

## Yapay Sinir Ağı Kullanılarak CPT Tabanlı Sıvılaşma Değerlendirme Abağının Geliştirilmesi

### *The Development of CPT Based Liquefaction Assessment Chart Using Artificial Neural Network*

**BORA SÖNMEZ<sup>1</sup>, GÜLSEREN DAĞDELENLER<sup>2</sup>, NAZLI TUNAR ÖZCAN<sup>2</sup>, MURAT ERCANOĞLU<sup>2</sup>, HARUN SÖNMEZ<sup>2\*</sup>**

<sup>1</sup>T.C. Ulaştırma Denizcilik ve Haberleşme Bakanlığı Dış İlişkiler ve Avrupa Birliği Genel Müdürlüğü Emek/Ankara

<sup>2</sup>Hacettepe Üniversitesi Mühendislik Fakültesi Jeoloji Mühendisliği Bölümü, 06800 Beytepe/Ankara

Geliş (received) : 30 Haziran (June) 2015

Kabul (accepted) : 10 Ağustos (August) 2015

#### ÖZ

Depremler sırasında suya doymun kohezyonsuz (veya düşük kohezyonlu) zeminlerde gelişen sıvılaşma olayı etkilediği alanlarda yapısal hasarları arttırarak çok sayıda can ve mal kayıplarına neden olmaktadır. Yeraltı su seviyesinin yüzeye yakın olduğu ve depremselliği yüksek bölgelerdeki suya doymun kumlu ve siltli toprak zeminlerin, sıvılaşmaya olan yatkınlığı bilinmektedir. Bununla birlikte, bu tür zeminlerde zeminin sıklılığını da yansıtan standart penetrasyon testi (SPT) ve/veya konik penetrasyon testi (CPT), makaslama dalgası hızı ( $V_s$ ) gibi yerinde uygulanan deney verilerinin de girdi olarak kullanıldığı yöntemlerle zeminlerin sıvılaşmaya karşı güvenlik katsayısı ( $F_L$ ) hesaplanabilmektedir. SPT, CPT ve  $V_s$  verilerini girdi olarak kullanan bu yöntemler ampirik yaklaşımlar olup, her ampirik yöntemde olduğu gibi artan veri sayısına bağlı olarak bu yöntemler de gelişmeye açıktırlar. Bu ampirik yaklaşımların şekillendirilmesinde kullanılan veriler sıvılaşmaya duyarlı alanlarda meydana gelen depremler sonucunda elde edildikleri için, yapay olarak üretilmeleri zor olup, bu nedenle verilerin bilimsel değerleri de oldukça yüksektir. SPT, CPT ve  $V_s$  verilerinin girdi olarak kullanıldığı üç yöntemde de sıvılaşmanın varlığı ile yokluğu arasındaki sınır eğrileri mevcut gerçek verilere uydurularak çizilmiş olup, analizlerde kullanılmak üzere bazı eşitliklerle tanımlanmışlardır. Diğer bir ifadeyle, bu eğrisel sınırların çizilmesinde analitik (veya bir hesabı dikkate alan) yaklaşımdan ziyade veriye dayalı uzmanların görüşleri kullanılmıştır.

Bu çalışma kapsamında, 1999 yılında Tayvan'daki Chi-Chi depremi sonrasında CPT deneylerinin de yapıldığı, sıvılaşma gözlenen ve gözlenmeyen sahalara ait olan ve Ku vd. (2004) tarafından raporlanan veri tabanı kullanılmıştır. Robertson ve Wride (1998) tarafından önerilen CPT tabanlı yaklaşımdaki normalize edilmiş konik uç direnci ( $q_{c1N}$ ) ve çevrimsel gerilim oranı ( $CSR_{7.5}$ ) girdi parametreleri olarak kullanılırken, sıvılaşmanın varlık (1) ve yokluk (0) bilgisi ise çıktı olarak kullanılmıştır.  $q_{c1N}$  ve  $CSR_{7.5}$  girdilerine bağlı olarak sıvılaşmanın varlığı (1) veya yokluğu (0) bilgisine analitik olarak ulaşmak için son yıllarda yerbilimleri alanında da başarıyla uygulanan yapay sinir ağı (Artificial Neural Network, ANN) öğrenme yöntemi kullanılmıştır. Öğrenme aşamasının devamında ise CPT tabanlı abaktaki  $q_{c1N}$  ve  $CSR_{7.5}$  değerlerinin olası kombinasyonları ANN modelinde girdi parametresi olarak kullanılarak 1 ile 0 arasında çıktı olarak elde edilen sıvılaşma varlığı veya yokluğuna yatkınlık değerleri ile hesaplanmıştır. Öğrenme sonrasında ANN modeliyle tüm abağı kapsayarak üretilen veri seti kullanılarak CPT tabanlı sıvılaşma değerlendirme abağı geliştirilmiştir.

**Anahtar Kelimeler:** Sıvılaşma, standart penetrasyon testi, konik penetrasyon testi, makaslama dalga hızı, yapay sinir ağı.

\* H.Sönmez

e-posta: haruns@hacettepe.edu.tr

**ABSTRACT**

Liquefaction phenomena occurred in the saturated non-cohesive (or low cohesive) soils during the earthquakes may cause many casualties and damages to humans and properties which may increase the structural damages in the affected areas. It is known that the saturated sandy and silty soils are more susceptible to liquefaction in the areas where the groundwater level is close to the ground surface with high seismicity zones. However, in this type of soils, factor of safety ( $F_v$ ) against liquefaction of soil can be calculated with some methods performed by the in-situ test data such as standart penetration test (SPT) and/or cone penetration test (CPT), representing the ground stiffness, shear wave velocity ( $V_s$ ) etc., used as inputs. These methodologies using the SPT, CPT and  $V_s$  data as inputs can be considered as the empirical methods at which they are open to modification, depending on the increase in the number of data, similar to almost every empirical methods. The data used in the forming of these empirical approaches which were obtained by the earthquakes occurred in the susceptible areas to liquefaction, it is difficult to produce them artificially, at which the scientific value of the data is quite high. These three methods, at which SPT, CPT and  $V_s$  data were used as inputs, were defined by some equations to be used in the analyses defined by the boundary curves between presence and non-presence of real liquefaction data. In other words, rather than the analytic approaches (or calculations that takes into account), data based expert opinions were considered while drawing of these curvilinear boundaries.

In this study, after the Chi-Chi earthquake in Taiwan in 1999, where CPT tests were performed and reported by Ku et al. (2004), the database characteristics, belonging to the observed and unobserved liquefaction areas, were used. Normalized conical tip resistance value ( $qc_{1N}$ ) and cyclic stress ratio ( $CSR_{7.5}$ ) in the CPT-based approach proposed by Robertson ve Wride (1998) were used as input parameters, while the presence (1) and non-presence (0) liquefaction data were the outputs. To achieve the presence (1) and non-presence (0) liquefaction data analytically, considering the  $qc_{1N}$  and  $CSR_{7.5}$  as inputs, artificial neural network learning method, successfully applied in the earth sciences in recent years, has been used. Following the learning stage, possible combinations of  $qc_{1N}$  and  $CSR_{7.5}$  in the CPT-based chart were used as the inputs in the ANN model to calculate the propensity values as the outputs, ranging from 0 to 1, to liquefaction existence or not. Finally, CPT-based liquefaction prediction chart, including all data sets produced by ANN model, was developed.

**Keywords:** Liquefaction, standart penetration test, cone penetration test, shear wave velocity, artificial neural network

**GİRİŞ**

Japonya'da 1964 yılında meydana gelen Niigata ve Alaska depremlerinde yaygın olarak gözlenen sıvılaşma olayı pek çok yapısal hasarlara ve can kayıplarına neden olmuş ve sıvılaşma olgusu konusunda günümüze kadar ulaşan sıvılaşma ve sıvılaşmaya bağlı zemin duraysızlıklarına ilişkin çok sayıdaki araştırmaların da başlangıcı olmuştur. Ülkemizde sıvılaşma ile ilişkili yapısal hasarların gözlemlenmesine yönelik bulguların izlendiği bazı depremlerin daha önce de yaşanmasına karşın, 13 Mart 1992 yılında meydana gelen Erzincan depremi ile birlikte sıvılaşma olayı Türkiye'de daha fazla dikkate alınmaya başlanmıştır (Aydan vd., 2000). Buna karşın 1998 Adana-Ceyhan ve hemen bir yıl sonra 1999 Kocaeli ve Düzce depremlerinde de zemin sıvılaşması yaygın bir şekilde gözlenmiş ve çok sayıdaki bilimsel çalışmaya da konu olmuştur. 1999 yılın-

da Tayvan'daki Chi-Chi depreminde de yaygın sıvılaşma alanları tespit edilmiş ve deprem sonrasında bu bölgelerde yapılan çalışmalar sonucunda pek çok sıvılaşma verisi raporlanmıştır.

Zemin sıvılaşmasının değerlendirilmesinde dikkate alınan yaklaşımları, (i) jeolojik ölçütler, (ii) jeomorfolojik ölçütler, (iii) zemin kompozisyonu ölçütleri ve (iv) ampirik sıvılaşma analizleri olmak üzere dört başlık altında değerlendirmek mümkündür (Ulusay, 2010). Jeolojik, jeomorfolojik ve zemin kompozisyonuna yönelik değerlendirme ölçütleri sıvılaşmaya yatkınlık yönünden tanımlayıcı yaklaşımlar olup, bu nedenle sadece ön değerlendirme amacıyla kullanılabilirler. Buna karşın, deprem sırasında zeminin dayanımının bir ifadesi olan tekrarlı dayanım oranının (Cyclic Resistance Ratio, CRR) depremin o lokasyonda yarattığı tekrarlı gerilim oranına (Cyclic Stress Ratio, CSR) bölünmesiyle elde edilen sıvılaşma-

ya karşı güvenlik katsayısı ( $F_L$ ) ise ampirik analiz ölçütü olarak literatürde yerini almış ve yaygın olarak kullanıla gelmiştir.

Bu çalışma kapsamında, CPT deneyi ile elde edilen normalize edilmiş konik uç direncine ( $q_{c1N}$ ) bağlı olarak CRR'nin belirlendiği Robertson ve Wride (1998) tarafından önerilen abaktaki sıvılaşmanın varlığı (1) ve yokluğu (0) arasındaki ampirik eğrisel sınır çizgisi, son yıllarda yaygın olarak yerbilimleri alanında da kullanılan yapay sinir ağı (Artificial Neural Network, ANN) modellemesi ile belirlenmiştir.

### CPT ile SIVILAŞMA ANALİZİ

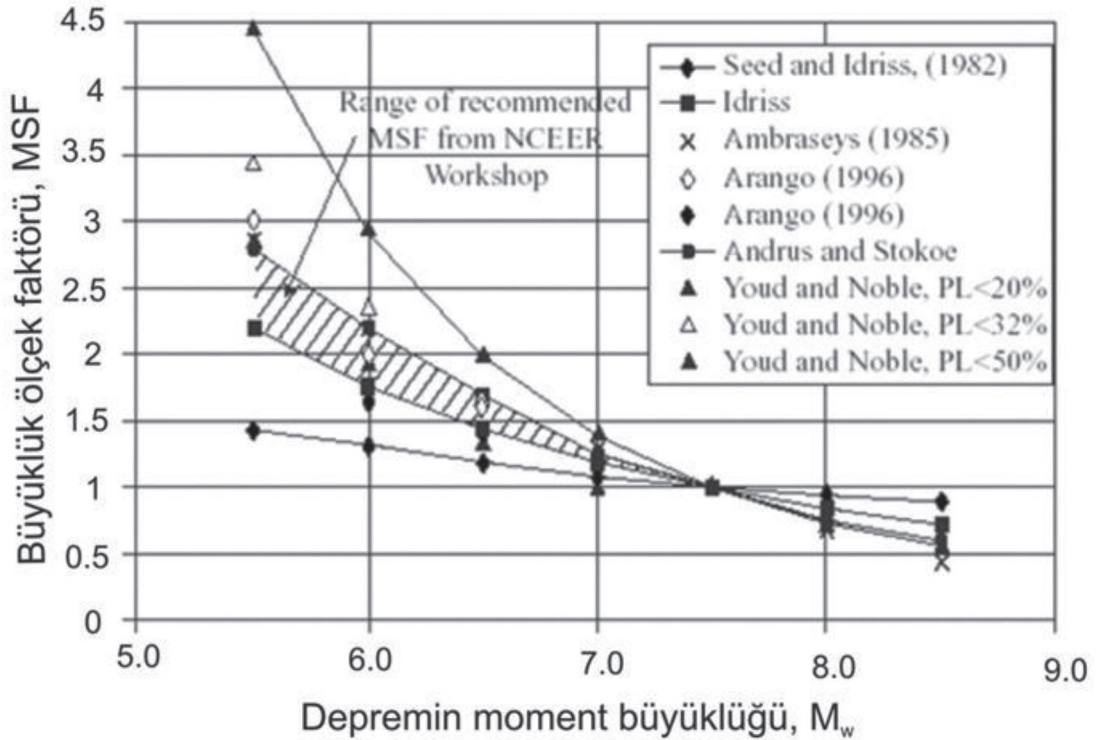
Bu çalışmada CPT deneyinden itibaren sıvılaşmaya karşı güvenlik katsayısının hesaplanmasında kullanılmak üzere CRR'nin belirlenmesine yönelik abaktaki sınır çizgileri yapay sinir ağı (ANN) modellemesi kullanılarak geliştirilmiştir. Bu nedenle, makalede bütünlüğün sağlanabilmesi için CPT ile sıvılaşma analizi de literatürde sıklıkla tercih edildiği ve Youd ve Idriss (2001)

tarafından önerildiği şekliyle aşağıda kısaca özetlenmiştir.

Sıvılaşmaya karşı güvenlik katsayısı ( $F_L$ ) bir senaryo deprem sırasında suya doymun toprak zeminde sıvılaşmanın gelişip gelişmeyeceğinin bir ölçüsüdür. Sıvılaşmaya karşı güvenlik katsayısı zeminin dayanımının bir ifadesi olan tekrarlı dayanım oranının (CRR) depremin analizi yapılan noktada yaratacağı tekrarlı gerilim oranına bölünmesiyle elde edilir (eşitlik (1)).

$$F_L = \frac{CRR}{CRS} \times MSF \quad (1)$$

Yukarıdaki eşitlikte MSF, deprem büyüklüğü ölçek faktörü olup, 7.5 büyüklüğündeki bir depreme göre elde edilen  $F_L$  üzerinde uygulanan bir düzeltmedir. Deprem büyüklüğüne bağlı olarak MSF'nin seçilmesine yönelik bazı araştırmacıların önerileri Şekil 1'de verilmiştir. Seed ve Idriss (1971) tarafından önerilen (2) no.lu eşitlik ortalama değer vermesi yönüyle pratikte



Şekil 1. MSF ile  $M_w$  arasında farklı araştırmacıların önerdiği ilişkiler (Youd ve Idriss, 2001).

Figure 1. The relations proposed by different researchers between MSF and  $M_w$  (Youd and Idriss, 2001).

MSF'nin seçilmesi için tercih edilebilir. Bu eşitlikte  $M_w$  depremin moment büyüklüğüdür.

$$MSF = \frac{10^{2.24}}{M_w^{2.56}} \quad (2)$$

Depremin analizi yapılan noktada oluşturacağı tekrarlı gerilim oranı (CSR) ise Seed ve Idriss (1971) tarafından önerilen eşitlik (3) kullanılarak hesaplanabilir.

$$CSR = 0.65 \frac{\sigma_v}{\sigma'_v} \frac{a_{\max}}{g} r_d \quad (3)$$

Yukarıdaki eşitlikte  $a_{\max}$  maksimum yatay yer ivmesi,  $g$  (gal) yerçekimi ivmesi,  $r_d$  zemin kolunun sonsuz rijit olmamasından kaynaklanan bir düzeltmedir.  $\sigma_v$  ve  $\sigma'_v$  ise sırasıyla düşey toplam gerilme ile düşey efektif gerilmedir. Youd ve Idriss (2001)  $r_d$  parametresinin derinliğe ( $z$ , metre) bağlı olarak eşitlik (4) kullanılarak hesaplanabileceğini Seed ve Idriss (1971)'in çalışmasını dikkate alarak önermektedirler.

$$r_d = \frac{(1.000 - 0.4113z^{0.5} + 0.04052z + 0.001753z^{1.5})}{(1.000 + 0.4177z^{0.5} + 0.05729z - 0.006205z^{1.5} + 0.001210z^2)} \quad (4)$$

Zeminin deprem sırasındaki dayanımının bir ifadesi olan tekrarlı dayanım oranı (CRR) ise; standart penetrasyon testi (SPT), konik penetrasyon testi (CPT), Becker penetrasyon testi (BPT) veya makaslama dalgası hızı ( $V_s$ ) gibi saha deneylerinin sonuçları kullanılarak belirlenebildiği gibi özel yöntemlerle alınmış örselenmemiş örnekler üzerinde yapılacak dinamik basit kesme deneyleriyle de belirlenebilmektedir.

Bu çalışmanın amacı dikkate alınarak CRR'nin belirlenmesine yönelik yöntemler burada verilmiş olup, CPT ile belirlenen normalize edilmiş konik uç direncinden ( $q_{c1N}$ ) itibaren CRR'nin hesaplanabilmesi için yapay sinir ağı modellenmesi ile hazırlanan abağın geliştirilmesi ise aşağıda ayrıntılı olarak sunulmuştur.

## VERİ TABANININ ÖZELLİKLERİ

CRR'nin CPT deneyiyle belirlenmesinde kullanılan abak, uzman yaklaşımıyla geliştirilmiş ampirik yaklaşımın sonucu oluşturulan bir abaktır. Tüm ampirik modellerde olduğu gibi bu yaklaşım da gelişmeye açık olup, bu çalışmada uzman görüşünden ziyade gerçek veri kullanılarak basit bir ANN mimarisi ile öncelikle öğrenme

aşaması çalıştırılmış ve sonrasında da genelleme en yüksek öğrenme aşaması kullanılarak  $q_{c1N}$ 'den itibaren CRR'nin belirlenmesine yönelik abak hazırlanmıştır.

Tayvan'daki 1999 Chi-Chi depremi sonrasında Yuanlin, Nantou and Wufeng bölgelerinde yaygın bir şekilde zemin sıvılaşmaları gözlenmiştir. Ulusal Deprem Araştırma Merkezi (National Center for Research on Earthquake Engineering, NCREE) tarafından bu bölgelerde ayrıntılı araştırmalar yürütülmüş olup, Yuanlin, Nantou, Wufeng ve the Chang-Bin endüstriyel park bölgelerindeki CPT deneylerinin de yer aldığı veriler Ku vd. (2004) tarafından hazırlanan raporda sunulmuş olup, veri tabanı bu çalışma kapsamında da kullanılmıştır. Chi-Chi depreminde kuvvetli yer hareketleri ölçüm istasyonlarında en büyük yer ivmeleri 121.3 gal ile 774.42 gal arasında ölçülmüştür.


Bu çalışmada girdi parametresi olarak kullanılan  $q_{c1N}$  ve  $CSR_{7.5}$  istatistiksel dağılımları Şekil 2'de verilmiştir.

## CPT TABANLI SIVILAŞMA ABAĞININ ANN İLE ÜRETİLMESİ


Ku vd. (2004),  $q_{c1N}$  ile  $CSR_{7.5}$  abağı üzerinde derledikleri verileri sıvılaşmanın varlık (1) ve yokluk (0) değerleriyle birlikte değerlendirmişler ve eşitlik (5)'teki eğrisel ilişkinin kullanılabileceğini belirtmişlerdir. Bu eğrisel sınır sıvılaşmanın yokluk (0) bilgisine sahip verilere olabildiğince yakın çizilmiştir (Şekil 3).

Ku vd. (2004), 1999 Chi-Chi depreminden sonra yürütülen kapsamlı araştırmalarla derlenen verileri kullanarak  $q_{c1N}$ 'den itibaren sıvılaşma için gerekli sınır  $CSR_{7.5}$  değerinin belirlenmesi için kritik sınır eğrisini uzman yaklaşımıyla olabildiğince sıvılaşmanın olmadığı verilere yakın bir şekilde uyarlamışlardır (Şekil 3). Aynı abak üzerinde Robertson ve Wride (1998)'in ince tane oranının %35, %15 ve %5 değerlerine bağlı olarak önerdikleri eğrilerde karşılaştırmalarının yapılabilmesi için verilmiştir.

Bu çalışma kapsamında tüm veri seti kullanılarak uzman görüşü de dahil hiç bir müdahalede bulunmadan sadece verinin yönlendirmesi dahilinde yapay sinir ağı (ANN) modellenmesiyle



Şekil 2. Veri tabanındaki parametrelerin istatistiksel grafikleri (a)  $q_{c1N}$  ve (b)  $CSR_{7.5}$ .  
Figure 2. Statistical graphs of parameters in the database (a)  $q_{c1N}$  ve (b)  $CSR_{7.5}$ .



Şekil 3.  $q_{c1N}$  ile CSR abağı üzerinde 1999 Chi-Chi depreminden sonra derlenen verilerin sivilaşmanın varlık (1) ve yokluk (0) bilgileriyle birlikte sunumu (Ku vd., 2004).  
Figure 3. The presentation of the presence (1) and non-presence (0) liquefaction data collected after the 1999 Chi-Chi earthquake on the  $q_{c1N}$  and CSR chart (Ku et al., 2004).

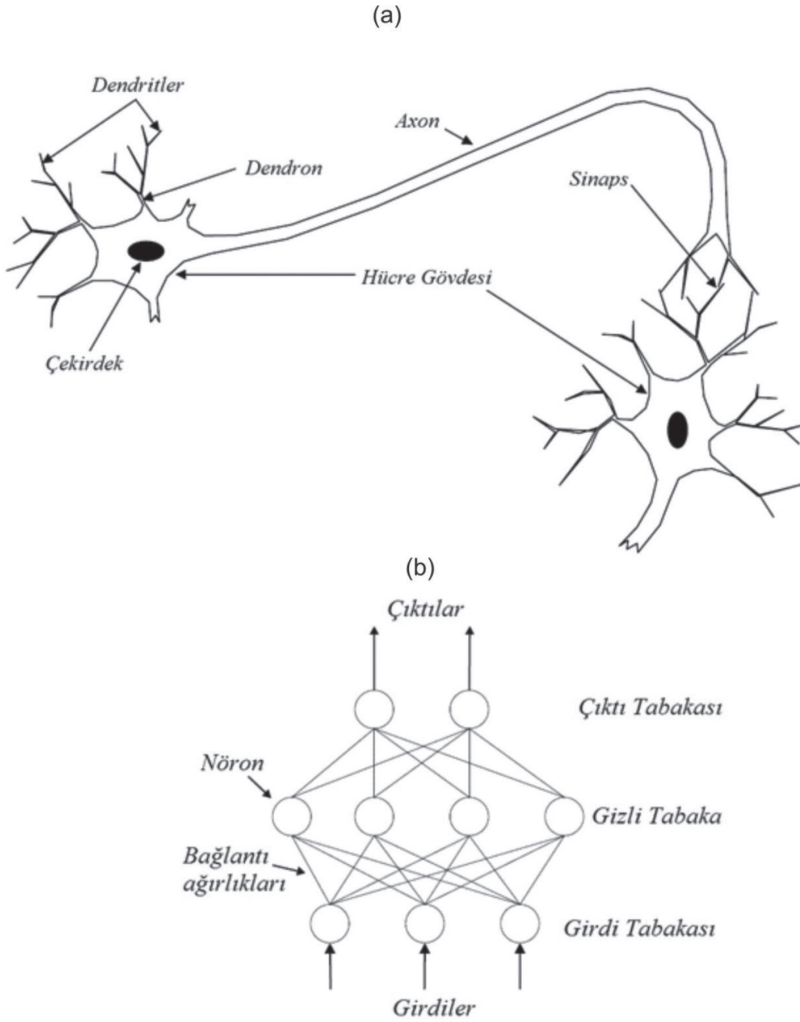
$q_{c1N}$  ile  $CSR_{7.5}$  arasındaki ilişki sıvılaştırmanın varlığı (1) ve yokluğu (0) şeklinde belirlenmiştir.

Bulanık mantık, yapay sinir ağları gibi esnek hesaplama araçları son 15 yılda yoğun olarak yerbilimleri alanında başarılı bir şekilde kullanılmaktadır (Goh vd., 1995; Shi vd., 1998; Neaupane ve Achet 2004; Lee vd., 2003; Gomez ve Kavzoğlu 2005; Ermini vd., 2005; Yeşilnacar ve Topal 2005; Aksoy ve Ercanoğlu, 2006; Sönmez vd., 2006; Sönmez vd., 2014). Çoğu kez birbirleriyle doğrusal olmayan ilişkilere sahip karmaşık problemlerin çözümünde esnek hesaplama araçları oldukça güçlü yaklaşımlardır. Bununla birlikte, bu araçların kullanımında genelleme kapasitesi yeterince kontrol edilmeden aşırı öğrenme veya sadece veriyi taklit eden so-

nuçlarda elde edilebilmektedir. Bu nedenle esnek hesaplama araçlarının kullanımında sonuçların ve girdi parametreleriyle çıktı parametreleri arasındaki yönelim ilişkilerinin anlamlılığının da dikkatli bir şekilde değerlendirilmesi gereklidir.

Yapay Sinir Ağları (ANN), insanoğlunun merkezi sinir sistemine benzer bir şekilde çalışan bir sistemdir. İnsan sinir sisteminin temelini, nöron adı verilen sinir hücreleri oluşturmaktadır ve nöronlar, dendrit, dentronit, gövde, sinaps ve akson adı verilen beş adet temel bileşenden oluşmaktadır. Biyolojik ve yapay sinir ağlarının yapısı, Şekil 4'de sunulmaktadır.

Aşağıda sözü edilen bileşenleri ve çalışma ilkesini temel alan ANN, farklı disiplinlerde uygula-



Şekil 4. (a) Biyolojik sinir ağı ile (b) yapay sinir ağının karşılaştırılması (Huang ve Wandstedt, 1998).

Figure 4. Comparison of (a) biological neural networks and (b) artificial neural network (Huang and Wandstedt, 1998).

ma alanı bulmakta, özellikle sınıflama ve matematiksel modellemelerde, doğru kullanıldığı takdirde, son derece başarılı sonuçlar üretmektedir. Genel olarak ele alındığında ANN, girdi, gizli ve çıktı tabakalarından oluşan ve aşamalı bir yapıya sahip olup, parametrik ilişkilerin ifade edilmesinde, analizinde ve sınıflandırılmasında son derece kullanışlı bir sistem olarak değerlendirilmektedir (Alvarez Grima, 2000). ANN'nin; dinamik, esnek ve doğrusal olmayan ilişkileri ifade edebilme özelliklerinden dolayı, yazılımsal ve donanımsal gelişmelere de koşut olarak, önemli gelişmeler kaydedilmiştir. Bunun sonucunda da YSA, otomasyon, nükleer enerji, kimya, yerbilimleri, bilgisayar mühendisliği gibi, birbirinden çok farklı disiplinlerde yaygın bir kullanım alanı bulmuştur (Huang ve Wanstedt, 1998).

Genel olarak ANN tahmin, sınıflama, veri üretimi vb. amaçlar için kullanılmaktayken, yapılacak çalışmanın amacı ve türüne göre de ağ yapısı ve/veya algoritmalar da değişim gösterebilmektedir. ANN uygulamalarının en önemli aşamasını eğitime aşaması oluşturmaktadır. Eğitime aşamasında, uygulamalarda sıklıkla kullanılan algoritmalara, İleri Beslemeli Geri Yayılımlı (İBGY), Levenberg-Marquardt, Hızlı yayılım algoritmaları örnek olarak gösterilebilir. Bu çalışmada, İBGY eğitime algoritması dikkate alınmıştır. ANN'nin ağırlık değerleri, geri besleme boyunca kabul edilebilir hata sınırına ulaşmaya kadar değiştirilerek, sistem tarafından ayarlanmaktadır.

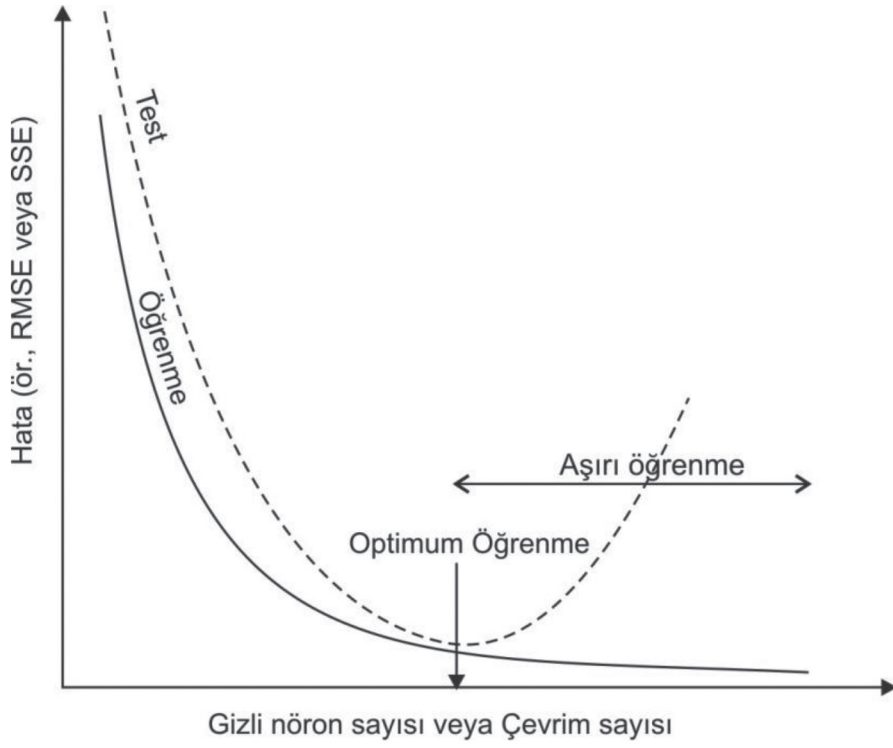
Bu çalışmada kestirim (tahmin) modellemelerinde literatürde de yaygın bir şekilde tercih edilen ileri beslemeli geri yayılımlı yapay sinir ağı modeli kullanılmıştır (Goh vd., 1995; Shi vd., 1998; Neaupane ve Achet 2004; Lee vd., 2003; Gomez ve Kavzoğlu, 2005; Ercanoğlu, 2005; Ermini vd., 2005; Yeşilnacar ve Topal 2005; Sönmez vd., 2006; Sönmez vd., 2014). Girdi, gizli ve çıktı seviyelerinden oluşan en basit ANN modelinde 1 gizli seviye sayısı kullanılırken, problemin karmaşıklığına da bağlı olarak gizli seviye sayısı artırılabilir. Her seviyede sinirler (neurons) bulunmakta olup, seviyeler arasındaki sinirler birbirlerine ağırlıklı olarak bağlıdır. ANN modelinde diğer bir önemli husus ise gizli seviye(ler)deki sinir (neuron) sayısıdır. Sinir sayısının artırılması modelin kestirim performansını arttırmaktadır.

Bununla birlikte sinir sayısındaki aşırı değerler ise modelin genelleme kapasitesini düşürmekte ve veriye öğrenmeden uzaklaşarak aşırı öğrenmeye, diğer bir ifadeyle verilerinin ezberlenmesine yönelmektedir (Şekil 5).

Kullanılan veri sayısına bağlı olarak ANN modelindeki gizli seviye(ler)de kullanılabilecek sinir sayısının ön görülmesi için bazı sezgisel yaklaşımlarda bulunmaktadır. Bu yaklaşımlardan sıklıkla dikkate alınan bazıları Çizelge 1'de verilmiş olup, iki girdi ve parametresi ( $q_{c1N}$  ve  $CSR_{7,5}$ ) ve bir çıktı parametresi (sıvılaştırmanın varlık bilgisi) için gizli seviyelerde kullanılabilecek sinir sayıları da aynı tabloda görülmektedir. Bu çalışma için iki girdi ve bir çıktı parametresiyle yapılandırılacak ANN modelinde sezgisel yaklaşımlara göre gizli seviye(ler)deki toplam sinir hücresi sayısının 2 ile 6 arasında değiştiği görülmektedir.

Bu çalışmada ANN modelinin kestirim performansında aşırılığa gidilmeden genelleme kapasitesinin yüksek olmasına özen gösterilmiş ve gizli seviyede 2 sinir hücresi kullanılarak ANN modeli 2x2x1 mimarisinde yapılandırılmıştır (Şekil 6).

Yapay sinir ağının öğrenme, test ve veri üretimi aşamalarında Dr. H. Sönmez tarafından geliştirilen ANNES isimli ANN yazılımı kullanılmıştır. Girdi ve çıktı parametreleri ANNES yazılımında 0 ile 1 arasında normalize edilerek girilmektedir. Bu nedenle,  $CSR_{7,5}$  değerleri 0 ile 1 arasında değiştiği için doğrudan girilirken,  $q_{c1N}$  ise en büyük değeri dikkate alınarak 200'e bölünerek 0 ile 1 arasında normalize edilmiştir. Literatürdeki yaygın kullanım değerleri dikkate alınarak öğrenme katsayısı 0.1 olarak seçilirken, momentum katsayısı ise 0.95 olarak seçilmiştir. Toplam 134 veri setinin %25'i test veri seti (34 adet) olarak rastgele seçilmiş ve geriye kalan %75'i ise öğrenme veri seti (100 adet) olarak kullanılmıştır. ANNES programında öğrenme aşamasındaki durdurma kriteri için en fazla 10000 çevrim ve RMSE (root mean square error) 0.001'in altına inmesi şeklinde iki tanım kullanılmıştır. ANNES programının çalıştırılması sonrasında çevrim sayısına karşılık öğrenme ve test verilerindeki RMSE değerlerinin değişimi Şekil 7'de görülmektedir. Öğrenme verilerinde kestirimdeki hatayı ifade eden RMSE değeri sürekli azalırken, test verilerinde RMSE




Şekil 5. Eğitim aşamasının sonlandırılması ve optimum ağ mimarisi seçim ölçütü (Basheer ve Hajmeer, 2000).  
Figure 5. A criteria for termination of training and selection of optimum network architecture (Basheer and Hajmeer, 2000).

Çizelge 1. Gizli seviyedeki sinir sayısının belirlenmesine yönelik bazı sezgisel yaklaşımlar.  
Table 1. Some heuristic approaches to determine the number of neuron in the hidden level.

Sezgisel yaklaşım	Bu çalışma için hesaplanan sinir sayısı	Kaynak
$\leq 2 \times N_i + 1$		Hecht-Nielsen (1987)
$3N_i$	6	Hush (1989)
$(N_i + N_o) / 2$	2	Ripley (1993)
$2N_i / 3$	2	Wang (1994)
$\sqrt{N_i \times N_o}$	2	Masters (1994) Kaastra ve Boyd (1996)
$2N_i$	4	Kannelopoulos ve Wilkinson (1997)

$N_i$ : girdi sinir sayısı ve  $N_o$ : çıktı sinir sayısı ( $N_i=2$  ve  $N_o=1$ ). Sezgisel ilişkiden çıkan ondalıklı sonuçlar yukarı tam sayıya yuvarlanmıştır.





Şekil 6. Kurgulanan 2x2x1 ANN mimarisini.  
Figure 6. Constructed 2x2x1 ANN architecture.

değeri çevrim sayısının ~70 değerine (1. aşama) ulaşmasından sonra artmaya başlamış, çevrim sayısının ~400 değerinden sonra tekrar azalmaya başlamış ve ~2000 (2. aşama) değerinden sonra yine artmaya başlamıştır. Öğrenme verilerinde RMSE'nin sürekli azalması da dikkate alınarak Şekil 7'de 2.aşama olarak işaretlenen çevrim sayısı=2000 optimum öğrenme aşaması olarak seçilmiştir. ANN mimarisinin çevrim sayısı=2000 için öğrenme ve test verilerindeki kestirim performansı Şekil 8'de irdelenmiştir. Şekil 8'den de görüleceği üzere gerek öğrenme ve gerekse test verilerinin önemli çoğunluğunda sivilaşma var (1) olanlar 0.9'dan büyük olarak belirlenirken, sivilaşma yok (0) olanlar ise 0.2'den düşük olarak belirlenmiştir. Sadece bir kaç veri dışında kurgulanan ANN modelinin kestirim performansının yeterli düzeyde genelmeye ulaştığı kabul edilebilir.

Tek gizli katmanda 2 sinir ile 2x2x1 olarak kurgulanan basit ANN modeli yukarıdaki değerlendirmeden de görüleceği üzere yeterli genelleme kapasitesi ile CPT tabanlı sivilaşma varlık ve yokluk sınırının belirlenmesi için kullanılmıştır. Bu amaçla  $q_{c1N}$  10'dan 200'e kadar 10'ar artırılmış ve  $CSR_{7.5}$  ise 0.025'den 0.9'a kadar 0.025'er artırılarak tüm abakı tarayacak şekilde toplam 840  $q_{c1N}$  ve  $CSR_{7.5}$  veri çifti hazırlanmıştır (Şekil 9).


Bu veri çiftleri 2x2x1 ANN modelinin optimum

öğrenme aşamasında (çevrim sayısı=2000) sivilaşma varlık değeri ANNES ile hesaplatılmıştır. Hesaplanan varlık değerleri konturlanarak Ku vd. (2004) tarafından hazırlanan abakın üzerine yerleştirilmiştir (Şekil 10).

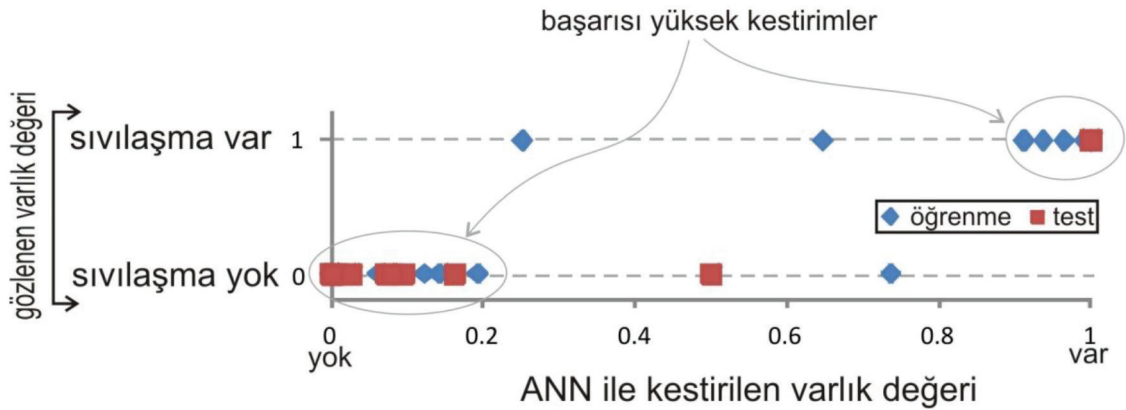
Abakın oluşturulmasında limit denge koşulu dikkate alınarak  $CSR_{7.5}$  bağımlı değişken olarak kullanılırken, olası bir deprem senaryosu için  $CSR_{7.5}$  Eşitlik 3'ten belirlenmekte abaktaki sınır eğrilerinden ise zeminin tekrarlı yükler altındaki sivilaşmaya karşı gösterebileceği dayanımının bir ölçüsü olan  $CRR_{7.5}$  belirlenmektedir. Bu nedenle Şekil 11'de verilen abakta bu eksen  $CRR_{7.5}$  olarak gösterilmiştir.

## SONUÇLAR ve TARTIŞMA

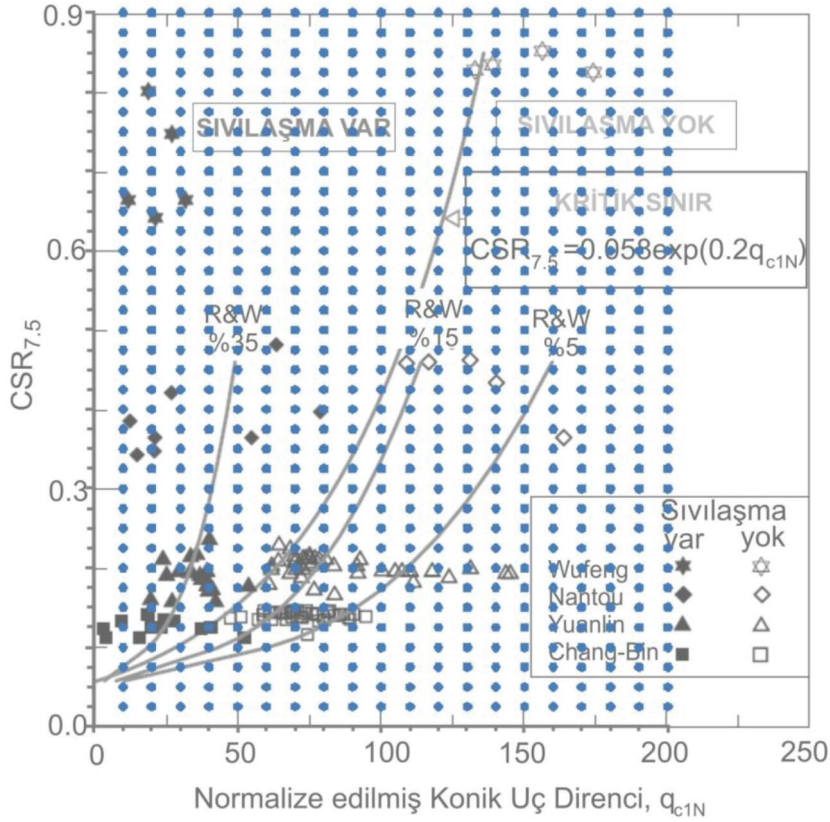
Depremler sırasında suya doygun özellikle kumlu siltli zeminlerde gelişen zemin sivilaşması sivilaşmaya bağlı zemin sorunlarını arttırmakta ve yapısal hasarların artmasına ve can kayıplarına neden olmaktadır. Güvenlik katsayısının hesaplandığı sivilaşma analizlerinde SPT, CPT, kayma dalgası hızı ölçümü gibi saha deneyleri kullanılarak zeminin tekrarlı yükler altındaki sivilaşmaya karşı gösterebileceği dayanımının bir ölçüsü (CRR) kullanılarak olası bir deprem senaryosu için değerlendirmeler yapılabilmektedir. Bu çalışmada, CPT deneyinden itibaren CRR'nin belirlendiği abak 1999 Chi-Chi depremine ait Ku vd. (2004) tarafından raporlanan



Şekil 7. Öğrenme ve test verilerinin kestirimlerinde çevrim sayısına bağlı olarak RMSE değışimleri.  
Figure 7. The RMSE changes depending of the number of cycles in the prediction of training and testing data.



Şekil 8. ANN modelinin kestirim performansının değeriendirilmesi.  
Figure 8. The evaluation of the prediction performance of the ANN model.



Şekil 9. CPT tabanlı sıvılaşma abağının hazırlanmasında kullanılan veri setinin dağılımı.

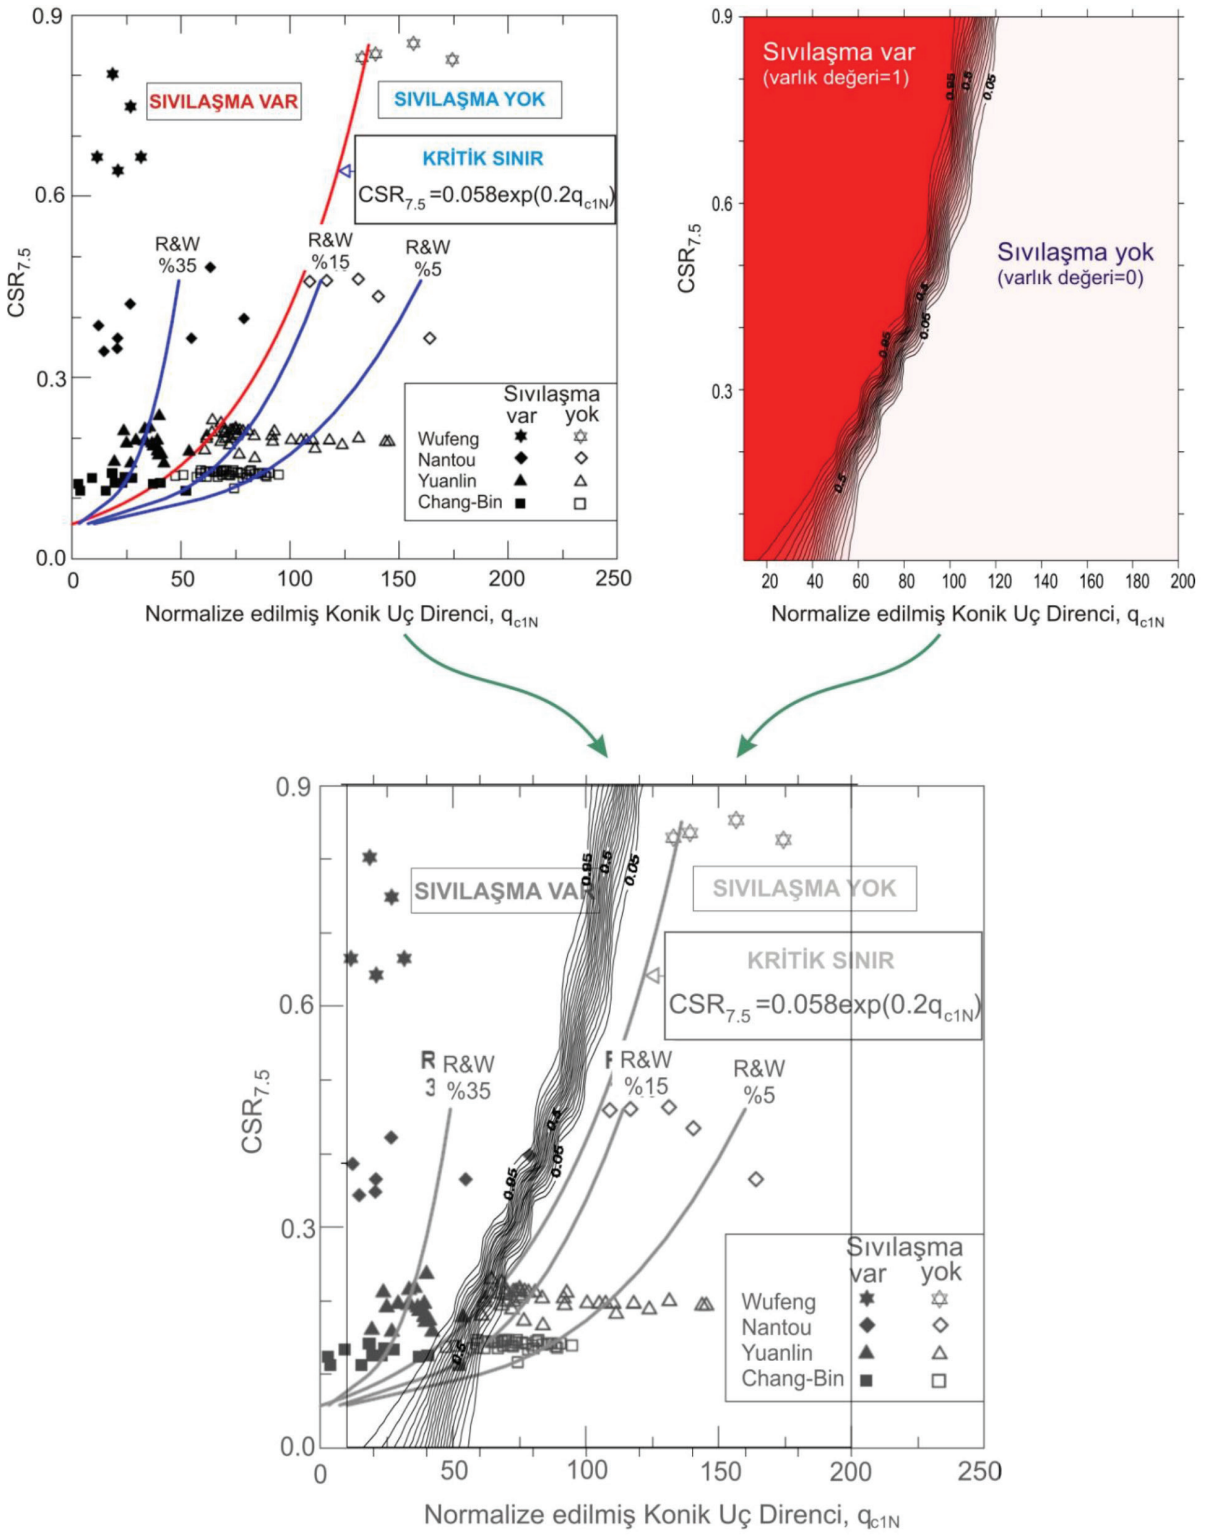
Figure 9. The distribution of the database used for the preparation of CPT-based liquefaction chart.

veriler kullanılarak yapay sinir ağı (ANN) geliştirilmiştir. Zemine ait CRR'nin belirlenmesinde her ne kadar CPT ile belirlenen  $q_{c1N}$  karakteristik bir girdi parametresiye de zeminin ince tane oranı, tane şekli gibi özellikleri bazı belirsizlikler yaratabilmektedir. Sıvılaşma analiz abaklarının kullanımında Youd ve Idriss (2001) ve Robertson ve Wride (1998)'de olduğu gibi bu tür parametreler de dikkate alınmaya çalışılmaktadır. Bununla birlikte bu tür belirsizliklerden dolayı olasılık kuramının kullanıldığı çalışmalarda mevcuttur (Çetin vd., 2002; Çetin ve Ozan, 2009; Kayen vd., 2013). Sonuç olarak, 1999 Chi-Chi depremine ait veriler kullanılarak ANN ile geliştirilen abağın kullanımında da bazı belirsizliklerin değerlendirme sonuçlarına yansımaları beklenen bir durumdur. Bu nedenle bu etkilerin güvenlik

katsayısının seçiminde dikkate alınması yerinde olacaktır.


Şekil 11'deki abak kullanılarak  $M_w=7.5$  büyüklüğündeki bir deprem sırasında sıvılaşma analizi yapılan zeminin çevrimsel dayanım oranı ( $CRR_{7.5}$ ) normalize edilmiş konik uç direnci için belirlenebilmektedir. Uygulama pratiğinin de sağlanabilmesi amacıyla  $q_{c1N}$  ile  $CRR_{7.5}$  arasında sıvılaşmanın varlık ve yokluk sınırı için belirlenen eğrisel ilişki formülize edilmiş ve eşitlik 5'te verilmiştir.

$$CRR_{7.5} = \frac{1.1145 - \left[ \frac{10\pi - (10\pi)^{\left( \frac{0.8333q_{c1N}}{100} \right)}}{(10\pi - 1)} \right]}{1.3473} \quad (q_{c1N} < 120) \quad (5)$$



Şekil 10. ANN ile hesaplanan varlık (1) verisine göre konturlanmış CPT tabanlı sıvılaşma abağı ve Ku vd. (2004)'nin abak üzerindeki durumu.

Figure 10. The CPT-based liquefaction chart contoured with the presence (1) data calculated by ANN and the status of Ku et al. (2004) on the chart.



Şekil 11. Çalışma kapsamında 1999 Chi-Chi depremi verileri kullanılarak ANN ile geliştirilen CPT tabanlı sıvılaşma abağı.

Figure 11. CPT-based liquefaction chart developed by ANN using 1999 Chi-Chi earthquake data.

**KATKI BELİRTME**

Yazarlar 1999 Chi-Chi depremine ait sıvılaşma ve CPT verilerinin kullanımına izin veren Prof. Dr. C. Hsein Juang'a teşekkür ederler.

**KAYNAKLAR**

- Aksoy, H., ve Ercanoğlu, M., 2006. Determination of the rockfall source in an urban settlement area by using a rule-based fuzzy evaluation, *Natural Hazards and Earth System Science*, 6, 941-954.
- Alvarez Grima, M., 2000. Neuro-fuzzy Modelling in Engineering Geology, Balkema, Rotterdam, 244p.
- Ambraseys, N., 1985. Intensity-attenuation and magnitude-intensity relationships for northwest European earthquakes. *Journal of Earthquake Engineering & Structural Dynamics*, 3, 733-778.
- Andrus, R. D., ve Stokoe, K. H., 2000. Liquefaction resistance of soils from shear-wave velocity, *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, 126, 11, 1015-1025.
- Arango, I., 1996. Magnitude scaling factors for soil liquefaction evaluations, *Journal of Geotechnical Engineering*, ASCE, 122, 11, 929-936.
- Aydan, Ö., Ulusay, R., Kumsar, H. ve Tuncay, E., 2000. Site investigation and engineering evaluation of the Düzce-Bolu Earthquake of November 12, 1999, Turkish Earthquake Foundation, TDV/DR 095-51, 307.
- Basheer, I.A., ve Hajmeer, M., 2000. Artificial neural networks: fundamentals, computing, design, and application, *Journal of Microbiological Methods*, 43, 3-31.
- Çetin, K.Ö., Der Kiureghian, A., ve Seed, R.B., 2002. Probabilistic models for the initiation of seismic soil liquefaction, *Structural Safety*, 24, 67-82.
- Çetin, K.Ö. ve Ozan, C., 2009. CPT-Based Probabilistic Soil Characterization and Classification, *Journal of Geotechnical and Geoenvironmental Engineering*, 135, 1, 84-107.
- Ercanoğlu, M., 2005. Landslide susceptibility assessment of SE Bartın (West Black Sea Region, Turkey) by artificial neural networks, *Natural Hazards and Earth System Science*, 5, 979-992.
- Ermini, L., Catani, F., ve Casagli, N., 2005. Artificial Neural Networks applied to landslide susceptibility assessment, *Geomorphology*, 66, 327-343.
- Goh, A.T.C., Wong, K.S., ve Broms, B.B., 1995. Estimation of lateral wall movements in braced excavations using neural networks, *Can Geotechnical Journal*, 32, 1059-1064.
- Gomez, H., ve Kavzoğlu, T., 2005. Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela, *Engineering Geology*, 78, 11-27.
- Hecht-Nielsen, R., 1987. Kolmogorov's mapping neural network existence theorem, *Proceedings of the First IEEE International Conference on Neural Networks*, USA, 11-14.
- Huang, Y., ve Wanstedt, S., 1998. Application of Kalman learning algorithm multilayer neural network to estimates of ore grades, *International Journal of Mining, Reclamation and Environment*, 12, 19-27.
- Hush, D.R., 1989. Classification with neural networks: a performance analysis, *Proc. of the IEEE International Conference on Systems Engineering*, USA, 277-280.
- Kaastra, I., ve Boyd, M., 1996. Designing a neural network for forecasting financial and economic time series, *Neurocomputing*, 10, 3, 215-236.
- Kanellopoulos, I., ve Wilkinson, G.G., 1997. Strategies and best practice for neural network image classification, *International Journal of Remote Sensing*, 18, 711-725.
- Kayen, R., Moss, R.E.S., Thompson, E.M., Seed, R.B., Çetin, K.Ö., Der Kiureghian, A., Tanaka, Y., ve Tokimatsu, K., 2013. Shear-Wave Velocity-Based Probabilistic and Deterministic Assessment of

- Seismic Soil Liquefaction Potential, *Journal of Geotechnical and Geoenvironmental Engineering*, 140,4, 07014006.
- Ku, C.S., Lee, D.H., ve Wu, J.H., 2004. Evaluation of soil liquefaction in the Chi-Chi, Taiwan earthquake using CPT, *Soil Dynamics and Earthquake Engineering* 24, 9-10, 659-673.
- Lee, S., Ryu, J.H., Lee, M.J., ve Won, J.S., 2003. Use of an artificial neural network for analysis of the susceptibility to landslides at Boun, Korea, *Environmental Geology*, 44, 820-833.
- Masters, T., 1994. *Practical Neural Network Recipes in C++*, Academic Press, ISBN 0-12-479040-2.
- Neaupane, K.M., ve Achet, S.H., 2004. Use of backpropagation neural network for landslide monitoring: a case study in the higher Himalaya, *Engineering Geology*, 74, 213-236.
- Ripley, B.D., 1993. Statistical aspects of neural networks, In: Barndoff-Neilsen OE, Jensen JL, Kendall WS (Eds.), *Networks and Chaos-Statistical and Probabilistic Aspects*, Chapman&Hall, London, 40-123.
- Robertson, P.K., ve Wride, C.E., 1998. Evaluating Cyclic Liquefaction Potential Using the Cone Penetration Test, *Canadian Geotechnical Journal*, 35, 442-459.
- Seed, H.B., ve Idriss, I.M., 1971. Simplified Procedure for Evaluating Soil Liquefaction Potential, *ASCE Journal of Geotechnical Engineering*, 97, 9, 1249-1273.
- Seed, H. B., ve Idriss, I. M., 1982. Ground motions and soil liquefaction during earthquakes, *Earthquake Engineering Research Institute Monograph*, Oakland, California.
- Shi, J., Ortiago, J.A.R., ve Bai, J., 1998. Modular neural networks for predicting settlements during tunnelling, *Journal of Geotechnical and Geoenvironmental Engineering*. ASCE, 124, 5, 389-394.
- Sönmez, H., Gökçeoğlu C., Medley, E.W., Tunçay, E., ve Nefeslioglu, H.A., 2006. Estimating the uniaxial compressive strength of a volcanic "bimrock", *International Journal of Rock Mechanics and Mining Science*, 43, 554-561.
- Sönmez, H., Coşkun, A., Ercanoğlu, M., Türer, D., Kasapoğlu, K.E., ve Tunusluoğlu, C., 2014. Artificial Neural Network (ANN) Based Model for Predicting of Overall Strength of Volcanic Bimrock, *Proc ISRM European Rock Mechanics Symposium, EUROCK 2014, Spain*, 83-87.
- Ulusay, R., 2010. *Uygulamalı Jeoteknik Bilgiler, TMMOB Jeoloji Mühendisleri Odası Yayınları*, No: 38, Ankara.
- Wang, C., 1994. *A theory of generalization in learning machines with neural application*, PhD Thesis, The University of Pennsylvania, USA.
- Yeşilnacar, E.K., ve Topal, T., 2005. Landslide Susceptibility Mapping: comparison between logistic regression and neural networks in a medium scale study, Hendek region TURKEY, *Engineering Geology*, 79, 251-266.
- Youd, T.L., ve Idriss, I.M., 2001. Liquefaction Resistance of Soils: Summary Report from the 1996 NCEER and 1998 NCEER/NSF Workshop on Evaluation of Liquefaction Resistance of Soils, *ASCE Journal of Geotechnical Engineering*, 127, 4, 297-313.
- Youd, T. L., ve Noble, S. K., 1997. Liquefaction criteria based on statistical and probabilistic analyses, *Proceedings, NCEER Workshop on Evaluation of Liquefaction Resistance of Soils, National Centre for Earthquake Engineering Research, State University of New York at Buffalo*, 201-215.

