kohezyonsuz zeminde bulunan kazık grubunun verim oranlarını araştırmak üzere bir yapay sinir ağı modeli tanımlamışlardır. Model kazık grubuna ait düzlem geometriyi açıklamakta (kazık çapı, kazık aralığı ve kazık yerleşimi) ve kazık grubu yerleşim etkisi, kazık uzunluğu, kazık başlığı durumu, zemin durumu ve yükleme tipinin etkisini içermektedir. Önerilen YSA modeli tarafından üretilen sonuçlar, mevcut laboratuvar ve arazi deneylerinden elde edilen değerleri ile karşılaştırılmıştır. YSA modeli, gerçekçi ve doğru bir biçimde kazık grup verimliliğini belirlemede geoteknik mühendislerine yardımcı uygun bir tasarım aracı görevi görmektedir. Üç katmanlı yapay sinir


ağı (girdi katmanı, gizli katman ve çıktı katmanı) genelleme yeteneği ve hesaplamadaki verimliliği nedeniyle seçilmiştir. Önerilen YSA modeline ait özgün sonuçlar aşağıdaki gibidir:

(1) Model yalnızca düzlem (planar) geometriyi (kazık aralığı, kazık çapı ve kazık grubu yerleşimi) değil kazık dayanımı belirlenmesinde verimlilik teşkil eden diğer parametreleri (kazık başlık durumu, zemin durumu, yükleme tipi, deney tipi, kazık kesiti ve yerleşim şekli) de içermektedir.

(2) Model çok-yönlüdür. Bu nedenle her türlü kazık grubu için kazık grup verimliliğini tahminde etkindir ve herhangi bir sadeleştirilmiş yaklaşım kullanılması gerekli değildir.

(3) Model, geleneksel modellerle kıyaslandığında, dahaz yüksek düzeyde doğruluk sağlamaktadır. En yüksek determinasyon katsayısı ($R^2 = 0.72$) ve en düşük hataya ($MAE = 0.157$ ve $RMSE = 0.23$) sahiptir. Geleneksel yöntemler çok daha düşük determinasyon katsayısına ulaşırken (R^2 0.0001 ile 0.081 Aralığında) ve yüksek hata değerlerine (MAE 0.42 ile 0.49, $RMSE$ 0.23 ile 0.62 Aralığında) sahiptir.

(4) Laboratuvar ve/veya arazi deneyleri ile elde edilen yeni verilerin kullanımı için model kolayca güncellenebilmektedir. İstatistikî deney değişken analizi (ANOVA), kazık grubu verimliliği (Şekil 7.8) ve bu verimliliği yönettiği kabul edilen niteliksel parametreler arasındaki ilişkiyi değerlendirmek için gerçekleştirilmiştir.



Şekil 7.8. Farklı tolerans değerlerinde YSA ve geleneksel yöntemlerin doğruluğu (Hanna at al. 2004)

Çizelge 7.3'te ilk iki sütun, muhtemel değerleri ile birlikte düzenleyici parametrelerin listesini vermektedir. Sonraki üç sütunda ise tanımlayıcı istatistikler gösterilmektedir: parametre değer frekansı (f), ortalama değeri (μ) ve standart sapma değeri (σ). Tablonun son iki sütununda ise F ve P değerleri kullanılarak ANOVA deneyinin işlenirliği vurgulanmıştır.

Burada F, parametre değerlerine bağlı ortalama farkının, veri hatalarına bağlı ortalama farkına oranıdır. P ise tüm ortalamaların birbirine eşit ve aralarındaki farkın ihmal edilebilecek kadar önemsiz olduğu sıfır hipotezi (H_0) olasılığıdır.

Çizelge 7.3. ANOVA deney sonuçları (Hanna at al., 2004)

Parametreler	f	μ	σ	F	P
Yerleşim yöntemi					
Fore kazık	31	1.27	0.36	4.43	0.014
Çakma kazık	60	1.48	0.33		
Jacked kazık	18	1.40	0.20		
Kazık başlık durumu					
Doğrudan temas	25	1.46	0.31	15.38	0.000
Serbest duran	151	1.11	0.43		
Yükleme tipi					
Basınç yükü	95	1.29	0.34	21.73	0.000
Kaldırma	81	1.00	0.47		
Deney tipi					
Arazi	39	1.35	0.41	10.19	0.000
Laboratuvar	137	1.11	0.43		
Zemin durumu					
Sıkı	67	0.76	0.24	191.70	0.000
Gevşek	109	1.40	0.33		
Kazık kesit alanı					
Dairesel	136	1.11	0.44	8.24	0.010
Kare	40	1.33	0.36		
Kazık yerleşimi					
1.5x2	12	1.45	0.36	5.92	0.000
1x2	27	1.21	0.42		
1x3	9	0.65	0.15		
1x4	13	1.22	0.39		
2x2	54	1.23	0.42		
2x3	15	0.76	0.29		
2x4	9	1.37	0.24		
3x3	37	1.15	0.45		


Çizelge 7.4. YSA girdi ve çıktı parametreleri (Hanna at al., 2004)

Parametreler	Aralık değeri	Nöron sayısı
Girdi		
Yerleşim yöntemi	Fore-çakma-jacked	3
Kazık başlık durumu	Doğrudan temas-serbest	2
Yükleme tipi	Basınç yükü-kaldırma	2
Deney tipi	Arazi-laboratuvar	2
Zemin durumu	Sıkı-gevşek	2
Kazık kesit alanı	Dairesel-kare	2
Kazık yerleşimi	1.5x2-1x2-1x3-1x4-2x2-2x3-2x4-3x3	8
(L/D)	8.0-35.4	1
(s/D)	1.5-6.0	1
Çıktı		
Kazık grubu etkinliği(μ)	0.43-2.23	1

M.A. Shahin ve M.B. Jaksa (2005) yaptıkları çalışmada, geçici olarak inşa edilen hafif yapılarda güvenlik artışını sağlamayı amaçlayan daha doğru bir çekme kapasitesi tahmini için yapay sinir ağı yöntemini kullanmışlardır. İki tip YSA değerlendirilmiştir.


Bunlardan MLP çok katmanlı sinir ağı, geri yayılım algoritması ile eğitilmekteyken; B-spline ağı ise, uyarlanabilir gözlem verisi spline modelleme (ASMOD) ile eğitilmektedir. MLP model kullanımını kolaylaştırmak için, işlenebilir bir denklem formunda oluşturulmuştur.

Geliştirilen YSA modelleri ile elde edilen çekme kapasitesi tahminleri ile geleneksel yöntemler ile elde edilen sonuçlarla Şekil 7.9'da karşılaştırılmaktadır. Sonuç olarak YSA ile elde edilen değerler zemin ankrajı çekme kapasitesini en doğru olarak tahminleyen yöntem olarak karşımıza çıkmaktadır.



Şekil 7.9. YSA ve diğer yöntemler için ölçülen karşısında tahmin edilen çekme yükleri (Shahin ve Jaksa, 2005)


MLP modelinin girdi verisi olarak kullanılan beş değişkeni sırasıyla; eşdeğer ankraj çapı D_{eq} ($D_{eq} = \text{ankraj çevresi} / \pi$), gömülme derinliği L , gömülme derinliği boyunca ortalama koni uç direnci q_c , gömülme derinliği boyunca ortalama yanal sürtünme ϕ_s , InsTech terimi ile tanımlanan yerleştirme tekniğidir ve Şekil 7.10'da gösterilmektedir. InsTech girdisi, eğer statik yerleşim gerçekleşirse 1; dinamik yerleşim gerçekleşirse 2 değerini almaktadır. Modelin tek çıktısı ise nihai çekme kapasitesi Q_u 'dur.



Şekil 7.10. Yapay sinir ağı mimarisi (Shahin ve Jaksa, 2005)


Das ve Bashudar (2006), killi zeminlerde kazıkların yanal yük kapasitesinin tahmini için yapay sinir ağı modeli tanımlamışlardır. YSA modelini, mevcut deneye dayalı yöntemlerle kıyaslamak için üç ölçüt seçilmiştir: tahmin edilen yanal yük kapasitesi (Q_p) ve ölçülen yanal yük kapasitesi (Q_m) için en uygun uyum hattı, Q_p/Q_m oranının standart sapma ve ortalaması, Q_p/Q_m kümülatif olasılığı. En önemli girdi parametresini belirlemek için farklı duyarlılık analizleri ele alınmıştır.

Yapılan çalışmada Rao ve Suresh Kumar'dan alınan veriler kullanılmıştır. Verilerden, kazık çapı (D), kazık saplanma derinliği (L), yük eksantrisitesi (e), zemin drenajsız kesme mukavemeti (S_u) girdi parametreleri, yanal yük ise tek çıktı parametresini oluşturmaktadır (Şekil 7.11.). 38 veri noktasının kullanıldığı çalışmada bu verilerin 29'u eğitim, 9'u ise test için ayrılmıştır. Kazıklar ise kısa ve rijit olarak tanımlanmıştır. Çok katmanlı geri beslemeli yapay sinir ağında aktivasyon fonksiyonu ise tanjant hiperbolik sigmoid olarak seçilmiştir. Azalan eğim geri besleme algoritması ile karşılaştırıldığında etkin olarak nitelendirilen Levenberg-Marquardt algoritması ile sinir ağı eğitilmiştir.



Şekil 7.11. Bağlantı ağırlıklarını gösteren aksonlar ve girdilerin Q_p üzerindeki etkisini gösteren şema (Das ve Bashudar, 2006)

Şekil 7.12’ de görüldüğü üzere, YSA ile gerçekleştirilen kazık yük kapasitesi tahmini, Broms ve Hansen yöntemleri ile karşılaştırılmakta ve gözlenen sapma grafikleştirilmektedir. YSA tahmini değerlerinin daha az dağınık ve gözlenen değerlere daha yakın sonuçlar verdiği görülmektedir.



Şekil 7.12. Farklı yöntemlerle elde edilen tahmini yük kapasitesi karşılaştırması (Das ve Bashudat, 2006)


Duyarlılık analizi sonucunda önemli girdi parametreleri belirlenmiş ve Çizelge 7.5’ te gösterilmiştir. Garson modeline göre S_u en önemli girdi parametresi olarak seçilirken, e , D ve L onu izlemektedir. Olden ve diğ. Yöntemine göre ise L ve S_u aynı seviyede değerlendirilirken bu parametreleri e ve D izlemektedir.

Çizelge 7.5. Garson algoritmasında farklı girdilerin göreceli önemi ve bağlantı ağırlıkları yaklaşımı (Das ve Bashudat, 2006)

Parametreler	Garson Algoritması (%)		Ağırlık Katsayıları Yaklaşımı	
	Görece önem	Görece öneme göre girdi sıralaması	Girdi nöronları ağırlık katsayıları	Görece öneme göre girdi sıralaması
D	17.02	3	1.54	4
L	15.78	4	4.61	1
E	23.20	2	-3.66	3
S_u	44	1	4.59	2

Ahmad, Naggar ve Khan (2007), yaptıkları çalışmada kinematik zemin-kazık tepki etkileşimi parametrelerini tahmin etmek üzere altı yapay sinir ağı (YSA) geliştirmişlerdir. Bu tepki

parametrelerinden biri, homojen zemin tabakasındaki serbest ve sabit kazıkların kinematik tepki faktörlerini ve bunlardan türetilen temel girdi hareketini içermektedir. Diğer bir parametre ise, homojen zemin tabakasındaki sabit kazığın normalize edilmiş eğilme momentidir. Son parametre ise, birbirinden çok farklı sertliklerdeki iki zemin tabakasının geçiş yüzündeki normalize edilmiş kazık momentidir. YSA eğitimi için gereken veriler, dinamik Winkler kiriş kullanılarak üretilmiştir. Üretilen verilerin %50'si YSA eğitimi için kullanılırken kalan %50'lik kısım ise test verisi olarak kullanılmıştır. Elde edilen yapay sinir ağı modeli dinamik Winkler formülü ile elde edilen veriler ile gereken uyumu göstermiştir.




Şekil 7.13. ANNM_{NFIX1} model mimarisi (Ahmad, Naggar ve Khan, 2007)

Yapılan araştırmada Levenberg–Marquardt geri yayılım algoritması kullanılmıştır. Bu yöntem orta ölçekli ileri beslemeli yapay sinir ağlarında kullanılabilecek en hızlı yöntemlerden biridir.


ANNM_{NFIX1} modeli mimarisi Şekil 7.13' te gösterildiği üzere iki girdi düğümlü bir girdi tabakası, iki düğümlü bir gizli tabaka ve tek girdi düğümlü bir çıkış tabakası içermektedir. Şekil 7.13' te gösterilen w ve b sembolleri ise, bağlantıları ve bias ağırlıklarını belirtmektedir. Şekil 7.14 ve 7.15 model tahminleri ile YSA tahminlerini karşılaştırmaktadır.

Çizelge 7.6. YSA model mimarileri (Ahmad, Naggar ve Khan, 2007)

YSA modelleri	Girdi parametreleri	Girdi nöronu sayısı	Gizli katman nöron sayısı/transfer fonksiyonu	Çıktı parametreleri	Çıktı nöron sayısı/transfer fonksiyonu
ANNKD _{Fix}	$E_p/E_s, L/d, \omega/\omega_1$	3	4/(logsig)	KDFix	1/(tanh)
ANNKD _{Free}	$E_p/E_s, L/d, \omega/\omega_1$	3	5/(logsig)	KDFree	1/(tanh)
ANNKR _{Free}	$E_p/E_s, L/d, \omega/\omega_1$	3	5/(logsig)	KRFree	1/(tanh)
ANNM _{NFIX1}	$E_p/E_s, L/d$	2	2/(tanh)	M_{NFIX1}	1/doğrusal
ANNM _{NFIX}	$E_p/E_s, L/d, a_0, \omega/\omega_1$	4	5/(tanh)	M_{NFIX}	1/doğrusal
ANNM _{NNTİ}	$E_p/E_{s1}, L/d, V_{s1}/V_{s2}, h_1/L$	4	5/(tanh)	$M_{NNTİ}$	1/doğrusal




Şekil 7.14. ANN_{M_NFIX1} model tahmini
(Ahmad, Naggar ve Khan, 2007)



Şekil 7.15. ANN_{M_NFIX} model tahmini
(Ahmad, Naggar ve Khan, 2007)


Ardalan, Eslami ve Narima-Zadeh (2009), yaptıkları çalışmada GMDH tip yapay sinir ağlarını genetik algoritma ile optimize ederek koni penetrasyon deneyine (CPT) ait parametrelerin tahmininde kullanılacak bir model elde etmişlerdir. Elde edilen modelde Şekil 7.16'da, efektif koni uç direnci (q_E) ve koni yanıl direnci (f_s) deneysel elde edilmiş verileri, kazık sürtünme direnci üzerinde girdi parametresi olarak kullanılmıştır.



Şekil 7.16. Kazık birim yanıl direnci için GMDH yapısı (Ardalan at al., 2009)


Statik yükleme deneyleri de dahil olmak üzere otuz üç kazık kaydı derlenmiş, CPT ve CPT_u arazi değerlerini içeren kazık yan ve uç dirençleri kullanılmıştır. Model girdilerinin çıktıları üzerindeki etkisini ölçmek adına duyarlılık analizi gerçekleştirilmiştir.

Kazığın birim yanıl sürtünme direncini tahmin için duyarlılık analizinden elde edilen sonuçlar grafik yaklaşım ile tanımlanmışlardır. Son olarak sunulan yöntem, direkt CPT ve CPT_u yöntemleri ile Şekil 7.17' de karşılaştırılmıştır.



Şekil 7.17. Ölçülen ve tahmin edilen kazık direnci karşılaştırması (Ardalan, Eslami ve Narima-Zadeh, 2009)


Geliştirilmiş GMDH tipi yapay sinir ağları, kazık birim yanal direncini tahmin eden bir model (Şekil 7.18) geliştirilmesi için başarıyla kullanılmıştır. Girdi parametrelerinin geliştirilmesi için sunulan modelin duyarlılık analizi gerçekleştirilmiştir. Efektif koni penetrasyon uç direnci (q_E) geometik ortalaması ve koni gömlek sürtünmesi (f_s) girdi parametreleri, çıktı parametresi olan kazık birim yanal sürtünmesini (r_s) etkilemektedir.



Şekil 7.18. Tahmin edilen karşısında ölçülen kazık yanal direncinin farklı yöntemlerle ifadesi (Ardalan, Eslami ve Narima-Zadeh, 2009)

Ismail ve D.S. Jeng (2011), yaptıkları çalışmada, yüksek mertebeden sinir ağı (HON) ile kazık yük-oturma eğrisini modellemek için, kazık gömülme derinliği boyunca SPT verisini ve kazık

özelliklerini girdi parametresi olarak kullanmışlardır. Sonuçlar; BPN, RBF ve GRNN modelleri ile karşılaştırıldığında HON tarafından alınan tahminlerde gözle görülür kalite iyileşmesi sağlanmıştır. Elastik ve hiperbolik model tahminlerinin karşılaştırılmasına dayanarak Şekil 7.19'da, önerilen HON modeli varolan geleneksel yöntemlere kıyasla daha doğru tahminler yapmakta olduğunu vurgulamışlardır.



Şekil 7.19. (a) BPN-eğitim verisi (b) BPN-test verisi (c) HON-eğitim verisi (d) HON-test verisi ölçülen ve tahmin edilen değer karşılaştırması (Ismail ve Jeng, 2011)

Kazık oturma tahminin nonlineer bir fonksiyon olarak ifadesinde ilgili değişkenler şu şekilde sıralanmaktadır: $s = f(P, k_s, E_p, D, L)$ Burada, P kazık yükü, k_s zemin geçirimliliği, E_p kazık elastisite modülü, D kazık çapı ve L kazık uzunluğudur.

7.2 Temellerin Oturması:

Temellerin tasarımı genel olarak taşıma gücü kapasitesi kriteri ve oturma tarafından kontrol edilmektedir ve bu iki özellik tasarıma yön vermektedir. Temellerin oturma tahmini problemi çok karmaşık, belirsiz ve henüz tam olarak anlaşılamamıştır. Bu durum bazı araştırmacıları, oturma tahmini konusunda YSA tekniğini uygulamak için teşvik etmiştir.

Oturma tahmini, birçok geoteknik mühendisliği problemi arasında önemli seviyelerdeki belirsizlikler nedeniyle en fazla etkilenen problem türlerinden biridir. Güvenilir oturma tahmini tasarım sürecindeki amaçların yerine getirilmesinde temel oluşturduğu için, bu tür belirsizlikler oturma büyüklüğünde güvenilir olamayan sonuçlarla karşılaşmamızayolaçar. Oturma analizini etkileyen belirsizlik genellikle aşağıda sıralanan bir veya daha fazla nedene bağlı olarak ortaya çıkar (Cherubini and Greco 1991; Krizek et al. 1977): (i) parametre (girdi değişkenleri) belirsizlikleri ve (ii) oturma tahmini için kullanılan model ile ilgili belirsizlik.


Parametre belirsizliğine neden olan temel ve ikincil bir dizi etken bulunmaktadır. Temel etkenler, (i) zemin özellikleri hakkında zayıf bilgi ve (ii) uygulanan yüklerin büyüklük tahmininde meydana gelen belirsizliktir. Zemin özellikleri ile alakalı bilgi zayıflığına bağlı belirsizlikler; zeminin oluşum süreci boyunca süren zemin mineral bileşimi ve özelliklerindeki değişimin neden olduğu doğal konumsal değişkenliği ile açıklanabilir. Ayrıca zemin özelliklerindeki sınırlı sayıda mevcut olan farklı konumsal örneklerin sonucu olarak yetersiz tanımlamalara da bağlıdır. Aynı zamanda mevcut zemin özelliklerinin ölçümünde kullanılan tekniklere bağlı hatalar da bu belirsizliklere neden olmaktadır. Teorik olarak temeller üzerine etki eden yüklere bağlı belirsizlikler, kabul edilebilir bir doğruluk derecesi yardımı ile tespit edilebilir (Greco ve Cherubini 1993). Ancak gerçekçi olarak bakıldığında, tasarım yükü büyüklüğü tahminindeki kabul edilebilir doğruluk ve bu değer rastgele değişken olarak kullanılması olası değildir (Corotis 1972; Peir ve Cornell 1973; Melchers 1987).

Parametre belirsizliği yaratan ikincil faktörler ise şu şekilde sıralanabilir: (i) temel boyutları ve (ii) temel gömülme derinliği. Bu parametre belirsizlik kaynakları; temel boyutları arasındaki uyumsuzluklara ya da arazide uygulamadaki temel gömülme derinliğine ve insan hatasına bağlı proje çizim kusurlarına bağlıdır. Belirsizliğin ikinci kaynağı ise, oturma tahminlerini tanımlamak için kullanılan modelleme tekniklerinden kaynaklı oluşan hataları kapsamaktadır ve bu durum genellikle modelleme belirsizliği olarak adlandırılır (Frey, 1998). Bu tip belirsizlikler, daha çok zemin davranışını tanımlamak için kullanılan ve genellikle belirsizliği ortaya çıkaran bir dizi varsayıma dayalı modellerin basite indirgenmiş yapısından kaynaklanmaktadır. Ne yazık ki, modelde meydana gelen belirsizlikleri fiziksel olarak ölçmek oldukça zordur (Juang at al., 1991).

Çoğu durumda, belirli bir olguyu açıklamak için kullanılan model, mükemmel bir gösterge olarak kabul edilir (yani ya hiç tahmin hatası yoktur ya da minimum düzeydedir.).

Shahin ve diğ. (2002) sığ temellerin oturmalarını tahmin eden bir yapay sinir ağı kullanmıştır. Yapay sinir ağları, sığ temellerin granüler zeminlerdeki oturma tahmininde başarılı sonuçlar elde etmiştir. En sık kullanılan geleneksel yöntemlere kıyasla çok daha iyi performans göstermiştir (Shahin at al., 2002a). Bununla birlikte, yapay sinir ağı şimdiye kadar sadece deterministik oturma tahmininde kullanılmıştır.

Goh (1994a), homojen zemin tabakasındaki yatay yüklenmiş kazık temel oturma tahmini için bir yapay sinir ağı modeli geliştirmiştir. Önerilen yapay sinir ağındaki girdi değişkenleri; kazık elastisite modülünün zemin kesme modülüne oranı, kazık uzunluğu, zeminin kesme modülü, zeminin poisson oranı ve kazık yarıçapını içermektedir. Girdi sonucu ise kazık oturmasıdır. YSA model eğitimi için kullanılmış olan istenen çıktı, sonlu eleman ve Randolph ve Wroth (1978) tarafından geliştirilen integral denklem analizi ortalaması olarak elde edilmiştir. Test ve eğitim setleri için teorik ve tahmini oturma tahminleri karşılaştırması aşağıda Şekil 7.20' de verilmiştir.




Şekil 7.20. Yapay sinir ağı ve teorik oturma karşılaştırması (Goh, 1994)

Şekil 7.20.' deki sonuçlar göstermektedir ki, yapay sinir ağı kazık temellerin oturma modellemesinde başarılıdır.


Papadrakakis ve diğ. (1996) yapay sinir ağı ve Monte Carlo simülasyonunu elastik-plastik yapıların güvenilirlik analizlerinde kullanmışlardır. Papadrakakis ve Lagaros ayrıca güvenilirlik tabanlı yapısal optimizasyon için de Monte Carlo simülasyonu ve yapay sinir ağını önermişlerdir.

Sivakugan ve diğerleri (1998), yapay sinir ağlarının, daneli zeminlerdeki yüzeysel temellerdeki oturma tahminlerinde kullanımlarını tartışmışlardır. Bir yapay sinir ağı beş girdi ile eğitilmiştir: uygulanan net gerilme, standart penetrasyon deneyi ortalama vuruş sayısı, temel kalınlığı, temel şekli ve temel derinliği. Bu yapay sinir ağına da çıktı, temelin oturmasıdır. Yapay sinir ağından elde edilen sonuçlar, Terzaghi ve Peck (1967) ve Schmertmann (1970) tarafından önerilen yöntemler ile karşılaştırılmıştır. Elde edilen sonuçlara dayanarak, Sırasıyla Terzaghi ve Peck ile Schmertmann geleneksel yöntemlerinin oturmaları 2.18 ve 3.39 kat fazla gösterdikleri aşağıda Şekil 7.21’de görülmektedir.



Şekil 7.21. Tahmin edilen ve gözlemlenen oturmaların farklı yöntemlerle irdelenmesi
(Sivakugan ve diğ., 1998)

Bu durumun aksine, YSA modelinden elde edilen tahminler çok iyi sonuç vermektedir. Aşağıda Şekil 7.22’ de bu durum gösterilmektedir.




Şekil 7.22. Tahmin edilen ve gözlemlenen oturmaların YSA yöntemi ile irdelenmesi (Sivakugan ve diğ.,1998)

Daha yakınlarda ise, Shahin ve arkadaşları (2000) kohezyonsuz zeminlerdeki sıgı temellerin oturma tahmininde benzer çalışmalar yürütmüşlerdir. Bu çalışmada, 272 veri kaydı modelleme için kullanılmıştır. Oturma tahmini üzerinde en çok etkili olarak nitelendirilen girdi değişkenleri ise şöyledir: temel genişliği, temel uzunluğu, temelin uyguladığı gerilme ve zeminin sıkışabilirliğidir. YSA sonuçları, en çok kullanılan üç geleneksel yöntem ile karşılaştırılmıştır. Bu yöntemler, Meyerhof (1965), Schultze ve Sherif (1973) ve Schmertmann ve arkadaşlarının (1978) yöntemleridir. Çalışmanın sonuçları göstermektedir ki, Sivakugan ve diğerleri (1998) tarafından bulunanlar, YSA olarak en fazla uygulanabilirliğe sahiptir ve geleneksel yöntemlere göre de daha iyi performans vermektedirler. Aşağıdaki Çizelge 7.7’de görüldüğü gibi, yapay sinir ağı diğer yöntemlerle karşılaştırıldığında yüksek korelasyon katsayıları ve düşük ortalama karekök hata ile düşük ortalama mutlak hata üretmektedir.

Çizelge 7.7. Hata oranlarının YSA ve diğer yöntemlerde karşılaştırması (Shahin ve diğerleri.,2000)


Kategori	YSA	Meyerhof (1965)	Schultze ve Sherif (1973)	Schmertmann ve diğ. (1978)
Korelasyon, r	0.99	0.33	0.86	0.70
RMSE (mm)	3.9	27.0	23.8	45.2
MAE (mm)	2.6	20.8	11.1	29.5

Kim, Bae, Hong ve diğerleri (2001), yaptıkları çalışmada tünel çalışması nedeni ile oluşan zemin yüzey oturmalarını incelemek üzere yapay sinir ağından Şekil 7.23.' te görüldüğü üzere yararlanmışlardır. Geleneksel yöntemlere bağlı ampirik formüllerle kıyaslanan YSA sonuçları daha doğru oturma tahmin değerleri vermektedir. YSA 113 arazi verisi ile eğitilmiş ve geri yayılım algoritması uygulanmıştır.



Şekil 7.23. Optimum yapay sinir ağı mimarisi (Kim ve diğ., 2001)

Genel olarak tünel boyunca meydana gelen zemin yüzey oturmalarını etkileyen en hassas faktörler; tünel derinliği, tünel kazı yüksekliği, yer altı su seviyesi, suyun debisi, kaya kütlesi türü ve tünel kazı hızıdır. Ayrıca çalışmada bu hassas faktörlerin koşullara göre değişim gösterebileceği ve doğru parametrelerin RSE analizi sonucunda belirlenebileceği de Şekil 7.24' te vurgulanmaktadır.



Şekil 7.24. Ölçülen ve tahmin edilen noktalar arasındaki karşılaştırma (Kim ve diğ., 2001)

Tran-Canh ve Tran-Cong (2002) olasılıksal simülasyon ve yapay sinir ağını viskoelastik akış hesaplamasında kullanmıştır. Zou ve arkadaşları (2002) Monte Carlo yaklaşımı katılmış yapay sinir ağını su kalitesi modellerindeki girdi verisi belirsizliklerini ortadan kaldırmak için kullanmışlardır. Shahin ve diğerleri (2002) daneli zeminlerde deterministik sığ temel oturma tahminleri için yapay sinir ağı modeli kullanmışlardır.

Goh ve Kulhawy (2003) limit durum yüzey modellemesinde güvenlik analizleri için yapay sinir ağı kullanmışlardır.

Suwansawat (2004), YSA'nın doğrusal olmayan karmaşık problem çözümlerinde oturma problemi verilerini analiz edebilen en iyi yöntem olduğunu ortaya çıkarmıştır. Bilinmeyen özellikler ile verilerin ilişkilendirilmesi, yapı özellikleri ve oturma ölçümlerini ilişkilendirmek isteyen araştırmacılar için çok kullanışlı sonuçlar oluşturmuştur.

M.A. Shahin, M. B. Jaksu ve H.R. Maier (2005), granüler zeminlerde meydana gelen, ya parametreye ya da modele bağlı belirsizliği bir araya getiren sığ temel oturması tahmini yapan YSA modeli elde etmek için, bir YSA modeli üzerinde olasılıksal analiz uygulamışlardır. Olasılıksal analizin, deterministik YSA modellerine uygulanması, inşaat mühendisliğinde birçok durumda kullanılmıştır. Bu çalışmada da üç amaç vurgulanmaktadır. İlk amaç, granüler zeminler üzerindeki sığ temellerde YSA oturma tahmini analizindeki tahmin yöntemi (modeli) veya parametre belirsizliklerini birleştiren olasılıksal bir yaklaşım sunabilmektir. İkinci amaç ise; tahmini oturma büyüklüğü üzerindeki, parametre belirsizliği değişim etkisinin incelenmesidir. Son ve en önemli amaç ise, YSA yöntemine bağlı olasılıksal tasarım çizelgeleri elde etmek ve geliştirmektir.

YSA modeli Shahin ve diğerleri (2005) tarafından geliştirilmiş ve ileri beslemeli çok katmanlı ağlar kullanılarak geri yayılım algoritması ile eğitilmiştir (Rumelhart et al., 1986). Modelde beş girdi bulunmaktadır. Temel genişliği, B ; uygulanan net temel yükü, q ; temel etki derinliği boyunca standart penetrasyon deneyinde elde edilen ortalama vuruş sayısı, N ; temel geometrisi (uzunluğun genişliğe oranı), L/B ; temel gömülme oranı (gömülme derinliğinin temel genişliğine oranı), D_f/B . Modelden elde edilen tek çıktı ise oturma değerini vermektedir. Çalışmada görülmüştürki diğer üç geleneksel yöntemle kıyasla YSA modeli en iyi oturma tahmini sonucunu vermiştir.

Eldeki veriler üç set halinde rastgele ayrılmıştır: eğitim, test ve doğrulama. Bu setler aynı istatistiksel çoğunluğu tanımlamaya ve istatistikî tutarlılıktadır (Masters 1993; Shahin et al. 2004). Eğitim setinde yer alan veriler model serbest parametrelerini (örn. bağlantı ağırlıklarını) ayarlamak için kullanılmaktadır. Test verileri, eğitim sürecinin ne zaman sonlanacağına karar

vermek için kullanılır. Doğrulama verileri ise gerçek durumlarda modelin öngörü yeteneğini sınamak için kullanılmaktadır. Toplamda verilerin %80'i eğitim için kullanılırken %20'lik kısım ise doğrulama verisi işlevini üstlenmiştir. Eğitim veri seti daha sonra , %70'i eğitim %30'u ise test için tekrar ayrılmıştır. Optimum model geometrisi, YSA modelinde tek gizli katman ve sırasıyla 1, 2, 3, 5, 7, 9 ve 11 gizli katman düğümü ile eğitilen, deneme-yanılma yaklaşımı ile belirlenmiştir. Optimum ağ parametreleri, öğrenme oranları ve momentum şartlarının farklı kombinasyonları ile çalışan YSA modelleri yardımıyla elde edilir. YSA'lar arasında iki gizli katman düğümlü, 0.2 öğrenme oranı ve 0.8 momentum şartına sahip, ayrıca gizli katmanlar için tanh transfer fonksiyonu ve çıktı katman düğümü için sigmoid transfer fonksiyonu kullanan yapay sinir ağı en iyi performansı üretmiştir.

Model belirsizliği içeren olasılıksal çözüm, daha önce ölçülmüş olan temel oturmalarının benzer koşullardaki başka temellerin oturma tahminlerinde görev alabilmesi temeline dayanmaktadır (Cherubini and Greco 1991).

Tahmin yöntemindeki belirsizlik (model belirsizliği), ölçülen oturmanın hatasız olduğu varsayımı ile tahmini oturmanın mevcut oturmaya bölümü olarak tanımlanan oturma oranı, k , hesaplanarak incelenebilir (Cherubini and Greco 1991; Sivakugan and Johnson 2002). Eğer tahmin edilen ve ölçülen oturma değerlerini içeren veri setleri mevcutsa, oturma oranları hesaplanabilir ve k 'nin olasılık yoğunluk fonksiyonu elde etmek için kullanılabilir.


YSA modeli geliştirmek için Shahin ve arkadaşları (2002a) tarafından kullanılan veri tabanı; net uygulanan taban basıncı, q ve ortalama SPT vuruş sayısı, N arasındaki 0.4'e eşit bulunan korelasyon katsayısını belirlemek için kullanılmaktadır.

Bir Monte Carlo benzetimi, tahmin edilen oturmalarından kaynaklı belirsizlikleri tahminlemek için kullanılabilir. Detaylı işlem sırası aşağıda verilmiştir:

- (1) Tahmin edilen ve ölçülen oturma setleri kullanılarak k 'nin PDF değeri tahmin edilir.
- (2) Tek bir oturma tahmini durumu için, deterministik oturma; (i) Shahin ve diğ. (2002a) tarafından geliştirilen YSA modeli, (ii) elle hesap formülü (Shahin ve diğ. 2002b) ya da (iii) deterministik tasarım çizelgesi kullanılarak hesaplanır.
- (3) Adım 1'de elde edilen k değerinin PDF'si, rastgele bir k değerine genellenerek atanır.
- (4) k 'nin tanımına bakıldığında, deterministik olarak adım 2'de tahmin edilen oturma adım 3'te rastgele genellenen k değerine bölünerek; ilgili mevcut oturma hesaplanır.
- (5) Adım 3 ve 4 birçok iterrasyon için tekrar edilir (Monte Carlo benzetimi).

(6) Monte Carlo benzetiminin bir parçası olarak elde edilen oturmalar, CDF tahmininde ya da risk seviyesine bağlı kümülatif olasılık dağılımı çiziminde kullanılır.

k değerinin mevcut dağılımıyla en fazla benzerlik gösteren dağılım Şekil 7.25.'te gösterilen Gamma dağılımı olmuştur.




Şekil 7.25. k Değeri Gamma Dağılımı (Shahin, Jaksa ve Maier, 2005)

Elde edilen Gamma dağılımına ait istatistiksel özellikler Çizelge 7.8.'de verilmiştir. Gamma dağılımının istatistiksel özelliklerinden, rastgele k değeri genellenerek oluşturulur.

Çizelge 7.8. k Değeri Gamma Dağılımı (Shahin, Jaksa ve Maier, 2005)

İstatistiksel parametreler	Değer
Minimum	0.30
Maksimum	10.30
Ortalama	1.40
Standart sapma	1.10
Şekil parametresi (α)	1.22
Ölçek parametresi (β)	0.97

Suwansawat ve Einstein (2006), yaptıkları çalışmada EPB tünel açma mekanizmasına bağlı yüzey zemin oturmalarının tahminini YSA tarafından gerçekleştirmişler ve en uygun değerdeki sinir ağı modelini geliştirmişlerdir. Tünel projesi tipik yerleşim planı Şekil 7.26' da gösterilmektedir.




Şekil 7.26. Tünel projesi tipik yerleşim diyagramı (a)Tipik plan görünüşü;(b)A-A kesiti;(c)B-B kesiti (Suwansawat ve Einstein, 2006)

Bu çalışmada yapay sinir ağları çalışması ile mevcut tahminler gerektiren durumlarda çok iyi sonuçlar alarak yöntemin kullanılabileceği tekrarlanmaktadır:


1. Aynı tünel kesitinden elde edilen verilerin yüzey oturmalarını tahminlemek üzere kullanılarak eğitildiği bir sinir ağında. Örnek olarak, A kesiminden elde edilen verilerin yine A kesimindeki meydana gelecek tahmini oturmaları elde etmek için eğitilmesi.
2. Tünelin ilk yarısındaki kesitten elde edilen oturma verilerinin, diğer tünel kesimindeki oturmaları tahminlemek için kullanılması.
3. Aynı zamanda daha az etkili olmak kaydıyla, tüm tünel kesitine ait veri kayıtlarının eğitim verisi olarak sinir ağında kullanılmasının ardından, belli bir tünel kesimine ait yüzey oturma tahmininde de uygulanması.

Şekil 7.27 yüzey oturmaları için kullanılan yapay sinir ağı modelini göstermektedir.




Şekil 7.27. Yüzey oturmaları tahmini için iki tabakalı sinir ağı modeli yapısı (Suwansawat ve Einstein, 2006)

Wang, Li ve Shen (2007), otoyol inşasının hızlı gelişimi ile birlikte, yol alt yapısında meydana gelen oturmalar geoteknik açıdan büyük problemler teşkil etmeye başlamıştır. Sonlu elemanlar yöntemine dayalı duyarlılık analizleri ve geliştirilmiş geri beslemeli yapay sinir ağı ile birlikte elde edilen (Şekil 7.28), zemin parametrelerinin yeniden değerlendirilmesine yönelik yeni bit yöntem sayesinde daha doğru oturma değeri sonuçları elde edilmektedir. Çalışmada bu yeni tahmin yöntemi tasarlanmakta ve tanıtılmaktadır.




Şekil 7.28. Oturma tahmini geri beslemeli sinir ağı modeli yapısı (Wang, Li ve Shen, 2007)

49 veri seti eğitim verisi olarak sinir ağlarını eğitmekte kullanılmış, 18070 döngüden sonra elde edilen eğitim döngüsü ve eğitim hatası grafiği Şekil 7.29' da gösterilmektedir.



Şekil 7.29. Oturma tahmini sinir ağı modelinde hata-epoch gösterimi (Wang, Li ve Shen, 2007)

Kim ve Kim (2008), beton yüzlü kaya dolgu barajlarda rölatif kret oturması tahmini için, yedi ayrı bölgeden alınan topla 30 veri tabanı (21'i eğitimde kalan 9'u test verisi olarak kullanılmak üzere) ile bir yapay sinir ağı modeli geliştirmişlerdir. Arazi verileri ile yapay sinir ağı verileri arasında önemli bir etkileşim bulunmakta ve doğruluk dereceleri en iyi YSA modeli için yüksek olmaktadır.




Şekil 7.30. Tahmin modelleri için ölçülen-tahmin edilen RCS karşılaştırmaları (Kim ve Kim, 2008)

Modelde tek gizli katman kullanılmıştır. Her bir yapay sinir ağı modelindeki gizli katman nöron sayısı, ezberleme ve uydurma işlemleri uygulanarak doğrulama değerleri üzerinde makul değerler elde edilmiştir. Şekil 7.30' da farklı tahmin modellerinin karşılaştırılması yapılmıştır.

Yapılan çalışma açıkça göstermektedirki, barajın üç temel özelliğini (e , H , E_v) kullanarak geliştirilen model bir baraj gövdesi oturma tahminini yapmakta başarılı olmuş ve doğru sonuçlar vermiştir. YSA'nın bias faktörleri ve ağırlıklara bağlı olarak çalışması önemli ve yapılan tahminin verimini kolaylaştıran bilimsel bir yaklaşım olarak da nitelendirilebilir.


Nejad ve diğ. (2009), standart penetrasyon deneyi (SPT) verilerine dayalı kazık oturma tahmini değerlendirmesi için bir YSA modeli geliştirmişlerdir. Çalışmada yaklaşık olarak 1000 veri seti yayınlanmış literatürdeki çalışmalardan elde edilerek YSA modeli geliştirmede kullanılmıştır.



Şekil 7.31. Kazık örneğinde en iyi YSA modeli, Poulos ve Davis, Vesic, Das ve lineer olmayan t-z yöntemleri için tahmin edilen-ölçülen oturma değerleri (Nejad ve diğ., 2009)

Kazıklarda meydana gelen oturma değerini tahminde YSA yaklaşımının etkin kullanılabilirliğini incelemek üzere geri beslemeli yapay sinir ağı modeli çalışmada kullanılmıştır. Kazık oturma değerlerini içeren arazi ölçümlerinden oluşan 1013 vaka kaydı veritabanı YSA modelini geliştirmek ve doğrulamak için kullanılmıştır.

Sonuçlar Şekil 7.31 ve 7.32' de göstermektedirki, 185 mm'ye kadar olan oturmalarda geri beslemeli yapay sinir ağı kabul edilebilir doğruluk derecelerinde ($r=0.972$, $RMSE=4.49$ mm) başarı sağlamıştır. Duyarlılık analizleri ise, bekleneneği üzere uygulanan yük (P), kazık gömülme uzunluğu ($L_{gömülme}$) ve zemin özelliklerinden bu çalışma için SPT-N değeri kabul edilmek üzere, kazık oturma tahmininde en önemli etkiye sahip girdiler sıralanmaktadır.



Şekil 7.32. Test veri setine göre tek gizli katmanlı YSA modeli için tahmin edilen-ölçülen oturma değerleri (a) 7 gizli katman nöronlu YSA, (b) 8 gizli katman nöronlu YSA (Nejad at al., 2009)

YSA üzerinde model girdi parametreleri olarak sunulan faktörler şu şekilde sıralanabilir: (i) kazık yükleme deneyi tipi (sabit yük veya sürekli penetrasyon oranı), (ii) kazık malzemesi (beton, çelik,, kompozit ve plastik), (iii) yerleştirme yöntemi (değiştirme veya yerdeğiştirme), (iv) kazık tipi (kapalı veya açık uçlu), (v) kazık eksenel rijitliği (E_A), (vi) uç kazık kesit alanı ($A_{uç}$), (vii) zemin ile temas eden kısım kazık çevresi (o), (viii) kazık uzunluğu (L), (ix) kazık gömülme uzunluğu ($L_{gömülme}$), (x) düzeltilmiş ve ortalama SPT vuruş sayısı/300 mm kazık gömülme uzunluğu boyunca (N_1, N_2, N_3, N_4, N_5), (xi) düzeltilmiş SPT vuruş sayısı/300 mm kazık ucunda ($N_{uç}$), ve (xii) uygulanan yük (P). Kazık oturma değeri ise tek çıktı değişkenidir.

7.3 Zemin Özellikleri ve Davranışı:

Zemin özellikleri ve davranışı, birçok araştırmacıyı YSA kullanarak modellemeye yönlendiren bir alandır.

Agrawal ve arkadaşları (1994); Gribb ve Gribb (1994), kil tabakalarının geçirimsizliğini tahmin için yapay sinir ağı yaklaşımını kullanmıştır.

Goh (1995a,1995c) değişik zemin parametreleri kullanarak aralarında mühendislik korelasyonları geliştirmiştir. Goh bağıl yoğunluk ile koni penetrasyon deneyinden elde edilen (CPT) koni penetrasyon direnci arasındaki korelasyonu normal konsolide ve aşırı konsolide kumlarda modelleyen bir yapay sinir ağı kullanmıştır. Kalibrasyon odası deneyine dayanan laboratuvar verileri, yapay sinir ağı modelini başarılı bir biçimde eğitmek için kullanılmıştır. Yapay sinir ağı modeli, bağıl yoğunluk ve seminin ortalama efektif gerilmesini girdi verileri olarak alırken, tek çıktı sonucu ise, CPT koni penetrasyon direncidir. YSA modeli, eğitim ve test verileri için sırasıyla 0.97 ve 0.91 gibi yüksek korelasyon katsayıları bulmaktadır ve bu durum da diğer parametreler ile CPT koni penetrasyon direnci arasındaki nonlineer bağlantının başarılı bir şekilde modellendiğini göstermektedir. Birçok başka çalışma da zemin özellikleri ve davranışını modellemek için YSA'yı başarılı biçimde kullanmıştır. Daha sonraki paragrafların da referans olacağı biçimde bu konu işlenmiştir.

Cal (1995) üç temel faktöre bağlı (plastisite indisi, likit limit ve kil içeriği) niceliksel bir zemin sınıflandırma sistemini genelleştirmek için yapay sinir ağı modeli kullanmıştır.

Ellis ve arkadaşları (1995) kumlar için, tane dağılımı ve gerilme geçmişine dayanan bir yapay sinir ağı modeli geliştirmişlerdir.

Attoh-Okine ve Fekpe (1996) tarafından demir ve alüminyum içeren zeminlerin mukavemet karakteristiklerini incelemek için yapay sinir ağı geliştirmişlerdir. Kaliforniya Taşıma Oranını (CBR) arazi mukavemet değer ve karakteristiğini modellemek üzere uygulanan uyarlanmış yapay sinir ağı ile geleneksel geri yayımlı ağ modeli karşılaştırılmıştır. Araştırma için seçilen mevcut arazi deney ve laboratuvar verilerini temel alan iki sinir ağı yaklaşımı incelenmiş ve CBR değerinin hesaplanması için kullanılmıştır. Her iki model de zeminlerin mukavemet karakteristiğini modellemede iyi sonuçlar vermiştir.

Najjar ve arkadaşları (1996a) sinir ağı tabanlı modellerin, doğru bir biçimde zemin şişmesini değerlendirebileceğini göstermiş ve istatistiksel modellere göre tahmin doğruluğunda önemli gelişmeler sağlamıştır. Romero ve Pamukçu (1996) yapay sinir ağlarının etkin bir biçimde daneli malzemelerin kesme modülünü tahmin edebileceğini ve tanımlayabileceğini göstermiştir.


Basheer ve Najjar (1996b) zemin kompaksiyonu için yapay sinir ağı yaklaşımı sunmuşlardır.

Penumadu ve Jean-Lou (1997) kum ve kil zeminlerin davranışını tanımlayan yapay sinir ağı modelleri kullanmışlardır.

Şenol (1997) Zeminlerde Ön Konsolidasyon Basıncının Belirlenmesi tez çalışmasında, belirli basınç altında ön konsolidasyona tabi zemin örnekleri üzerinde ödometre deneyleri gerçekleştirmiştir. Ön konsolidasyon basıncını grafik olarak belirleme yöntemleri arasında karşılaştırma yapmıştır. Bu çalışma sonucunda Tavenas yönteminin en doğru sonuca ulaştığını ortaya çıkarmış ve yeni bir yöntem de ortaya koymuştur.

Jian-Hua Zhu, Musharraf M. Zaman, and Scott A. Anderson (1998a, 1998b), tekrarlı bir yapay sinir ağı (RNN) modeli, kumul ve rezüidal ince taneli zeminlerin her ikisi için kesme dayanımını tahmin etmek ve temsili modelini oluşturmak için, geliştirilmiştir. Tek gizli katmanlı ve 20 düğümlü RNN modeli, gizli katmanın girdi katmanına geri besleme bağlantısının mevcudiyetine bağlı olarak, karmaşık zemin modellemesi için etkili bir çözüm sunmaktadır. Dinamik eğim düşümlü (gradient descent) öğrenme algoritması yapay sinir ağının eğitmek için kullanılmıştır. Rezüidal Hawaii volkanik zemini üzerinde uygulanan gerilme-kontrollü drenajlı ve gerilme-kontrollü drenajsız deney sonuçlarını içeren deneysel verilerin bir kısmının eğitilmesi ile yapay sinir ağı modeli, rezüidal zeminde varolan kesme dayanımı tahmininde önemli düzeyde sonuç elde etmek için uygun duruma gelmiştir. Nadir özellikler RNN ile doğu olarak modellenebilmiştir. Yüksek gerilme düzeyinde genişleyen yoğun zemin örnekleri, düşük seviyelerde gerilme uygulamasında daralma gösteren gevşek durumdaki zemin örnekleri de RNN ile modellenenilmektedir. Yükleme-boşaltma-geri yükleme koşullarında incelenen kumul zemin davranış tahmini ve simülasyonunda önemli sonuçlar elde edilmiştir. Hawaii volkanik zemini, kumul ve ince taneli rezüidal zeminlerin kesme davranışı modellemesi için yapay sinir ağı modellemiştir.

Ölçülen veri ve modelleme sonuçları arasındaki mükemmel uyum, hacimsel değişim ve gerilme-şekil değiştirme özellikleri açısından gözlemlenmiştir. Gerilme izi benzetimleri için iki farklı deney uygulanmıştır. İlk deney gerilme-kontrollü drenajsız, diğer deney seti ise gerilme-kontrollü drenajlı deneyleri içermektedir. Drenajsız deneyler iki farklı gerilme izi üzerinde: izotropik konsolidasyonlu drenajsız (ICU) ve anizotropik konsolidasyonlu drenajsız (ACU) olarak uygulanmıştır. Kontrollü şekil değiştirme oranı %0.1 minimum düzeyindedir ve %15'lik bir şekil değiştirme ile sonuçlanır. ICU ve ACU deneyleri, ACU deneyleri için konsolidasyon gerilme oranı σ'_1/σ'_3 değerinin 2.5 olması dışında, aynı geleneksel üç eksenli drenajsız deneylerdir. Bir eğri seti, kesme gerilmesi-eksenel şekil değiştirme değeri, değeri ise boşluk suyu basıncı ve eksenel şekil değiştirme değeri arasındaki ilişkiyi Şekil 7.33' te göstermektedir.



Şekil 7.33. (a) AC1 deneyi için eğitilmiş verilerle ACU deney sonuçlarının tekrarlı yapay sinir ağı modeli (RNN) ile simülasyonu, (b) IC2 deneyi için eğitilmiş verilerle ICU deney sonuçlarının tekrarlı yapay sinir ağı modeli (RNN) ile simülasyonu (Zhu ve diğ., 1998)

Geliştirilen RNN modeli, diğer sinir ağları ile karşılaştırıldığında, daha fazla esneklik ve daha az veri giriş kısıtı içermektedir. Sıralı ve düzenli sinir ağında, Penumadu (1996), yapay sinir ağında uygulama limiti meydana getiren zemin davranışı tahmini için eksenel şekil değiştirme oranı değerini sabit almıştır. Makalede görülmektedirki, daha az sayıda deneysel veri ile zemin numunelerine ait kesme dayanımı değerleri tahmininde bulunmak da etkili sonuçlar verebilmektedir bu tip bir yapay sinir ağında.

RNN modeli zeminde meydana gelen çökmeleri tahmin etmede büyük potansiyele sahiptir. RNN modeli, yükleme-boşaltma-yeneden yüklemeye maruz kalmış kohezyonsuz zeminlerin nonlineer davranışını tahmin ve görselleştirmede kendine has özelliğini göstermektedir. Yükleme-boşaltma-geri yükleme aşamaları boyunca kumun hacimsel şekil değiştirme değişimlerini tam olarak yansıtır. Geleneksel modellerde karşılaştırıldığında, RNN modeli çok daha kolay uygulamaya sahiptir ve daha verimli sonuçlara ulaşmayı sağlar.

RNN model mimarisi ele alınan problemin özelliklerine göre değişmekle birlikte, tek gizli katman ve 20 düğümlü yapay sinir ağı mimarisi gerilme-kontrollü drenajsız ve gerilme-kontrollü drenajlı deneylerde kullanılan rezüidal ve kumul zemin için yükleme-boşaltma-geri yükleme sürecinde kullanımda uygun bulunmuştur.

Ghaboussi ve Sidarta (1998) üç eksenli basınç deneyine tabi tutulan kumlu zeminlerin drenajlı ve drenajsız davranışını modelleyen yapay sinir ağları kullanmışlardır.

Sidarta ve Ghaboussi (1998) sonlu eleman analizi ile üniform olmayan malzeme deneylerinden zemin malzemesi temel davranışını aydınlatan bir yapay sinir ağı çalışmışlardır.

Monoton ve tekrarlı yükler altında ince taneli zeminlerin tek eksenli gerilme-şekil değiştirme temel davranışını canlandırma (Basheer 1998; Basheer ve Najjar 1998), üç eksenli basınç ve çekmeye maruz kalan Nevada kumunun drenajsız gerilme-şekil değiştirme karakterizasyonu (Najjar ve Ali 1999; Najjar at al., 1999), yükleme, boşaltma ve geri yükleme süresince hacimsel ve eksenel gerilme-şekil değiştirme davranışın tahmini gibi konularda yapay sinir ağı kullanmışlardır.

Penumadu ve Zhao (1999) çakıl ve kumlarda üç eksenli basınç drenaj koşulları altında gerilme-şekil değiştirme ve hacim değişimi davranışını modelleyen bir YSA kullanmışlardır.

Karagöz (1999) aşırı konsolide olmuş killerde ön konsolidasyon basıncının ödometre deneyleri ile belirlenmesi adlı tez çalışmasında 25 ödometre deneyi uygulamış ve ilk aşamada zemin numuneleri belirli basınçlar altında ön konsolidasyon basıncına tabi tutulmuştur. İleriki aşamada ödometre deneyleri uygulanmış ve grafik yöntemlerle (Casagrande, Tavenas, Butterfield, Burmister) ön konsolidasyon basıncı belirlenmiştir. Yöntemlerle bulunan değerler ile daha sonra gerçekteki ön konsolidasyon basınçları karşılaştırılmıştır. En iyi yöntemin ise Tavenas yöntemi ile ortaya koyulduğu ifade edilmiştir.

Wang (1999) geoteknik modellemeleri işlediği çalışmasında, sinir ağları, sinir ağları birleştirilmiş tiplerini ve bulanık mantığı farklı problemler üzerinde uygulamış ve sinir ağı modelleri geliştirmiştir. Çalışmanın amacı lineer olmayan ve karışık geoteknik problemlerinde çözüm yolunu kolaylıkla bulmak ve modellemek olarak açıklanmaktadır. Kullanılan veriler ise literatürde yer alan önceki çalışmalara ait veri tabanlarından elde edilmiştir. Elde edilen modellerin uygulanabilirliği ise geleneksel nümerik ve analitik modeller ile karşılaştırılarak doğrulanmaktadır.

Turk, Logar ve Majes (2001), yaptıkları çalışmada tek eksenli deformasyon koşullarında zemin davranışını modellemiştir. Model, ileri beslemeli yapay sinir ağıdır ve genel zemin özellikleri için tek eksenli deformasyon modellemek üzere ödometre deney sonuçları kullanılmıştır. Model sonuçlarının, elde edilen deneysel verilere uyum sağladığı gözlemlenmektedir. Yapay sinir ağı modeli, Slovenya'nın farklı bölgelerinden elde edilmiş farklı kohezyon içeriğine sahip zemin numunelerinin verilerini kullanarak eğitilmiştir.

Hurtada, Londono ve Meza (2001), yayınladıkları makalede zemin dinamiği analizlerinde yapay sinir ağlarının uygulanabilirliğini araştırmışlardır. Karmaşık zemin profilinde serbest yüzeye etkiyen ve ana kayadan gelen sismik ivmenin tahmini yoluna gidilmiş ve yapay sinir ağı modellenmesi bu şekilde elde edilmiştir. Çalışmada zamandan bağımsız çok tabakalı ve zamana bağlı çok tabakalı Perseptron kullanılmıştır. Tepki spektrum ilişkilendirmesinde birincil ağlar kullanılırken, serbest yüzey- zaman serileri için ise ikincil ağlar kullanılmıştır.

Hsein, Caroline ve Chen (2002) yaptıkları çalışmada kumların geoteknik parametrelerin tahmini için koni penetrasyon deneyi ölçümlerini veri olarak kullanarak yapay sinir ağı modellenmesi kurmuşlardır. Yapay sinir ağı modelinde, aşırı konsolidasyon oranı OCR, sükunetteki toprak basınç katsayısı K_0 , rölatif sıkılık D_r gibi parametrelerin kum geoteknik parametreleri tahmininde önemli olduğu vurgulanmıştır. Çalışmada fonksiyon tahmini için geri yayımlı sinir ağı, sınıflandırma için ise olasılıksal sinir ağı kullanılmıştır. eğitim sonucu elde edilen değerler ile ampirik sonuçlar karşılaştırılmış ve yapay sinir ağlarının çok daha doğru ve gerçekçi sonuçlar verdiği görülmüştür.

Habibagahi ve Bambad (2003), doymamış zeminlerin mekanik davranışlarını tanımlamak için yapay sinir ağı yaklaşımı geliştirmişlerdir. Sinir ağı için, sıralı mimari seçilmiştir. Geri besleme kapasiteli çok katmanlı algılayıcı ağ kullanılmıştır. Girdi katmanı; altısı başlangıç zemin koşullarını, üçü ise bir önceki gerilme artışından oluşan çıktılarına dayalı her bir güncel eksenel şekil değiştirme artışını temsil eden nöronları oluşturmaktadır.

Elde edilen önemli sonuçlar aşağıdaki gibidir:

- 1) YSA, doymamış zeminlerde mekanik davranış(gerilme-şekil değiştirme, hacim değişimi ve emme değişimi) modellenmesinde önemli başarı elde etmektedir.
- 2) Bir kere eğitildiği zaman, YSA doymamış zeminlerde ani çökme durumlarını simüle eder duruma gelir.

Yukarıda belirtilen sonuçların pratik uygulamaları şöyle sıralanabilir:

- Eğitilmiş YSA, çok karmaşık ve zaman alıcı laboratuvar deneylerine gerek kalmadan, benzer koşullar altında üç eksenli deneyleri simüle etmek için kullanılabilir.
- Belirli bir doymamış zemin için eğitilen YSA daha sonra birçok parametrenin zeminlerin mekanik davranışı üzerindeki etkisini araştırmak amacıyla kullanılabilir.
- Son olarak, eğitilmiş bir YSA gerçek mühendislik vakalarında doymamış zeminlerin mekanik davranışlarını incelemek üzere sonlu elemanlar programına da dahil edilebilir.

Basma ve diğ. (2003), YSA yöntemini şişen zeminlerin zamana bağlı şişme durumunu incelemek için uygulamışlardır. Farklı başlangıç basıncı altındaki şişen zeminlerde şişme genişlemesini yapay sinir ağlarıyla modellemişleridir.

Najjar (2004), çok katmanlı ileri beslemeli yapay sinir ağı geliştirmiş ve geliştirilen modellerin tek jeolojik tabanlı zemine ait veri setlerini içermesi durumu için, iyi sonuçlar verdiğini ortaya koymuştur.

Banimahd ve diğ. (2005) yaptıkları çalışmada, nonplastik ince malzeme içeren kumlu zeminlerde arazideki gerilme-şekil değiştirme davranışını modellemek için yapay sinir ağlarını uygulamışlardır. Modellerde karşılaşılabilecek dezavantajları tartışmışlardır.


Örnek olarak yapay sinir ağları modellemelerinde girdilerin çıktı sonuçlarını nasıl etkilediğinin cevabı yoktur. Bu nedenle, genel YSA tabanlı temel zemin modelleri üzerine bilgi edinme ve doğrulama için sistematik bir yaklaşım kullanmışlardır. İlgili girdilere ait çıktının duyarlılıkları matematiksel olarak tanımlanmıştır.

Deneysel gözlemlerle karşılaştıran duyarlılık analizi, önerilen modelde baskın kuralları ayıklamak için kullanılmıştır. Drenajsız koşullar altındaki toplam 129 gerilme kontrollü üç eksenli deney sonuçları veritabanı olarak kullanılmıştır. Bu çalışmada kullanılan model çok katmanlı yapay sinir ağına ait iki çıktı içermektedir (Çizelge 7.9.).

Çizelge 7.9. Çok katmanlı yapay sinir ağı (MLP) modeli girdi ve çıktıları (Banimahd at al. , 2005)

Yapay sinir ağları	Girdiler	Çıktı
M-q	$\Delta\sigma_n, \gamma_n, q_n, D_r, \sigma'_3, C_c, C_u, I_s, P_f$	q_{n+1}
M-u	$\Delta\sigma_n, \gamma_n, u_n, D_r, \sigma'_3, C_c, C_u, I_s, P_f$	u_{n+1}

İlk konsolidasyon sonrası numune rölatif sıkılığı (D_r); efektif hücre basıncı (σ'_3); kum kısmının tane boyutu dağılımı diğer bir adla eğrilik katsayısı (C_c) ve kumun (#200 elek üzerinde kalan) üniformluk katsayısı (C_u); deviatör gerilme (q_n), aşırı boşluk suyu basıncı (u_n), şekil değiştirme (e_n), n. basamaktaki şekil değiştirme artışı (Δe_n), ince tane oranı (P_f), ve ince tane şekil indisi (I_s) modelin girdi parametrelerini oluştururken, çok katmanlı yapay sinir ağının çıktı sonucunu ise bir sonraki seviyedeki gerilme değeri (q_{n+1}, u_{n+1}) oluşturur ve Şekil 7.34' te YSA yapısı görülmektedir.



Şekil 7.34. Tipik MLP tabanlı zemin temel modeli (Banimahd at al., 2005)

Moosavi ve diğ. (2006), yaptıkları çalışmada zaman gecikmeli yapay sinir ağını döngüsel şişme basıncını Masjed-Soleiman bölgesindeki zemin üzerinde modelleme yapmak için kullanmıştır. Çok sayıda birbirine bağlı değişkenlerin varlığında döngüsel şişme davranışının olasılıksal doğasını en iyi şekilde tanımlayan model yapay sinir ağları ile uygulanabilecektir. Bu yöntem, kabul edilebilir düzeyde doğruluk sağlayarak şişme basıncı tahminini modellemede neredeyse imkansız olan matematik model geliştirmeyi kolay kılmıştır.

YSA modeli geliştirmek için kullanılan veriler:

Şişme basıncı birbirini takip eden dört gecikme hattı ($P(t)$, $P(t-1)$, $P(t-2)$, $P(t-3)$, $P(t-4)$) ile şişme basıncı sinyali verir. $P(t-i)$ i'nci zaman dilimine ait basınç sinyalini tanımlamaktadır. Şişme olgusunun zamana bağlı davranışına bağlı olarak her ay meydana gelen şişme basıncı kendini takip eden son 4 ay içerisinde oluşan basınçlar ile etkileşim içerisinde.


b) yağış düşme sinyali (R). Geçen 5 ay içerisindeki zaman zarfında her basınç noktası yağış düşme sinyali 7 noktası tarafından etki altındadır.


Zhai ve diğ. (2006), yapay sinir ağlarının çorak zeminlerin sınıflandırılmasında etkinliğini belirlemek ve alternatif yapay sinir ağı mimarilerini karşılaştırmak için çalışmalar yapmıştır. İleri beslemeli-geri yayımlı yapay sinir ağı tabanlı bir grup sınıflandırıcı, modellerde uydu ve hava uzaktan algılama verileri ile eğitilmiştir. Bu sınıflandırıcılar, tek bir zemin yapısından fazlasını sınıflandırmak için eğtilebilen uzman sistemler veya sadece tek bir zemin yapısı tanımlamaya yardımcı özel sistem olarak işlerler. Kullanılan 54 girdi nöronu verilerden elde edilen normalize edilmiş ışınım spektrumunu içermektedir. Elde edilen üç çıktı ise üç farklı zemin yapısını tanımlayacaktır. Gizli nöron sayısı en iyi sonuç için, 50 olarak belirlenmiştir.

Erzin ve diğ. (2007), kil, silt, siltli kum, ince ve kaba kumlardan deneysel olarak elde edilmiş termal rezistivite değerlerine dayanan yapay sinir ağı modelleri geliştirmişleridir. Bu zeminler birbirinden tamamen farklı özellikler göstermeleri ve doğada en sık karşılaşılan zeminler olmaları nedeniyle çalışmalarda araştırılma gereği görülmüştür. Farklı kompaksiyon

aşamalarındaki bu zeminlerin termal dirençleri laboratuarda termal prob yardımıyla ölçülmüş ve elde edilen değerler tek tek YSA modeli ile elde edilenlerle karşılaştırılmıştır. YSA modelinden elde edilenler ile deneysel araştırmalar sonucunda ulaşılanlar, bu zeminlere ait termal dirençlerin doğru bir biçimde bulunabildiğinin kanıtı olmaktadır. Bu çalışmada geliştirilen modellerin performans kontrolleri ise; determinasyon katsayısı, ortalama karekök hata, ortalama mutlak hata ve varyans hesabı ile yapılmıştır. Buna ek olarak, YSA modelleri tarafından elde edilen zemin termal dirençleri, literatürde yer alan deneysel bağıntılar ile hesaplanan değerleri ile karşılaştırılmış ve YSA yönteminin daha üstün olduğu sonucuna varılmıştır. Bu çalışma, YSA modellerinin zemin termal direnç tahminindeki verimlilik ve kullanılabilirliğini göstermektedir.

M.D. Ferentinou, M.G. Sakellariou (2007), özellikli mühendislik problemlerinden olan şev stabilitesi performans değerlendirmeleri birçok farklı parametre içermekte olduğunu vurgulamışlardır. Şev duraylılığı üzerindeki tüm bu parametrelerin etkileri, ayarlanabilir ve değiştirilebilir ağırlıklara sahip eşik değer mantık birimleri kullanımı yolu ile araştırılmıştır (Sakellariou ve Ferentinou, 1999; Roussos, 2000; Ferentinou, 2004). Şev stabilitesi tahmini girdi verileri sırasıyla şu girdi parametrelerinin değerlerini taşımaktadır: birim hacim ağırlık, kohezyon c , içsel sürtünme açısı ϕ , yükseklik H , su seviyesi yüksekliği H_w 'ya göre boşluk suyu basıncı oranı r_u , toprak ya da yüksek çatlaklı kaya şevleri için geçerlidir. Tek çıkış olarak, yapay sinir ağı güvenlik faktörü F ve stabilite S' 'yi tahminde bulunmaktadır.





Şekil 7.35. Silindirik, düzlem ve kama kayma mekanizmaları (Ferentinou ve Sakellariou, 2007)

İlki bir yaklaşım problemi fonksiyonu olarak modellenebilirken ikincisi, hem yaklaşım problemi hem de bir sınıflandırma modeli olarak dairesel şev kayması kabulü ile modellenebilir. Kama biçimli ve düzlemsel kayma durumlarında ise Şekil 7.35' te gösterildiği gibi, kullanılacak girdi verileri ve temsil ettikleri parametreler şu şekilde sıralanabilir: Birim hacim ağırlık, kohezyon C_a ve C_b , içsel sürtünme açısı ϕ , yükseklik H , kama kesişim hattı açısı ψ_p , şev açısı ψ_f . a ve b alt indislerine farklı kayma yüzeylerindeki kohezyonu tanımlamak üzere başvurulmuştur. Çalışmada kullanılan veriler hiçbir gerilme çatlak taşımayan kuru veya yaş kaya şevleri temel alınarak kullanılmıştır. Aşağıdaki kural kullanılarak olasılıksal bir yaklaşım hayata geçirilmiştir: S değeri 1'e ne kadar yakın olursa şevin duraylılığı o kadar iyi sağlanmakta, aynı değer 0'a yaklaştığında ise şev kaymaya daha yakın olarak tanımlanmaktadır.


Çizelge 7.10' da yapay sinir ağı modelinin (Sakellariou, ve Hlias, 1997), Bayezyen sinir ağı ile karşılaştırılmasında, aynı veri ve deney setlerinde, yapay sinir ağının, Sakellariou M, Hlias P. 1997'de kullandığı geleneksel mühendislik yöntemi ve yaklaşım fonksiyonu yönteminden (Sah, Sheorey, Upadhyama, 1988) daha iyi sonuçlar verdiği gözlemlenebilmektedir.

Çizelge 7.10. Sakellariou ve Hlias YSA modeli ile Bayezyen YSA modelinin karşılaştırılması (Ferentinou ve Sakellariou, 2007)

	YSA BPN	Fonksiyon benzeştirme modeli	NN_{MP}	NN_{Eg}
$F_{silindirik}$	0.0525	0.0986	0.1251	0.0937
F_{kama}	0.1099	0.9593	0.1214	0.1055

Das ve Basudhar (2008), yaptıkları çalışmada mevcut şevlerde, uzun vadeli stabilite sağlanması ve şev kaymalarına karşı düzüeltici tedbir alınmasında killerin rezüidal


dayanımlarının önemli olduğunu vurgulamışlardır. İçsel sürtünme açısı (ϕ_r) ile zemin indeks özellikleri arasında korelasyon bulmak amacıyla birçok ölçüm gerçekleştirilmiştir. Bu çalışma, içsel sürtünme açısı ve Atterberg parametreleri göz önüne alınarak yapılan yapay sinir ağlarında stabilite modellemesini içermektedir. İçsel sürtünme açısını etkileyen parametreleri belirleyebilmek için de yine birçok hassaslık analizi gerçekleştirilmiştir. Sonuç olarak içsel sürtünme açısının, zemin indeks özelliklerine ve ΔP 'ye bağlı belirlenmesinde ileri beslemeli ve geri yayımlı sinir ağı kullanılmış ve Şekil 7.36' da gösterilmiştir.




Şekil 7.36. Bağlantı ağırlıklarının ϕ_r üzerindeki etkisinin gösterimi (Das ve Basudhar, 2008)

He ve Li (2009), çalışmalarında fiberle güçlendirilmiş ve stabilize edilmiş kompozit zeminin nonlinear elastik davranışını modellemek için çok katmanlı sinir ağını kullanmışlardır. İlk olarak güçlendirilmiş zeminin kayma modülü, kısa fiber ve lime tozları gibi çoklu değişkenlerin nonlinear fonksiyonu gibi düşünülmüştür. İkinci olarak ise, kayma gerilmesi ve şekil değiştirme arasında nonlinear ilişkiyi belirlemek için çok katmanlı sinir ağı modellenmiştir.

İkizler ve diğ. (2010), yaptıkları çalışmada iletilen yanıl şişme basıncı ve düşey düzlemdeki şişme basınçlarının dayanma yapıları üzerindeki etkilerini tahmin etmeye yarayan bir yapay sinir ağı geliştirmişlerdir (Şekil 7.38). Çalışmanın ilk aşamasında, yanıl ve düşey şişme basınçlarını ölçmek için, farklı kalınlıklarda genişletilmiş polistren (EPS) geoköpek şişen zemin ile çelik deney kutusu düşey duvarları arasına yerleştirilerek değerler elde edilmiştir. Süregelen aşamada ise, bu kaydedilen basınçlar, dayanma yapıları üzerinde iletilen yanıl şişme ve düşey düzlemdeki şişme tahmini için YSA'yı eğitmek üzere kullanılmıştır. Şişen zeminlerdeki şişme davranışını dayanma yapılarında yanıl ve düşey düzlemlerde modellemede YSA'nın önemli ve geçerli doğrulukta sonuçlar verdiği Şekil 7.37' de gözlemlenmiştir.



Şekil 7.37. ölçülen düşey şişme basıncı-YSA ile tahmin edilen düşey şişme basıncı ilişkisi (İkizler ve diğerleri., 2011)




Şekil 7.38. YSA modeli (İkizler ve diğerleri., 2011)

Çevik ve diğ. (2011), yaptıkları çalışmada deneysel veriye dayalı kil içeren kayalar için YSA tabanlı kurucu model elde etmişlerdir. YSA tek eksenli basınç dayanımı (UCS)'na bağlı olarak önerilmiştir. Deneysel veriler rastgele olarak eğitim (tüm verinin %80'i) ve test (tüm verinin %20'si) setleri olarak bölünmüştür ve Çizelge 7.12' de gösterilmiştir. Test veri setinin kullanılmasındaki fikir, önerilen yapay sinir ağının genelleme kapasitesini doğrulamaktır. Tek eksenli basınç dayanımı için en iyi YSA mimarisi 3 girdi, tek gizli katmanlı ve tek çıktılı olmalıdır. Transfer fonksiyonu olarak logsig ve tanjant hiperbolik fonksiyonları katmanlarda kullanılmıştır. Şekil 7.39' da test sonuçları ve modellerin karşılaştırması göstermektedirki YSA önemli ve geçerli doğrulukta sonuçlar vermiştir.

Çizelge 7.11. YSA modellerinde test ve eğitim setlerinin istatistiksel parametreleri (Çevik ve diğerleri., 2011)

	Ortalama	Kovaryans(COV)	R^2
UCS			
Test seti	1.04	0.25	0.97
Eğitim seti	1.02	0.16	0.99
Toplam	1.03	0.22	0.98



Şekil 7.39. Test sonuçlarının ve modellemenin karşılaştırılması (Çevik ve diğerleri., 2011)

7.4. Sıvılaşma:

1970'lerden bu yana, dalga-kaynaklı sıvılaşma için çok sayıda araştırma yapılmıştır. Bjerrum (1973), muhtemelen, doymuş deniz dibi çökellerinde dalga kaynaklı sıvılaşmayı araştıran ve Kuzey Denizi'nde temel tasarımı ile ilişkilendiren ilk kişi olmuştur. Daha sonra, Ishihara ve Yamazaki (1984), fırtına parametrelerine bağlı olarak, tekrarlı gerilme büyüklüğü ve dalga-kaynaklı sıvılaşma değerlendirmesini gerçekleştirmek üzere bir yöntemler bütünü ortaya atmıştır. Zen ve diğ. (1985), dairesel kaymayı takiben, dalga-kaynaklı sıvılaşmanın temellerdeki en büyük olası çökme nedenlerini oluşturduğunu göstermiştir. Bu çalışmaların sonucunda, düşük geçirimliliğe sahip tabakaların varlığında boşluk suyu basıncının dağılım ya da dağıtımının sınırlandığı koşul altında, sıvılaşmanın okyanus dalgaları tarafından meydana geldiği belirtilebilir. Taotsos ve diğ. (1989), nümerik bir model kullanarak döngüsel dalga hareketlerinin deniz tabanında sıvılaşma potansiyeli ve boşluk suyu basıncı üretimine etkilerini değerlendirmişlerdir. Çalışma sonuçları göstermektedirki, zemin geçirimliliği, yüksek geçirgenlik fazla boşluk suyu artışını engellediği için boşluk suyu basıncı gelişimi ve sıvılaşma üzerinde

önemli etkilere sahiptir. Zen ve Yamazaki (1993), sonlu farklar yöntemi kullanarak geçirgen deniz tabanında dalga kaynaklı sıvılaşma ve yoğunlaşma mekanizmasını araştırmışlardır. Çalışmada elde edilen sonuçlar, periyodik dalga yüklemesi ile, deniz tabanında sıvılaşma ve yoğunlaşmanın dönüşümlü olarak meydana geldiği sonucuna ulaşmaktadır.

Sıvılaşma sınıflandırma problemi nonlineer bir problemdir. Bu nonlineerlik ise modelleme aşamasında; geleneksel modelleme teknikleri kullanılarak, zemin özellikleri ve sismik özellikler gibi bağımsız değişkenler arası ilişkilendirme yapılamadığından kapsamlı bir model gelişimi de zor olmaktadır. Bu nedenle, Stark ve Olson (1995) ile Andrus ve Stokoe (1997) tarafından geliştirilen prosedürler ve benzeri diğer yöntemlerde olduğu gibi basitleştirilmiş varsayımlar yapılmıştır.

Zemin sıvılaşması, sığ ve derin temeller üzerine oturan yapılara zarar verip onları tahrip edebilen en kötü deprem vakalarından birisidir. Ayrıca, yer altındaki elektrik, su gaz gibi hatlara zarar veren en tehlikeli deprem olayıdır. Özetle sıvılaşan yerlerde bulunan yapılar göçmekte veya zemine batmakta gaz hatları tahrip olup yangınlara sebebiyet vermekte veya şev kaymaları ile toprak kaymaları oluşmaktadır (Rourke ve Pease, 1997).

Güçlü bir depremde sıvılaşma riski çok yüksek olan zemin şartlarında dahi sıvılaşmanın olabilmesi için deprem yatay zemin yüzey ivmesinin $0.1g$ 'yi geçmesi gerekmektedir (Ishihara, 1985 ve National Research Council, 1985). Bu yüzden sıvılaşma için $0.1g$ bir alt sınır olarak kabul edilebilir. Ayrıca geçmişte olan depremlerden elde edilen verilere göre sıvılaşmanın meydana gelmesi için, deprem büyüklüğü (M)'nin en az 5 olması gerekmektedir. Fakat sıvılaşmanın etkisinin yaygın olarak gözüktüğü en düşük deprem limiti $M=5.5-6.0$ dır (Ambraseys, 1988).

Zemlerde sismik sıvılaşma potansiyelinin tespitinde başlıca iki yöntem kullanılmaktadır. İlk yöntemde laboratuvar koşullarında deneyler gerçekleştirilirken, burada elde edilen sonuçlar sıvılaşmaya neden olana tekrarlı gerilme ve deformasyon değerlendirilmesiyle konuya ışık tutmaktadır (Seed ve Lee 1966; Seed ve Idriss 1971;1979). Bu gruptaki yöntemlerde birçok belirsizlikler bulunmaktadır. Laboratuvar ortamında koşulların araziye yansıtmadığı gerçeği göz önüne alınmalıdır. Laboratuvar ortamında; arazideki zemin yapısı, yoğunluğu ve gerilme durumu, üzerindeki sürşarja bağlı gerilme durumu ve zeminin tarihçesini oluşturmak zor olmasından öte neredeyse tamamen imkansızdır (Robert ve Campanella 1985; Mahmood at al., 1991). Bu durumda, özellikle iri taneli zeminlerde bozulmamış numuneleri elde etmek ve ayrıca test etmek çok zordur, ikinci yöntem dizisi daha fazla kullanılmaktadır.

İkinci yöntemde ise, arazi deneylerinden yararlanılır ve arazi sıvılaşma karakteristiklerinin bir indeksi olan SPT, CPT, VS, BPT gibi tekniklere başvurulur. Standart penetrasyon (SPT) ve çevrimsel gerilme oranı (CSR)'ye bağlı olarak Seed ve meslektaşları zemin sıvılaşma potansiyelini değerlendirmek için bir prosedür geliştirmişlerdir (Seed ve Idriss 1967, Seed ve Idriss 1971, Seed at al., 1983, Seed at al., 1984). SPT verilerine dayanan istatistiki ve probabilistik yöntemler de ayrıca sunulmuştur (Christian ve Swiger 1975, Haldar ve Tang 1979, Liao at al., 1988). Fakat tüm bu yöntemler içerisinde bir takım belirsizlikleri barındıran deneysel formüller kullanılarak elde edilmektedir.

Bu arazi tekniklerinden elde edilen değerler ise, deneysel bağıntılara baş vurularak sıvılaşma potansiyeli ve arazinin bu konudaki performansı korelasyonlara dayandırılır (Seed at al., 1983; 1985). İkinci yöntemler arasında ise en çok uygulanan SPT yöntemleridir (Seed at al., 1985, Tokimatsu ve Yoshimi 1983). Arazi karakterizasyonunda ayrıca CPT'ye dayalı sıvılaşma potansiyelini değerlendirmeye yönelik yöntemler de geliştirilmiştir (Robertson ve Campanella 1985, Seed ve De Alba 1986, Shibata ve Teparaksa 1988, Stark ve Olson 1995).

Masri ve diğ. (1993), yapay sinir ağlarını, yapısal dinamik sistemlerin tanımlamasında güçlü bir araç olarak açıklamışlardır.

Goh (1994b) sıvılaşma potansiyeli araştırması amacıyla sismik veriler ve zemin parametreleri arasında oluşan karmaşık ilişkiyi modellemek için yapay sinir ağı kullanmıştır. Goh bu çalışmalarında 1891-1980 yılları süresince Japonya, Birleşik Devletler ve Amerika kıtasının belirli bölgelerinden elde edilen 13 deprem kaydına ait veriler yapay sinir ağı mimarisinde kullanılmıştır. Çalışmada sekiz girdi değişkeni kullanılırken sadece tek bir çıktı elde edilmektedir. Yapay sinir ağına kullanılan girdi değişkenleri; SPT değeri, ince malzeme oranı, ortalama dane boyutu, toplam gerilme, efektif gerilme, eşdeğer dinamik kesme gerilmesi, deprem magnitütü ve zemin yüzündeki maksimum yatay ivmedir. Çıktı sonucu Yüksek ve orta dereceli sıvılaşmanın olduğu arazilerdeki sonuçlar için, ikili sistem kullanılarak, 1 değerine atanmıştır. Sıvılaşmanın olmadığı durumlarda ise 0 değerine atama olmuştur. Yapay sinir ağından elde edilen sonuçlar Seed ve diğerlerinin (1985) yöntemi ile karşılaştırılmıştır. Yapılan çalışma sonuçları göstermektedir ki, Seed ve diğerlerinin yöntemine kıyasla yapay sinir ağı incelemeye konu olan vakaların %95'lik gibi büyük bir kısmında doğru tahminler vermiştir. Bahsedilen aynı çalışmalar, Seed ve diğerlerinde ise %84 oranında başarı sağlamıştır.

Goh (1995), Sıvılaşma değerlendirmesi için, sismik sıvılaşma potansiyeli veri kayıtlarına geri yayımlı yapay sinir ağı uygulamıştır.

Chen ve diğ. (1995) geri-yayılımlı algoritmayı yapısal dinamik model tanımlamasında kullanmışlardır.

Goh (1996a) ayrıca koni penetrasyon deneyi (CPT) sonuçlarından yararlanarak ve direnç verilerini değerlendirerek, sıvılaşma potansiyelini elde etmek için yapay sinir ağı kullanımı yoluna başvurmuştur. Çalışmada kullanılan Birleşik Devletler, Çin, Japonya ve Romanya'daki kumlu zeminler siltli kum yataklarından alınan veri kayıtları, 1964-1983 döneminde meydana gelen beş depremi temsil etmektedir. Benzer bir yapay sinir ağı modelleme stratejisi bu çalışmada kullanılmış ve Shibata ve Teparaksa (1988) yaklaşımı ile karşılaştırılmıştır.

Rahman ve Zahaby (1996), probabilistik sıvılaşma risk analizinde, bulanık değişkenleri kullanmışlardır. Chern vd (2001), CHI-CHI depreminde Yuan-Lin alanındaki sıvılaşmayı tahmin etmek için bulanık küme mantığı ile yapay sinir ağları yöntemini beraber kullanmışlardır. Rahman ve Wang (2002), bulanık modellerle yapay sinir ağları modelini kullanarak sıvılaşma tahmini yapmışlardır. Geliştirdikleri model, geniş sıvılaşma data tabanı kullanılarak test edilmiştir. İki farklı test algoritmasının ikinci fazında tek parametreler için bulanık kümelerin üyelik dereceleri geliştirilmiş ve test fazı boyunca girdi değişkenleri "yüksek", "düşük" gibi dilsel terimlerle ifade edilmiştir. Çalışmalarında, sıvılaşmaya etki eden faktörler; "magnitüd", "toplam düşey zemin gerilmesi", "düşey efektif gerilme", "SPT, N", "deprem ivmesi ", "ince tane yüzdesi", "ortalama tane çapı- D_{50} (mm)" ve "yer altı suyu derinliği"dir.

Tekrarlı gerilmelerin arazi davranış modelleri ile elde edildiği ve laboratuvar deneylerine dayanan ileri dinamik analizlerde ve ayrıca yine tekrarlı gerilmelerin deneysel verilere bağlı ampirik yöntemlerle belirlendiği arazi deneylerine dayalı basitleştirilmiş yöntemlerde tüm bahsi geçen olumsuzluk ve sınırlar yaşanmaktadır. Tüm bu olumsuzluklar nedeniyle de sıvılaşmaya yol açan tekrarlı gerilmelerin doğru olarak elde edilmesinde bazı güçlükler ortaya çıkmaktadır. Olumsuzlukların hesapları etkilememesi ve sağlıklı biçimde sıvılaşma analizlerinin gerçekleştirilebilmesi için istatistiksel yöntemler ve bunun yanı sıra günümüzde sıkça başvuru alan ve zemin mühendisliğinde uygulama alanı bulan yapay sinir ağları ile modelleme uygulanmaktadır.

Tüm bu yöntemlerde tekrarlı kayma gerilmelerinin doğrudan kullanımına ihtiyaç yoktur. İstatistiksel yöntemlerle; $\%D_r$, SPT ve sıvılaşma yüzdesi arasında ilişkiler kurulması yoluna gidilmiştir (Christran ve Swige 1975, Liao at al., 1988). Bu ilişkiler ortaya atılırken; sıvılaşma veya sıvılaşmamaya ait durum bireysel varyansı ve kovaryanslarının beraber alınan tüm durumlar için aynı olduğu şeklinde kabuller yapılmaktadır (Christian ve Surge, 1975).

Sıvılaşma durumunun birçok değişkene bağlı olduğu düşünülürse, yapay sinir ağları yönteminin kullanılışlılığı ortaya çıkmaktadır. Çünkü sinir ağları yöntemi kullanılarak işlenen sıvılaşma potansiyeli tahmini tespit edilirken bilgisayar programları ve araziden toplanan kayıtlar kullanılmakta ve klasik, karmaşık matematiksel modellerin yerine, yapay sinir ağları metodu kullanılırsa, birçok değişkene sahip karmaşık ilişkileri, kolayca değerlendirmek mümkün olmaktadır. Konu ile alakalı ilk sıvılaşma tahmini çalışmaları ise yapay sinir ağları kullanılarak Goh (1994) tarafından yürütülmüştür. Goh ve Seed (1985) sıvılaşmayı çalıştıkları yapay sinir ağında tahminlerini sıvılaşma üzerinde etken olan benzer parametreleri kullanarak yapmışlardır. Bu parametreleri ise; SPT değeri, D_{50} tane boyutu, eşdeğer dinamik gerilme oranı (τ_{av}/σ_0'), ince tane oranı, toplam düşey gerilme (σ_0), efektif düşey gerilme (σ_0'), deprem magnitüdü (M) ve zemin yüzeyindeki maksimum yatay deprem ivmesi (a_{max}) olarak sıralayabiliriz. Sıvılaşma tahminini en fazla etkileyen ise bu değişkenler içerisinde; ince tane oranı, SPT değeridir.

Yakın zamanlarda, Kuzey Amerika, Tayvan, Japonya, Türkiye ve Çin gibi dünyanın birçok köşesinde sayısı oldukça fazla ve güçlü depremler meydana gelmiştir. Depremlerin meydana gelmesi sadece şehirlerde mal kaybına neden olmamakla birlikte toplumların yerleşim düzeni ve yaşamlarını da önemli ve yıkıcı bir biçimde etkilemektedir. Örneğin Richter ölçeğinde 7.3 olan Chi-Chi kentinde 1999'da meydana gelen deprem, Tayvan'da meydana gelen ve genel kaygıları son derece arttıran en ağır felaket olmuştur. Deprem süresince; binalar, otoyol dolguları ve dayanma duvarları gibi birçok yapı ya hasar görmüş ya da tamamen yıkılmıştır. Depremden etkilenen ikamet bölgeleri ise henüz düzenlenememiş ve yeniden kurulamamıştır. Genel olarak deprem süresince yapılarda belirgin olarak iki hasar tipi oluşur. İlk hasar tipi, depremin güçlü ivmesinden kaynaklanan yapısal hasarlardır, binanın kendisinde ortaya çıkarlar. İkinci tip hasar ise sıvılaşma kaynaklı olarak temellerde meydana gelir ve yapının bir bütün olarak çökmesi ile sonuçlanan hasarlara yol açar. Bu nedenle deprem kaynaklı sıvılaşma tahmini tasarım aşamasında esas alınır. 1960'lı yıllardan bu yana birçok araştırmacı, çalışmalarını deprem kaynaklı sıvılaşma değerlendirmelerine adanmıştır. Standart penetrasyon deneyinin (SPT) batırma direnci genel olarak bir sıvılaşma potansiyeli indisi olarak kullanılır. SPT'nin çokça sıvılaşma potansiyeli tahmininde kullanılmasının en büyük neden ise araz koşullarında yerinde yapılan deneylerde SPT-N değerinin uygun hassasiyet ve doğrulukta kolayca elde ediliyor olmasıdır.

SPT-N değeri yönteminde ilk olarak deprem kaynaklı çevrimsel gerilme oranı (CSR) tanımlanmalıdır, daha sonra deprem kaynaklı sıvılaşma potansiyeli tahmini yapmak üzere çevrimsel gerilme oranı hesap edilebilir (Tokimatsu ve Yoshimi 1983, Seed at al., 1985). Ayrıca Japon Yol Birliği sıvılaşma değerlendirmesi için bir deneysel prosedür sunmuşlardır (Japanese Road Association, 1996).

Geleneksel SPT-N yöntemi ile sıvılaşma potansiyeli tahmini; deprem magnitüdü, düşey gerilme, düşey efektif gerilme, N değeri, ortalama kayma gerilmesi, derinlik, zemin yüzeyindeki yatay en büyük ivme, ince malzeme oranı, ortalama zemin dane boyutu gibi zemine ait değişkenleri ve sismik verileri gerektirir. Eğer sınırlı sayıda arazi malzeme parametresi mevcutsa, istenilen malzeme parametreleri korelasyon formülleri yardımıyla elde edilir. Bununla birlikte bazı parametreler doğrudan deney sahasında elde edilemez. Bu durumda en iyi değer belirleme metodolojisi sorun teşkil etmektedir. Görüldüğü gibi bu yöntemlerin sınırlamaları mevcuttur. Dalga kaynaklı sıvılaşma potansiyeli tahmininde yapay sinir ağı modelleme uygulaması ise uygun görünmektedir. YSA model uygulamasını resmetmek için Jeng tarafından önerilen ve gerçek durumlardaki dalga ve zemin karakteristikleriyle en iyi örtüşen poro-elastik modeli örnek alan bir veri bankası kurulmuştur (Jeng, 1997).

Ural ve Saka (1998) yaptıkları çalışmada sıvılaşma potansiyelini değerlendirmek üzere yapay sinir ağı modellemesinden yararlanmışlardır. Sismik parametreler ve zemin parametreleri girdi olarak kullanılmış, geriye yayımlı öğrenme algoritması ile modelleme gerçekleştirilmiştir. Toplam 11 sismik ve zemin parametresi girdi olarak kullanılmış, farklı modeller kurmak için parametreler farklı gruplandırılmıştır.

Juang, Tien ve Chen (1999), yaptıkları çalışmada sıvılaşma problemini çözmek üzere koni penetrasyon verilerinden yararlanmış ve yapay sinir ağı modellemesi kurmuşlardır. Makalede kum zeminlerin sıvılaşma direnci değerlendirilmiş ve bu değerlendirme için iki geleneksel koni penetrasyon metodu verileri kullanılmıştır. bu yöntemler Olsen ve Robertson yöntemleridir. Modellenen sinir ağıları sonucunda kum zeminlerde sıvılaşma potansiyeli tahmininde, az da olsa Robertson yönteminin Olsen yönteminden daha doğru ve tutarlı sonuçlar verdiği sonucu çıkarılmıştır.

Wang ve Rahman (1999), sismik etkiler altındaki sıvılaşma tarafından ortaya çıkan yatay zemin etkisinin, mühendislik yapılarının önemli hasar sebeplerinden biri olduğunu ortaya koymuştur. Geri-yayımlı bir yapay sinir ağı modeli yatay zemin hareketlerini tahmin etmek için geliştirilmiştir. Sekiz büyük depremde meydana gelen yatay yerdeğiştirmelerin bulunduğu geniş bir veritabanı kullanılmıştır. Bu çalışmanın sonuçlarında, yatay zemin yerdeğiştirmelerinin miktarında yapay sinir ağı modellemesinin önemli ve güvenilir olduğu anlaşılmıştır. Daha fazla verinin kullanılmasıyla, daha geniş ölçekte saha koşulları ve deprem durumunda, modelin daha doru yatay yer değiştirme tahmini yapabileceği ortaya çıkmaktadır.

Araştırmacılar, çalışmalarında sıvılaşmanın neden olduğu düşey zemin yer değiştirmesi için yapay sinir ağları modelleme yöntemini kullanmışlardır. Makalede geri yayımlı yapay sinir ağları kullanılmıştır. Modelde kullanılacak veriler ise sekiz büyük depreme ait deprem kayıtlarını içeren bir veri tabanından sağlanmıştır. Sonuçta yapay sinir ağından elde edilen verilerin literatürdeki ampirik yöntemlerle elde edilenlere göre daha doğru ve gerçek sonuçlar verdiği ortaya koyulmuştur.

Juang ve diğerleri (2000) saha sıvılaşma potansiyeli kayıtlarının yapay sinir ağı analizine dayalı limit durum fonksiyonu geliştirmek için yeni bir yöntem önerişlerdir. Bu yöntem, geniş arazi sıvılaşma potansiyeline ait kayıt veri tabanı ile işleyen mevcut basitleştirilmiş yöntemlerle aynı avantajlara sahiptir. Juang ve arkadaşları (2000) tarafından geliştirilen yöntem, modifiye edilmiş ve SPT tabanlı limit durum fonksiyonu geliştirmek üzere kullanılmıştır. Veritabanında mevcut ve sıvılaşma olasılığını tanımlayan hesaplanmış güvenlik katsayısı ile ilişkilendirilen tüm vakaların analizine dayalı bir eşleme fonksiyonu geliştirilmiştir. Geliştirilen Sıvılaşma olasılık – Güvenlik katsayısı eşleme fonksiyonu risk tabanlı tasarım grafiği geliştirmek üzere kullanılmıştır. Bu anlamda, Juang ve diğ. (2000); arazi sıvılaşma performansı kayıtlarının yapay sinir ağlarına (YSA) dayanan limit durum fonksiyonunu geliştirmek için yeni bir yöntem önermişlerdir. Bu yeni yöntem, geniş bir arazi sıvılaşma performansı veri tabanına dayanan mevcut basitleştirilmiş yöntemlerle aynı avantajlara sahiptir. Bununla birlikte, yöntem limit durum fonksiyonunu tanımlamada mekanik bir süreç kullanımına gider ve önemli ölçüde oluşabilecek söz konusu sakıncaları ortadan kaldırır.

Sıvılaşma potansiyeli zeminde sıvılaşmaya karşı bir güvenlik katsayısının belirlenmesi ile mümkündür ve bu genellemeye dayanan çözümler bulunmaktadır. Bu güvenlik katsayısı sıvılaşmaya yol açan tekrarlı direnç oranının depremin oluşturduğu tekrarlı gerilme oranına bölünmesiyle bulunur (Youd at al., 2001).

Yanal yer değiştirme değerinin sıvılaşmaya etkisinin yapay sinir ağları ile araştırıldığı çalışmada sıvılaşma tahmini bu açıdan Wang ve Rahman tarafından araştırılmıştır. Iwasaki ve diğerleri (1982) sıvılaşma potansiyeli indeksi kullanarak sıvılaşma potansiyelini çok düşük ve çok yüksek mertebeleri arasında farklı derecelere sınıflandırıp nitelilemişlerdir. Iwasaki ve diğerleri tarafından bu sıvılaşma potansiyeli indeksi sıvılaşmanın bir temel hasarı meydana getirip getirmeyeceğini ölçümlemek için geliştirilmiştir (1978).

Sismik veriler, büyük boyutlarda hacimlere sahip veri gruplarını oluşturmaktadır. Tüm bu sismik verilerin yorumlanıp kullanılabilmesi için ise orijinal veri toplamları içerisinde çok sayıda verinin elde edilmesi gerekmektedir. Büyük verilerin işlenip kullanılabilir duruma gelebilmesi ise, çok değişkenli analiz tekniklerinin kullanımıyla basite indirgenebilir. Sismik veriler genelde bozucu

etki taşır ve bilinmeyen sismik dalgacık varlığı yüzünden karmaşık bir yapıya sahiptirler. Yüksek hacimli verileri içeren, bozucu etkilere sahip ve kayıp verilerin oluşabildiği bu tür problemlerde çok değişkenli istatistik analiz yöntemleri sağlıklı sonucu sağlayamayabileceğinden alternatifi olarak yapay sinir ağı kullanımına başvurulabilir (Bishop 1995, Haykin 1984). YSA'nın, eksik veya gürültülü verilere sahip karmaşık problemlerin çözümündeki etkinliği kanıtlanmıştır YSA genel jeofizik uygulamalarda (dalga şekli tanıma, sismik tersinme, kuyu-kayıt analizi, iz düzeltme/düzenleme, sismik dekonvolüsyon) sıklıkla kullanılan bir yöntemdir(Dowla, 1990; Roth, 1994; Poulton, 1992; Huang, 1996, Calderon, 1997; Baan, 2000).

Diğer yöntemlere kıyasla, sismik veri yorumlamada, öğrenebilme yetisine sahip olması, özellik uzayında yüksek dereceden doğrusal olmayan “karar sınırları” oluşturabilme yeteneği, gürültü gibi genelde bozucu etki olarak nitelendirilip yorumlamaya katılmayan veriler işleyebilme ve farklı veri türlerine uyum yeteneği önemli özelliklerindendir (Richard, 1991).

Cassagrande tarafından ortaya atılan sıvılaşma kavramı Mogami ve Kubu (1953) tarafından tekrar yorumlanmış, suyun zemin ortamından uzaklaşmadığı koşullarda, suya doymun kohezyonsuz zeminlerin tekdüze, geçici ve tekrarlanmalı şekilde örselenmesinden kaynaklı zemin deformasyonları kapsayan tüm davranış biçimini nitelemek için kullanılmıştır. Yer sarsıntısı gibi deformasyon tetikleyici etkenler, yüksek boşluk suyu basınçlarının ortaya çıkması ve efektif gerilmelerin sıfıra ulaşmasına yol açarak, taneler arasında hiçbir tutucu kuvvetin iş görmemesine neden olur (Ishihara 1985).


Sıvılaşma depremin bir sonucu olarak daha çok gevşek ve doymun kumlu zeminler başta olmak üzere meydana gelen bir olaydır. Sıvılaşma çoğu inşaat mühendisliği yapılarında hasar oluşturacak büyüklüklerde önemli, boşluk suyu basıncı artımına bağlı, zeminde kesme gerilmesi kayıpları oluşturan bir durumu tanımlamaktadır. Deprem sebepli sıvılaşma potansiyeli tespiti önemli ve karmaşık bir geoteknik mühendisliği problemidir.

Araştırmacılar, gerçek çok katlı ve deprem yer hareketlerine maruz binalarda yapay sinir ağına bağlı yapısal dinamik modellemenin doğru sonuçlara ulaştırdığını vurgulamışlardır. Yun ve Bahng (2000) geri-yayıma algoritmasını, iki boyutlu kafes ve çerçevelerin rijitlik parametrelerinin tayininde kullanmışlardır.

C. Hsein Juang, Caroline J. Chen Tao Jiang ve Ronald D. Andrus (2000), yaptıkları çalışmada sıvılaşma olgusundan sıvılaşmanın gözlemlenmediği durumu ayıran sıvılaşma sınır hali fonksiyonunu geliştirmek üzere yeni bir yaklaşım ortaya atmışlardır. Yeni yaklaşım, standart penetrasyon(SPT) deneyleri yapılmış 243 arazi sıvılaşma performansı gözlemi içeren bir veri

tabanı kullanılarak geliştirilmiştir. Başarılı bir biçimde eğitilen yapay sinir ağı daha sonra sınır değer sıvılaşma fonksiyonu oluşturmak üzere kullanılmıştır.

Geliştirilmiş sınır sıvılaşma fonksiyonuna dayanan ve hesaplanmış sıvılaşma olasılık faktörünü geçerli kabul eden haritalama uygulaması ile yapay sinir ağı başarıya ulaşmıştır. Kurulan haritalama uygulamaları, sıvılaşma potansiyeli değerlendirmesi için risk tabanlı grafik geliştirmeye yarayan bir temel oluşturur. Uygulanan sismik yüke eş değerde sıvılaşma direncine sahip zemin varlığında sınır durum koşulundan söz edilebilir. Zemin sıvılaşma direncinin, tekrarlı gerilme oranı (CRR) cinsinden ifade edilmekte olduğu kabul edilmiştir. YSA tabanlı sınır durum fonksiyonu geliştirmede ikinci adım bilinmeyen sınır durum yüzeyinde noktaların tespiti olmaktadır. Bu aşamada Juang ve diğ. (2000) tarafından geliştirilen arama tekniği, çalışmaya uyarlanmak üzere değişime uğramıştır.



Şekil 7.40. CRR modelleri uygulanarak türetilmiş haritalama fonksiyonu (Juang ve diğ., 2000)

Şekil 7.40' ta, elde edilen sıvılaşma olasılığı (SO) - güvenlik sayısı (GS) haritalama fonksiyonunun kullanımını açıklamak üzere kullanılabilir. Bu durumda risk seviyesini düşürmek için istenilen güvenlik faktörü seçimi yapılabilir. Örneğin, referans alınan sıvılaşma güvenlik sayısı (SGS) modelinde, 0.20 değerindeki risk seviyesinde (sıvılaşma olasılığı), istenilen GS 1.43 değerine eşit olmaktadır. Seed ve diğ. (1985) 'ne ait modelde güvenlik sayısı 1.19'a çekilebilirken, basitleştirilmiş SGS yönteminde bu değer 1.01'dir.

Huang ve Loh (2001), büyük depremler süresince, doğrusal olmayan ayırık-zamanlı sistemlerin tanımlanması için, yapay sinir ağı tabanlı model önermişlerdir. Üç katlı bir çerçeveyi farklı deprem kuvvetleri altında incelemiş yapısal değişiklikleri, fizibilite ve güvenilirlikleri doğrulamak amacıyla Tayvan'da bir köprü üzerinde iki boyutlu bu analizleri uygulamışlardır.

Chiru-Danzer, Juang, Christopher ve Suber (2001) sivilaşma konusunu işledikleri çalışmalarında, yapay sinir ağlarını kullanarak sivilaşmanın neden olduğu yatay yer değiştirmeleri, arazi performans verilerini temel alarak modellemişlerdir. Analizde 444 kaydedilmiş yatay yer değiştirme verisi veri tabanı olarak kullanılmıştır. Duyarlılık analizleri ile girdilerin önemi ve model üzerindeki etkisi araştırılmıştır. Yapay sinir ağı mimarilerine dayalı modellemelerin diğer geleneksel yöntemler ile karşılaştırıldığında daha doğru ve güvenilir sonuçlar verdiği görülmüştür.

PNN temel anlamda, Specht (1990) tarafından ortaya koyulan yaygın olarak birçok klasik model-tanılama probleminde kullanılan Bayezyen sınıflama tekniğine dayanmaktadır. PNN algoritması CPT verileri ve kayma dalga hızı verilerini ayrı ayrı analzi edebilmek için kullanılmıştır. Stark ve Olsen (1995), ile Andrus ve Stokoe (1997), sivilaşma oluşumu ya da sivilaşmanın meydana gelmediği durumları doğru bir biçimde sınıflandırmak üzere yapay sinir ağının test ve eğitim aşamalarındaki yeterliliğini araştırmışlardır.


Goh (2002) yaptığı çalışmada, Bayezyen sınıflandırma yöntemi uygulamasına sahip olasılıksal sinir ağı (PNN) kullanmıştır. Çalışmada, PNN (Specht 1990) kesme dalgası hızı verileri ile CPT verilerinin ayrı ayrı analizi için kullanılmıştır. sivilaşma meydana gelmesi yada sivilaşmanın meydana gelmemesi durumunu doğru bir şekilde ortaya çıkarmak için yapay sinir ağının eğitim ve test aşamalarında Stark ve Olson (1995) ile Andrus ve Stokoe (1997) tarafından elde edilen veritabanı kayıtları kullanılmıştır. Goh (1995, 1996) ve Juang ve diğ. (1999) tarafından elde edilen önceki başarılı sinir ağları farklı bir yaklaşım esas alarak çok katmanlı ileri beslemeli sinir ağı algoritması kullanmışlardır.

Makalede bahsi geçen yapay sinir ağı temel olarak Goh (1996) tarafından tanıtılan yaklaşıma benzerlik göstermektedir. Goh tarafından yapılan bu çalışmada yapay sinir ağı modelinin test ve eğitim aşamalarında Shibata ve Teparaksa (1988)'nin deneylerindeki 109 noktadaki arazi performans veri değeri kullanılmıştır. Bu çalışmada ise Stark ve Olson (1995)'un deneylerinden derlenen 104 sivilaşan ve 66 sivilaşmayan arazi verisi ele alınmıştır.

Orijinal kayıtlardan bazıları birkaç eksik veri bulundurmaları nedeniyle ihmal edilmiştir. Sivilaşma potansiyeli tek bir çıkış nöronu ile temsil edilmiştir. Bahsi geçen nöron sivilaşma gözlemlenen durumda 1, sivilaşma gözlemlenmeyen durumda ise 0 değeri almaktadır. Girdi değerleri; deprem magnitüdü M , maksimum yüzey ivmesi a_{max} , toplam düşey derinlik basıncı σ_{v0} , düşey efektif derinlik basıncı σ'_{v0} , ölçülen CPT uç direnci q_c ve ortalama tane boyutu D_{50} , 6 nöron içermektedir

Wang ve Rahman (2002), özellikle yatay zemin yer deđiřtirmesine bađlı sıvılařma durumunu yansıtacak yapay sinir ađı modelini yapmıřtır. alıřmada, yapay sinir ađı modelinin basit ve gvenilir bir yatay zemin yer deđiřtirmesi miktarı lme aracı olduđunu gstermiřlerdir.

Baziar (2003), arařtırmasında geniř bir deđiřken le sahip gvenilir koni penetrasyon deney veri setleri toplamıřtır. Tm bu veriler STATISTICA Sinir-Ađları adı verilen bir yapay sinir ađı yazılımında kullanılmıřtır. Farklı blgelerdeki sıvılařma oluřumunu analiz etmek iin ok katmanlı algılayıcı ve geriye yayılma algoritmalı sinir ađı kullanılmıřtır.



řekil 7.41. 1976 Tangshan Depremi sıvılařma sınırları ($M=7.8$, $a_{max}=0.2$, $\sigma'_o=100$ kPa)
(Baziar, 2003)


YSA diđer geleneksel yntemlere gre; daha dođru sıvılařma potansiyeli sonu tahmininde bulunması nedeniyle byk neme sahiptir. Bu alıřmada da yapay sinir ađında kullanılacak parametreler daha dođru sonular alınması iin farklı deney setlerine ait etkin deđiřkenler olarak seilmiřtir ve sıvılařma sınırları řekil 7.41' de gsterilmiřtir. Stark tarafından yapılan deneylerden 170 arazi alıřmasına ait 180 veri derlenmiřtir. alıřma dzeninde D_{50} ortalama tane boyutu veya q_c deđerlerinin eksik olduđu 10 adet veri, zemine ait etkili parametreleri iermedikleri iin kullanılmamıřtır. ABD (San Fernando Vadisi 1971, Imperial Valley 1979 ve Loma Prieta 1989)'ye ait 57 veri, Japonya (Niigata 1964 ve Nihonkai ubu 1983) 16 veri, in (Haicheng 1975 ve Tangshan 1976)'e ait 85 veri, Romanya (Vrancea 1977)'ya ait 5 ve Kanada

(Sanguenay 1988)'ya ait 7 veri kaydı kullanılmıştır. Bu arazilerin 104'ünde sivilaşma oluşmuştur. Kalan 66 bölgede ise sivilaşma meydana gelmemiştir. İnce tane oranı İTO, her veri alınan arazi kesimi için alınan mevcut değerlerden değildir. Bu durumda İTO değeri bir girdi parametresi olarak kabul edilmemiştir.

Baziar ve Ghorbani (2004), çalışmalarında sivilaşmaya bağlı yanal yayılmaların, büyük depremler sırasında meydana gelen en etkili zemin taşıma gücü kaybına sebep hasar tipi olduğunu vurgulamışlardır. Belirli bir arazi kesitindeki yanal yayılma ve sivilaşma oluşumu tahmin edilebilir olmakla birlikte, ortaya çıkan deformasyonların büyüklüklerini tahmin konusu hala birçok araştırmacının çalışmalarının odak noktasını oluşturmaktadır.

Bu çalışmada, STATİSTİCA adlı profesyonel yazılım kullanılmasıyla, sivilaşma nedenli yatay yayılmaya bağlı zemin şev ve yatay düzlemlerindeki yatay zemin yer değiştirmeleri tahmin için bir yapay sinir ağı yöntemi geliştirilmiştir. Geleneksel yöntemlerin çoğu, yer değiştirmeyi etkileyen ana faktör olarak görülen; deprem magnitüdü (M), sismik enerji kaynağına en yakın mesafe (R), 15'ten az düzeltilmiş SPT vuruş sayısına sahip doymuş granüler katmanların kümülatif kalınlığı (T15), T15'in içerdiği granüler malzemenin ortalama ince tane içeriği (F15), T15'in içerdiği granüler malzemenin ortalama tane boyutu ortalaması ($D_{50}15$), zemin eğimi (S), yatay düzlem oranı (W) parametrelerini hesaplarda kullanmaktadır.

Bu Çalışmada da aynı parametreler, yapay sinir ağı girdi değişkenleri olarak atanmıştır. Bu tipte bir analiz için, YSA yönteminin tüm etkili parametreleri birlikte değerlendirip ilişkilendirme işlemini gerçekleştirmesi sebebiyle, parametrelerin MRL modellemesi gibi deneysel yöntemlerde kullanıldığı üzere normalize edilmesi veya kalibrasyondan geçmesi gerekmemektedir. Yanal zemin yer değiştirmesi (YZY) yapay sinir ağının tek çıktı nöronunu oluşturmaktadır. Tahmin edilen ve ölçülen değerlerin karşılaştırması Şekil 7.42' de sunulmuştur.



Şekil 7.42. YSA-2003 modeli ve MLR modeli arasındaki karşılaştırma (toplam 1 veri seti ile)
(Baziar ve Ghorbani, 2004)

Chen ve diğ. (2004), çalışmasında sıvılaşma olasılığını değerlendirmek üzere, geri yayımlı yapay sinir ağı ile sismik dalga enerjisi tabanlı bir yöntem sunmuştur. Sismik dalga enerjisini hesaplamak için sırasıyla, deneysel bir denklem ve Fourier genlik spektrumu kullanılmaktadır. Sıvılaşan ve sıvılaşmayan veri noktalarını birbirinden ayıran sınır eğrisinin denklemini belirlemek için diskriminant analizi kullanılmıştır.

Önerilen yöntem, sınır eğrisi ve logaritmik- normal dağılıma dayalı zemin sıvılaşma olasılığını değerlendiren yeteneğe sahiptir. Bu makalede, Chi-Chi depreminden toplanan veriler doğrulama amacıyla kullanılarak, sismik dalga enerjisi yardımıyla iki farklı sıvılaşma değerlendirme modeli geliştirilmiştir. Ayrıca, normal dağılım ve diskriminant analizi sıvılaşma olasılığını tahmin etmek için kullanılmıştır. Bu makalede, model ağırlıkları geri-yayımlı yapay


sinir ağına atanmış ve tek gizli tabakalı çok katmanlı ileri beslemeli yapay sinir ağı kullanılmıştır.

Chen ve ark. (2005) tarafından, sivilaşma olasılığı geriye yayılım yapay sinir ağı tabanlı bir enerji yöntemi kullanılarak değerlendirilmiştir. Önerilen yöntemin, sivilaşma olasılığı değerlendiren bir özelliği vardır.


Dihoru ve diğ. (2005), değişken sınırlı üç eksenli test cihazları (TTAF) zeminlerin gerilme-şekil değiştirme davranışlarını tam olarak tanımlayan çok yönlü araçlardır. TTAF'de zemin numunesinin uğradığı deformasyonlara, numune kılıfının, basınçlandırma yastığının, cihaz çerçevesinin üniform olmayan konumsal rijitliğinin ve elektronik hataların etkileri de hesaba katılmalıdır. Bu şekilde sıralanan bir dizi karmaşık faktörün birbiriyle olan ilişkilerinin etkisinin üstünden gelmek için yapay sinir ağı (YSA) yaklaşımı kullanılmakta ve yer değiştirmeleri etkileyecek hatalar tahmin edilmeye çalışılmaktadır. Tahminler yüksek doğruluğa sahip olmakta ve hata oranlarını en düşüğe tutmaktadır.

Hanna, Ural ve Saygılı (2007), Türkiye ve Tayvan'da meydana gelen iki büyük depremdeki sivilaşmalar için, alternatif olarak genel regresyon yapay sinir ağı önerisinde bulunmuşlardır. Önerilen yöntemin sismik koşullarda deprem nedenli sivilaşmaları duyarlı ve doğru bir biçimde değerlendirmek için uygun bir araç olduğu tespit edilmiştir. Khozaghi ve Choobbasti (2007), yapay sinir ağı yaklaşımı kullanarak, İran'da Tahran şehri güneydoğusundaki bölgede meydana gelen sivilaşmayı tahmin etmiştir. Seed (1979) yönteminden elde edilen sonuçlarla, çalışma sonuçları karşılaştırılarak, çalışılan alanlarda sivilaşmanın %92 doğruluk ile yapay sinir ağı yöntemiyle tahmin edilebildiği ortaya koyulmuştur.

Baziar ve Jafarian (2007), yaptıkları çalışmada zemin parametreleri ile kumlarda ve siltli kumlarda şekil değiştirme enerjisi arasındaki korelasyonu kurmak için bir yapay sinir ağı modeli geliştirmişlerdir. Son derece geniş bir set olan, üç eksenli kesme ve basit kesme deneylerine ait 284 veriyi kapsayan veri seti yapay sinir ağı modeli geliştirmek üzere Şekil 7.43' te kullanılmıştır. Çalışmanın parametrik devamında, elde edilen sonuç ve gidişatlar daha önceden elde edilen laboratuvar çalışmaları ile teyit edilmiştir.




Şekil 7.43. Figuerroa ve diğ. Değerlendirmesi kapasite enerjisi modeli, (veri tabanındaki tüm elemanların test verisi olarak kullanılarak geliştirilmiş) (Baziar ve Jafarian, 2007)



Şekil 7.44. MLR-tabanlı kapasite enerjisi modeli, (veri tabanındaki tüm elemanların test verisi olarak kullanılarak geliştirilmiş) (Baziar ve Jafarian, 2007)

Bu çalışmada, yapay sinir ağı temelli zemin kapasite enerjisi hesap modeli geliştirmek için, ilk olarak diğer modeller incelenerek sonuçların değerlendirilmesi yoluna gidilmiştir. Girdi vektörü;


Leighton Buzzard kumu ve mika çeşitli oranlarda birbirine karıştırılmıştır. Bu çalışmada referans alınan mika yüzdesi, mikanın kuru ağırlığının karışımın toplam kuru ağırlığına oranı ile ifade edilir. İki mika yüzdesi %5 ve %10 olarak seçilmiş ve bu şekilde adlandırılarak, temiz Leighton Buzzard kumu ile karşılaştırılmışlardır. Şekil 7.46' da taramalı elektron mikroskobu (SEM) görüntüsünde deneysel çalışmada kullanılan mika ve kum görülmektedir. Optimumda verimli yapay sinir ağı mimarisi, sönüm oranı için 3-3-1 mimari yapısı, kesme modülü için ise 3-2-1 mimarisi olarak tespit edilmiştir. Şekil 7.47 ve Şekil 7.48'de en iyi YSA modelleri sırasıyla verilmiştir.




Şekil 7.46. Leighton Buzzard kum mika karışımı SEM fotoğrafı (Cabalar ve Çevik, 2008)

Kum-mika karışımlarının kesme modülü ve sönüm oranları tahmini için çalışmada önerilen YSA modelleri, deneysel verilere dayanan gerilme, mika içeriği ve şekil değiştirmenin fonksiyonu olarak sunulmaktadır. Boşluk suyu basıncı 300 kPa sabit iken, 350 - 450 kPa arasında değişen basınç altındaki farklı kum ve mika karışımlarının üzerinde dokuz drenajsız konsolide burulma rezonans kolonu testi uygulanmıştır.

Deney sonuçları ile karşılaştırıldığında YSA modellerinin oldukça doğru sonuçlar verdiği gözlemlenirken, geliştirilen YSA'larda kesme modülü için denklemin ($R^2=0.99$) ve sönüm oranı için ($R^2=0.97$) değerlerinde olduğu görülmektedir.



Şekil 7.47. Sönümlleme oranı (D) için en iyi YSA modeli (Cabalar ve Çevik, 2008)



Şekil 7.48. Kesme modülü (G) için en iyi YSA modeli (Cabalar ve Çevik, 2008)

Baykasoğlu ve diğ. (2009), çalışmalarında sıvılaşma tahminin geoteknik alanında son derece önemli bir konu olduğunu vurgulamışlardır. Sıvılaşma tahminin aynı zamanda birçok farklı fiziksel faktöre dayalı zor bir problem olduğunu, bu değişkenler arasındaki ilişkinin de yüksek non-lineerlikte ve karmaşıklıkta olduğunu tekrarlamışlardır. Literatürde verilen birçok yapay sinir ağının klasik istatistiksel yaklaşımlara ve yapay sinir ağlarına dayandığı açıklanmıştır. Çalışmada, literatürde ilk defa sıvılaşma tahmini için, sınıflandırma veri madenciliğine dayalı bir yaklaşım önerilmiştir. Yapılan çalışmada en çok kullanılan YSA'lardan olan çok katmanlı algılayıcı (MLP) yapay sinir ağı kabul edilmiştir. MLP'nin özellikle sınıflandırma problemlerinde yararlı olması özelliğini vurgulamışlardır.

Çizelge 7.12. Sembol dizini ve açıklamaları (Baykasoğlu ve diğerleri, 2009)

Sembol	Açıklama	Kodlama	Sembol aralığı
q_c	Koni uç direnci	X_1	0.9 - 25
R_f	Kılıf sürtünme oranı	X_2	0.1 - 5.2
S_1	Efektif gerilme	X_3	22.5 - 215.2
S_2	Toplam gerilme	X_4	26.6 - 274
a_{max}	Maksimum zemin yatay ivmesi	X_5	0.08 - 0.8
M_w	Deprem moment magnitüdü	X_6	6 - 7.6
L(sınıflandırma)	Sıvılaşma var veya yok (1=var,0=yok)	λ	0 ve 1


Çalışmada kullanılan veri seti; Juang, Yuan, Lee ve Lin (2003) tarafından derlenen koni penetrasyon deneyi (CPT) verilerine dayalıdır. Veri seti toplam 226 kayıt içerirken; bunların 133 tanesi sıvılaşmanın gerçekleştiği, 93'ü ise sıvılaşmanın meydana gelmediği vakaları içermektedir.

Altı girdi değişkeni olarak; koni uç direnci q_c , kılıf-koni sürtünme oranı R_f , ilgili derinlikteki efektif gerilme S_1 , aynı derinlikteki toplam gerilme S_2 , maksimum zemin yüzü yatay ivmesi a_{max} , deprem moment magnitudü M_w , seçilmiş ve sıvılaşmayı temsil eden ikili değişken L parametresi ise çıktı olarak atanmıştır ve Çizelge 7.13' te gösterilmiştir.

Lee ve Hsiung (2009), yaptıkları çalışmada çok katmanlı algılayıcı (MLP) yapay sinir ağlarında arazi sıvılaşma durumlarının tanınmasını etkileyen anahtar parametrelerin, sistem hassasiyetini tanımlamasında kullanılacak yeni bir yaklaşım sunmuşlardır.

Yeni bir indis olan ortalama duyarlılık faktörü SF_i , duyarlılık analizi sonucunu ölçmek için yapay sinir ağı matematik formülasyonundan türetilmiştir. Deprem parametreleri (M_w ve PGA), zemin tabakası gerilme durumu parametreleri (ρ_δ , ρ_σ , σ_σ , σ_σ') ve zemin dayanım parametreleri (SPT-N, C_N , C_E ve F.C.) yapay sinir ağında, yaklaşık olarak eşit rol oynamaktadır. Sismik faktörler (M_w , PGA, ρ_δ , σ_v , σ_v') sıvılaşma direnç kapasitesi parametrelerine (SPT-N, C_N , C_E ve F.C.) göre daha hassastırlar.

Tsompanakis ve diğ. (2009), yaptıkları çalışmada tipik basit bir dolgudaki sismik tepki simülasyonu üzerine odaklanmışlar ve YSA uygulamasını bu konu üzerine kurmuşlardır. Dolgunun dinamik tepkisi ise, geo-malzemelerin doğrusal olmayan davranışının, eşdeğer doğrusal prosedür biçiminde hesaba katılabileceği sonlu elemanlar yöntemi kullanılarak değerlendirilmiştir. Yapılan çalışmada ayrıca çokça zaman alıcı bir süreç, düzgün bir YSA eğitimi ile ortadan kalkmaktadır (Şekil 7.49).




Şekil 7.49. Hesaplan (FEM-QUAD4M) – tahmin edilen (YSA) en büyük ivmeye bağlı simik değerin 5 farklı PGA'ya göre grafikleştirilmesi (Tsompanakis at al., 2009)

Yapılan çalışmanın amacını, çeşitli sismik uyarım ve yoğunluk seviyeleri altında bir dolgunun non-lineer dinamik tepkisini ölçmede YSA sisteminin yeteneğini araştırmak olarak özetleyebiliriz. Genel amaç ise, büyük ölçekli bir deprem mühendisliği probleminin yaratacağı aşırı maliyeti azaltmaktır. Bu amaca ulaşmak için ise, çeşitli parametrelerin incelendiği ayrıntılı bir araştırma yapılmıştır.


Adeli ve Panakkat (2009) çalışmalarında, sismik gösterge olarak bilinen sekiz matematiksel hesaplanmış parametrenin, önceden tanımlanmış bir gelecek zaman diliminde sismik bir bölgede meydana gelebilecek en büyük depremin magnitudünü tahmin etmek için, olasılıksal yapay sinir ağı (PNN) kullanmışlardır.

Yapay sinir ağı, Güney Kaliforniya bölgesi için elde edilen verilerin kullanılması ile eğitilmiş ve test edilmiştir. Model 4.5 ile 6.0 arası magnitudlerde gerçekleşen depremlerde doğruluk derecesi yüksek tahminler vermiştir. Bu çalışmada ortaya atılan PNN modeli Şekil 7.50' de gösterildiği gibi, önceki araştırmacılar tarafından geliştirilen ve 6.0 magnitud üzeri depremler için geçerli olan modelleri tamamlayıcı olarak çalışmaktadır.




Şekil 7.50. Takip eden zaman periyodundaki en büyük sismik durumun magnitüd değerinin tahmini için oluşturulan PNN mimarisi (Adeli ve Panakkat, 2009)

Cha, Zhang ve Blumenstein (2010) son on yıl içerisinde deniz yapılarının tasarımında ve deniz tabanı analizlerinde kullanılan en önemli faktörlerden biri olan dalga-kaynaklı sıvılaşma olgusu üzerinde çalışmış ve bu etkiyi araştırmıştır. Çok sayıda dalga-kaynaklı sıvılaşma konulu çalışma yürütülmüş olmasına karşın, sıvılaşmanın deniz yapıları üzerindeki etkisi çok az bilinmektedir. Şekil 7.51’ de Dalga-deniz tabanı etkileşim tanımı resmedilmiştir. Yapılan çalışmada, dalga-kaynaklı sıvılaşma derinliği tahmini için multi yapay sinir ağı (MANN) kullanılmıştır. Bu yapay sinir ağının, orijinal ağa göre %10 daha fazla doğru öngörü sağlayabildiği görülmüştür.



Şekil 7.51. Dalga-deniz tabanı etkileşim tanımı (Cha, Zhang ve Blumenstein, 2010)

Yapılan çalışmada geri yayılım algoritması uygulanmıştır. Önerilen yapay sinir ağı model yapısı, Şekil 7.52' de gösterilmektedir. Çok katmanlı geri yayımlı sinir ağı, sigmoidal aktivasyon fonksiyonu kullanmaktadır.




Şekil 7.52. Dalgaya kaynaklı sivilaşma tahmini için önerilen YSA mimarisi (Cha, Zhang ve Blumenstein, 2010)

Farrokhzad ve diğ. (2010) yapmış oldukları çalışmada, Seed ve Idriss (1983) yöntemini temel alan Babol şehri sivilaşma mikrobölgesel haritası hazırlığında yapay sinir ağı yöntemlerini kullanmayı amaçlamışlardır. Yapay sinir ağı, yapay zeka yaklaşımlarından biri olmakla birlikte makine öğrenmesini temel alan bir sınıflandırmayı da problemlerde öngörmektedir. Basitleştirilmiş yöntemler, zeminin lineer olmayan sivilaşma potansiyelini değerlendirmek için, araştırmacılar tarafından uygulanmıştır. Yapılan çalışmada, sivilaşmaya yönelik geleneksel mühendislik yöntemlerine yeni bir yaklaşım getirilerek, alternatif bir genel regresyon yapay sinir ağı sunulmuştur. 7 km²'lik bir alandaki 30 sondaj kuyusundan arazi deneyleri ile elde edilen veriler, yapay sinir ağı ile eğitilmiş ve sonuçta araştırma alanı için gerekli sivilaşma mikrobölgeleme haritası elde edilmiştir.

Ismail ve diğ. (2011), kazığın yüklemeye karşı verdiği yanıtın doğru tahminin, zemin özelliklerindeki belirsizlik ve zemin-kazık arasındaki etkileşimin karmaşıklığı nedenleri ile tanımlanması zor bir problem olarak ortaya çıktığını, yaptıkları çalışmada vurgulamışlardır. Kazık yükleme-oturma ilişkisini tahminleyen geleneksel yöntemler ise problemi basite indirirken, hesaplarda laboratuvar ortamında belirlenemeyecek kadar zor parametreleri de gerektirmektedir. Yapılan çalışmada, yüksek dereceli yapay sinir ağı (HON), kazık yük-yerdeğiştirme eğrisini simüle etmek üzere, kazık batma derinliğindeki SPT verileri ve kazık özelliklerinin girdi parametresi olarak kullanılması ile geliştirilmiştir. Elde edilen sonuçlar HON modelinin, BPN, RBF ve GRNN modelleri ile kıyaslandığında daha iyi sonuçlar verdiğini göstermiştir. Elastik ve hiperbolik modellerin karşılaştırılması sonucunda da HON yöntemi ile

elde edilen değerlerin varolan geleneksel yöntemler ile karşılaştırıldığında daha iyi tahmin edildiği Şekil 7.53.' te görülmektedir.



Şekil 7.53. (a) BPN-eğitim verisi, (b) BPN-test verisi, (c) HON1-eğitim verisi, (d) HON2 test verisi (Ismail ve diğ. , 2011)

Model, kazık başı yerdeğiřtirmesi ve uygulanan eksenel yük büyüklüğü arasındaki iliřkiyi, kazık geometrik parametreleri ve elastisite modülü ile kazığın batmış olduđu zemin özelliklerini tanımlayan standart penetrasyon deneyi vuruř sayısı (SPT-N) yönünden tahmin etmektedir. Önerilen HON modeli ile BPN ve elastik yaklaşıp ve hiperbolik model arasında çalışma içerisinde kapsamlı bir karşılaştırma gerçekleştirilmiştir. HON yöntemi performansı ayrıca, diğeri polinom regresyon yöntemleri, RBF ve GRNN ile de karşılaştırılmıştır.

Girdi verileri, kazık gövdesi boyunca elde edilen SPT sayılarının ortalamasını, kazık tabanındaki SPT değerini, kazık rijitliğı, gövde ve taban alanı ve kazık yükü olarak sıralanmaktadır. Diğeri parametreler ise zemin tipi ve yerleşim yöntemini içermektedir.

Gevşek suya doymun bir kum depozit, zemin titreşimlerine maruz kaldığında, sıkışma eğilimi ve hacimce küçülme gösterir. Suyun drenajı mümkün değilse, oluşan hacimdeki azalma eğilimi boşluk suyu basıncında artışa neden olur. Boşluk suyu basıncındaki bu artış düşey gerilmeye eşit olma noktasına erişirse, efektif gerilme sıfırlanır ve kum depoziti kayma mukavemetini tamamen kaybeder. Bu durumda sıvılaşma gelişir (Seed ve Idriss, 1982).

8. SIVILAŞMA ANALİZLERİ

8.1 Sıvılaşma Potansiyeli Hesap Yaklaşımları ve Çevrimli Gerilme Yaklaşımı:

Sıvılaşma potansiyeli yüksek bulunan bir zemin için olası bir deprem öngörüsü yapılarak sıvılaşma analizi yapılması gerekmektedir. Literatürde bu amaç için kullanılan çeşitli metodlar:

- Çevrimli Gerilme Yaklaşımı
- Çevrimli Deformasyon Yaklaşımı
- Enerji Sönümü Yaklaşımı
- Efektif Gerilme Bazlı Analiz Yaklaşımı başlıkları altında incelenebilir.

Tez çalışmasında Çevrimli gerilme yaklaşımı kullanılmıştır.

Deprem etkisine maruz kalan bir zemin tabakasında oluşan boşluk suyu basıncı artışının tamamen çevrimli kayma gerilmelerine bağlı olduğu düşüncesinden yola çıkarak, sıvılaşmaya sebep olacak sismik yüklemeyi ve zeminin sıvılaşmaya karşı direncini gerilme oranı cinsinden karşılaştırma işlemidir. Sismik yükleme oranının sismik direnç oranından büyük olması zeminin sıvılaşma direncinin aşıldığını ve sıvılaşma riski olduğunu gösterecektir.

8.1.1 Sismik Gerilme Oranının Bulunması:

Metodun uygulanması için gerekli sismik kayma gerilmesi oranını bulmak için çeşitli metodlar mevcuttur. Bu değer elde edilmesinde yaygın olarak Seed ve Idriss (1971) amprik ifadesi kullanılmaktadır. Bu yöntemde bir deprem sırasında zemin tabakası içerisinde herhangi bir noktada oluşan kayma gerilmesinin, kayma dalgasının düşey olarak yayılımı nedeniyle meydana geldiği kabul edilir. Eğer h kadar derinde yer alan bir zemin elemanı üzerinde bulunan bir zemin kütlesi rijit bir cisim olarak kabul edilirse zemin elemanı üzerindeki maksimum kayma gerilmesi aşağıdaki eşitlik ile bulunabilir.

$$(\tau_{max})_r = \frac{\gamma h}{g} a_{max} \quad (8.1)$$

a_{max} = yüzeydeki maksimum ivme

γ =zeminin birim hacim ağırlığı

g =yer çekimi ivmesi

Bununla birlikte zemin deforme olabilen bir malzeme olduğundan bu değer azaltılmalıdır.

$$(\tau_{max})_d = r_d(\tau_{max})_r \quad (8.2)$$

Eşitlikler bir arada değerlendirildiğinde deprem sırasında, zemin içerisinde herhangi bir noktada meydana gelecek maksimum kayma gerilmesi,

$$(\tau_{max}) = \frac{\gamma h}{g} a_{max} r_d \quad (8.3)$$

olarak bulunur. Bu değer tekrarlı yükleme sırasında etkiyecek ortalama kayma gerilmesi cinsinden yazılacak olursa,

$$(\tau_{av}) = 0.65 \frac{\gamma h}{g} a_{max} r_d \quad (8.4)$$

şeklinde elde edilebilir. Bu değer efektif gerilme ile normalize edilirse eşdeğer çevrimsel kayma gerilmesi elde olunur.

$$CSR_{eş} = \frac{\tau_{av}}{\sigma'_{vo}} \quad (8.5)$$

Aynı ilişki Idriss (1998) tarafından deprem büyüklüğünü dikkate alan bir düzeltme faktörü kullanılarak aşağıdaki formda sunulmuştur.

$$CSR = 0.65 \frac{a_{max}}{g} \frac{\sigma_{vo}}{\sigma'_{vo}} \frac{r_d}{MSF} \quad (8.6)$$

burada MSF deprem büyüklüğü düzeltme faktörü olup

$$MSF = 37.9(M_W)^{-1.81} \quad (M_W > 5.75' ten büyük olduğu zaman) \quad (8.7)$$

$$MSF = 1.625 \quad (M_W \leq 5.75 ise)$$

Şeklinde tanımlanmaktadır.

8.2. Sıvılaşmaya Tesir Eden Önemli Parametrelerin Seçimi:

Yapay sinir ağları ile sıvılaşma potansiyelinin tespitinde, bilgisayar programları ve gerçek arazi kayıtları kullanılmaktadır. Klasik, karmaşık matematiksel modellerin yerine, yapay sinir ağları

metodu kullanılırsa, birçok değişkene sahip karmaşık ilişkileri, kolayca değerlendirmek mümkün olmaktadır. Yapay sinir ağları ile sıvılaşma potansiyelinin tahmin çalışması, ilk olarak Anthony Goh (1994) tarafından yapılmıştır. Goh, Seed, vd (1985) çalışmalarında; sıvılaşmaya etken benzer parametreler kullanmışlardır. Bunlar; SPT değeri, ince tane oranı, D_{50} tane boyutu, eşdeğer dinamik gerilme oranı (τ_{av}/σ_0'), toplam düşey gerilme (σ_0), efektif düşey gerilme (σ_0'), deprem magnitüdü (M) ve zemin yüzeyindeki maksimum yatay deprem ivmesi (a_{max})'dır. Bu parametrelerin içinde; SPT değerleri ile ince tane oranı, sonuçları en çok etkileyen parametreler olarak verilmiştir.

Gerek teorik çalışmalar, gerekse laboratuvar araştırmaları, sıvılaşma potansiyelini etkileyen birçok faktörün olduğunu göstermiştir. Her bir faktörün kumların sıvılaşması üzerine, farklı seviyelerde etkisi bulunmaktadır.

- En fazla tesir eden birinci derecede etkin olan faktörler.
- Sıvılaşma veri tabanının dikkate alındığı faktörler
- Teorik olarak ve arazi çalışmalarıyla elde edilmesi kolay olan faktörler
- Literatürde yer alan sıvılaşma veri tabanında verilen faktörler

Bu şartlar dikkate alınarak seçilen bulanık küme giriş değişken faktörleri özetle şunlardır:

- SPT-N değeri
- Deprem Magnitüdü/- Kayma Dalgası Hız, V_s değeri
- İnce Tane Oranı
- Maksimum Yüzey İvmesi değeri
- Yer altı su seviyesi
- Zemin Derinliği
- Zemin doygun ve kuru birim hacim ağırlıkları

Tüm bu değişkenler, sıvılaşma potansiyelinin yapay sinir ağları ile tahmin edilerek modellenmesinde kullanılmıştır.

8.2.1.SPT :

SPT, N değeri, sıvılaşma veri tabanında enerji düzeltmesi ve derinlik düzeltmesi yapıldıktan sonra, çoğunlukla $(N1)_{60}$ değeri ile verilmektedir:

$$N_{60} = \frac{C_E C_B C_S C_R N_m}{0.60} \quad (8.8)$$

N_{60} = Enerji düzeltmesi yapılmış SPT değeri

N_m = SPT arazi ölçülmüş değeri

C_E = Çekiş verimi (enerji) düzeltmesi (%60 için)

C_B = 1.0 ~1.15 (delik çapı düzeltmesi)

C_S = Numune kaşığı tipi düzeltmesi (standart koruyuculu tip için $C_S=1.0$, koruyucusuz tip için $C_S=1.20$)

C_R =0.75 ~1.0 (Çubuk uzunluğu düzeltmesi: $C_R=1.0$ $L>10$ m için)

$$(N_1)_{60} = N_{60} \sqrt{\frac{101.325 kPa}{\sigma'_{vo}}} \quad (8.9)$$

8.2.2. Kayma dalgası hızı ve Deprem Magnitudü:

Arazideki kayma dalgası hızları kullanılarak, tekrarlı gerilme oranları ile ilişkili, sıvılaşma bölgesi sınırlarını veren korelasyon eğrileri literatürde mevcuttur. Kayma dalgası hızı yönteminin, SPT ve CPT tekniklerine göre üstün yönleri vardır. Çünkü SPT metodunda kum içinde yer alan iri taneli malzemeler varsa, deney çubuğu bunların üstüne geldiğinde, zemin direnci suni olarak artacağından, sonuçlarda sapmalar olabilmektedir.

Ayrıca kayma dalgası hızı tekniği, zemini mümkün olduğunca örselemeyen bir deneydir. Diğer deneylerde ise bu mümkün değildir. Kayma mukavemeti düşük olan zeminlerde, sismik dalga hızları düşük olmaktadır. Örnek vermek gerekirse, kaya zeminler boşluğu az olan ortamlar olduğundan sismik dalga hızları yüksektir. Seed (1982), kayma dalgası hızı (V_s) yaklaşık 360 m/s'nin altında olan zeminleri, sıvılaşma potansiyeli yüksek zeminler olarak kabul etmiştir.

Genel olarak $V_s > 700$ m/s ise, zemin, ana kaya (sağlam kayaç) veya pekleşmiş çok sıkı kum, çakıl, sert kildir. Böyle zeminlerde sıvılaşma riski çok düşüktür. Hatta yoktur. $300 < V_s < 700$ m/s ise zemin, ayrışmış kayaç veya sık kum, çakıl, çok katı kil ve siltli kildir. $200 < V_s < 300$ ise, zemin çok ayrışmış kayaçlar ile orta sıkı kum, çakıl, katı kil ve siltli kildir. $V_s < 200$ ise, yer altı su seviyesinin yüksek olduğu, yumuşak kalın alüvyon tabakalar, gevşek kum, yumuşak kil ve siltli kildir. Gevşek kum ve silt zeminlerde $V_s < 200$ ise sıvılaşma riski fazladır. Kayma dalgası hızı < 180 m/s olan zeminlerde SPT, N değeri genelde 15 den küçüktür (Wang at al., 2001).

Deprem magnitudü depremde çıkan enerji ile belirtildiğinden büyük bir depremde çıkan enerjide büyük olacak dolayısıyla sarsıntı siddetide büyük olacağından sıvılaşma potansiyeli artacaktır.

8.2.3. İnce dane oranının etkisi:

Sıvılaşma potansiyeli üzerinde ince dane oranını belirlenmesi amacı ile birçok araştırmacı tarafından laboratuvar ve arazide kapsamlı araştırmalar yapılmıştır. Dinamik üç eksenli basınç deneyi aletinde düşük plastisiteli ince daneler üzerinde yapılan deneyler sonucunda plastik olmayan ince dane oranı arttıkça dinamik dayanımda azalma olustugu gözlenmiştir.

Erken ve Ansal (1994) tarafından, dinamik üç eksenli deney sisteminde, örselenmemiş düşük plastisiteli siltli kum numunelerinin davranış biçimleri incelenmiştir. Kumlu zeminin içerdigi silt oranının dinamik dayanımı olumsuz etkiledigi, silt oranı arttıkça dinamik dayanımın azaldığı anlaşılmıştır. Yine Erken ve Ansal (1994) tarafından yapılan dinamik basit kesme deneylerinde, değişik oranlarda plastik ince daneli zemin kullanılmış, plastik ince dane oranının artmasıyla sıvılaşma potansiyelinin azaldığı ortaya koyulmuştur. Prakash (1981) ise çalışmalarında aşağıdaki sonuçları elde etmiştir;

- Düşük plastisiteli siltlerin sıvılaşma direnci, artan plastisite ile azalır.
 - Kil boyutlu dane oranının artması, tekrarlı gerilme oranını düşürmektedir.
 - Düşük plastisiteli siltlerin eksenel deformasyonu, kil yüzdesinin artması ile artar.
- %5 kil için, ilk sıvılaşma durumuna, %5 göçme durumundan sonra erişilir.

8.2.4. Maksimum Yüzey ivmesi değeri:

İvme depremin en can alıcı noktasıdır, çünkü ivme büyüdükçe hasarlar ve kayıplar anormal bir şekilde artmaktadır. İvme, artmasıyla danelerin yer degistirmesini ve yeraltı suyunun transfer hızını arttırarak sıvılaşmaya çok büyük bir etken olarak katılmaktadır.


8.2.5. Yeraltı Su Seviyesi

Literatür çalışmaları da göstermektedirki, sıvılaşma riski, yeraltı suyu derinliği arttıkça azalır. Yeraltı suyu derinliğini sadece Birkaç metre düşürmek bile, sıvılaşma riskini oldukça azaltabilmektedir. Yeraltı su seviyesi 3.0 m derinliğe kadar olan yerlerde sıvılaşma riski yüksek olmaktadır. Ancak, yeraltı su seviyesi 15 - 20 m derine indiğinde dahi sıvılaşma olayı görülebilmektedir.

8.2.6. Zemin Derinliği:

Zemin tabakasının derinliği arttıkça, sıvılaşmanın gelişmesi yavaşlamakta veya sıvılaşma riski azalmaktadır. Çünkü yüksek statik düşey efektif gerilme, zeminin kesmeye ve kayma

deformasyonlarına karşı olan direncini oldukça artırır. Seed, 20 m ye kadar sıvılaşmanın olabileceğini rapor etmiştir.



Şekil 8.1. Her hangi bir deprem durumunda sıvılaşmanın zor olduğu SPT değerleri (Seed ve Idriss, 1971)

Kumlu zeminler, ince taneli silt ve kil zeminlere göre daha geçirimlidir. Ancak, geçirimli bir kum zemin tabakası kalın ve geniş ise bu durumda drenaj yolu uzayacağından, bir deprem anında oluşan ani yükleme altında, bu tür zeminler drenajsız zemin tabakası gibi davranabilir ve sıvılaşma riski artar (Prakash, 1980) ve (Ishihara, 1980).

9. SIVILAŞMA POTANSİYELİ TAHMİNİNDE YAPAY SİNİR AĞININ KURULMASI:

Backpropagation algoritması, Genelleştirilmiş Delta Kuralı ve Levenberg- Marguardt metodunun adımları 'Matlab-Neural Network Toolbox-NNTool' programına girdi ve hedeflerin girilmesi, ağ tipi, girdi aralığı, öğrenme fonksiyonu, performans fonksiyonu, ara katman nöron sayılarının belirlenmesi ve eğitim, test ve uygulama verilerinin tanıtılarak ağırlıklandırma işleminin yapılmasıyla program tarafından otomatik olarak hesaplanacaktır. η ; öğrenme oranı, α ; momentum katsayısı ve diğer parametreler hazır olarak programın öngördüğü şekilde alınmıştır. Öğrenme katsayısı ağırlıkların değişim miktarını, momentum katsayısı ise ağırlık öğrenmesi esnasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlar.

9.1.Transfer fonksiyonunun secimi:

Girdi değerlerini bir algoritma ile gerçek bir çıktıya donusturen transfer fonksiyonu olarak doğrusal olmayan ve geri yayılım algoritmasında en çok kullanılan sigmoid transfer fonksiyonu kullanılmıştır. Uygulamada denenen dört ağ modelinde birinci katmanda ve ara katmanda Sigmoid transfer fonksiyonu aktif olarak kullanılmıştır.

9.2. Sıvılaşma Potansiyeli Tahmini için Yapay Sinir Ağının Eğitilmesi:

Eğitim sayısının ağın genelleştirme özelliğine büyük etkisi vardır. Ağın iyi bir genelleştirme yapabilmesi için eğitimde kullanılan verilerin yeterli olması gerekmektedir. Her ağ için 8 girdi ve 1 çıktı olmak üzere 9 adet parametre bulunmaktadır. Buna göre her ağ için 16100 adet veri oluşturulmuştur. Her bir eğitim seti için verilerin % 54'i eğitim, % 20 si ise validation ve % 26 si test değeri olarak ayrılmıştır.

Eğitim işlemi tamamlandıktan sonra mavi ile gösterilen train(eğitim) eğrisi, yeşil ile gösterilen validation (onay) eğrisi ve kırmızı ile gösterilen test eğrilerinden oluşan ortalama hata grafikleri elde edilmiştir. Bu hata grafiklerinde dikey eksen hataların karelerinin ortalaması olan MSE (Mean Square Error) değerini ve yatay eksen epok (devir) sayılarını göstermektedir. RMSE (Root Mean Square Error) ile de hataların karelerinin ortalamasının (MSE) karekökü yani hata değeri elde edilir.

Modellerde kullanılmak üzere, veriler aşağıda yazılmış denklem yardımıyla normalize edilmiştir. Eşitlik (9.1) verilerin [0-1] aralığında oluşturulmasını sağlamaktadır.

$$X_{nor} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (9.1)$$

Çizelge 9.1. YSA modelinde kullanılan girdi parametreleri sınır değerleri

Girdi Parametreleri	Minimum Değer	Maksimum Değer
Magnitüd	4	8
SPT-N	5	35
İnce Tane Oranı (%)	5	50
a_{max} (cm/sn ²)	0.1	0.5
γ_n (kN/m ³)	16	20
γ_d (kN/m ³)	18	22
Y.A.S.S. (m)	1	9
Derinlik (m)	1.5	19.5

Matlab programında; ağ tipi olarak hatayı geriye yayma özelliği bulunan ve ağ parametrelerini yenileyebilen ileri beslemeli geri yayılım (backpropagation) algoritması kullanılır. Eğitim fonksiyonu olarak; kısa sürede daha az epokla sonuca ulaşan Levenberg-Marguardt, adaptif öğrenme fonksiyonu olarak; beklenen çıktı ile gerçekleşen çıktı arasındaki farklılığı azaltmak için yapay sinir ağının elemanlarının bağlantılarının ağırlık değerlerinin sürekli değiştirilmesi ilkesine dayanarak geliştirilen ve ağın ürettiği çıktı ile üretilmesi beklenen çıktı arasındaki

hatanın karelerinin ortalamasını minimuma indirmeyi hedefleyen Genelleştirilmiş Delta Kuralı, performans fonksiyonu olarak Mean Square Error, transfer fonksiyonu olarak; geniş girdi aralığını ele alma özelliğine sahip ve yumuşak bir geçiş sağlayan Sigmoid fonksiyonu kullanılarak iki katmanlı bir ağ modeli oluşturulmuştur.

Çizelge 9.2. Sıvılaşma potansiyelini tahminde geliştirilen YSA modeli için Ağırlık ve Bias değerleri (1. Deneme)

Gizli Tabaka Nöronu No	Ağırlık Katsayıları									Bias	
	Girdi Nöronları								Çıktı Nöronları		
	M	N	İT0	a_{max}	γ_n	γ_d	YASS	Derinlik	FS	Gizli Tabaka	Çıktı Tabakası
1	-0,4536	-0,1103	0,3577	7,3444	-0,6761	0,0265	-1,8737	-0,5415	-0,4526	3,4871	2,7294
2	-3,1864	5,1215	6,7064	-3,6100	-3,0879	5,6359	5,6688	0,9876	0,1194	1,7199	
3	0,0485	13,7691	0,0629	-0,0256	-1,1855	-1,3723	-0,8910	-9,7579	-6,0985	-17,7449	
4	0,2728	3,9376	0,6705	0,0975	-0,5697	1,3574	0,6089	-7,6777	0,3561	-8,6732	
5	-2,3962	4,7945	9,8988	0,1011	-4,3487	9,3410	-4,9980	-3,3361	-0,0488	-8,9761	
6	-1,7852	-1,3714	4,1319	-1,4412	-0,2023	3,0207	0,7212	3,5949	0,1786	-4,1066	
7	0,0104	-14,2702	-0,6528	0,0910	1,2239	1,3505	0,9578	9,8119	-6,0744	18,0493	
8	-0,4416	0,2906	0,0688	-0,1429	-0,0096	-0,0648	-0,0083	-0,1282	5,6339	-1,2243	
9	-9,9317	17,4226	-1,3187	-1,1141	1,3131	0,6704	-9,0395	-0,7850	-0,0345	-8,9000	
10	-0,1314	5,0755	8,6025	-0,2991	-0,7520	-1,2604	-2,9924	-6,9716	3,3263	-9,9150	
11	6,8041	-1,7709	0,4039	3,0535	-3,1385	-9,3221	1,1665	4,2373	-0,0254	10,2808	
12	-0,0729	5,0253	9,3541	-0,2372	-0,6287	-1,3740	-3,0279	-7,1434	-3,2869	-10,3089	
13	-0,2113	10,7853	4,4854	0,0176	-0,8679	-0,9721	-0,4352	-8,0668	-1,0394	-17,5601	

Çizelge 9.3. Sıvılaşma potansiyelini tahminde geliştirilen YSA modeli için Ağırlık ve Bias değerleri (2. Deneme)

Gizli Tabaka Nöronu No	Ağırlık Katsayıları									Bias	
	Girdi Nöronları								Çıktı Nöronları		
	M	N	İT0	a_{max}	γ_n	γ_d	YASS	Derinlik	FS	Gizli Tabaka	Çıktı Tabakası
1	-0,0195	0,4283	-0,0291	-0,1129	0,0550	-0,0784	-0,0403	-1,0320	3,7835	-2,5178	-10,8119
2	1,4135	-1,9836	-1,9269	0,4038	-3,9631	4,7795	-2,0345	-1,8485	-0,1040	4,0645	
3	-0,2187	9,5314	2,3340	-0,2394	-0,8480	-0,7693	-0,8568	-6,1993	5,2255	-13,5519	
4	0,0979	-3,9878	0,4372	0,1406	1,0348	0,9602	1,0538	7,4445	3,1376	12,0965	
5	0,3042	11,6549	-5,3951	0,8446	4,0108	-7,4647	-0,3761	4,1243	-0,0809	2,5665	
6	-0,1911	0,0931	0,0774	-0,2138	-0,0221	0,0102	-0,0002	0,0803	11,1149	-0,71431	
7	-0,3928	16,0152	7,9890	-0,4910	-1,3846	-1,3858	-1,2108	-10,3279	-1,7012	-24,6646	
8	-0,6590	-1,1432	11,6270	0,0331	-0,3709	0,6120	-0,6227	3,1522	-0,2083	-8,3067	
9	0,0515	-9,1223	-0,5318	0,0694	0,7793	1,0058	0,7719	7,1400	13,4754	14,4012	
10	-2,5023	-1,5479	-0,3854	-9,0670	-0,1945	0,0874	-0,3532	0,5078	-0,3675	4,3304	
11	-0,1539	2,2385	0,9183	0,4494	2,7871	-2,3158	6,7023	1,8695	0,1552	8,0656	
12	-3,7255	-5,9283	-1,5556	0,6009	2,1121	1,4595	4,1142	-6,9648	0,1054	-4,4882	
13	0,0017	-7,4601	0,1626	0,0196	0,7987	0,9959	0,7824	7,2743	-11,8007	13,4795	

Çizelge 9.4. Sıvılaşma potansiyelini tahminde geliştirilen YSA modeli için Ağırlık ve Bias değerleri (3. Deneme)

Gizli Tabaka Nöronu No	Ağırlık Katsayıları									Bias	
	Girdi Nöronları								Çıktı Nöronları		
	M	N	İT0	a _{max}	Y _n	Y _d	YASS	Derinlik	FS	Gizli Tabaka	Çıktı Tabakası
1	0,1412	-0,6412	1,2486	-2,1349	1,0909	1,5505	-0,6630	2,0749	0,2750	-3,8583	-1,6232
2	1,7364	-1,5868	-1,3186	-1,3919	-1,4420	-1,7776	-0,1870	0,6353	0,2003	-3,2153	
3	-1,7274	2,4630	0,0437	-0,8257	0,6898	0,5957	2,0185	-0,4981	1,1985	2,5722	
4	1,8220	-1,7368	-0,7794	-1,6675	1,1272	-1,6629	-0,4157	-0,9767	-1,1340	-1,9292	
5	-0,3897	-1,2676	1,7390	1,5997	1,4920	-1,2415	1,8155	-0,6942	0,5699	1,2861	
6	-1,1874	-0,7635	1,6603	2,0016	-0,6743	-1,4386	1,5985	1,0252	1,0441	0,6431	
7	0,9345	1,5836	2,0203	-1,7866	1,2553	-0,9751	1,3052	-0,0457	-0,7917	0,0000	
8	0,1784	-0,0839	-0,6561	-1,5559	-2,2975	0,5192	1,9083	1,6754	1,0329	0,6431	
9	-0,6614	-1,5390	0,0429	-2,1853	-2,1674	1,0323	-0,8540	-0,9005	0,8353	-1,2861	
10	-0,5271	-0,8150	1,1138	0,3275	1,3696	1,8920	-1,9574	-1,8194	0,4310	-1,9292	
11	-1,6373	2,3114	-0,5794	-0,3648	0,2720	0,9006	-1,3496	1,9205	0,4069	-2,5722	
12	1,2917	-1,8450	1,6154	-1,5388	1,4787	0,5001	-1,5247	-0,2744	0,0923	3,2153	
13	-2,1942	-1,6708	-0,3705	1,4126	-1,6044	-0,5031	0,8777	-1,2452	-0,9141	-3,8583	


Çizelge 9.5. Sıvılaşma potansiyelini tahminde geliştirilen YSA modeli için Ağırlık ve Bias değerleri (4. Deneme)

Gizli Tabaka Nöronu No	Ağırlık Katsayıları									Bias	
	Girdi Nöronları								Çıktı Nöronları		
	M	N	İT0	a _{max}	Y _n	Y _d	YASS	Derinlik	FS	Gizli Tabaka	Çıktı Tabakası
1	-0,4324	0,2287	0,0902	-0,1624	-0,0310	0,0228	0,0704	-0,1105	5,2059	-0,7782	-12,5347
2	0,0459	-13,1280	-1,8239	0,1161	0,9563	1,3980	1,4241	9,0305	8,1391	17,986	
3	0,2377	6,2546	1,9242	-0,0004	0,3547	0,2727	0,6048	-11,729	-5,5295	-16,551	
4	0,2172	1,0760	0,9241	-0,4793	1,6009	-2,1184	-1,7314	3,0572	0,2066	-2,3268	
5	-0,0734	13,8319	2,1740	-0,1736	-1,0839	-1,3966	-1,5600	-9,2223	7,6527	-18,646	
6	0,0934	-9,8280	-8,7851	0,3053	0,7816	0,9606	1,7990	8,6750	7,7517	16,072	
7	1,1330	15,2138	-7,9670	9,5616	-0,2488	-1,4812	-0,3842	-6,7142	-0,1021	-5,6597	
8	0,0760	4,8503	2,1318	-0,1086	0,4707	-1,2126	-0,5184	-5,9528	0,3636	-4,5994	
9	3,1804	7,4290	-12,333	2,0762	-6,8476	3,7556	-3,0265	10,064	0,0770	-2,2846	
10	0,1865	-0,9848	-0,9982	-17,902	1,5803	0,0028	5,1293	1,4765	0,3732	-8,7907	
11	0,1499	-10,4110	-8,8312	0,3460	0,9131	0,9298	1,9061	9,0997	-7,4345	16,664	
12	0,2032	7,2385	2,1340	-0,0383	0,4318	0,2568	0,6347	-12,955	5,0845	-18,056	
13	-9,1805	-6,4292	2,1075	-6,5069	-4,3553	10,273	6,1235	12,046	-0,0617	4,7884	


10. SONUÇLAR:

10.1. MODEL KURULUMLARI:

YSA modelinden elde edilen sıvılaşma potansiyeli sonuçları Çizelge 10.1'den Çizelge 10.4'e kadar dört farklı ağırlık ve bias değerleri için karşılaştırılmıştır. Gözlemlendiği gibi programdan elde edilen sıvılaşma potansiyeli güvenlik değerleri ile YSA ile elde edilen sıvılaşma potansiyeli güvenlik değerleri oldukça uyumludur.



Şekil 10.1. Çalışmada kullanılan YSA'nın Yapısı



Şekil 10.2. Çalışmada kullanılan YSA'nın Yapısı ve parametreler

Çizelge 10.1. Sıvılaşma potansiyeli güvenlik sayısı tahmininde kullanılan değişkenlere göre program ve YSA ile elde edilen değerlerin karşılaştırması.(Eğitim -1. Deneme)

Kullanılan Değişkenler								Sıvılaşma G.S.	
M	N	İT0	amax	yn	yd	YASS	Derinlik	Program	YSA
4	5	5	0,3	16	18	1	4,5	0,9970	1,437
4	5	5	0,3	16	18	1	7,5	0,9316	1,479
4	5	5	0,3	16	18	5	1,5	1,7325	1,963
4	5	5	0,3	16	18	5	4,5	1,6536	1,854
4	5	5	0,3	16	18	5	7,5	1,3515	1,789
4	5	5	0,3	16	22	9	13,5	1,4475	1,962
4	5	5	0,3	16	22	9	16,5	1,4956	1,950
4	5	5	0,3	16	22	9	19,5	1,5779	1,941
4	5	5	0,3	20	22	5	13,5	1,2501	1,685
4	5	5	0,3	20	22	5	16,5	1,3317	1,675
4	5	5	0,3	20	22	5	19,5	1,4335	1,682
4	5	5	0,3	20	22	9	1,5	1,7012	2,260
4	5	5	0,3	20	22	9	4,5	1,5995	2,159
4	5	5	0,5	16	20	1	13,5	0,6050	0,155
4	5	5	0,5	16	20	5	4,5	0,9921	1,301
4	5	5	0,5	16	20	5	7,5	0,8117	1,258
4	5	20	0,1	16	22	5	10,5	5,4872	5,337
4	5	20	0,1	16	22	5	13,5	5,4799	5,502
4	5	20	0,1	20	22	9	7,5	6,9798	5,492
4	5	20	0,1	20	22	9	10,5	6,6374	6,461
4	5	20	0,3	16	18	1	1,5	2,0619	1,724
4	5	20	0,3	16	18	1	4,5	1,4607	1,586
4	5	20	0,3	16	18	1	7,5	1,3668	1,569
4	5	20	0,3	16	18	1	10,5	1,3523	1,644
4	15	5	0,1	16	20	9	10,5	8,1225	7,035
4	15	5	0,1	16	20	9	13,5	7,3725	8,398
4	15	5	0,1	16	22	1	10,5	5,6202	2,734
4	15	5	0,1	16	22	1	13,5	5,5332	5,876
4	15	5	0,1	16	22	1	16,5	5,7513	6,055
4	15	5	0,1	16	22	1	19,5	6,0300	6,298
4	15	5	0,1	16	22	5	1,5	10,8294	10,022
4	15	50	0,5	16	22	1	10,5	1,7989	1,188
4	15	50	0,5	16	22	1	13,5	1,7896	1,790
4	15	50	0,5	16	22	1	16,5	1,8797	1,848
6	5	35	0,1	16	18	9	16,5	2,7124	2,638
6	5	35	0,1	16	18	9	19,5	2,8245	2,733
6	5	35	0,1	18	20	1	1,5	2,6029	2,284
6	5	35	0,1	18	20	1	4,5	1,9150	2,158
6	5	35	0,1	18	20	1	7,5	1,8016	2,185
6	5	35	0,1	16	22	1	4,5	1,9598	1,900
6	5	35	0,1	16	22	1	7,5	1,8606	1,769
8	5	20	0,5	16	18	1	1,5	0,2098	0,324
8	5	20	0,5	16	18	1	4,5	0,1486	0,299
8	5	20	0,5	16	18	1	7,5	0,1391	0,288
8	5	20	0,5	16	18	1	10,5	0,1376	0,289
8	5	20	0,5	16	18	5	10,5	0,1827	0,354
8	5	20	0,5	16	18	5	13,5	0,1797	0,288
8	5	20	0,5	16	18	5	16,5	0,1885	0,314
8	5	20	0,5	16	18	5	19,5	0,2003	0,320
8	15	5	0,3	18	20	9	19,5	0,4123	0,482
8	15	5	0,3	16	20	1	1,5	0,5056	0,424
8	15	5	0,3	16	20	1	4,5	0,3598	0,398
8	15	5	0,3	16	20	1	7,5	0,3315	0,393

Çizelge 10.2. Sıvılaşma potansiyeli güvenlik sayısı tahmininde kullanılan değişkenlere göre program ve YSA ile elde edilen değerlerin karşılaştırması.(Eğitim -2.Deneme)


Kullanılan Değişkenler								Sıvılaşma G.S.	
M	N	İT0	amax	yn	yd	YASS	Derinlik	Program	YSA
4	5	5	0,1	18	20	5	13,5	3,676	3,853
4	5	5	0,1	18	20	5	16,5	3,888	3,727
4	5	5	0,1	18	20	9	13,5	4,346	4,825
4	5	5	0,1	18	20	9	16,5	4,492	4,785
4	5	5	0,1	18	20	9	19,5	4,726	4,866
4	5	5	0,3	16	18	9	13,5	1,444	1,481
4	5	5	0,3	18	20	1	13,5	1,012	1,224
4	5	5	0,3	18	20	1	16,5	1,103	1,139
4	5	5	0,3	18	22	5	7,5	1,354	1,395
4	5	5	0,3	20	22	5	13,5	1,250	1,251
4	5	20	0,1	16	18	5	7,5	5,986	5,765
4	5	20	0,1	16	18	5	10,5	5,386	5,374
4	5	20	0,1	16	18	9	7,5	7,239	7,205
4	5	20	0,1	16	20	9	10,5	6,773	6,764
4	5	20	0,1	16	20	9	13,5	6,429	6,767
4	5	20	0,1	16	20	9	16,5	6,602	6,507
6	5	20	0,1	16	18	9	10,5	2,403	2,560
6	5	20	0,1	16	18	9	13,5	2,274	2,423
6	5	20	0,1	18	20	1	10,5	1,529	1,782
6	5	20	0,1	18	20	1	13,5	1,593	1,723
6	5	20	0,1	18	20	1	16,5	1,737	1,724
6	5	20	0,3	16	20	5	13,5	0,637	0,667
6	5	20	0,3	16	20	5	16,5	0,674	0,659
6	5	35	0,3	18	20	1	19,5	0,739	0,779
6	5	35	0,3	18	20	5	1,5	1,041	0,905
6	5	35	0,3	18	20	5	4,5	0,993	0,854
6	5	35	0,3	18	20	5	7,5	0,828	0,820
6	5	35	0,3	16	22	5	1,5	1,049	1,003
6	5	35	0,3	16	22	5	4,5	1,009	0,965
6	5	50	0,1	16	18	1	7,5	1,696	1,624
6	5	50	0,1	16	18	1	10,5	1,678	1,515
8	5	35	0,3	16	18	1	19,5	0,330	0,394
8	5	35	0,3	18	20	1	19,5	0,354	0,413
8	5	35	0,3	18	20	5	1,5	0,498	0,477
8	5	35	0,3	18	20	5	4,5	0,475	0,455
8	5	50	0,1	16	22	1	7,5	0,891	1,089
8	5	50	0,1	16	22	5	4,5	1,449	1,437
8	15	5	0,1	16	22	9	4,5	1,637	1,635
8	15	5	0,1	16	22	9	7,5	1,539	1,490
8	15	5	0,1	16	22	9	10,5	1,369	1,408
8	15	5	0,1	16	22	9	13,5	1,236	1,346
8	15	20	0,1	16	18	1	10,5	1,253	1,317
8	15	20	0,1	16	18	5	7,5	1,792	1,523
8	15	20	0,1	16	18	5	10,5	1,581	1,432
8	15	20	0,1	16	18	5	13,5	1,503	1,350
8	15	20	0,1	16	18	5	16,5	1,531	1,275
8	15	20	0,1	16	18	5	19,5	1,584	1,209
8	15	20	0,1	16	18	9	1,5	2,456	2,104

Çizelge 10.3. Sıvılaşma potansiyeli güvenlik sayısı tahmininde kullanılan değişkenlere göre program ve YSA ile elde edilen değerlerin karşılaştırması.(Eğitim -3.Deneme)


Kullanılan Değişkenler								Sıvılaşma G.S.	
M	N	İT0	amax	yn	yd	YASS	Derinlik	Program	YSA
4	5	5	0,1	20	22	9	7,5	4,710	4,786
4	5	5	0,1	20	22	9	10,5	4,479	4,709
4	5	5	0,5	16	20	1	13,5	0,605	0,622
4	5	5	0,5	16	20	5	4,5	0,992	1,058
4	5	5	0,5	16	22	1	13,5	0,631	0,665
4	5	5	0,5	16	22	1	16,5	0,691	0,629
4	5	20	0,1	18	20	5	4,5	7,202	7,206
4	5	20	0,1	16	22	1	13,5	4,679	4,828
4	5	20	0,1	16	22	5	7,5	6,003	6,167
4	5	20	0,1	16	22	5	10,5	5,487	6,422
4	5	20	0,3	16	18	9	4,5	2,439	2,486
4	5	20	0,3	16	18	9	7,5	2,413	2,350
4	5	20	0,3	16	18	9	10,5	2,261	2,337
4	5	20	0,3	16	18	9	13,5	2,140	2,409
4	5	20	0,3	16	20	5	4,5	2,439	2,419
6	5	20	0,1	16	18	1	7,5	1,452	1,765
6	5	20	0,1	16	18	1	10,5	1,437	1,725
6	5	20	0,1	18	20	9	19,5	2,471	2,479
6	5	20	0,1	16	20	1	1,5	2,205	2,550
6	5	35	0,3	16	18	9	7,5	0,998	1,205
6	5	35	0,3	16	18	9	10,5	0,935	1,154
6	5	35	0,3	16	20	9	19,5	0,953	1,008
6	5	35	0,3	16	22	1	1,5	0,863	1,094
6	5	50	0,1	18	20	9	13,5	2,662	2,820
6	5	50	0,1	18	20	9	16,5	2,747	2,755
6	5	50	0,1	18	20	9	19,5	2,883	2,955
6	5	50	0,1	16	20	1	1,5	2,575	2,633
6	5	50	0,3	16	18	9	16,5	0,904	0,997
6	5	50	0,3	16	18	9	19,5	0,941	1,102
6	15	20	0,5	16	18	9	10,5	0,797	0,792
6	15	20	0,5	16	18	9	13,5	0,733	0,754
8	5	20	0,3	18	20	9	13,5	0,364	0,396
8	5	20	0,3	18	20	9	16,5	0,376	0,381
8	5	20	0,3	18	20	9	19,5	0,394	0,394
8	5	20	0,3	20	22	9	19,5	0,400	0,395
8	5	35	0,3	16	20	1	16,5	0,323	0,351
8	5	35	0,3	16	20	1	19,5	0,353	0,347
8	5	35	0,5	18	22	1	16,5	0,203	0,283
8	5	35	0,5	18	22	1	19,5	0,222	0,282
8	15	5	0,1	18	22	9	10,5	1,320	1,120
8	15	5	0,1	18	22	9	13,5	1,209	1,010
8	15	5	0,1	18	22	9	16,5	1,202	0,998
8	15	5	0,3	16	22	9	7,5	0,513	0,537
8	15	5	0,3	16	22	9	10,5	0,456	0,467
8	15	5	0,3	18	22	1	4,5	0,366	0,396
8	15	5	0,3	18	22	1	7,5	0,335	0,354
8	15	5	0,3	18	22	1	10,5	0,318	0,335
8	15	5	0,3	20	22	1	10,5	0,318	0,324

Çizelge 10.4. Sıvılaşma potansiyeli güvenlik sayısı tahmininde kullanılan değişkenlere göre program ve YSA ile elde edilen değerlerin karşılaştırması.(Eğitim -4.Deneme)


Kullanılan Değişkenler								Sıvılaşma G.S.	
M	N	İT0	amax	yn	yd	YASS	Derinlik	Program	YSA
4	5	5	0,1	20	22	5	16,5	3,995	4,303
4	5	5	0,1	20	22	5	19,5	4,301	4,287
4	5	5	0,3	20	22	5	19,5	1,434	1,456
4	5	5	0,5	20	22	9	16,5	0,908	1,206
4	5	5	0,5	20	22	9	19,5	0,963	1,140
4	5	20	0,1	18	20	1	10,5	4,317	4,689
4	5	20	0,1	18	20	1	13,5	4,498	4,636
4	5	20	0,1	18	20	1	16,5	4,905	4,867
4	5	20	0,1	18	20	1	19,5	5,359	5,368
4	5	20	0,3	16	18	5	7,5	1,995	1,953
4	5	20	0,3	16	18	5	10,5	1,795	1,810
4	5	20	0,3	16	18	5	13,5	1,766	1,721
4	5	20	0,3	16	18	9	4,5	2,439	2,512
4	5	20	0,3	16	18	9	7,5	2,413	2,307
4	5	20	0,3	16	18	9	10,5	2,261	2,129
4	5	20	0,3	16	20	1	1,5	2,075	2,086
4	5	20	0,3	16	20	9	7,5	2,413	2,432
4	5	20	0,3	16	20	9	10,5	2,258	2,243
4	5	20	0,3	16	20	9	13,5	2,143	2,124
6	5	20	0,3	18	20	5	4,5	0,850	0,838
6	5	20	0,3	18	20	5	7,5	0,709	0,777
6	5	20	0,3	16	22	5	19,5	0,738	0,754
6	5	20	0,3	20	22	5	13,5	0,656	0,679
6	5	20	0,3	20	22	5	16,5	0,698	0,664
6	5	20	0,1	16	18	9	7,5	2,564	2,544
6	5	20	0,1	16	18	9	10,5	2,403	2,357
6	5	20	0,1	16	18	9	13,5	2,274	2,201
6	5	20	0,1	18	20	1	10,5	1,529	1,849
6	5	20	0,1	18	20	1	13,5	1,593	1,918
6	5	20	0,1	18	20	5	13,5	1,930	1,921
6	5	20	0,1	16	20	5	1,5	2,695	2,706
6	5	20	0,1	16	20	5	4,5	2,592	2,484
6	5	20	0,1	18	22	1	1,5	2,239	2,249
6	5	20	0,3	18	20	5	4,5	0,850	0,838
6	5	20	0,3	18	20	5	7,5	0,709	0,777
8	15	20	0,1	16	18	1	1,5	2,020	2,002
8	15	20	0,1	16	18	1	4,5	1,409	1,575
8	15	20	0,1	16	18	1	7,5	1,303	1,550
8	15	20	0,1	18	20	1	19,5	1,426	1,412
8	15	20	0,1	16	20	1	7,5	1,339	1,454
8	15	20	0,1	16	20	1	10,5	1,285	1,292
8	15	20	0,3	16	18	9	10,5	0,636	0,656
8	15	20	0,3	16	18	9	13,5	0,585	0,586
8	15	20	0,3	16	18	9	16,5	0,583	0,561
8	15	20	0,3	16	18	9	19,5	0,593	0,569
8	15	20	0,3	16	20	1	1,5	0,676	0,697
8	15	20	0,3	16	22	1	16,5	0,455	0,467
8	15	20	0,3	16	22	1	19,5	0,481	0,459




a) Eğitim Verileri (Deneme-1)



b) Eğitim Verileri (Deneme-2)




c) Eğitim Verileri (Deneme-3)




d) Eğitim Verileri (Deneme-4)


Şekil 10.3. Sıvılaşma potansiyeli güvenlik sayısı tahmininde, program ve YSA ile elde edilen değerlerin 4 deneme için ayrı ayrı karşılaştırması



a) Eğitim Verileri (Deneme-4)



b) Test Verileri (Deneme-4)



c) Doğrulama Verileri (Deneme-4)

Şekil 10.4. Sivilleşme potansiyeli güvenlik sayısı tahmininde, program ve YSA ile elde edilen değerlerin 4. deneme için eğitim-test ve doğrulama karşılaştırması

10.2. MODEL KARŞILAŞTIRMASI VE DUYARLILIK ANALİZİ:

Kurulan modellerin karşılaştırılması için bazı tahmin değerlendirme analizleri yapılmıştır. Tahmin doğruluğunun ölçülmesinde öncelikli konu bir kayıp fonksiyonunun belirlenmesidir. Kayıp fonksiyonunun belirlenmesi, aynı zamanda uygun bir doğruluk ölçüsünün belirlenmesi anlamına geldiğinden önemlidir. Kullanılacak doğruluk ölçüsünün seçimi için yapılan analizin konusu ve amacı önem kazanmaktadır. Tahmin doğruluğunu ölçmek için kullanılabilecek birçok ölçüt bulunmaktadır.

Tahmini değerler ile gerçekleşen değerler arasındaki sapma genellikle $e(t) = x(t) - f(t)$ şeklindeki basit hata terimi tez alınarak hesaplanır. Bu doğruluk ölçütlerinin temelini, sapmayı ölçmek için kullanılan Ortalama Hata (Mean Error, ME) kavramı oluşturur ve;

$$ME = \frac{1}{n} \sum e(t) \quad (10.1)$$

denklemleri ile ifade edilir. Ortalama Hata kavramını temel alan ve yaygın olarak kullanılan diğer ölçütler arasında Ortalama Hata Kareleri (Mean Squared Error, MSE), Ortalama Hata Kareleri Kökü (Root Mean Squared Error, RMSE) ve Ortalama Mutlak Hata (Mean Absolute Error, MAE) sayılmaktadır. Bu ölçütlerin formülleri aşağıda verilmiştir.

$$MSE = \frac{1}{n} \sum [e(t)]^2 \quad (10.2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum [e(t)]^2} \quad (10.3)$$

$$MAE = \frac{1}{n} \sum |e(t)| \quad (10.4)$$

Yapay sinir ağlarında duyarlılık analizi, olaya etki eden bağımsız değişkenlerin etkinlik derecesinin araştırılmasıdır. Bu konuda akla ilk gelen, girdi hücrelerini, gizli hücrelere bağlayan ağırlıklardan değeri sıfıra yakın olanlara sahip girdi sinir hücrelerinin az öneme sahipken; mutlak değerce büyük değerlere sahip olan girdi hücrelerinin öneminin de büyük olacağı doğrultusundadır.

Çizelge 10.5. Duyarlılık analizi ile parametrelerin etkinliğinin ölçülmesi

Kullanılan Değişkenler (%)								
Deneme No.	M	SPT-N	İT0	a_{max}	γ_n	γ_d	YASS	derinlik
1	0,79	47,18	7,97	1,99	3,96	4,28	3,33	30,51
2	1,35	44,78	7,69	2,67	4,20	5,26	3,11	30,93
3	1,47	44,47	7,88	2,34	3,93	5,41	3,75	30,74
4	2,35	35,48	12,62	2,43	4,66	3,67	14,93	23,87
Ortalama	1,49	42,98	9,04	2,36	4,19	4,66	6,28	29,01
Sıralama	8	1	3	7	6	5	4	2

Duyarlılık analizinde sıvılaşma potansiyelini hesaplayan program çıktısı ile YSA ile elde edilen model dört farklı kez denenmiş, bu denemelerden alınan ağırlık katsayılarının ortalaması kullanılarak duyarlılık analizi yapılmıştır. Parametrelerin önemi ise bu analiz ile anlaşılmıştır.

Çizelge 10.6. Performans parametreleri

Model	Veri	R^2	MAE	VAF(%)
YSA	Eğitim	97.08	0.02	97.08
	Test	94.26	0.03	94.26
	Doğrulama	96.51	0.03	96.51

KAYNAKLAR

1. Abu-Kiefa, M.A. 1998. General regression neural networks for driven piles in cohesionless soils, *Journal of Geotechnical and Geoenvironmental Engineering*, 124(12), 1177-1185.
2. Ahmad, I., El Naggat, M.H. and Khan, A.N., 2007, Artificial neural network application to estimate kinematic soil pile interaction response parameters. *Soil Dynamics and Earthquake Engineering*, Vol. 27, pp. 892-905.
3. Anderson, J.A., 1983,. Cognitive and psychological computation with neural models. *IEEE Transactions on Systems, Man and Cybernetics*, 13.
4. Arslan, A., İnce, R., 1996, The Neural Network Approximation to The Size Effect in Fracture of Cementitious Materials, *Engineering Fracture Mechanics*, Vol 54, No 2, 249-261
5. Baykasoğlu, A., Çevik, A., Özbakır, L., Kulluk, S., 2009. Generating prediction rules for liquefaction through data mining. *Expert Systems with Applications* 36 (2009) 12491–12499.
6. Chan, W.T., Chow, Y.K., Liu, L.F. 1995. Neural network: An alternative to pile driving formulas, *Computers and Geotechnics*, 17, 135-156
7. Chen, C.J., and Juang, C.H., 2000, Calibration of SPT- and CPT-based liquefaction evaluation methods. *In* Innovations and applications in geotechnical site characterization. *Edited by* P.W. Mayne and R. Hryciw. American Society of Civil Engineers, Geotechnical Special Publication 97, pp. 49–64.
8. Chiru-Danzer M, Juang C.H., Christopher R.A., Suber J., 2001, Estimation of liquefaction-induced horizontal displacements using artificial neural networks *Canadian Geotechnical Journal*, 38:(1) 200-207, 10.1139/t00-087.
9. Cıvlek, Ö., Y. Calayır, 2007, İnce Dikdörtgen Plakların Titreşim Frekanslarının Yapay Sinir Ağları Yaklaşımı ile Tahmini, *İMO Teknik Dergi*, 2007 4161 -4176, Yazı 275
10. Das S. K. and Basudhar P. K., 2005, "Prediction of coefficient of lateral earth pressure using artificial neural networks," *The Electronic Journal of Geotechnical Engineering*, vol. 10, pp. 1–5
11. Das, S.K., Basudhar, P.K. 2006. Undrained lateral load capacity of piles in clay using artificial neural network, *Computers and Geotechnics*, 33, 454–459.

12. Demir, Y.K., 1997, Yapay Sinir Ağları ile Ulaştırma Taleplerinin Modellenmesi, İTÜ Fen Bilimleri Enstitüsü, Yüksek Lisans tezi, İstanbul
13. Efe, M., Kaynak, O., 2000, Yapay Sinir Ağları ve Uygulamaları (1. Basım), Boğaziçi Üniversitesi, 148 s, İstanbul
14. Elmas, Çetin. 2003, *Yapay Sinir Ağları*. Ankara: Seçkin Yayıncılık.
15. Erkoç, M., 2008, Yapay zeka perspektifinde eğitime yönelik uzman sistem modellemesi. Yüksek lisans tezi, Marmara Üniversitesi Eğitim Bilimleri Enstitüsü.
16. Fu, L.M. (1994), *Neural Networks in Computer Intelligence*, McGraw-Hill, OH.
17. Gardner, H., 1993, *Multiple Intelligence, the theory in practice*. New York: Basic Books.
18. Goh, A. T. C. (1996) Neural network modeling of CPT seismic liquefaction data. *Journal of Geotechnical Engineering*, American Society of Civil Engineers, USA, vol. 122(1), 70-73.
19. Goh, A. T. C., 1994, Seismic liquefaction potential assessed by neural networks. *Journal of Geotechnical Engineering*, American Society of Civil Engineers, USA, vol. 120 (9), 1467-1480.
20. Goh, A. T. C., 1995, Modeling soil correlations using neural networks. *Journal of Computing in Civil Engineering*, American Society of Civil Engineers, USA, vol. 9.
21. Goh, A.T.C. 1994a. Nonlinear modelling in geotechnical engineering using neural networks, *Australian Civil Engineering Transactions*, CE36(4), 293-297.
22. Goh, A.T.C. 1995a. Back-propagation neural networks for modeling complex systems, *Artificial Intelligence in Engineering*, 9, 143-151.
23. Goh, A.T.C. 1995b. Empirical design in geotechnics using neural networks, *Geotechnique*, 45(4), 709-714.
24. Goh, A.T.C. 1996b. Pile driving records reanalyzed using neural networks, *Journal of Geotechnical Engineering*, 122(6), 492- 495.
25. Goh, A.T.C. and F.H. Kulhawy, 2003. Neural network approach to model the limit state surface for reliability analysis. *Can. Geotech. J.*, 40: 1235-1244.

26. Goh, A.T.C., 2002, Probabilistic neural network for evaluating seismic liquefaction potential. *Canadian Geotechnical Journal*, Canada, vol. 39(1) 219-232.
27. H. Ardalan; A. Eslami; N. Nariman-Zadeh, 2009, *Computers and Geotechnics*, 36 (4), pg. 616-625
28. Hanna, A.M., Morcous, G., Helmy, M. 2004. Efficiency of pile groups installed in cohesionless soil using artificial neural networks, *Canadian Geotechnical Journal*, 41, 1241-1249.
29. Harvey, R. L., 1994, *Neural Network Principles*, Prentice-Hall, Inc., New Jersey
30. Haykin S., 1994, *Neural Networks: A Comprehensive Foundation*, ISBN 0-02-352761-7, Macmillan College Publishing Company, New York, USA,
31. Haykin, S., 1994, *Neural Networks*. Macmillan College Publishing Company, Inc, New York
32. Hopfield, J., 1982, "Neural Networks and Physical Systems with Emergent Collective Computational Abilities", *Proceedings of the National Academy of Sciences*, Vol. 79, pp. 2554–2558.
33. Hopfield, JJ., 1982, Neural networks and physical systems with emergent collective computational abilities., In *Proc. of National Academy of Sciences*, 79: 2554 58,
34. <http://geotech.civeng.okstate.edu/ejge/ppr9909/index.html>
35. Huang, C. C. and C. H. Loh, 2001, "Nonlinear identification of dynamic systems using neural
36. Ismail ve D.S. Jeng., 2011, *Engineering Applications of Artificial Intelligence*, Volume 24 Issue 5
37. Jang R., Sun, C.T. ve Mizutani, E., 1997, *Neurofuzzy and soft computing*, Prentice-Hall, Upper Saddle River 1997, 245.
38. Juang, C.H. and Chen, C.J., 1999, CPT-based liquefaction evaluation using artificial neural networks, *Computer-Aided Civil and Infrastructure Engineering*, 14(3), 221-229.
39. Juang, C.H., Chen, C.J., Jiang, T., and Andrus, R.D., 2000b, Risk-based liquefaction potential evaluation using standard penetration tests. *Canadian Geotechnical Journal*, 37: 1195–1208.

40. Juang, C.H., Chen, J.C., Tang, W.H., and Rosowsky, D.V., 2000a, CPT-based liquefaction analysis. Part 1: Determination of limit state function. Part 2: Reliability for design. *Géotechnique*, 50(5): 583–599.
41. Kaltakçı, M.Y., Dere, Y., 1997, “Yapay Sinir Ağı Uygulamalarının İnşaat Mühendisliğinde Kullanımı”, Bildiri, Prof. Dr. A. Rifat Yazar Sempozyumu
42. Kambekar, A. R., Deo, M. C. 2003. Estimation of pile group scour using neural networks. *Applied Ocean Research*, 25, 225-234.
43. Kang H:T,Yoon C:J,, 1994, “Neural networks approaches to aid simple truss design problems”, *Microcomputers in Civil Engineering*, 9, 211#218.
44. Kang, H. T., Yoon, C.J., 1994, Neural network approches to aid simple truss design problems.
45. Kim CY, Bae GJ, Hong SW, Park CH, Moon HK, Shin HS, 2001,. Neural network based prediction of ground surface settlements due to Tunneling. *J. Comp. Geotech.*, 28: 517–547.
46. Kim, B.T., and Kim, Y.S. 2002., Lateralload – deflection Modeling of groups of piles using artificial neural networks. *In Deep Foundations: Proceedings of the International Deep Foundations Congress*, Orlando, Fla., 14–16
47. Koçer, D., 2006, Zeka nedir?. *Bilim ve Aklın Aydınlığında Eğitim*. 72 (6).
48. Kohonen, T., 1977, *Associative memory: a system-theoretical approach*, Springer-Verlag, New York., .
49. Kröse B., van der Smagt P., 1996, *An introduction to Neural Networks*
50. Krycha Karl A., Wagner Udo, 1999, “Applications of Artificial Neural Networks in Management Science: A Survey”, *Journal of Retailing and Consumer Services*, Vol. 6, p. 185 – 203.
51. Lee, I.M., Lee, J.H. 1996. Prediction of pile bearing capacity using artificial neural networks. *Computers and Geotechnics*, 18(3), 189-200.
52. Maren A, Harston C and. Pap R., 1990, *Handbook of Neural Computinff Applications*, Academic Press, London ISBN 0-12-471260-6.
53. *Microcomputers in civil engineering*, Vol 9.

54. Miller, G. A., 1956. The magical number seven, plus or minus two: Some limits on our capacity for processing information. *Psychological Review*, 63, 81-97.
55. Mohamedzein Y. E. A., Ibrahim R, and Alsanosi A., 2007, "Prediction of swelling pressure of expansive soils using Neural Networks", *Expansive Soils: Recent advances in characterization and treatment*, Ed. Al2Rawas, A.A.,and Goosen,F.A., Chapter 17.
56. Nawari N.O.; Liang, R. & Nusairat, J., 1999, Artificial intelligence techniques for the design and analysis of deep foundations, *Electron. J. Geotech. Eng.*,
57. networks," *Computer-Aided Civil and Infrastructure Engineering*, 16, 28-41.
58. Öztemel E., 2003. Yapay Sinir Ağları. Papatya Yayıncılık, 28-110s, 232s. İstanbul
59. Rojas, R., 1996, Neural networks, A systematic introduction., Springer, Germany
60. Sağıroğlu, Ş., Beşdok, E. ve Erler, M., 2003, *Mühendislikte yapay zeka uygulamaları I- yapay sinir ağları*. Kayseri, Ufuk Yayınevi.
61. Sağıroğlu, Ş., Beşdok, E., ve Erler M., 2003, *Mühendislikte Yapay Zeka Uygulamaları- 1 Yapay Sinir Ağları*.Ufuk Kitap Kirtasiye-Yayıncılık, Kayseri
62. Saraç, T., 2004, Yapay Sinir Ağları, Basılmamış Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Bölümü Anabilim Dalı, Ankara.
63. Shahin, M.A., Jaksa, M.B. 2005a. Neural network prediction of pullout capacity of marquee ground anchors, *Computers and Geotechnics*, 32(3), 153-163.
64. Shahin, M.A., Jaksa, M.B., Maier, H.R. 2005a. Neural network based stochastic design charts for settlement prediction, *Canadian Geotechnical Journal*, 42(1), 110-120.
65. Shahin, M.A., Jaksa, M.B., Maier, H.R. 2005b. Stochastic simulation of settlement prediction of shallow foundations based on a deterministic artificial neural network model. *Proc. Int. Congress on Modelling and Simulation, MODSIM 2005, Melbourne (Australia)*, 73-78
66. Sivakugan, N., Eckersley, J.D., and Li, H. 1998. Settlement predictions using neural networks, *Australian Civil Engineering Transactions*, CE40, 49-52.

67. Suwansawat, S., Einstein, H. H., 2006, "Artificial Neural Network for Predicting the Maximum Surface Settlement Caused by EPB Shield Tunnelling," *Tunnelling and Underground Space Technology*, 21, 133-150.
68. Teh, C.I., Wong, K.S., Goh, A.T.C., Jaritngam, S. 1997. Prediction of pile capacity using neural networks, *Journal of Computing in Civil Engineering*, 11(2), 129-138.
69. Tektaş, M., 2005, yapay zeka teknolojilerinin endüstrideki uygulamaları. Marmara üniversitesi te
70. nik bilimler meslek yüksek okulu elektrik programı tezi,8-10.
71. Turing, A., 1950, Computing machinery and intelligence. *Mind*, 59(236), 433-460
72. Uçarlar, A.,2006,. bir uçak kanadının sağladığı toplam taşıma değerini ortam ve uçuş şartlarına bağlı olarak değişiminin yapay sinir ağları metodu ile programlanması. Yüksek lisans tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü.
73. Ural, D. and Saka, H., 1998, "Liquefaction Assessment by Artificial Neural Networks", *Electronic Journal of Geotechnical Engineering*, (<http://www.ejge.com/1998/JourTOC3.htm>), Vol.3.
74. Wang J., Rahman M.S., 2002, Fuzzy neural network models for liquefaction prediction *Soil Dynamics and Earthquake Engineering*, 22 (8), pp. 685–694
75. Wang, J., and Rahman, M.S., 1999, "A neural network model for liquefaction-induced horizontal ground displacement," *Soil Dynamics and Earthquake Engineering*, Vol 18, No 8, pp 555-568.
76. Weizenbaum, J., 1966,. ELIZA--A computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), 36-45
77. Yeh, Y. C., 1993, Implementation and Application of Artificial Neural Network, Ru Lin Publication, 957499628X, Taiwan.
78. Yurtoğlu, H., 2005, Yapay sinir ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği. Uzmanlık Tezi, Yayın No: Dpt: 2683, Ankara.

79. Zahaby K.M., Rahman M.S., 1996, Non-statistical uncertainties in liquefaction risk assessment. Proceedings of uncertainty in geologic environment; from theory to practice, ASCE. Geotech Spec Publ;58:1068–82.