

Geoteknik mühendisliğinde yapay sinir ağı uygulamaları ve bir örnek: Zemin profilinin tahmin edilmesi

Akın ÖNALP^{*1}, Ersin AREL²

¹İKÜ, İnşaat Mühendisliği Bölümü, 34156, Ataköy, İstanbul

²SAÜ, İnşaat Mühendisliği Bölümü, 54187, Adapazarı, Sakarya

Özet

Dünyada ve Türkiye’de yapay sinir ağlarının (YSA) geoteknik mühendisliğinin pek çok alanında kullanımı son yıllarda yaygınlaşmıştır. Literatür araştırmasında; geoteknik probleminin çözümünde kullanılan YSA’nın özellikle; zeminlerin sınıflandırılması, arazi karakterizasyonu, sıvılaşma, geçirimsizlik ve hidrolik iletkenlik, sıkıştırma, dayanma yapıları, temellerin oturması, kazık hizmet yükünün tahmini ve zemin davranışının modellenmesi gibi karmaşık ve ilişkinin iyi anlaşılamadığı pek çok doğrusal olmayan problemlerin çözümünde başarılı ve hızlı çözümler sağladığı görülmektedir. Yapılan son çalışmalar, YSA’nın bulanık mantık ve genetik algoritma ile bütünleştiğini göstermektedir. Bu makalenin konusunu, geoteknik mühendisliğinin çeşitli dallarındaki problemlerin çözümünde YSA uygulamalarının genel bir değerlendirmesi oluşturmaktadır. Bu kapsamda YSA modellenmesi ve bu konuda yapılmış yurtdışından ve ülkemizden bazı çalışmalara örnekler verilmiştir. Makalenin ikinci bölümünde yazarlarca geliştirilen Adapazarı zeminlerinde 2-7m arası zemin profilinin CPT verileriyle analizinde yapay sinir ağının kullanımına yer verilmiştir. Koordinatları bilinen toplam 117 adet Koni Penetrasyon (CPT), verilerinden oluşturulan veri tabanı ile her 2cm. de bir alınan toplam 3236 okumayla geliştirilmiş yapay sinir ağı modeli ile rastgele seçilen lokasyonlar için yapılan tahminlerde %92 gibi oldukça yüksek bir başarı elde edilerek arazi karakterizasyonu hakkında yorum yapılabileceği görülmüştür.

Anahtar Kelimeler: Geoteknik mühendisliği, yapay sinir ağları, yapay zeka, zemin profili, koni penetrasyon deneyi, arazi karakterizasyonu.

*Yazışmaların yapılacağı yazar: Akın ÖNALP. a.onalp@iku.edu.tr; Tel: (212) 498 42 54.

Makale metni 18.03.2011 tarihinde dergiye ulaşmış, 11.08.2011 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 29.02.2012 tarihine kadar dergiye gönderilmelidir.

Bu makaleye “Önalp, A., Arel, E., (2011) ‘Geoteknik mühendisliğinde yapay sinir ağı uygulamaları ve bir örnek: Zemin profilinin tahmin edilmesi’, İTÜ Dergisi/D Mühendislik, 10: 4, 3-14” şeklinde atıf yapabilirsiniz.

Artificial neural network applications in geotechnical engineering and prediction of soil profile

Extended abstract

The use of artificial neural networks (ANN) in geotechnical engineering has gained wide application in Turkey as well as the world during the past ten years.

A comprehensive literature survey has shown that applications are concentrated in basic areas such as classification, site characterization, liquefaction, hydraulic conductivity, compaction, consolidation as well as practice comprising the problems of retaining structures, settlement of foundations, pile capacity and modeling of soil behavior where the relationship among the several parameters involved is not always thoroughly understood. Several case histories are presented as examples.

Latest research shows that artificial neural networks are heading towards unison with fuzzy logic and genetic algorithms and it is certainly superior to the statistical methods .

The second part of the paper gives an account of research conducted into estimation of the soil profiles in the city of Adapazari, Turkey. There has been widespread damage and destruction in the city during the $M_w=7.4$ earthquake in 1999. The damage has largely been blamed on inferior alluvial deposits and parts of the city have been moved to the North where the soil was found to be "sound". The sediments in the city are the products of the meandering river Sakarya which also flooded the region almost biannually. The two processes have resulted in the formation of complex soil profiles and near chaotic profiles are frequent. The silty layers are possibly the source of ground failures, occasionally leading to liquefaction in the absence of sands.

A comprehensive soil investigation has been carried out since 1990 by boreholes and cone penetration soundings. The authors have used the rich database available established from previous and current laboratory and field investigations. Out of this voluminous data those pertaining to depths of 2 to 7m have been used for the ANN work, as those depths have been diagnosed as the possible liquefaction

zone. Data from 117 CPT sites whose coordinates were known were employed for this study. The 3236 readings of tip resistance and sleeve friction were used to establish the ANN model.

The well established Robertson classification chart defines nine types of soil. It requires the normalised values of tip resistance(Q_t) and sleeve friction(F_r) to identify the soil layer. The Q_t^* and F_r^* are further defined to form the spatial distribution by the use of equations.

$$Q_t^* = \left[\alpha_1 \left(\left(\frac{\Delta x}{a} \right)^2 + \left(\frac{\Delta y}{b} \right)^2 + \left(\frac{\Delta z}{c} \right)^2 \right) + \alpha_2 \left(\frac{Q_t}{1000} \right)^2 \right]^{\frac{1}{2}}$$

$$F_r^* = \left[\alpha_1 \left(\left(\frac{\Delta x}{a} \right)^2 + \left(\frac{\Delta y}{b} \right)^2 + \left(\frac{\Delta z}{c} \right)^2 \right) + \alpha_2 \left(\frac{F_r}{10} \right)^2 \right]^{\frac{1}{2}}$$

The training matrix even for a limited depth of 5m using the data from 90 CPTU tests came out to be of size 3236x3236, which was difficult to handle. Consequently, thirteen 1800 by 1800 matrices were established (1.60-1.98m, 2.00-2.38m, 2.40-2.78m, 2.80-3.18m, 3.20-3.58m, 3.60-3.98m, 4.00-4.38m, 4.40-4.78m, 4.80-5.18m, 5.20-5.58m, 6.00-6.38m, 6.40-6.78m, 6.80-6.98m).

Data from 27 CPTU were used to form the thirteen 540 by 1800 simulation matrices and 1800 by 1800 training matrices.

Analyses were carried out on the Matlab 2010a Toolbox7 NNtraintool interface. 60% of the data were employed for Training, 15% for Validation and 15% for Testing.

Inspecting the results, it was found that the success rate in estimating the soil profile anywhere in the 26 km² city area was as high as 92%. This is a surprisingly high success rate considering the highly complex and laterally variable soil profiles throughout the city.

Keywords: Geotechnical engineering, artificial neural network, artificial intelligence, soil profile, cone penetration test, site characterization.

Giriş

Hebb (1949) bugünün sinir ağı teorisini tesis eden kişi olarak bilinmektedir. İki sinir hücresinin birbirleriyle nasıl bir korelasyon sergilediklerini incelemiş ve sinir ağı teorisini bu temel üzerine oturtmuştur. Günümüzde kullanılan ve başarı oranı %99'lar ile ifade edilen pek çok yapay sinir ağı modeli tanımlanmıştır.

Yapay sinir ağları (YSA), insan beyni ve sinir sisteminin benzeştirme fonksiyonu olarak geliştirilen bir yapay zeka biçimidir. YSA, veriler arasındaki var olan ilişkileri öğrenerek yeni örneklerdeki ilişkilerin tahmin edilmesinde oldukça başarılı sonuçlar vermektedir. Böylece geleneksel ampirik ve istatistiksel yöntemlere göre, veriler arasındaki ilişkilerin önceden bilinmesi gerekliliği ile zıtlık oluşturmaktadır. YSA, yapılan kabullerden beliren problemleri gidererek girdi ve çıktılarla modelleme yaparak aralarında ilişki kurabilmektedir.

1990'larda başlayan geoteknikte YSA kullanımı elde ettiği yüksek orandaki başarısı ile günümüzde oldukça yaygın kullanılmaktadır. Geliştirilen programlar ve bu programlarda kullanılan toolbox'lar yardımıyla istenen tahminlere hızlı ulaşılmaktadır.

Çelik, beton gibi homojen yapıda olan diğer inşaat mühendisliği malzemelerine benzemez olarak, karmaşık (belirsiz) yapıdaki zeminlerin uzaysal dağılımını tahmin etmede YSA kullanım tekniği değişkenlerin arazide beliren duruma benzer sonuçlar vermektedir.

Geoteknik parametreler; çevre faktörleri, dinamik özellikler, boşluk suyu basıncı gibi pek çok değişkenle kontrol edilmektedir. Bunların birbirleriyle bağımlı etkileşimi geleneksel istatistik yöntemlerinin kullanılmasını zorlaştırmaktadır. YSA ile geliştirilen yöntemler dizisinin kullanımıyla geoteknik parametrelerin tahmin edilmesi eldeki veri grupları temel alınarak yapılmaktadır. Ancak, aynı bölgeden alınan numunelerin birbirleriyle aynı geoteknik özellikleri göstermediği de bilinmektedir. Bu çalışmadaki amaç; YSA'nın eldeki verileri kullanarak öğrenme yöntemi ile istenen parametrelerin tahmin

edilmesini çeşitli örneklerle açıklanmasını sağlamaktır. Burada önemli olan, geniş veri tabanının sağlanmasıdır.

Yapay sinir ağlarına genel bakış

Yapay Sinir Ağları yönteminin temel mimarisi, Rumelhart ve McClelland (1986), Lippmann (1987), tarafından detaylı bir şekilde ele alınmıştır. 1990 yıllarında, (Hecht 1990, Maren vd., 1990, Zurada 1992, Fausett 1994, Ripley 1996) ile devam ederek doğrusal olmayan problemlerin çözümünde çoklu değişkenler arasında mükemmel performansı yakalamasından dolayı YSA'ya olan ilgi her geçen gün artmaktadır.

Yapay sinir ağları tekrarlanan girdiler sayesinde kendi yapısını ve ağırlığını değiştirir. Aynı canlıların sinir sisteminde olduğu gibi uyum sağlayabilen bir yapıya sahiptir. Yani içsel ve dışsal uyarmalara göre yapısı değişebilmekte, bu sayede öğrenebilmektedir. Karar verme aşamasında bağlantı ağırlıkları devreye girerek çözümü kendi kendine bulduğundan, sistemin belli bir durumda ne yapacağı bilinemez. Sisteme bir bilinmezlik özelliği katan öge de budur.

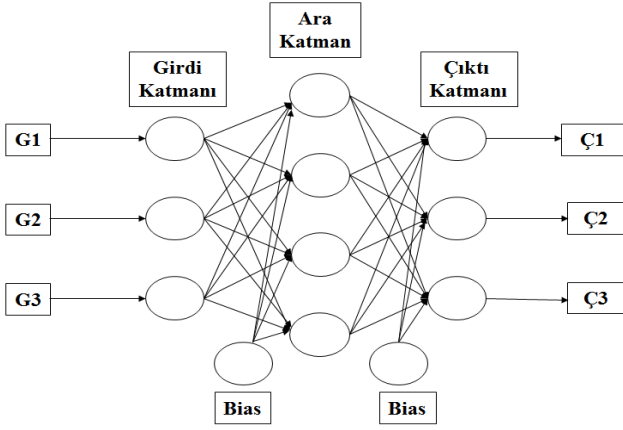
Yapay sinir ağları genellikle problemin türüne göre belirli oranlarda hata ile sonuca ulaşabilmektedir. Ancak bu hata düzeyi güvenlik katsayılarının oldukça büyük seçildiği geoteknik problemlerinde önemsiz mertebede kalmaktadır. Kullanılan malzemenin zemin gibi heterojen, daneli ve doğrusal davranış göstermeyen bir malzeme olduğu gerçeği ve projenin uygulanması sırasında yapılan hatalar göz önüne alındığında problemin çözümünde yapılan %5-10 düzeyindeki hataların birçok problemde önemli olmadığı ortaya çıkar.

Literatürde, çok çeşitli sayıda yapay sinir ağı modeli rapor edilmektedir. Bunların her birinin diğerlerine göre farklı problemlerde yararı veya sakıncaları bilinmektedir. Şekil 1'de tipik yapay sinir ağı mimari yapısı gösterilmiştir.

Yazılım yardımıyla daha kolay kurulabilen yapay sinir ağlarına bir örnek olan MATLAB'ta kullanılabilecek pek çok transfer fonksiyonu bulunmaktadır. Bir nöronun çıkışı hesaplanırken çok çeşitli transfer fonksiyonları kullanılabilir.

En çok kullanılan 3 transfer fonksiyonu:

1) Keskin-limitli (Hard-Limit) transfer fonksiyonu; genelde sınıflandırma uygulamalarında, 2) Doğrusal (Linear) transfer fonksiyonu; doğrusal problemlerde, 3) Log-Sigmoid fonksiyonu; doğrusal olmayan problemlerin çözümünde kullanılmaktadır.



Şekil 1. Tipik yapay sinir ağı mimari yapısı

Giriş işleme elemanları çıkış birimlerine gizli elemanlarla bağlıdır. Gizli birimler (gizli katmanlar) giriş ve çıkış bilgileri arasındaki doğrusal olmayan ilişkileri temsil etmektedir. Burada nöronun giriş verileri (x), ağırlıklandırılarak (w) elde edilen toplam giriş bir etkinleştirme fonksiyonundan (f) geçirilerek nöronun çıkışı (sonuç) üretilmektedir. Genel olarak bir nöron birden fazla giriş değerine sahiptir. Bir sinir ağının “gücü”, örnekleme verilerinden ne kadar iyi genelleştirme yapabildiğine bağlıdır. Öğrenme algoritması; istenen (hedef) çıkış vektörü ile gerçekleşen çıkış vektörü arasındaki fark cinsinden bir ölçü değeri olan hata fonksiyonunu kullanarak; deneme (eğitim) seti üzerindeki ortalama hatayı azaltacak şekilde, ağ içindeki ağırlıkları dengelemektedir. Bu doğru olarak gerçekleştirildiğinde sinir ağı, yeni giriş verileri için istenen sonuçları doğru olarak tahmin edecektir (Hertz vd., 1991). Genel olarak YSA kullanımı, tasarım ve uygulama sırasında karşılaşılan sorunlar nedeniyle karmaşık ve zaman alıcı bir süreçtir. Farklı nitelikteki problemler (veriler) için kurulacak ağ topolojisi (katman ve nöron sayısı, bağlantı ilişkileri) de aynı olmayacaktır. Tasarım açısından gizli katmanların sayısı ve büyüklüğünün (nöron sayısı) belirlenmesi, ağı

“öğrenme” ve genelleştirme kapasitesini etkilediği için son derece önemlidir. Öğrenme algoritması bir YSA uygulamasının temel bileşeni olup çok sayıda öğrenme stratejisi (kontrollü, kontrolsüz ve zorlamalı) geliştirilmiştir. En çok kullanılan ve bilineni geriyayılımlı (*backpropagation*) olup, bazı sakıncaları bilinmektedir. Bir diğer önemli konu, öğrenme algoritmasının performansını etkileyen uygun parametre seçimi konusundadır.

Uygun parametrelerin belirlenmesi konusunda genelde bir “deneme-yanılma” stratejisinin uygulandığı söylenebilir. Eğitim (*training*) esnasında bu parametreler dinamik olarak değiştirilebilir ve öğrenmenin sağlanıp sağlanmadığı sorgulanabilir.

YSA'ların yapılarına göre sınıflandırılması

Yapay sinir ağları, yapılarına göre, ileri beslemeli (*feedforward*) ve geri beslemeli (*feedback*) ağlar olmak üzere iki şekilde sınıflandırılırlar. İleri beslemeli ağlarda işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. Bunlar bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. İleri beslemeli ağlara örnek olarak çok katmanlı perceptron (*Multi Layer Perceptron-MLP*) ve LVQ (*Learning Vector Quantization*) ağları verilebilir. Geri beslemeli ağlar ise; 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. 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 ağlara örnek olarak Hopfield (1982) ve Self Organizing Map (Kohonen 2001) verilebilir.

Geoteknik mühendisliğinde YSA uygulamaları

Geoteknik mühendisliğinde YSA kullanımının gün geçtikçe her alanda yaygınlaşmasını ve bu konuda yapılan çalışmaları Toll (1996) ile Shahin ve diğerleri (2001) yazdıkları makalede derlemişlerdir. Bu bölümde, arazi karakterizas-

yonu, temellerin oturması, kazık hizmet yükü, sıvılaşma ve dayanma yapıları gibi geotekniğin önemli konularına bazı örnekler verilmeye çalışılmıştır.

Arazi karakterizasyonu

Arazi karakterizasyonu, geoteknik arazi araştırması verilerinden yapılan analiz ve yorumlamalarla ilgili bir alandır.

Goh 1995'te zemin korelasyonlarının modellenmesi adlı çalışmasının birinci aşamasında, normal yüklenmiş ve aşırı konsolide kumlar üzerinde gerçekleştirdiği YSA modellemesinde bağıl birim hacim ağırlık (D_r) ve ortalama efektif gerilmeyi (σ') girdi olarak almıştır. Çıktı olarak CPT (cone penetration test) koni uç direnci (q_c) ni tahmin etmiştir. Bu çalışmada eğitim için 93, test için 74 veri kullanmıştır. Doğrusal olmayan bu ilişkide korelasyon katsayısı eğitim için 0.97, test için 0.91 gibi yüksek düzeylerde elde edilmiştir. İkinci aşamada ise sıkıştırılmış killerin hidrolik iletkenliğini tahmin etmek amacıyla kurduğu modelde, girdi parametreleri olarak likit limit (w_L), plastisite indisi (I_p), çakıl, kum ve incelerin yüzdesi, kompaksiyon başlangıç doygunluk derecesi ve sıkıştırılmış durumdaki ağırlığı girdi olarak almıştır.

1995'te Ellis ve diğerleri; kumlu zeminlerde gerilme-şekil değiştirme grafiklerini YSA ile modelleyerek, bunların deney eğrilerine çok benzerlik gösterdiğini açıklamışlardır. Aynı yıl Cal; likit limit, plastisite indisi ve kil içeriğini kullanarak zemin sınıflandırmasını sayısal olarak belirlemiştir. Basheer ve diğ. (1996) atık depolama alanlarında yeraltı su seviyesine bağlı olarak zemin geçirimsizlik değişimlerinin harita üzerinde tahmin ve sınırlarının belirlenmesinde YSA kullanmışlardır. Aynı yıl Rizzo ve diğerleri yeni alan karakterizasyonu metodu SCANN (*Site Characterisation using Artificial Neural Networks*) ile ayrık uzaysal dağılım (discrete spatially-distributed fields) haritalaması yapmışlardır.

Penumadu ve Zhao (1994)'te YSA kullanarak drenajlı üç eksenli sıkışma koşullarında kumlu zeminlerde gerilme-deformasyon ve hacim de-

ğişikliği davranışlarını modellemişlerdir. Romero ve Pamukcu (1996); kayma modülü, Gribb ve Gribb (1994) doymun olmayan zeminlerde hidrolik iletkenliğin bulunması, Najjar ve Basheer (1996) kil dolgularda geçirimsizliğin tahmini ve zemin sıkıştırması ile ilgili YSA modelleri geliştirmişlerdir. Zhu ve diğerleri (1997, 1998a, b) zemin davranışları ile ilgili olarak yerinde oluşmuş zeminlerin modellenmesini yapmışlardır. Ghaboussi ve Sidarta (1998); üç eksenli deneyler yaparak kumlu zeminlerin drenajlı ve drenajsız davranışını modellemişlerdir. Basheer (2000), zeminlerin histeresis modellemesi ile (*Extended Kondor stress - strain curve with one hysteresis loop*) 960 veri kullanarak $R^2=0.99$ gibi çok yüksek değere ulaşmıştır. 2004'te Sivrikaya ve diğerleri su muhtevası (w_n), likit limit (w_L), plastisite indisi (I_p), efektif gerilme (σ_v'), SPT N_{arazi} , N_{60} ile oluşturdukları 2 benzer YSA modelinde drenajsız kayma dayanımını (c_u) $R^2=0.78$ ve $R^2=0.81$ düzeyinde bulmuşlardır.

Güllü ve diğerleri 2007'de YSA ile en büyük yer ivmesinin tahmin edilmesi başlıklı eserlerinde; ağ modelinde girdi parametrelerini büyüklük, uzaklık ve zemin koşulu, çıktı parametresini ise en büyük yer ivmesi olarak almışlardır. Ağın eğitim aşamasında, tahmin edilen en büyük yer ivmeleri ile ölçülen ivmeler arasındaki korelasyon katsayısı %92, test aşamasında ise %64 olarak bulunmuştur. Sinha ve Wang (2008), iri ve ince daneli zeminlerde sıkıştırma ve geçirimsizlik özelliklerini bulma amacıyla fiziksel özellikleri girdi parametreleri olarak almışlardır ($R^2=0.92$). Altun ve diğerleri (2008), üniform kumlarda sıkıştırma deneyi ile maksimum kuru birim hacim ağırlığının tahmininde $R^2=0.98$ bulmuşlardır.

Temellerin oturması

Temellerde oturmaların tahmini geotekniğin diğer karmaşık konularına benzer olarak belirsizliklerden etkilenir. Bu amaçla YSA ile oturma tahmini bazı araştırmacılar tarafından denenmiştir.

Sivakugan ve diğerleri (1998) iri daneli zeminlerde yüzeysel temellerin oturmasını YSA'da tahmin etmiştir. Girdi olarak 5 parametre kullanmıştır. Bunlar; uygulanan net basınç, ortalama

ma SPTN, temel genişliği, temel biçimi ve temel derinliğidir. 2002 yılında Shahin ve diğerleri ise, kohezyonlu zeminler üzerinde yüzeysel temellerin oturmasını tahmin etmişlerdir. Burada girdiler; temel boyu, temel genişliği, taban basıncı ve zeminin sıkışabilirliğidir. Bulunan korelasyon katsayıları geleneksel metodlarla karşılaştırıldığında; Meyerhof (1965), Schultze ve Sherif (1973), Schmertmann ve diğerleri (1978) temellerin oturmasını 60mm'nin üzerinde aşırı tahminle (*overpredict*) bulmuşken YSA ile yapılan tahminde 10-20mm gibi gerçeğe yakın oldukça düşük bir değer elde edilmiştir. Goh 2002'de olasılıksal YSA (*PNN, Probability Neural Network*) ile sismik ve zemin parametreleri arasındaki ilişkileri irdeleyerek sınıvlaşma potansiyelini belirlemiştir. Diğer bir çalışma ile 2003'te Baziar ve Nilipour Statistica programı ile D_{50} (orta dane boyutu), a (maksimum deprem ivmesi), σ'_0 (efektif gerilme), FC (ince dane miktarı), M_w (büyüklük), Z (zemin tabakasının derinliği), q_c (CPT koni uç direnci) parametreleri arasında güçlü ilişkilerin varlığını saptamışlardır. Daha sonra bu parametreler ile YSA'da 3 farklı model geliştirerek sınıvlaşma potansiyelini değerlendirmişlerdir. 2006'da Kurup ve Griffin, çok katmanlı, ileri beslemeli (*GRNN General Regression Neural Network*) algoritması ile CPT verilerinden koni direnci (q_c), sürtünme oranı (R_f), toplam örtü yükü eşdeğer gerilmesi (σ_{v0}), efektif gerilme (σ'_{v0}), denge boşluk suyu basıncı (u_0) parametrelerini girdiler olarak almışlar ve kum (%), silt (%) ve kil (%) miktarlarını tahmin etmişlerdir.

Kazık hizmet yükü

Yük kapasitesinin tahmininde Goh (1996,) YSA ile killi zeminlerde kazıklar üzerinde çalışmıştır. Geliştirdiği modelde girdi parametreler olarak; kazık boyu ve çapı, efektif gerilme ile drenajsız kayma direncini almış, çıktı olarak sürtünme direncini bulmuştur. Korelasyon katsayıları eğitim için 0.99 ve test için 0.96 olarak güvenilir düzeyde çıkmıştır. Oysa geleneksel regresyon yöntemi ile daha önce yapılmış bu konudaki çalışmada Semple ve Ridgen'in (1986), eğitim için buldukları korelasyon katsayısı 0.97 ve test için 0.88 olarak daha düşük düzeyde kalmıştı. Lee ve Lee (1996), kazıkların son taşıma kapa-

sitesinin tahmininde kazık yükleme deneyi sonuçlarını YSA'da girdi olarak; penetrasyon derinlik oranı (kazık penetrasyon derinliği / kazık çapı), normal gerilme, SPTN (kazık şaftı boyunca, kazık ucunda ve enerji miktarı), şaft çevresinde kayma direnci değerlerini alarak son taşıma gücünü çıktı olarak tahmin etmişlerdir. Daha sonraları 1997'de Teh ve diğerleri betonarme kazıkların statik kapasitesinin tahmininde CAPWAP programı kullanarak YSA'da modelleme yapmışlardır. Burada, MSE (*mean square error*) 0.0003 gibi oldukça düşük bir değerde bulunmuştur.

Sınıvlaşma

Geoteknikte YSA'nın sıkça kullanıldığı diğer bir alan olan zeminlerin sınıvlaşması ile ilgili pek çok çalışma bulunmaktadır. Tung ve diğerleri (1993), SPT verilerinden sınıvlaşma potansiyeli üzerinde yaptıkları çalışmada girdi parametreleri olarak; deprem büyüklüğü, yeraltı su seviyesi, sınıvlaşan zeminin derinliği ve zemin penetrasyon direncini kullanmış ve denetimli eğitim sonucu 1 ile sınıvlaşmayı, 0 ile güvenli durumu tanımlamışlardır. Wang ve Rahman 1999'da sismik etkiler sonucu oluşan zemin ötelenmelerini tahmin için geri beslemeli YSA modelleri oluşturmuşlardır. Juang ve diğerleri (1999)'da kumlu zeminlerde CPT verileri ile yaptıkları çalışmada; girdi olarak koni uç direnci (q_c), kılıf çevre sürtünmesi (f_s), toplam gerilme (σ_{v0}), efektif gerilme (σ'_{v0}) yi; çıktı olarak çevrimsel direnç oranı CRR 'ı alarak eğitim için 674, test için 289 adet geniş veri tabanı ile oluşturdukları ANN modelinde R^2 yi 0.99 bulmuşlardır. CRR 'yi tahminde YSA'yı kullanan diğer araştırmacılar olan Kim ve Kim (2006) geliştirdikleri 5 ayrı modelde kumlu numunelerde CTX (*Cyclic Triaxial*) ve DSS (*Direct Simple Shear*) deneylerinden oluşturdukları 346 veri seti ile zeminin fiziksel özellikleri ve çevrim sayısını girdi olarak almışlardır. Liu ve diğerleri (2006), 413 takım CPT verileriyle girdi parametrelerini değiştirerek oluşturdukları modellerde sınıvlaşma indisini tahmin etmişlerdir. 2007'de Hanna ve diğerleri 1999 Türkiye ve Taiwan depremlerinden elde ettikleri veritabanını kullanarak GRNN (*General Regression Neural Network*), yöntemle sınıvlaşma potansiyelini belirlemiştir.

Dayanma yapıları

YSA'nın dayanma yapılarında kullanımı; dizayn, oluşacak hareketler (*movements*) ve yenilme analizlerinin tahmini amaçlıdır. Bu konudaki çalışmalar; toprak dayanma duvarlarının dizaynında Hutchinson ve diğerleri (1987) YSA'nın uygulanabilirliğini 9 çeşit dayanma duvarı tipinde göstermişlerdir. 1995'te Arockiasamy ve diğerleri duvar tipi seçimi ve dizaynı ile ilgili olarak ağırlıktan palplansa değişen 10 tip dayanma yapısı üzerinde çalışmışlardır.

2011'de Heidari, girdiler olarak kayma direnci açısı ϕ , birim hacim ağırlık γ , betonun elastisite modülü E , zeminin eğimi β , duvarın yüksekliği ve ortalama kalınlığını alarak, aktif (W_a) ve pasif (W_p) durum için geriyayımlı YSA modellemesinde korelasyon katsayılarını 0.998 0.997 ile tahmin etmiştir.

ZM13 (2010) Türk ulusal kongresi

Türk Geoteknik topluluğunun bir araya geldiği, Zemin Mekaniği ve Temel Mühendisliği Türk Milli Komitesince düzenlenen (ZMTM) son kongre ZM13'te, YSA ile ilgili toplam 3 adet bildiri sunulması şaşırtıcıdır. Bu kongrede sunulan bildirimler; Arel, Önalp ve Sert, normal yüklenmiş zeminlerde sıkışma indisinin yapay sinir ağları kullanımıyla fiziksel özelliklerden tahmini, Erzin ve Ecemiş, yapay sinir ağlarının koni penetrasyon direncini tahmin etmede kullanımı, Bol, Önalp ve Özocak'ın yapay sinir ağlarıyla zemin özellikleri ve deprem hasarı ilişkisinin belirlenmesi adlı bildirimleridir.

Adapazarı zemin profilinin CPT verileri ile YSA'da analizi

Adapazarı zeminleri oluşum koşulları açısından sıradışı özellikler gösterirler. Bunun nedeni Sakarya nehrinin sıkça yatak değiştirerek şimdiki kent merkezinden de geçmiş olması, bunun sonucu kentin ortasında çökel kalınlığının 1000 m'ye eriştiği yerlerin varlığı, hızlı çökmenin, şimdilerde kentin doğu kenarından aksa da, 1965 yılına kadar Sakarya Nehri'nin merkeze uzanan yıllık taşkınlarıyla sürmüş olmasıdır. Sonuçta, Adapazarı merkezi ve ovasında çok genç ve yatay/düşeyde değişken özellikte silt, kil ve kum profilleri ve depolarının oluştuğu saptanmıştır. Bu amaçla; oldukça karmaşık yapıda olan ve derinliğe göre çok sık değişen ze-

min profili için SPT verileri yerine her 2cm de bir okuma alan CPT verileri ile zemin profilinin uzaysal dağılımının (x-y-z koordinatları) çıkarılması gerekli olmuştur.

Yazarlar tarafından geliştirilen Adapazarı zemin profili, toplam 117 adet arazi CPT verilerinden 1.6-6.98m arasında 3236 adet okuma ile modellenmiştir. Şekil 2'de kent içinde yapılan CPT ve SPT noktaları gösterilmiştir.

Arazi CPT verilerinden elde edilen; normalize edilmiş koni direnci (Q_t) ve sürtünme faktörü (F_r) ile Robertson kartına (Şekil 3) göre 9 tip zemin sınıfı ayırt edilmektedir. YSA'da uzaysal dağılımın tahmin edilmesi için öncelikle Q_t^* ve F_r^* değerlerinin belirlenmesi gerekmektedir. Bu amaçla oluşturan eşitlikler aşağıda verilmiştir:

$$Q_t^* = \left[\alpha_1 \left(\left(\frac{\Delta x}{a} \right)^2 + \left(\frac{\Delta y}{b} \right)^2 + \left(\frac{\Delta z}{c} \right)^2 \right) + \alpha_2 \left(\frac{Q_t}{1000} \right)^2 \right]^{\frac{1}{2}}$$

$$F_r^* = \left[\alpha_1 \left(\left(\frac{\Delta x}{a} \right)^2 + \left(\frac{\Delta y}{b} \right)^2 + \left(\frac{\Delta z}{c} \right)^2 \right) + \alpha_2 \left(\frac{F_r}{10} \right)^2 \right]^{\frac{1}{2}}$$

Burada;

$$a: x_{\max} = 36852 - x_{\min} = 33597 = 3.255 \text{ km}$$

$$b: y_{\max} = 36706 - y_{\min} = 30580 = 6.126 \text{ km}$$

c: toplam derinlik

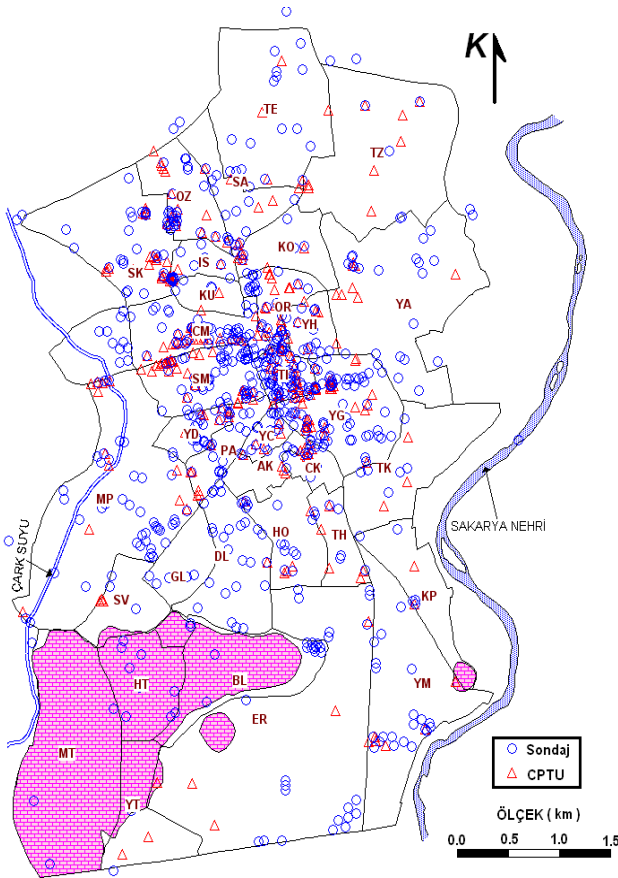
$$\alpha_1: 0.2 \quad \alpha_2: 0.8$$

Eğitim için oluşturulan 90 adet CPT datası ile tek matris büyüklüğünün 3236x3236 olması, derinliğe göre 13 ayrı matrise bölünme zorunluluğunu getirmiştir. Toplam derinlik 1.6 - 7 m arası 0.38 m aralıklarla 13 matris elde edilmiştir. YSA'da eğitim için Microsoft Excel çarşaf çizelgesinde (*worksheet*) her biri 1800x1800 olarak hazırlanan toplam 13 matris oluşturulmuştur (1.60-1.98m, 2.00-2.38m, 2.40-2.78m, 2.80-3.18m, 3.20-3.58m, 3.60-3.98m, 4.00-4.38m, 4.40-4.78m, 4.80-5.18m, 5.20-5.58m, 6.00-6.38m, 6.40-6.78m, 6.80-6.98m). Son matrisin kısa olması nedeniyle 900x900 den oluşmakta-


dır. Q_t^* ve F_r^* ayrı ayrı olmak üzere toplam 26 matristen oluşmaktadır. Simülasyon için toplam 27 CPT datası kullanılmıştır. 13 tane eğitim matrisi 1800x1800 boyutunda, 13 tane simülasyon matrisi ise 540x1800 boyutundadır. 6.80 – 6.98 matrisinin aralığı diğer matrislerden kısa olduğundan eğitim matrisi 900x900, simülasyon matrisi ise 270x900 dür.

Analizler Matlab 2010a Toolbox7 NNtraintool arayüzünde gerçekleştirilmiştir. Verilerin %60'ı Eğitim (Training), %15'i Validation (Onaylama), %15'i Test için ayrılmıştır.

Arazi CPT verilerinden elde edilen Q_t ve F_r değerleri ile YSA'dan tahmin edilen Q_t^* - F_r^* arasındaki korelasyonlara örnek, Şekil 4 ve 5'te 1.60-1.98m için verilmiştir. Bulunan korelasyon katsayılarının $R=0.98-0.99$ 'a kadar yüksek değerlerde çıkması YSA'da yapılan modellemenin başarısını göstermektedir. Simülasyon için seçilen CPT lokasyonları Tablo 1'de verilmiştir.



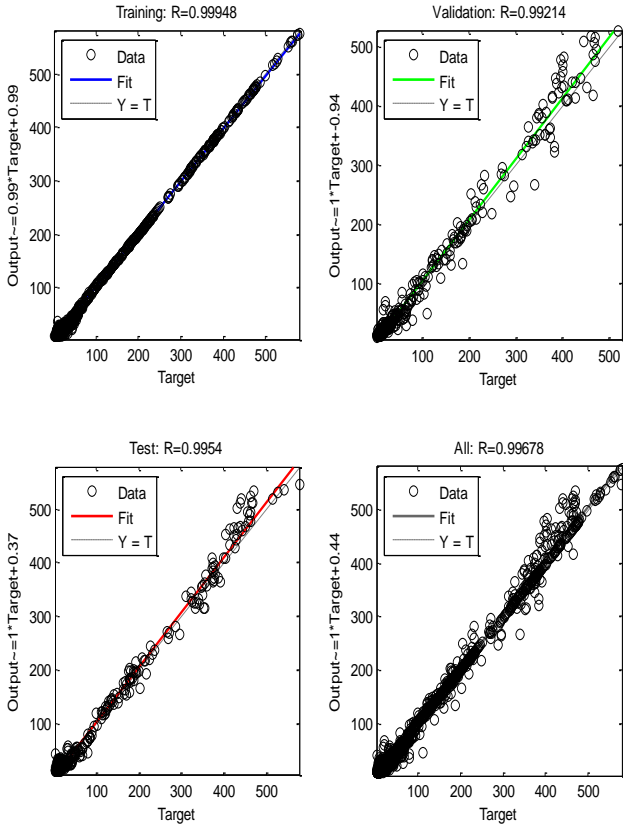
Şekil 2. Çalışma alanında yapılan CPTU ve sondaj yerleri



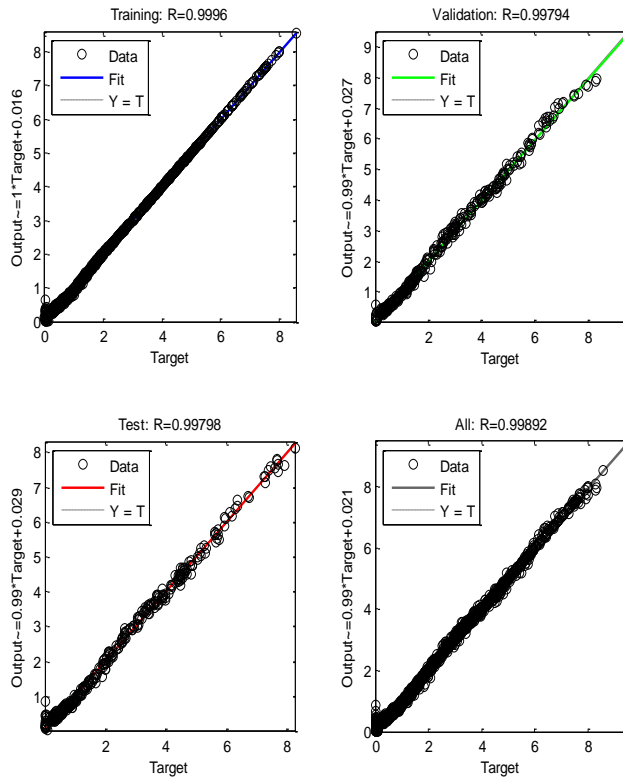
Şekil 3. CPT ile yapılan zemin sınıflandırma kartı (Robertson 1990)

Tablo 1. Simülasyon için seçilen CPT lokasyonları

CPT_ID	X-KOORD	Y-KOORD
CYD131	34780	33270
CYH142	35822	34454
CMP209	33787	33085
CMP209	33756	33190
COZ188	34353	35246
CSM079	35119	33695
CCM086	34459	34263
CYG041	36287	33112
CYG278	35697	33396
CTE283	35580	36090
CYD129	34883	33597
CYG130	35703	33481
CSM167	34284	33980
CKU286	34680	34470
CTI287	35354	33966
CSM256	35184	33743
CKP226	36745	31847
CTH255	35928	32724
CYG250	36296	33627
CYM268	36852	30726
CSA281	34722	35736
CSM289	34370	33926
CTI004	35437	33707
CTI006	35428	33713
CTI008	35556	33908
CTI009	35422	33895
CTI010	35422	33886




Şekil 4. $Q_t-Q_t^*$ için örnek YSA performansı

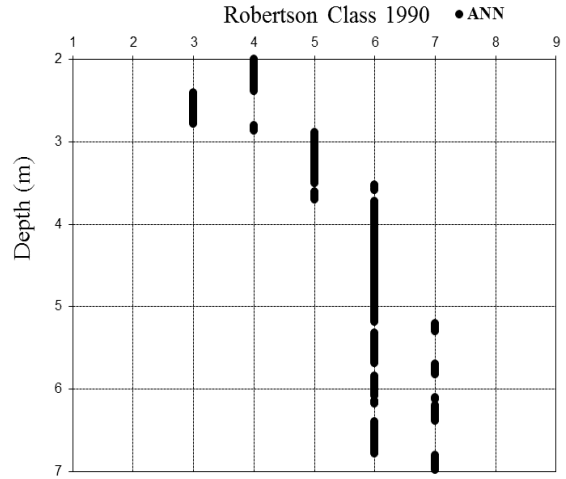


Şekil 5. $F_r-F_r^*$ için örnek YSA performansı

Şekil 6'da arazi CPT değerlerinden yapılan sınıflandırma derinliğe göre noktalanmış, YSA'dan tahmin edilen $Q_t^*-F_r^*$ değerleri ise yine Robertson kartına göre sınıflandırılarak derinliğe göre Şekil 7'de noktalanmıştır. 2-7m arası yapılmış analizlerin tamamında korelasyon katsayısı $R=0.92$ olarak bulunmuştur.



Şekil 6. Derinliğe göre arazide ölçülmüş gerçek (actual) Robertson zemin sınıflaması



Şekil 7. Derinliğe göre YSA da yapılmış benzeştirme ile Robertson zemin sınıflaması

Sonuçlar

YSA pek çok avantajı ile geleneksel matematik yöntemlerden daha yüksek korelasyon katsayıları vermektedir. Belirlenen girdiler ve hedeflenen çıktılar ile bir kez modellendikten sonra ilave verilerin kullanılmasıyla güncellenmeye el-

verişlidir. Özellikle deneysel çalışmalarda optimum değere ulaşılabilir. Unutulmaması gereken en büyük olumsuz yanı, geniş veri tabanına ihtiyaç duymasındır.

Geoteknik mühendisliğinde, karmaşık ve net olmayan ilişkilerin anlaşılmasında yapay sinir ağlarının etkin kullanılması yaygınlaşmıştır. Bu amaçla, makalenin birinci aşamasında, bu alanda yapılan çalışmalara verilen örneklerde YSA'nın başarısı gösterilmiştir. İkinci aşamada yazarlarca geliştirilen CPT verileriyle zemin profilinin tahmini $R=0.92$ gibi oldukça yüksek korelasyon katsayısı ile 2-7m arası Adapazarı zeminlerine uygulanması sunulmuştur.

Kaynaklar

- Arel, E., Önalp, A. ve Sert, S., (2010). Normal yüklenmiş zeminlerde sıkışma indisinin yapay sinir ağları kullanımıyla fiziksel özelliklerden tahmini, Zemin Mekaniği ve Temel Mühendisliği Onüçüncü Ulusal Kongresi, 327-336, İstanbul Kültür Üniversitesi.
- Arockiasamy M., Radhakrishnan N., Sreenivasan G. ve Lee S., (1991). KBES Applications to the Selection and Design of Retaining Structures, Proc. Geotechnical Engineering Congress, Geotechnical Special Publication (eds. McLean, F.G., Campbell, D.A. ve Harris, D.W.), Boulder, Colorado: ASCE, **27**, 391-402.
- Baziar, M.H. ve Nilipour, N. (2003). Evaluation of liquefaction potential using neural-networks and CPT results, *Soil Dynamics and Earthquake Engineering*, **23**, 631-636.
- Bol, E., Önalp, A. ve Özocak, A., (2010). Yapay sinir ağlarıyla zemin özellikleri ve deprem hasarı ilişkisinin belirlenmesi, Zemin Mekaniği ve Temel Mühendisliği Onüçüncü Ulusal Kongresi, 369-380, İstanbul Kültür Üniversitesi.
- Ellis, G.W., Yao, C., Zhao, R. ve Penumadu, D., (1995). Stress-Strain Modeling of sands using artificial neural networks, *Journal of Geotech. Eng.*, ASCE, **121**, 5, 42-435.
- Erzin, Y. ve Ecemiş, N., (2010). Yapay sinir ağlarının koni penetrasyon direncini tahmin etmede kullanımı, Zemin Mekaniği ve Temel Mühendisliği Onüçüncü Ulusal Kongresi, 337-346, İstanbul Kültür Üniversitesi.
- Basheer, I.A., Reddi, L. N., ve Najjar, Y.M., (1996). Site characterization by neuronets: An application to the landfill sitting problem, *Ground Water*, **34**, 610-617.
- Basheer, I.A., (2000). Selection of Methodology for Neural Network Modeling of Constitutive Hystereses Behavior of Soils, *Computer-Aided Civil and Infrastructure Engineering*, **15**, 440-458.
- Cal, Y., (1995). Soil classification by neural-network, *Advances in Engineering Software*, **22**, 2, 95-97.
- Fausett, L.V., (1994). *Fundamentals neural Networks: Architecture, algorithms, and applications*, 449, Englewood Cliffs, New Jersey.
- Ghaboussi, J., ve Sidarta, D.E., (1998). New nested adaptive neural networks for constitutive modeling, *Computer and Geotechnics*, **22**, 1, 29-52.
- Goh A. T. C., (1995). Modeling soil correlations using neural networks, *ASCE*, **9**, 4, 275-278.
- Goh, A. T. C., (1996). Pile driving records reanalyzed using neural Networks, *Journal of Geotech. Eng. ASCE*, **122**, 6, 492-495.
- Goh A. T. C., (2002). Probabilistic neural network for evaluating seismic liquefaction potential, *Can. Geotech. Journal*, **39**, 219-232.
- Gribb, M. M., ve Gribb, G. W. (1994). Use of neural networks for hydraulic conductivity determination in unsaturated soil, *Proceedings.*, 2nd Int. Conf. Ground Water Ecology. J. A. Stanford ve H. M. Valett, eds., Bethesda, MD: Amer. Water Resources Assoc., 155-163.
- Güllü, H., Pala, M. ve İyisan, R., (2007). Yapay sinir ağları ile en büyük yer ivmesinin tahmin edilmesi Altıncı Ulusal Deprem Mühendisliği Konferansı, 185-194.
- Hanna, A.M., Ural, D. ve Saygılı, G., (2007). Neural network model for liquefaction potential in soil deposits using Turkey and Taiwan earthquake data, *Soil Dynamics and Earthquake Engineering*, Elsevier, **27**:521-540.
- Hebb, D. O., (1949). *The Organization of Behavior: A neuropsychological theory*, 62, New York, Wiley.
- Hecht N. R., (1990). Neurocomputing, Addison-Weseley, MA, 147-153.
- Heidari, A., (2011). Calculation of frequency of retaining wall by back propagation neural network, *Asian Journal of Civil Engineering (Building and Housing)*, **12**, 3, 267-278.
- Hertz, J., Krogh, A. ve Palmer, R.G., (1991). *Introduction to the theory of neural computation*, Westview Press.
- Hopfield, J.J., (1982). Neural networks and physical systems with emergent collective computational abilities, *Biophysics*, **79**:2554-2558, *Proceedings, NatL Acad. Sci. USA*.

- Hutchinson P.J., Rosenman M.A. ve Gero J.S., (1987). RETWALL: An expert system for the selection and preliminary design of earth retaining structures, *Knowledge-based Systems*, **1**, 1, 11-23.
- Juang, C.H., Chen, C.J. ve Tien Y., (1999). Appraising cone penetration test based liquefaction resistance evaluation methods: artificial neural network approach *Can. Geotech. Journal* **36**, 3, 443-454.
- Kim, B.T. ve Kim, Y.S., (2006). Use of artificial neural Networks in the prediction of liquefaction resistance of sands, *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, **132**, 11, 1502-1504.
- Kohonen, T. (2001). Self-organizing maps, Third, extended edition. Springer.
- Kurup, P.U., ve Griffin, E.P., (2006). Prediction of soil composition from CPT data using general regression neural network, *Journal of Computing in civil Engineering*, ASCE, **20**, 4, 281-289.
- Lee, I. M. ve Lee, J. H., (1996). Prediction of pile bearing capacity using artificial neural Networks, *Computers and Geotechnics*, **18**, 3, 189-200.
- Lippmann R. P., (1987). An introduction to computing with neural nets. IEEE ASSP Mug. 4:22.
- Liu, B., Ye, M., Xiao, M. ve Miao, S. (2006). Artificial neural network methodology for soil liquefaction evaluation using CPT values, *ICIC*, 329-336.
- Maren, A., Harston, C., ve Pap, R., (1990). *Handbook of neural computing applications*, Academic Press, CA. McClelland.
- Matlab, (2010). Matlab the language of technical computing. Version 7.10. Natick, MA, USA: The MathWorks.
- Meyerhof, G. G., (1965). Shallow foundations, *Journal Soil Mech. ve Found. Div.*, ASCE, **91**(SM2), 21-31.
- Najjar, Y.M., Basheer, I.A., ve Naouss, (1996). On the identification of compaction characteristics by neuronets, *Computer and Geotechnics*, **18**, 3, 167-187.
- Neural Network Toolbox 7, (2010). User's Guide, MathWorks.
- Penumadu, D. ve Zhao, R., (1994). Modeling drained triaxial compression behaviour of sand using ANN, *Conf. Proceedings*, ASCE.
- Ripley, B.D., (1996). Pattern recognition and neural networks, Cambridge University Press, Cambridge.
- Robertson, P.K., (1990). Soil classification using the cone penetration test. *Canadian Geotechnical Journal*; **27**, 1, 151-158.
- Romero, S., ve Pamukcu, S. (1996). Characterization of granular material by low strain dynamic excitation and ANN. *Geotechnical Special Publication*, ASTM-ASCE, **58**, 2, 1134-1148.
- Rumelhart D. E. ve J. L. McClelland (Eds), (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. MIT Press, Cambridge, Mass.
- Schmertmann, J. H., Hartman, J. P., ve Brown, P. B., (1978). Improved strain influence factor diagrams, *Journal Geotech. Engrg.*, ASCE, **104**, GT8, 1131-1135.
- Schultze, E., ve Sherif, G., (1973), Prediction of settlements from evaluated settlement observations for sand, *Proc.*, 8th Int. Conf. Soil Mech. & Found. Engrg., **1**, 3, 225-230.
- Semple, R. M., ve Rigden, W. J., (1986). Shaft capacity of driven pipe piles in clay, *Ground Engineering*, **19**, 1, 11-17.
- Shahin, M.A., Jaksa, M.B. ve Maier, H.R., (2001). *Artificial neural network applications in geotechnical engineering*, 49-62, Australian Geomechanics.
- Shahin, M.A., Maier, H.R., Jaksa, M.B., (2002). Predicting settlement of shallow foundations using neural networks, *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, **128**, 9, 785-793.
- Sinha, S.K. ve Wang, M.C., (2008). Artificial neural network prediction models for soil compaction and permeability, *Geotech Geol Eng*, **26**, 47-64.
- Sivakugan, N., Eckersley, J. D., ve Li, H., (1998). Settlement predictions using neural Networks, *Australian Civil Engineering Transactions*, CE40:49-52.
- Sivrikaya, O., Toğrol, E. ve Kömür, M., (2004). Yapay sinir ağları ile serbest basınç mukavemetinin (qu) belirlenmesi, Zemin Mekaniği ve Temel Mühendisliği Onuncu Ulusal Kongresi, İTÜ, İstanbul.
- Rizzo, D.M., Lillys, T.P. ve Dougherty, D.E., (1996). Comparisons of site characterization methods using mixed data, *ASCE Geotechnical Special Publication*, **58**, 1, 157-179.
- Teh, C. I., Wong, K. S., Goh, A. T. C., ve Jaritngam, S., (1997). Prediction of pile capacity using neural networks. *J. Computing in Civil Engineering*, ASCE, **11**:2:129-138.
- Toll, D.G., (1996). Artificial intelligence applications in geotechnical engineering, *EJGE*.

- Tung, A.T.Y., Wang, Y.Y. ve Wong, F.S., (1993). Assessment of liquefaction potential using neural Networks, *Soil Dynamics and Earthquake Engineering*, Elsevier, **12**,325-335.
- Wang, J., ve Rahman, M.S., (1999). A neural network model for liquefaction-induced horizontal ground displacement, *Soil Dynamics and Earthquake Engineering*, Elsevier, **18**, 555-568.
- Zurada, J.M., (1992). *Introduction to artificial neural systems*, 764, West Publishing Company, St. Paul.
- Zhu, J. H., and Zamman, M. M. (1997). Neural network modeling for a cohesionless soil, 76th Meeting of the Transportation Research Board, January, Washington, D.C.
- Zhu, J. H., Zaman, M. M., ve Anderson, S. A., (1998a). Modeling of soil behavior with a recurrent neural network, *Canadian Geotech. Journal*, **35**, 5, 858-872.
- Zhu, J. H., Zaman, M. M., ve Anderson, S. A., (1998b). Modelling of shearing behaviour of a residual soil with recurrent neural network. *Int. of Journal Numerical and Analytical Methods in Geomechanics*, **22**, 8, 671-687.