

Deprem Hasarlarının Hızlı Tespitinde Yapay Sinir Ağları Yaklaşımı

Ali Kemal Baltacıoğlu¹, Ömer Civalek², Bekir Akgöz³, Armağan Korkmaz⁴

^{1,2,3}Akdeniz Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Antalya

⁴Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Isparta

Özet– Çalışmada, hatanın geriye yayılım algoritmasına dayalı çok katmanlı yapay sinir ağı kullanılarak deprem geçirmiş bir betonarme yapının hasar durumu tahmin edilmiştir. Ağın eğitimi, depremde hasar görmüş yeterli sayıda binaya ait veri kullanılarak yapılmıştır. Yöntem, mevcut bir yapının hasar miktarını hızlı tespit açısından uygundur.

Anahtar Kelimeler– Yapay sinir ağları, deprem hasarları, betonarme yapılar.

Artificial Neural Networks Approach for Fast Earthquake Damage Determination

Abstract– In the present study, damage status of a RC structure after earthquake is estimated by using the back-propagation based multi layered artificial neural networks. A sufficient datum is used for training of the network via the information on damaged structures after earthquake. The method is suitable for the fast damage assessment of any existing structures.

Keywords– Artificial neural Networks, Earthquake damages, RC structures

1. GİRİŞ

Yapay zekânın pek çok farklı açıdan tanımını yapmak mümkündür. Yapay zeka bir bilgisayarın genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, karar verme, anlam çıkartma, genelleme yapma ve geçmiş deneyimlerden yararlanarak öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlansa bile yapay zeka kavramı, üzerinde çok tartışılan bir konudur [1-10]. 20. yüzyılın ikinci yarısında temelleri atılan ve günümüzde büyük bir kitlenin üzerinde çalıştığı yapay zeka tekniği, pek çok problemin analizinde başarı ile kullanılmış ve klasik programlamaya alternatif olmuştur. Başlangıçta çok farklı amaçlar (tıp alanında hastalık teşhisi, uydu fotoğraflarının okunması ve belirlenmesi, strateji belirleme gibi askeri amaçlı uygulamalarda, kontrol problemlerinde, endüstriyel uygulamalarda) için geliştirilen bu teknik, günümüzde hemen her disiplinde kullanılır olmuştur. Yapay zeka olarak bilinen ve yapay sinir ağları; bulanık küme teorisi, genetik algoritmalar, uzman sistemler gibi çeşitli dalları

olan mantıksal programlama tekniği geçen birkaç yıl içinde hemen her disiplinde yaygın olarak kullanılmaya başlanmıştır. Geçen zaman içinde yapay sinir ağları ve diğer mantıksal programlama tekniklerinin ispatlanmış teorilerinin ortaya çıkartılması nedeniyle konu pek çok teorisyenin ilgisini çekmiştir. Bilgisayar tekniğindeki bu gelişmeler teorik ve pratik çalışmalar yapan yapı mühendislerinin de ilgisini çekmiş ve yapay zeka genel adıyla bilinen yöntemler; bir çok tasarım parametresi arasından etkin çözüme ulaşma, taşıyıcı sistem seçme, standartların kontrolü, deprem riski altındaki yapıların hasar görülebilirliği, zemin özelliklerinin belirlenmesi ve sınıflandırılması, şevlerde stabilite analizi, şantiye yönetimi ve organizasyonu, malzeme kalite kontrolü, şehir içi trafik sinyalizasyonu ve optimum sinyal süreleri belirlenmesi, üstyapı malzeme karışım hesabı, hava trafik kontrolü, ulaşım sistemlerinin planlanması, trafik akışının kontrolü ve kaza analizi, yol alt yapısı sırasında tahmini maliyet gibi uzman sistem; yapıların optimum boyutlandırılmasında genetik algoritmalar, betonun karmaşık davranışının modellenmesi, yapıların statik ve dinamik analizi, risk analizi, plak ve kabukların çözümü,

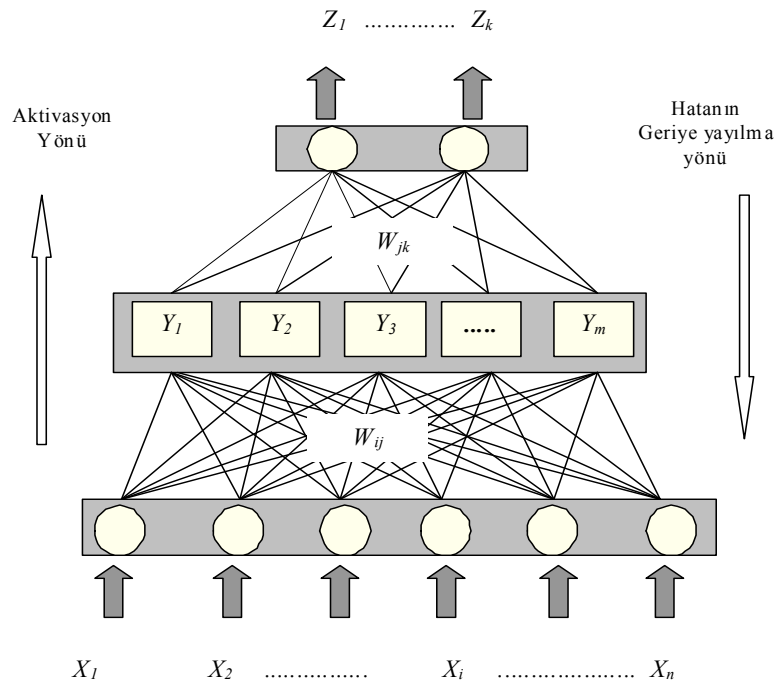
depreme dayanıklı yapı tasarımı, hasar tespiti, köprülerin dinamik analizi gibi uygulamalarda yapay sinir ağları (YSA) uygulamaları, zemin sıvılaşması ve zemin parametrelerinin analizi, optimizasyon ve kontrol uygulamaları bu alanda yapılmış çalışmalardan bazılarıdır. Tekniğin inşaat mühendisliğinde kullanım potansiyeli için geniş bir literatür Vanluchene[11], Wu ve diğerleri [12], Kang ve Yoon [13], Ghaboussi ve diğerleri [14], Ghaboussi ve Lin [15] ve Hajela ve Leh [16], uygulama prensipleri ise Adeli ve diğerleri tarafından verilmiştir [1,2,6]. Bu uygulamalar daha çok malzeme modellenmesi, boyutlandırma, optimizasyon, hasar analizi, deprem mühendisliği gibi konuları içermektedir. Daha önce yapılan bu çalışmalarda daha çok geri-yayımla ve Hopfield sinir ağları kullanılmıştır. Yapılardaki hasarların belirlenmesi konusunda yapılan çalışmada yapay sinir ağları uygulaması hayli ümit verici olmuştur. Yapay sinir ağları boyutlandırma problemlerine başarıyla uygulanmış, elde edilen sonuçların klasik optimizasyon teknikleri kullanılarak elde edilen sonuçlardan daha elverişli olduğu gösterilmiştir [13]. Pek çok diğer çalışma ve güncel kaynak bu alanda sürekli olarak yapılmaktadır [14-36] Bu çalışmada hasarlı yapılardan elde edilen veriler ile eğitilen bir ağ mimari, mevcut bir binanın hasar miktarını tespit etmek için kullanılmıştır. Eğitim setinde yapı elemanlarındaki çatlaklar girdi olarak alınmıştır. Çatlak miktarları (az, orta, çok şeklinde ifade edilen) bulanık üyelik değerleri hesaplanarak ağa sunulmuştur. Literatürde gerek pek çok bilinen kitap ve ilk yapılan

makalelerde ve gerekse yazarlardan birinin yüksek lisans tez ve makalelerinde bulunan formül ve diğer detaylar bu yazıda verilmemiştir.

2. YAPAY SİNİR AĞLARI (YSA)

Genel anlamda YSA, beynin bir işlevini yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir [25,26]. Bir yapay sinir ağı, bir biriyle etkileşim içindeki pek çok yapay nöronun paralel bağlı bir hiyerarşik organizasyonudur [30]. Nöral hesaplama algoritmik programlamaya bir seçenek oluşturan, temel olarak yeni ve farklı bir bilgi işleme tekniğidir. Programda adım adım yürütülen bir yöntemin verilmesi yerine nöral ağ ilişkilendirmeyi yapan iç kurallarını kendi üretir ve bu kuralları, sonuçları örneklerle karşılaştırarak düzenler [31].Yapay sinir ağları konvansiyonel programlama gibi belirli bir algoritma çerçevesinde programlanmazlar [32]. Sinir ağları insanlar gibi örnekler ile eğitilirler.

Yapay sinir ağlarında kullanılan öğrenme metotları en genel anlamda; denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olarak üç ana gruptur. Sinir ağlarında öğrenme girdi ve çıktı kümesi için test edilen ağın, istenilen çıktıyı verecek ağırlık kümesinin belirlenmesidir. Bu ağırlık vektörü istenen çıktı ile ağ çıktısı arasındaki fark minimum oluncaya kadar



Şekil 1. Tek Saklı Katmana Sahip Bir Geri-Yayımla Ağ Mimarisi

ayarlanarak bulunur. Bu amaçla her bir öğrenme grubu için farklı öğrenme algoritmaları geliştirilmiştir. Geriye yayılma algoritması esasen çok katmanlı ağların eğitiminde kullanılan bir denetimli öğrenme algoritmasıdır. Çok katmanlı sinir ağları girdi ve çıktı katmanına ilaveten bir veya daha fazla saklı katmandan oluşur. Şekil 1’de bir adet saklı katmandan oluşan çok katmanlı bir ağ görülmektedir. Katmanlardaki nöronlar arasında ve bir katmandan önceki katmana geriye doğru bağlantı yoktur. Geriye yayılma algoritması bu tür ağlarda yaygın olarak kullanılan bir öğrenme algoritması olmasına rağmen daha çok geriye yayılma sinir ağları olarak tanınmıştır. Yayınma ve uyum gösterme olmak üzere iki aşamada işlemleri gerçekleştiren bu ağlar, katmanlar arasında tam bir bağlantının bulunduğu çok katmanlı, ileri beslemeli ve denetimli olarak eğitilen bir YSA modelidir. Geri yayılmalı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Çalışmada geliştirilmiş delta kuralı kullanılmıştır. Genelleştirilmiş delta kuralı özellikle çok katmanlı ağların eğitiminde kullanılır [33-36].

Herhangi bir k . Girdi-çıkı örnek çifti için j . girdi ile i . nöron arasındaki ağırlık değişimi;

$$\Delta w_{ij}^k = \alpha (T_i^k - O_i^k) x_j^k \quad (1)$$

ile ifade edilir. Burada T_i istenen hedef çıktı, O_i gerçek çıktı, α öğrenme oranı ve x_j ise j . ağ girdisidir. Herhangi bir k . tabakadaki örnek çifti için toplam hata fonksiyonu [1,31]

$$E = \frac{1}{2} \sum_k (T_k - O_k)^2 \quad (2)$$

olarak tanımlanır. Burada, T_k istenen hedef çıktı, O_k hesaplanan çıktı, P ise eğitim setinde bulunan girdi-çıkı çiftlerinin toplam sayısıdır. Yine Rumelhart tarafından, ağın yakınsamaması durumunda β momentum terimini de içerecek şekilde ağırlıkların ayarlanması formülü aşağıdaki şekilde geliştirilmiştir [32,36].

$$\Delta w_{ij}(t+1) = \alpha \delta_i^k o_j^k + \beta \Delta w_{ij}(t) \quad (3)$$

Burada β momentum terimi, δ_i^k eğitim setindeki k . örnek çifti için i . nöronun hata değeridir ve kullanılan eşik fonksiyonunun türevini içeren bir terimdir. Bu nedenle eşik fonksiyonu ağırlıklandırılmış girdi toplamları ile hesaplanmış net girdiyi alarak, işlem elemanlarının çıktısını belirleyen ve türevlenebilir olması tercih sebebi olan bir fonksiyondur. Aktivasyon veya işaret fonksiyonu

olarak da adlandırılan eşik fonksiyonları pek çok sayıda olmasına rağmen geriye yayılma algoritmasında daha çok sigmoid fonksiyon kullanılmaktadır.

Çalışmada, çatlak büyüklüğüne bağlı (her eleman için) üyelik değerleri Şekil 2’de ve kullanılan ağ yapısı Şekil 3’te sunulmuştur. Ayrıca çatlak bilgisi dışında sadece deprem bölgesine ait bilgi girilmiştir.


Çalışmada hatanın geriye-yayılma algoritması kullanıldığından, girdi ve çıktı seti sırasıyla [0-1] ve [0.05-0.96] aralığında hesaplanarak ağa sunulmuştur. Yapay sinir ağında sigmoid fonksiyon kullanılmıştır. Çıkı setinde [0.05-0.96] arasında hasar miktarları derecelendirilmiştir. Buna göre yapılacak değerlendirme Tablo 1’ de verilmiştir. Öğrenmede ezberleme ve tekrar olmaması için çıkı setinde 0 kullanılmamıştır.

3. ÖRNEK

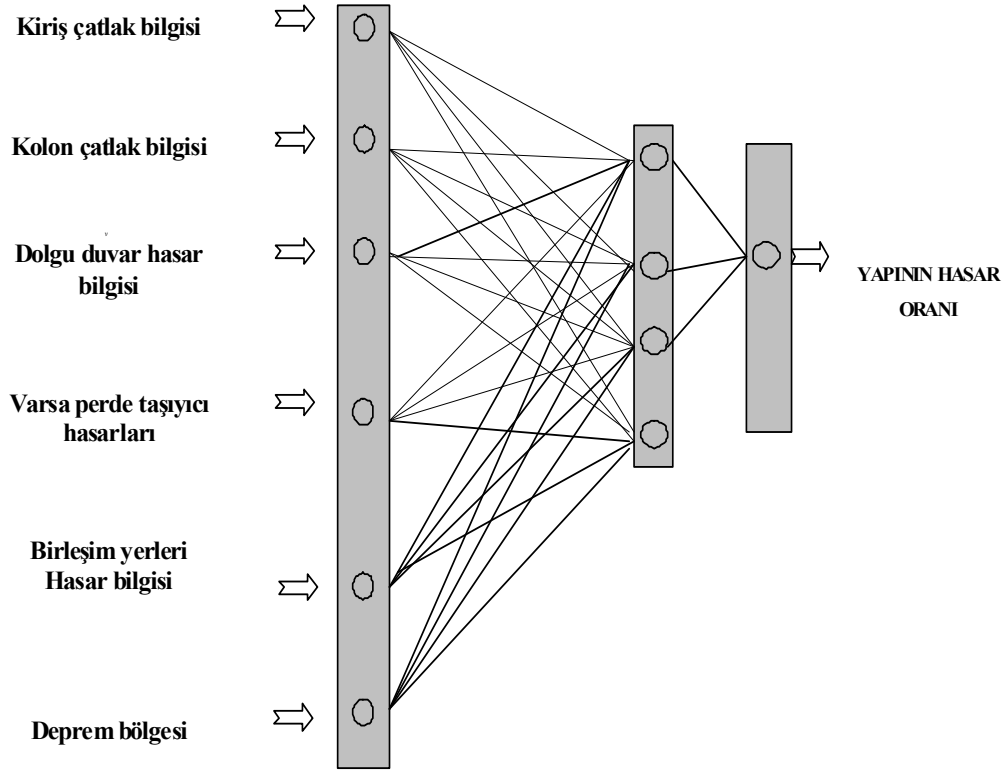
Geliştirilen program yardımıyla 8 katlı betonarme bir bina seçilmiştir. Bina 1. derece deprem bölgesinde ve yapılan detaylı incelemede orta hasarlı olarak tanımlanmıştır. Binada deformasyonlar belirgin ve çatlaklar kolon, kiriş ve dolgu duvarlarda orta ve büyük çatlak sınıfına girecek kadar belirgindir. Bina zemin katı yumuşak kat (dükkan artı+çekme kat) olup bir adet yer kolon kazanmak açısından kesilmiştir. Yapıda ölçülen çatlaklar girdi seti için üyelendirilmiş ve eğitilmiş olan ağa sunulmuştur. Yapay sinir ağı tarafından üretilen çıkı 0.428 olup, bina çok hasarlı sayılacak durumdadır. Binanın 1. deprem bölgesinde olması ve birleşim yerlerindeki büyük çatlaklar bu sonuca etkilidir.

Tablo 1. Ağ çıkı değerlerinin üyelendirilmesi


Ağ çıkı	Sonuç
[0.05-0.25]	Göçme sınırı
[0.26-0.42]	Çok hasarlı
[0.43-0.61]	Orta hasarlı
[0.62-0.80]	Az hasarlı
[0.81-0.96]	Hasarsız



Şekil 2. Eleman çatlak miktarının üyelik dereceleri



Şekil 3. Deprem hasar tespiti için geliştirilen yapay sinir ağı modeli



Şekil 4. Test edilen binaya ait normal kat planı (zemin +8 kat)

4. SONUÇLAR VE TARTIŞMA

Çalışmada geliştirilen sistemle yapay sinir ağları kullanılarak deprem geçirmiş bir yapının veya hasarlı bir yapının hasar miktarı tahmin edilebilmektedir. Bu amaçla pek çok data girdi olarak kullanılabilir olması rağmen bu çalışmada sadece yapı elemanlarındaki çatlaklar dikkate alınmıştır ve ek olarak sadece yapının bulunduğu deprem bölgesi girilmiştir. Bu çatlaklar bulanık küme kuramıyla üyelendirilerek ağa girilmiştir. Bilinen örnekler üzerinde yapının hasar durumu (hasarsız, az hasarlı, orta hasarlı, çok hasarlı ve göçme sınırı) beş farklı grupta incelenmiş ve bunlar ağıncı çıkışı olarak yine bulanık üyelendirilerek ağa sunulmuştur. Eğitim %81 oranında başarılı bulunmuş ve ağ test edilmiştir. Yöntem eğitilmiş bir ağıncı mevcut hasarlı binaların hasar oranını belirlemede etkin ve hızlı bir yöntem olarak düşünülebilir yapıdadır. Eğitim seti artırılarak (deprem bölgelerinde ciddi kurumlar tarafından incelenmesi yapılmış binalardan alınacak veriler ile) eğitilen ağ, daha iyi öğrenme oranlarına ulaşabilecektir.

Yapay sinir ağları eğitim aşaması bittikten sonra klasik programlama tekniklerinden hız ve gerektirdikleri kapasite açısından bazı avantajlara sahiptir. Esasında yapay sinir ağlarının en önemli ve ayırt edici özelliklerinden birisi de; yeni durumlara adaptasyon ve hiyerarşik yapılarının esnek olması ve sonradan veri girişini kabul etmeleridir. Kullanılan metod ve yapılan kabul ne olursa olsun sayılar mühendise tasarım aşamasında sadece bir fikir vermek için vardır ve yapının

gerçekteki davranışının tam olarak anlaşılması ise daha da önemlidir.

KAYNAKLAR

- [1] H. Adeli, S.L. Hung, **Machine learning- neural networks, genetic algorithms and fuzzy systems**, John Wiley & Sons, Inc, 1995.
- [2] H. Adeli, C. Yeh, "Perceptron learning in engineering design", *Microcomputer in Civil Engineering*, 4, 247-256, 1989.
- [3] I. Aleksander, I. Morton, **An introduction to neural computing**, International Thomson Computer Press, 1995.
- [4] H.S. Park, H. Adeli, "Distributed Neural Dynamics Algorithms for Optimization of Large Steel Structures", *Journal of Structural Engineering, ASCE*, 123(7), 880-888, 1997.
- [5] J. M. Zurada, **Introduction to artificial neural networks**, West Publishing Company, 1992.
- [6] H. Adeli, H.S. Park, "A neural dynamics model for structural optimization- theory", *Computers and Structures*, 57(3), 383-390, 1995.
- [7] H.M. Chen, G.Z. Qi, J.C.S. Yang, and F. Amini, "Neural Networks for Structural Dynamic Model Identification", *Journal of Engineering Mechanics, ASCE*, 121(12), 1377-1381, 1995.
- [8] J. Ghaboussi, "An overview of the potential applications of neural networks in civil engineering", **In Proceedings, ASCE Structures Congress'93**, Irvine, California, 19-21 April, 1993.
- [9] K.B. Hani, J. Ghaboussi, "Neural Networks for Structural Control of A Benchmark Problem, Active Tendon System", *Earthquake Engineering and Structural Dynamics*, 27, 1225-1245, 1998.
- [10] Z.P. Szewczyk, P. Hajela, "Damage detection in structures based on feature- sensitive neural networks", *Journal of Computing in Civil Engineering, ASCE*, 8(2), 163-178, 1994.
- [11] R.D. Vanluchene, S. Roufei, "Neural networks in structural engineering", *Microcomputers in Civil Engineering*, 5, 207-215, 1990.
- [12] X. Wu, J. Ghaboussi, J.H. Garrett, "Use of neural networks in detection of structural damage", *Computers & Structures*, 42(4), 649-659, 1992.

- [13] H.T. Kang, C.J. Yoon, "Neural networks approaches to aid simple truss design problems", *Microcomputers in Civil Engineering*, 9, 211-218, 1994.
- [14] J. Ghaboussi, Jr. Garrett, X. Wu, "Knowledge-based modeling of material behavior with neural networks", *Journal of Structural Engineering, ASCE*, 117(1), 132-153, 1991.
- [15] J. Ghaboussi, C.C. Lin, "New method of generating spectrum-compatible accelerograms using neural networks", *Earthquake Engineering and Structural Dynamics*, 27, 377-396, 1998.
- [16] P., Hajela, L. Berke, "Neurobiological computational models in structural analysis and design", *Computers and Structures*, 41(4), 657-667, 1991.
- [17] Ö. Civalek, "The design of structures under earthquake effects by using neuro-fuzzy method" **Fourth National Earthquake Engineering Conferences**, Ankara, 431-438, 17-19 September, 1997.
- [18] Ö. Civalek, **Plak ve Kabukların Nöro-Fuzzy Tekniği ile Lineer ve Lineer Olmayan Statik-Dinamik Analizi**, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, , Elazığ, 1998.
- [19] Ö. Civalek, "The analysis of the rectangular plates without torsion via hybrid artificial intelligent technique", **Proceedings of the Second International Symposium on Mathematical & Computational Applications**, Azerbaijan, 95-101, 1-3 September, 1999.
- [20] Ö. Civalek, Dikdörtgen Plakların Nöro-Fuzzy Tekniği ile Analizi, **III. Ulusal Hesaplamalı Mekanik Konferansı**, İstanbul, 517-525, 16-18 Kasım, 1998.
- [21] Ö. Civalek, "Nöro- Fuzzy Tekniği ile Dairesel Plakların Analizi", *Journal of Engineering Science of Dokuz Eylül University*, Vol. 1(2), 13-31, 1999.
- [22] Ö. Civalek, H.H. Çatal, "Geriye Yayılma Yapay Sinir Ağı Kullanılarak Elastik Kirişlerin Statik ve Dinamik Analizi", *Dokuz Eylül Üniversitesi Fen ve Mühendislik Dergisi*, Cilt 6(1), 1-17, 2004.
- [23] Ö. Civalek, H.H. Çatal ve O. Demirdağ, "Geriye Yayılma Yapay Sinir Ağları ile Düzlem Çerçeve ve Kirişlerin Titreşim Frekanslarının Tahmini", *İMO Teknik Dergi*, Cilt 13(3), 2709-2726, 2002.
- [24] Ö. Civalek, H.H. Çatal, "Geriye Yayılma Sinir Ağı Kullanılarak Elastik Kirişlerin Eğilme Titreşimlerinin Yaklaşık Hesabı", **Teorik ve Uygulamalı Mekanik Türk Milli Komitesi (TUMTMK), Ulusal Mekanik Kongresi**, Selçuk Üniversitesi, Konya, Eylül 2001.
- [25] Ö. Civalek, "The analysis of time dependent deformation in R.C. Members by artificial neural network", *Journal of Engineering Sciences of Pamukkale University*, 3(2), 331-335, 1997.
- [26] Ö. Civalek, "Elastik Zemin Oturan Kirişlerin Nöro-Fuzzy Tekniği ile Analizi", **7th National soil mechanics and foundation engineering conferences**, Yıldız University, İstanbul, 22-23 October, 1998.
- [27] Ö. Civalek, "Flexural and Axial Vibration Analysis of Beams with Different Support Conditions Using Artificial Neural Networks", *International Journal of Structural Engineering and Mechanics*, 18 (3), 303-314, 2004.
- [28] M. Ülker, Ö. Civalek, "The Buckling Analysis of Axially Loaded Columns with Artificial Neural Networks", *Turkish Journal of Engineering and Environmental Sciences*, TUBITAK, 26, 117-125, 2002.
- [29] J.J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities", **In Proceedings of National Academy of Sciences**, USA, 79, 2554-2558, April, 1982.
- [30] R. C. Eberhart, and R. W. Dobbins, **Neural network PC tools**, Academic Press, San Diego, California, 1990.
- [31] L. Fausett, **Fundamentals of neural networks, architectures, algorithms, and applications**, Prentice-Hall, Inc., New-Jersey, 1994.
- [32] L.M. Fu, **Neural Networks in Computer Intelligence**, McGraw-Hill, Inc. New York, 1994.
- [33] W.S. McCulloch, and W. Pitts, "A logical calculus of ideas imminent in nervous activity", *Bulletin of Mathematical Biophysics*, 5, 115-133, 1943.
- [34] R. Rojas, **Neural networks-A systematic introduction**, Springer, Germany, 1996.
- [35] D.E. Rumelhart, G.E. Hinton, and R J. Williams, "Learning internal representation by error propagation", **Parallel distributed processing: Explorations in the microstructures of cognition**, MIT Press, Cambridge, MA, 318-362, 1986.