

SIVILAŞMAYA KARŞI GÜVENLİK KATSAYISININ YAPAY SİNİR AĞLARI İLE TAHMİN EDİLMESİ: DENİZLİ-GÜMÜŞLER ÖRNEĞİ

Gulmustafa ŞEN¹, Erdal AKYOL¹ ve Mahmut FIRAT²

¹Pamukkale Üniversitesi Mühendislik Fakültesi Jeoloji Mühendisliği Bölümü, DENİZLİ

²Pamukkale Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü, DENİZLİ

ÖZET: Depremlerin neden olduğu önemli zemin davranışlarından biri de sıvılaşmadır. Sıvılaşma, suya tamamen doygun kohezyonsuz zeminlerin deprem etkisi ile zeminin içindeki boşluk suyu basıncının artması ve zeminin taşıyıcı özelliğini kaybetmesi sonucu meydana gelir. Sıvılaşma Potansiyeli İndeksi (SPI), sıvılaşmanın yüzeydeki şiddetini göreceli olarak değerlendirmek amacıyla geliştirilmiştir. Sıvılaşma riskinin belirlenmesi için SPI'nin doğru bir şekilde hesaplanması gerekir.

Yapay Sinir Ağları (YSA), insan sinir sisteminden esinlenerek geliştirilmiş bir yöntem olup, son yıllarda doğrusal olmayan ve karmaşık mühendislik problemlerinde oldukça başarılı bir şekilde kullanılmaktadır.

Bu çalışmada, Denizli ili Gümüşler Belediyesi mücavir alanındaki zeminlerin, sıvılaşma potansiyeli değerlendirilmiş ve YSA yardımı ile sıvılaşmaya karşı Güvenlik Katsayısı (GK) tahmin edilmiştir. GK'nın tahmini için ileri beslemeli sinir ağları kullanılmıştır. Bu amaçla, 7.5 büyüklüğündeki bir deprem için zeminin tekrarlı direnç oranı ($CRR_{7.5}$), depremin oluşturduğu tekrarlı gerilim oranı (CSR), yeraltı suyu seviyesi, Standart Penetrasyon Deneyi (SPT) derinliği ile darbe sayısı girdi parametreleri olarak seçilmiştir. 21 adet sondaj kuyusuna ait 317 adet verinin 194'ü YSA'nın eğitimi için, 123'ü ise test işlemleri için kullanılmıştır. Test sonuçları ile hesaplanan değerler karşılaştırıldığında, YSA ile elde edilen sonuçların hesaplanan değerlere oldukça yakın çıktığı görülmüştür.

Anahtar Kelimeler: Güvenlik Katsayısı, Sıvılaşma Potansiyel İndeksi, Yapay Sinir Ağları.

Estimation Of Liquefaction Resistance By Artificial Neural Network: A Case Study For Denizli – Gümüşler

ABSTRACT: Liquefaction is one of the major natural hazards caused by earthquakes and it can be defined as an increase of pore pressure and lost of bearing capacity of the soils because of a dynamic impact (earthquake). In order to estimate liquefaction potential, Liquefaction Potential Index (LPI) is calculated. LPI has been developed for evaluating the surface impacts of the liquefaction.

Artificial Neural Networks (ANN) developed biological human brain system has been recently used for modeling of complex and nonlinear engineering problems.

In this study LPI of the Gümüşler Municipality settlement area has been calculated and factor of safety (FS) against liquefaction has been estimated by using ANN. Feed forward type of ANN is employed. The input parameters are cyclic resistance ratio for $M_w=7.5$ earthquakes ($CRR_{7.5}$), cyclic stress ratio (CSR), depth of ground water level, depth and N values of standard penetration test. 194 borehole values have been used in training process while 123 data have been used in test procedure. Satisfactory results have been obtained.

Keywords: Artificial Neural Networks, Factor of Safety, Liquefaction Potential Index.

GİRİŞ

Sıvılaşma kavramı ilk önce 1930'lu yılların sonlarında Casagrande tarafından ortaya

atılmıştır (Casagrande, 1975). Mogami ve Kubu (1953) sıvılaşmayı, suyun zemin ortamından uzaklaşmadığı koşullarda, suya doygun

kohezyonsuz zeminlerin tekdüze, geçici veya tekrarlanmalı şekilde örselenmesinden kaynaklanan zemin deformasyonlarını kapsayan davranış biçimlerinin tümü için kullanmışlardır. Yer sarsıntısı nedeniyle yüksek boşluk suyu basınçlarının gelişimi ve suyun yukarı doğru akışı kumda sıvılaşma denilen olayı meydana getirir. Bu durumda efektif gerilme sıfır olur ve zemin taneleri arasında herhangi bir tutucu kuvvet kalmaz (Ishihara, 1985). Depremle sıvılaşan gevşek kum çökeli üzerindeki yapı batar veya devrilir; gevşek kum sıvılaştığı zaman gömülü tanklar yüzeye doğru çıkar (Seed, 1970).

Genelde, gevşek alüvyal çökeller, özellikle kil bulunmayan kum ve silt ve bazen çakıl tabakaları sıvılaşma potansiyeline sahiptirler. Yeraltı suyu seviyesinin yüzeye 10 m'den daha yakın olması da sıvılaşma tehlikesini artırır. Buna karşılık yeraltı suyu seviyesinin 20 m'den daha derinde bulunması durumunda ve sıkı zeminlerde sıvılaşma potansiyeli azdır.

Sıvılaşma duyarlılığının belirlenmesinde arazi (standart penetrasyon testi (SPT), koni penetrasyon testi (CPT), kayma dalgası hızının (V_s) belirlenmesi) ve laboratuvar deneylerine (dinamik üç eksenli deneyler, tekrarlı basit kayma testi) bağlı birçok analiz yöntemi literatürde mevcuttur.

Bu çalışmada, Denizli ili Gümüşler Belediyesi mücavir alanındaki zeminlerin, sıvılaşma analizinde kullanılan GK değerleri YSA ile tahmin edilmiştir. Zeminin sıvılaşması için gerekli tekrarlı gerilim oranı ($CRR_{7.5}$), depremin oluşturduğu tekrarlı gerilim oranı (CSR), yeraltı suyu seviyesi (YASS), Standart Penetrasyon Deneyi (SPT) derinliği ve darbe sayısı girdi parametreleri olarak seçilmiştir. Elde edilen sonuçlar, hesaplanan deney sonuçları ile karşılaştırılmış ve YSA'nın sıvılaşma analizinde kullanılan GK'nın tahmin edilmesinde kullanılabilirliği tartışılmıştır.

YAPAY SİNİR AĞLARI

YSA, insan biyolojik sinir sistemini temel olarak geliştirilen bir yöntemdir. YSA, karmaşık mühendislik problemlerinin çözümüne yeni yaklaşımlar getirmiştir. 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 tanımlanabilir (Nasr ve diğ., 2003). YSA ile yapılan bazı çalışmalar, maksimum taşkın tahmini (Bodri ve Cermak, 2000), akış miktarının tahmini (Dibike ve Solomatine, 2001; Hsu ve diğ., 1998; Zhang ve Govindaraju, 1998), yağış ve akış modellemesi (Luk ve diğ., 2001), askı maddesi ve konsantrasyonun tahmini (Firat ve Güngör, 2004) gibi sıralanabilir.

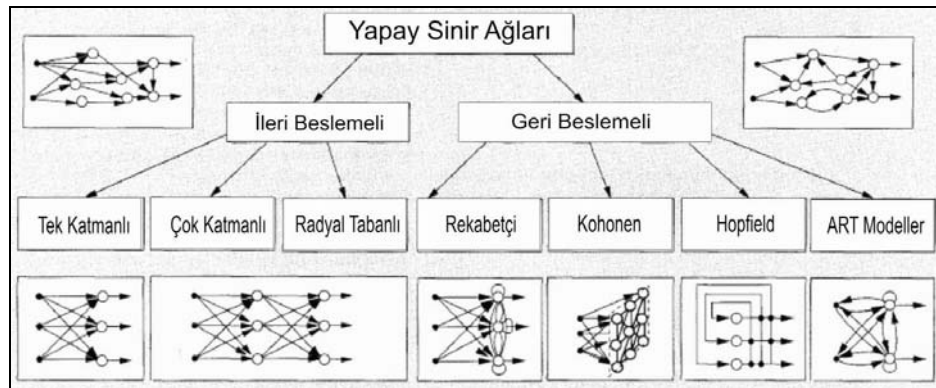
YSA, birbirine paralel bir şekilde bağlanmış ve doğrusal olmayan bir yapıya sahip olan nöron olarak adlandırılan birçok elemandan oluşmaktadır (Jang ve diğ., 1997). Literatürde farklı yapay sinir ağ yapıları kullanılmaktadır (Şekil 1). Bunlar, ileri beslemeli, geri beslemeli ve radyal tabanlı sinir ağlarıdır (Luk ve diğ., 2001). İleri beslemeli bir yapay sinir ağı; giriş, çıkış ve gizli katman olmak üzere en az üç katmandan oluşmaktadır. Giriş katmanındaki nöron sayısı, problem üzerindeki etkili parametreler dikkate alınarak belirlenmiştir. Gizli tabaka sayısı ve nöron sayısı ise deneme yanılma ile belirlenmiştir. Şekil 2'de bir nöronun matematiksel modeli gösterilmektedir. Nöron girdileri sinaptik bağlantılar üzerindeki ağırlıklar ile çarpılarak bir toplayıcıya uygulanmakta ve elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar eşitlik 2 yardımıyla hesaplanmıştır.

YSA, biyolojik sinir sisteminden esinlenerek geliştirildiği için, insanlar gibi örneklerle eğitilirler. İncelenen bir problemin çözümünde mevcut örneklerden başka bilgiye ihtiyaç duymaz. Ancak YSA ile bir problemi çözerken sonuç üzerinde etkili olan giriş verileri iyi seçilmelidir. YSA'da giriş parametre sayısı arttıkça modelin ve sistemin karmaşıklığı artmakta ve çözüm zorlaşmaktadır. Bu yüzden giriş sayısı en aza indirilmiştir.

$$Y_{net} = \sum_{i=1}^N Y_i \cdot w_i + w_0 \quad (1)$$

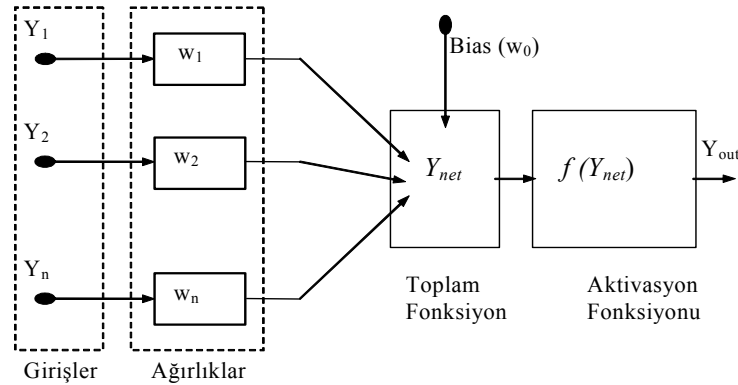
$$Y_{ağ} = f(Y_{net}) = f\left(\sum_{i=1}^N Y_i \cdot w_i + w_0\right) \quad (2)$$

Burada, $Y_{ağ}$ ağın ürettiği sonuç, $f(Y_{net})$ seçilen transfer fonksiyonu, Y_{net} toplam fonksiyonu, Y_i nöron girdisi, w_i her bir nöron girdisine ait ağırlık katsayısı ve w_0 bias'tır.



Şekil 1. Yapay sinir ağ yapıları.

Figure 1. Artificial neural network structures.



Şekil 2. Nöronun matematik modeli.

Figure 2. Mathematical model of a neuron.

Öğrenme genel anlamda, denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki şekilde verilebilir. Yapılan bu çalışmada, denetimli öğrenme tipi seçilmiştir. Denetimli öğrenmede, ağa giriş ve çıkış verileri sunulur ve bu verilere göre ağırlık katsayılarını düzenlemesi istenir (Fırat, 2002; Luk ve diğ., 2001). Bir ağ mimarisi, aktivasyon fonksiyonu ve öğrenme algoritması ile karakterize edilir. Aktivasyon fonksiyonu olarak, eşitlik (3)'te verilen sigmoid tipi aktivasyon fonksiyonu kullanılmıştır (Dibike ve Solomatine, 2001). Öğrenme algoritması olarak da, hatayı geriye yayma algoritması kullanılmıştır (Hjelmfelt ve Wang, 1996).

$$Y_{ağ} = f(Y_{net}) = \frac{1}{1 + e^{-Y_{net}}} \quad (3)$$

Eşitlik (1)'den hesaplanan toplam fonksiyon, aktivasyon fonksiyonundan geçirilerek ağın çıkışı elde edilir. Daha sonra ağın ürettiği sonuç ile gerçek sonuç karşılaştırılarak eşitlik (4) yardımıyla ağ hatası hesaplanır.

$$J_r = \frac{1}{2} \cdot \sum_{i=1}^k (Y_{gerçek} - Y_{ağ})^2 \quad (4)$$

Burada, J_r gerçek değer ile ağın ürettiği sonuç arasındaki hata ve $Y_{gerçek}$ gerçek çıkış değeridir. Bu hata kabul edilebilir değere ulaşana kadar eğitime devam edilir.

Bu çalışmada, Matlab R.14'de yazılan program ile çözüm yapılmıştır.

SIVILAŞMA RİSKİNİN TAHMİN EDİLMESİ

Sıvılaşma potansiyelinin belirlenmesi, zeminin sıvılaşmaya karşı güvenlik katsayısının belirlenmesi esasına dayanmaktadır. GK, zeminin sıvılaşması için gerekli tekrarlı direnç oranının ($CRR_{7.5}$), depremin oluşturduğu tekrarlı gerilim oranına (CSR) bölünmesi ile bulunur (Youd ve diğ., 2001).

Zeminlerin sıvılaşma duyarlılığının güvenlik katsayısı ile değerlendirilmesinin yanında,

Iwasaki ve diğ., (1982) tarafından önerilen sıvılaşma potansiyeli indeksi (SPI) ile sıvılaşma potansiyeli çok düşükten çok yükseğe kadar değişik derecelere ifade edilebilmektedir (Çizelge 1). Sıvılaşma potansiyeli indeksi, Iwasaki ve diğ., (1978) tarafından sıvılaşmanın bir temel hasarı meydana getirip getiremeyeceğinin tahmini için geliştirilmiştir. Yazarlar, Japonya'da altı depremin meydana geldiği toplam 85 inceleme alanında SPT sonuçlarını kullanmışlar ve bu alanların 63'ünde sıvılaşma görmüşler, 22'sinde ise sıvılaşmaya rastlamamışlardır. Toprak ve Holzer (2003), tarafından Kaliforniya (ABD) bölgesinde sıvılaşma üzerine bir deneysel çalışma yapılmış ve SPI değerinin 5 ve 15 olduğu durumlarda sıvılaşmanın yüzeyde görülebilme olasılığını incelemişlerdir. Wang ve Rahman (1999), yaptıkları çalışmada, sıvılaşma etkisinin önemli belirtilerinden olan yanal yer değiştirmelerin yapay sinir ağları ile tahmininde geliştirdikleri model çalışmalara yer vermişlerdir. Sönmez (2003) ile Sönmez ve Gökçeoğlu (2005), Iwasaki ve diğ., (1982)'nin önerdiği sıvılaşma potansiyeli sınıflamasında değişiklikler önermişlerdir.

Ayrıca, YSA kullanılarak jeoteknik modelleme, sıvılaşma potansiyeli tahminlerinin yapılması ve yanal yayılmanın belirlenmesi literatürde birçok araştırmacı tarafından değerlendirilmiştir (Wang, 1999; Baziar ve Ghorbani, 2005; Young-Su ve Byung-Tak, 2006; Hanna ve diğ., 2007).

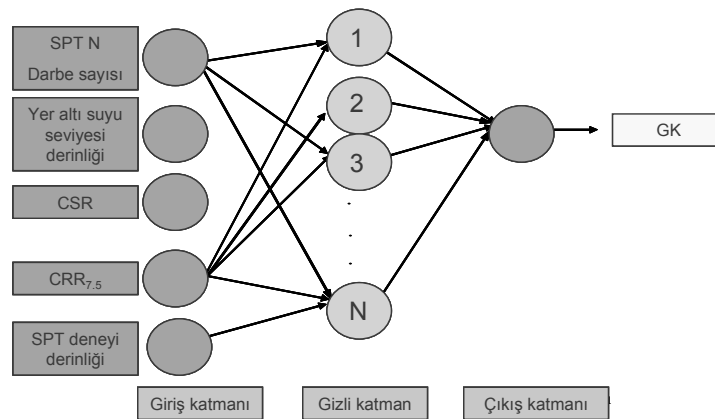
Yapay sinir ağları insanlar gibi örnekler ile eğitildikleri için eğitim sırasında yeterli sayıda veri grubunun kullanılması gerekir. YSA'nın eğitim ve test işlemleri için toplam 21 adet sondaj kuyusuna ait 317 adet veri Şen (2004), tarafından yapılan çalışmadan alınmıştır. Bu verilerden 194 tanesi ağın eğitiminde, geri kalan 123 tanesi ise test edilmesinde kullanılmıştır. Şekil 3'de GK'nın tahmin edilmesinde kullanılan YSA modeli gösterilmektedir.

Şekil 3'de verilen modelin eğitiminde aktivasyon fonksiyonu olarak (3) numaralı eşitlikte tanımlanan sigmoid tipi aktivasyon fonksiyonu kullanılmıştır. Her bir veri seti için eğitim yapılırken; gizli katman sayısı, gizli katmandaki nöron sayısı, öğrenme derecesi, momentum katsayısı ve iterasyon sayısı deneme-yanılma yoluyla belirlenmiştir (Çizelge 2).

Çizelge 1. Sıvılaşma indeksi değerlerine göre sıvılaşma potansiyeli dereceleri (Iwasaki ve diğ., 1978, 1982).

Table 1. Liquefaction potential ranges by liquefaction index values (Iwasaki et al., 1978, 1982).

| Sıvılaşma Potansiyel İndeksi (SPI) | Sıvılaşma Potansiyeli Derecesi |
|------------------------------------|--------------------------------|
| 0 | Çok Düşük |
| 0<SPI≤5 | Düşük |
| 5<SPI≤15 | Orta |
| 15<SPI | Yüksek-Çok Yüksek |



Şekil 3. GK tahmini için kullanılan ağ yapısı.

Figure 3. ANN structures used to estimate FS.

Çizelge 2. GK tahmini için eğitimde seçilen parametreler.*Table 2. Selected training parameters to estimate FS.*

| Eğitim veri sayısı | Test veri sayısı | Ağ yapısı | Öğrenme derecesi | Momentum katsayısı | İterasyon sayısı |
|--------------------|------------------|-----------|------------------|--------------------|------------------|
| 194 | 123 | 5-18-1 | 0.01 | 0.7 | 12000 |

Çizelge 3. SPI için YSA sonuçları ve hesaplanan sonuçlarının karşılaştırılması.*Table 3. Comparison of ANN and calculated values for LPI.*

| Sondaj Kuyu No | YASS=0,5 m. | | YASS=1 m. | | YASS=1,5 m. | | YASS=2 m. | |
|----------------|-------------|-------------|-----------|-------------|-------------|-------------|-----------|-------------|
| | YSA (SPI) | Hesap (SPI) | YSA (SPI) | Hesap (SPI) | YSA (SPI) | Hesap (SPI) | YSA (SPI) | Hesap (SPI) |
| SK 4 | 2,8 | 3,2 | 2,7 | 3,1 | 3,4 | 3,0 | 3,3 | 3,0 |
| SK 5 | 54,8 | 55,1 | 52,3 | 51,6 | 51,3 | 49,3 | 37,3 | 37,3 |
| SK 6 | 36,0 | 37,8 | 33,9 | 31,5 | 30,9 | 27,4 | 22,5 | 19,4 |
| SK 20 | 6,0 | 6,7 | 6,7 | 6,4 | 7,1 | 5,0 | 6,3 | 4,9 |
| SK 25 | 23,0 | 21,0 | 19,3 | 18,7 | 18,2 | 16,7 | 2,1 | 2,0 |

Eğitimden sonra ağın doğruluğunu kontrol etmek için daha önce eğitimde kullanılmayan 123 adet veri ile ağ test edilmiştir. Test işlemlerinde, SK 4, SK 5, SK 6, SK 20 ve SK 25 kuyularının 0,5, 1, 1,5 ve 2 m. yeraltı suyu seviyesindeki ölçümler kullanılmıştır. YSA sonuçları ile deney sonuçlarının karşılaştırılması Şekil 4'de verilmiştir. Test sonuçlarına bakıldığında en büyük hata % 14,47 ve ortalama hata % 6,55 olarak elde edilmiştir. Ayrıca Karesel Hataların Toplamı (SSE-Sum Square Error) 1.095, Karesel Hataların Ortalaması (MSE-Mean Square Error) 0.0089 ve Ortalama Karesel Hataların Karekökü (RMSE-(Root Mean Square Error) 0.0943 olarak hesaplanmıştır.

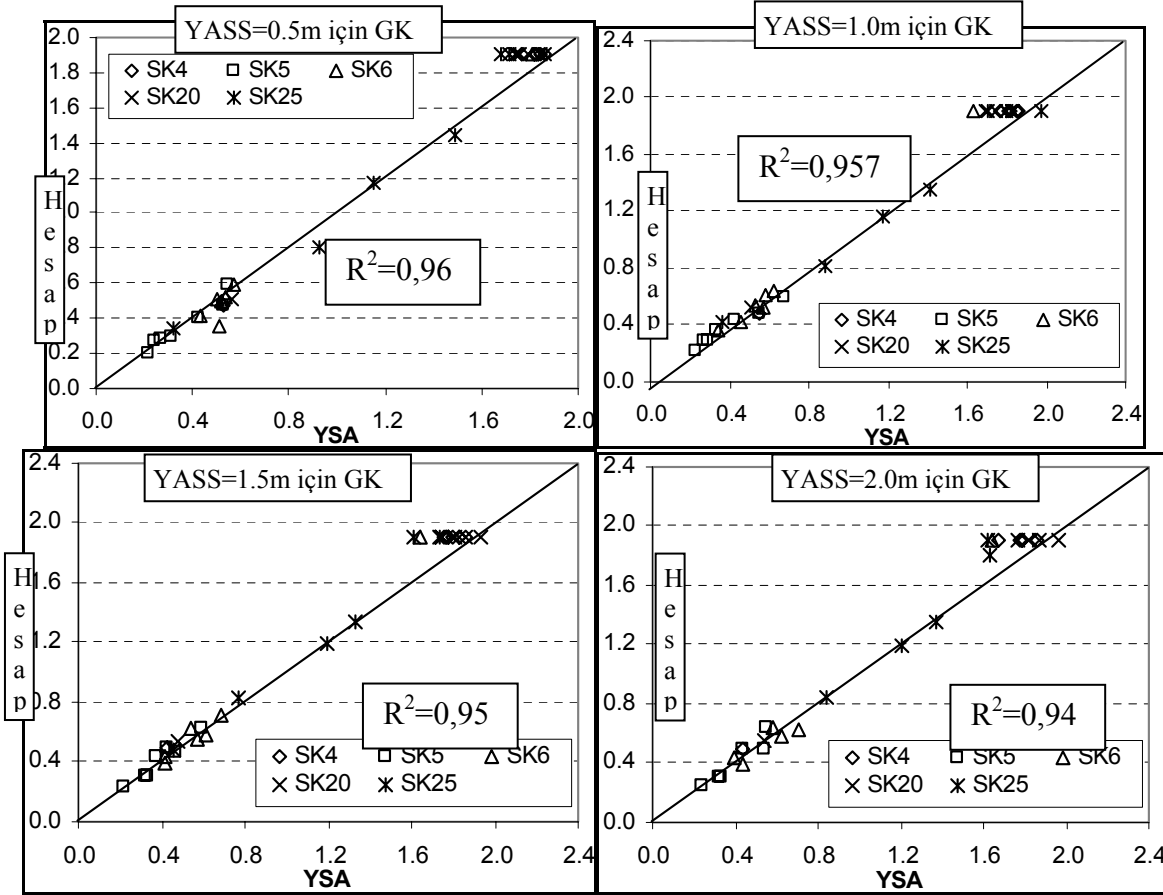
Hesaplanan performans değerlendirme kriterlerine bakıldığında elde edilen sonuçların kabul edilebilir değerlerde olduğu görülmektedir. Şekil 4'deki grafiklere bakıldığında, her bir YASS'indeki SK 4, SK 5, SK 6, SK 20 ve SK 25 için YSA, GK tahmin değerlerinin deney sonuçları ile uyum içinde olduğu görülmektedir. Elde edilen sonuçlar, SPI'nin belirlenmesinde kullanılan GK'nın tahmini için YSA'nın başarılı bir şekilde uygulanabileceğini göstermektedir. Bu çalışmada ayrıca, tahmin edilen GK değerlerine göre SPI değerleri Iwasaki ve diğ., 1982 (Eşitlik 5)'ye göre hesaplanmıştır.

$$SPI = \int_0^{20} Fw(z)dz \quad (5)$$

Eşitlik 5 ve yukarıda belirtilen koşullara göre 0,5, 1, 1,5 ve 2 m. YASS derinliklerinde SK 4, SK

5, SK 6, SK 20 ve SK 25 no'lu sondaj kuyuları için tahmin edilen GK değerleri dikkate alınarak SPI değerleri hesaplanmıştır. Çizelge 3 de bütün YASS için SK 4, SK 5, SK 6, SK 20 ve SK 25 no'lu sondaj kuyularına ait SPI değerleri karşılaştırmalı olarak verilmiştir. Burada dikkat çeken bir diğer nokta ise, Şekil 3'de gösterilen giriş katmanındaki a_{max} , r_d , SPT-N düzeltmesi ve ince tane düzeltme parametrelerinin olmamasıdır. Bir başka ifadeyle bu parametreler arazide ve/veya laboratuarda belirlenmemiş olsalar da, YSA ile tahmin edilen sonuçların kabul edilebilir olduğu gözlenmiştir (Çizelge 3). Bu da YSA'nın, GK'nın tahmin edilmesinde başarılı bir şekilde uygulanabileceğini göstermiştir.

İnceleme alanı ve yakın çevresinin arazi gözlemleri sonucu jeoloji haritası hazırlanmıştır (Şekil 5). Çalışma alanında Neojen ve Kuvaterner yaşlı birimler ayırt edilmiştir. Alttan üste doğru neojen yaşlı gölsel kireçtaşı, silt-kum-çakıl (N2) ardalması, kıltaşı-marn-silt (N1) birimleri ve Denizli-İzmir karayolu çevresinde yoğunlaşan Kuvaterner yaşlı alüvyonlar yer alır. Ayrıca çalışma alanından elde edilen jeoteknik veriler Coğrafi Bilgi Sistemi (CBS) programlarından MapInfo kullanılarak sayısallaştırılmıştır. Bölgenin sıvılaşma potansiyelini gösterir harita hazırlanmış ve SPI değerlerine göre eş sıvılaşma eğrileri oluşturulmuştur (Şekil 5). İnceleme alanının kuzeydoğu kesimleri sıvılaşma potansiyeli açısından riskli bölgelerdir.



Şekil 4. GK için YSA sonuçları ile hesaplanan sonuçların karşılaştırılması.

Figure 4. Comparison of ANN and calculated values.

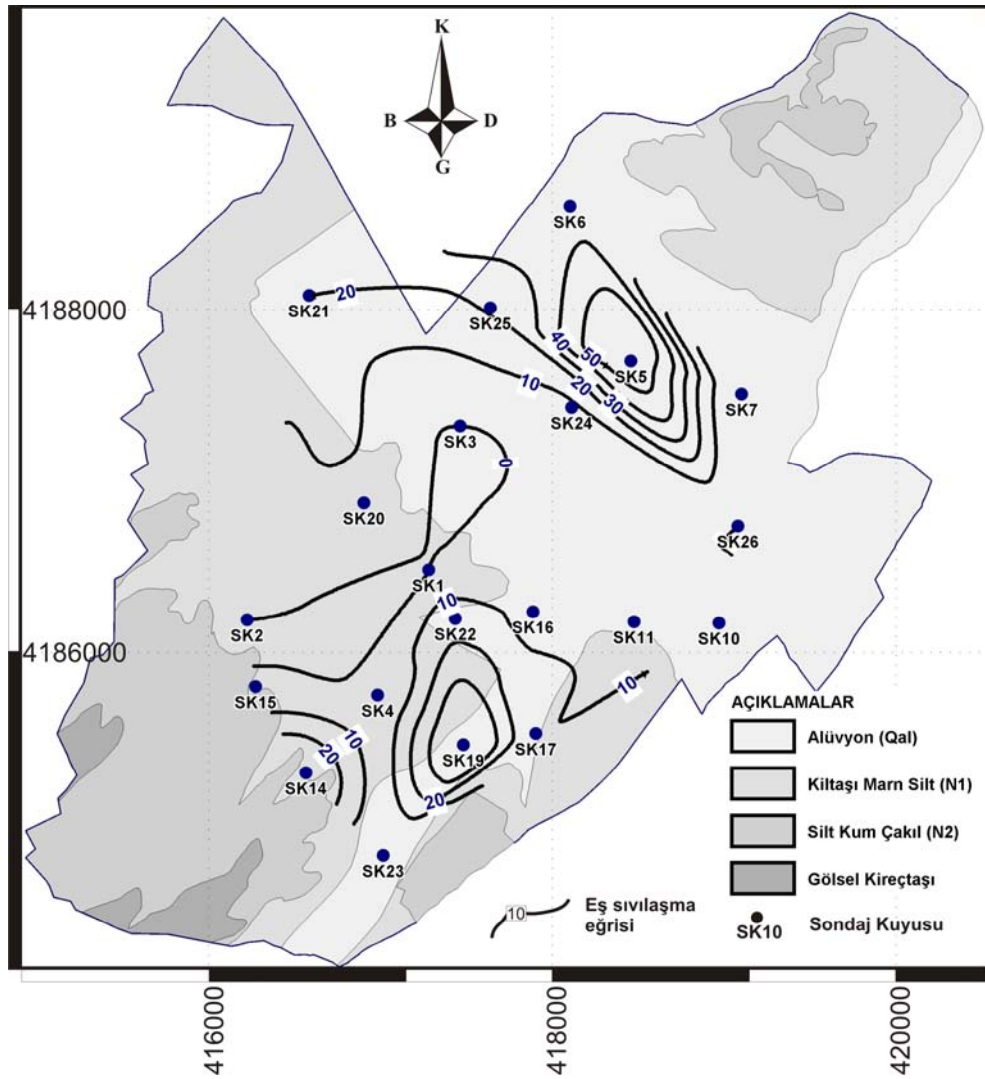
SONUÇLAR

Bu çalışmada, Denizli ili Gümüşler Belediyesi mücavir alanındaki zeminlerin, sıvılaşma riskinin belirlenmesinde kullanılan güvenlik katsayısı (GK) yapay sinir ağları (YSA) ile tahmin edilmiştir.

YSA'nın eğitim ve test işlemleri için toplam 317 adet veri kullanılmıştır. Ağın eğitiminden sonra daha önceden eğitimde kullanılmayan SK 4, SK 5, SK 6, SK 20 ve SK 25 numaralı sondaj kuyularına ait değerler test verisi olarak seçilmiştir. Ağın eğitimi için değişik ağ mimarileri ve eğitim parametreleri denenmiş ve en iyi sonucu veren model seçilmiştir. YSA'nın hem eğitimi hem de sorgulanması sırasında, hesaplamalarda kullanılan bazı parametreler (özellikle bazı düzeltme katsayıları) kullanılmamıştır. YSA ve hesaplanan sıvılaşma

potansiyel indeks değerlerinin sonuçlarının karşılaştırılması ilgili şekilde verilmiştir. Şekil incelendiğinde YSA sonuçları ile deney sonuçlarının uyum içerisinde olduğu görülmektedir. Ayrıca, ağın performansını değerlendirmek için hata değerleri hesaplanmıştır. Test sonuçlarına bakıldığında maksimum rölatif hata % 14.47, ortalama rölatif hata % 6.55, SSE 1.095, MSE 0.0089 ve RMSE 0.0943 olarak hesaplanmıştır.

Bu sonuçlara bakılarak YSA'nın, GK'nın tahmininde başarılı bir şekilde uygulanabileceği görülmektedir. Tahmin edilen GK değerlerine göre SPI değerleri hesaplanmış ve 0.5, 1, 1.5 ve 2 m. yeraltı suyu seviyesi için sonuçlar ilgili çizelgede verilmiştir. Bu çalışma ile YSA kullanılarak daha az parametre ile SPI ve GK'nın kabul edilebilir sınırlar içerisinde hesaplanabileceği gösterilmiştir.



Şekil 5. İnceleme alanının jeoloji ve eş sıvılaşma eğrilerini gösterir harita.

Figure 5. Geological and liquefaction risk map of study area.

KAYNAKLAR

- Baziar, M. H. and Ghorbani, A., 2005, Evaluation of Lateral Spreading Using Artificial Neural Networks, *Soil Dynamics and Earthquake Engineering* 25, pp. 1–9.
- Bodri, L. and Cermak, V., 2000, Prediction of Extreme Precipitation Using a Neural Network: Application to Summer Flood in Moravia, *Advances in Engineering*, 31, pp. 311–321.
- Casagrande, A. 1975, Liquefaction and Cyclic Deformation of Sands: A Critical Review, *Proceedings of the 5th Pan-American Conference on Soil Mechanics and Foundation Engineering*, Vol. 5, Buenos Aires, Argentina, pp. 79-133.
- Dibike, Y. B. and Solomatine, D. P., 2001, River Flow Forecasting Using Artificial Neural Networks, *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 26, No.1, pp. 1–7.
- Fırat, M., 2002, Doğrusal ve Kıvrımlı Akarsulara Yerleştirilen Köprü Ayakları Etrafında Meydana Gelen Oyulma Derinliğinin Yapay Sinir Ağları ile Belirlenmesi, *Yüksek Lisans Tezi, Pamukkale Üniversitesi*, 133 s.
- Fırat, M. and Güngör, M., 2004, Askı Maddesi Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi. *İMO Teknik Dergi*, Cilt 15 (3), 3267–3282.

- Hanna, A. M., Ural, D., and Saygili, G., 2007, Neural Network Model for Liquefaction Potential in Soil Deposits Using Turkey and Taiwan Earthquake Data, *Soil Dynamics and Earthquake Engineering* 27, pp. 521-540.
- Hjelmfelt, A. T. and Wang, M., 1996, Predicting Runoff Using Artificial Neural Networks, *Surface Water Hydrology*, pp. 233-244.
- Hsu, K., Gupta, H. V. and Sorooshian, S., 1998, Streamflow Forecasting Using Artificial Neural Networks, *ASCE Water Resources Engineering Conference* 98, pp. 967-972.
- Ishihara, K. 1985, Stability of Natural Deposits During Earthquakes, *Proceedings of the Eleventh International Conference on Soil Mechanics and Foundation Engineering*, vol., 1, San Francisco, pp. 321-376.
- Iwasaki, T., Tatsuoka, F., Tokida, K. I., and Yasuda, S., 1978, A Practical Method for Assessing Soil Liquefaction Potential Based on Case Studies at Various Sites in Japan, *Proceedings 2nd International Conference on Microzonation*, San Francisco, pp. 885-896.
- Iwasaki, T., Tokida, K. I., Tatsuoka, F., Watanabe, S., Yasuda, S. and Sato, H., 1982, Microzonation for Soil Liquefaction Potential Using Simplified Methods, *Proceedings Third International Earthquake Microzonation Conference*, Seattle, pp. 1319-1330.
- Jang, J. S. R., Sun, C. T. and Mizutani, E., 1997, *Neuro-Fuzzy and Soft Computing*, PrenticeHall, ISBN 0-13-261066-3, p. 607.
- Luk, C. K., Ball, J. E. and Sharma A., 2001, An Application of Artificial Neural Networks for Precipitation Forecasting, *Mathematical and Computer Modelling*, 33, p. 683-693.
- Mogami, T., and Kubu, K., 1953, The Behavior of Soil During Vibration, *Proceedings 3rd International Conference on Soil Mechanics and Foundation Engineering*, Zurich, Vol. 1, pp. 152-155.
- Nasr, G., E., Badr, E., A. and Joun, C., 2003, Back Propagation Neural Networks for Modelling Gasoline Consumption, *Energy Conversion and Management*, 44, pp. 893-905.
- Seed, H. B., 1970, Soil Problems and Soil Behaviour, Chapter 10 of *Earthquake Engineering*, Robert L. Wiegel, coordinating ed. Prentice Hall, Englewood Cliffs, NJ, pp. 227-251.
- Sönmez, H., 2003, Modification of the Liquefaction Potential Index and Liquefaction Susceptibility Mapping for a Liquefaction-Prone Area (Inegol, Turkey), *Environmental Geology*, 44, pp. 862-871.
- Sönmez, H. ve Gökçeoğlu, C., 2005, A Liquefaction Severity Index Suggested for Engineering Practice, *Environmental Geology*, 48, pp. 81-91.
- Şen, G., 2004, Gümüşler Belediyesi Mücavir Alanının Sıvılaşma Analizi ve Coğrafi Bilgi Sisteminde Uygulaması, Yüksek Lisans Tezi, Pamukkale Üniversitesi, 99 s.
- Toprak, S. and Holzer, T. L., 2003, Liquefaction Potential Index: Field Assessment, *ASCE Journal of Geotechnical and Geoenvironmental Engineering*, 129, pp. 315-322.
- Wang, J., 1999, Artificial Neural Network and Fuzzy Neural Integrated Systems for Geotechnical Modeling, PhD Thesis, Graduate Faculty of North Carolina State University, p. 280.
- Wang, J. and Rahman, M. S., 1999, A Neural Network Model for Liquefaction-induced Horizontal Ground Displacement, *Soil Dynamics and Earthquake Engineering*, 18, pp. 555-568.
- Young-Su, K. and Byung-Tak, K., 2006, Use of Artificial Neural Networks in the Prediction of Liquefaction Resistance of Sands, *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, Vol. 132, No. 11, pp. 1502-1504.
- Youd, T. L., Idriss, I. M., Andrus, R. D., Arango, I., Castro, G., Christian, J. T., Dobry, R., Liam Finn, W. D., Harder Jr., L. F., Hynes, M. E., Ishihara, K., Koester, J. P., Liao, S. S. C., Marcuson III, W. F., Martin, G. R., Mitchell, J. K., Moriwaki, Y., Power, M. S., Robertson, P. K., Seed, R. B. and Stokoe II, K. H., 2001, Liquefaction Resistance of Soils: Summary Report from the 1996 NCEER and 1998 NCEER/NSF Workshops on Evaluation of Liquefaction Resistance of Soils, *ASCE, Journal of Geotechnical and Geoenvironmental Engineering*, 127, pp. 817-833.
- Zhang, B. and Govindaraju, R. S., 1998, Using Modular Neural Networks to Predict Watershed Runoff, *ASCE Water Resources Engineering Conference* 98, pp. 897-902.