



ISSN:1306-3111
e-Journal of New World Sciences Academy
2009, Volume: 4, Number: 3, Article Number: 1A0039

ENGINEERING SCIENCES

Received: October 2008
Accepted: June 2009
Series : 1A
ISSN : 1308-7231
© 2009 www.newwsa.com

Ömer Keleşoğlu
Firat University
okelesoglu@firat.edu.tr
Elazig-Turkey

YAPAY SİNİR AĞLARI İLE KISA KONSOLLARIN DONATI TAYİNİ

ÖZET

Genellikle sanayi yapılarında ve köprülerde kullanılan kısa konsollar önemli yapı elemanlarından biridir. Bu nedenle kısa konsolların donatı alanlarının belirlenmesi de büyük öneme sahiptir. Bu çalışmada, kısa konsollar konusunda bilgi verilerek bir uygulama çalışması yapılmıştır. Uygulamada ileri beslemeli yapay sinir ağı kullanılmış ve konsol kirişlerin donatı alanı tespit edilmiştir. Uygulamada kullanılan veriler normalize edilerek ağa sunulmuştur. Ağdan elde edilen sonuçlar, sayısal sonuçlarla karşılaştırıldığında yeterli hassasiyette sonuçlar elde edildiği görülür.

Anahtar Kelimeler: Yapay Sinir Ağı, Geri Yayılım Ağı,
Kısa Konsol, Matlap, Yapısal Analiz

THE DETERMINATION OF THE REINFORCEMENT STEEL OF THE SHORT CANTILEVERS WITH ARTIFICIAL NEURAL NETWORK

ABSTRACT

The short cantilevers used commonly in industry building and in bridges are one of the important structure components. Therefore the determinations of the steel reinforcement areas of the short cantilevers have great importance. In this study, one application has been presented by giving information about the short cantilevers. In application, a feed-forward artificial neural network has been used and the cantilever reinforcement steel area has been determined. The data that were used in application have been presented to the network by normalizing. The results obtained from the network are seen that the results obtained are sensitive enough when in comparing with numerical results.

Keywords: Artificial Neural Network, Backpropagation Neural Network, Short Cantilever, Matlap, Structural Analysis



1. GİRİŞ (INTRODUCTION)

Yapay sinir ağları kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya atılmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır [1]. Yapay sinir ağları (YSA), beyin hücrelerindeki görev dağılımının ve birbirleri arasındaki ilişkilerin benzerlerinin bilgisayar ortamında oluşturulmasıdır. Matematiksel olarak modellenen çok sayıda nöron birbirlerinden aldıkları bilgileri değerlendirerek bir çıktıya dönüştürmektedirler. Birçok nöronun eşzamanlı olarak çalışması, eğitilebilmesi, denetlenmesi ve çözüme ulaşma hızının kısa olması gibi özellikleri nedeni ile bilimsel araştırmalarda giderek artan bir şekilde kullanılmaktadır [2].

Genel olarak bir YSA, tek katmanlı ya da çok katmanlı olarak düzenlenebilen ve paralel olarak çalışan çok sayıda doğrusal olmayan yapay hücreden (işlem elemanı) meydana gelen bir sistem ya da matematiksel model olarak tanımlanır. Hücreler arasındaki ağırlıklar, arzu edilen tasarım amaçlarını sağlayacak şekilde çeşitli öğrenme kuralları ile ayarlanır. Bu yapısı ile YSA, öğrenme sürecinde bilgiyi toplayan ve ağırlıkları yardımıyla bu bilgiyi saklayan paralel bir işlemcidir. Günümüzde, çok çeşitli YSA yapıları ve öğrenme algoritmaları geliştirilmiştir. Herhangi bir uygulama için uygun YSA yapısını ve öğrenme algoritmasını seçmek ya da geliştirmek gerekir. YSA, olayların örneklerine bakmakta, onlardan ilgili olay hakkında genellemeler yapmakta, bilgiler toplamakta ve daha sonra hiç görmediği örnekler ile karşılaşınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. Yapısı, bilgi işleme yöntemindeki farklılık ve uygulama alanları nedeniyle çeşitli bilim dallarının da kapsam alanına girmektedir. Bilgisayar, endüstri, tıp, ekonomi ve askeri uygulamalarda başarıyla kullanılan bu teknik, yapı mühendisliğinde de kullanılmaya başlanmıştır [3].

YSA tekniği, betonarme elemanlardaki zamana bağlı etkilerin analizine başarıyla uygulanmış elde edilen sonuçlar çeşitli yazarlar tarafından verilen teorik ve deneysel sonuçlara çok yakın çıkmıştır [4]. YSA, derin betonarme kirişlerin kesme dayanımlarının belirlenmesinde başarıyla uygulanmış ve elde edilen sonuçlardan etkili, alternatif bir metot olduğu görülmüştür [5]. Betonun farklı yüklemeler altındaki gerilme-şekil değiştirme bağıntılarının belirlenmesine başarıyla uygulanmış ve çalışmada malzeme davranışı ile ilgili herhangi bir kabul yapılmamıştır [6]. Yapılan başka bir çalışmada dairesel beton kolonların gerilme ve dayanım analizlerinde bu teknik kullanılarak sağlıklı sonuçlara ulaşılmıştır [7]. Ayrıca bir tuğla duvardaki yalıtım malzemesinin kalınlığı yapay sinir ağları ile başarılı bir şekilde tespit edilmiştir [8].

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Bu çalışmada, YSA kullanılarak konsol kirişlerin donatı alanlarını bulan bir program Matlab da bulunan hazır fonksiyonlar kullanılarak geliştirilmiştir. Geliştirilen program genel amaçlı olup uygulanabilirliği bir sayısal örnekle gösterilmiştir.

3. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORKS)

Sinir ağları insan beynindeki nöronlara benzer olarak çalışan karmaşık sistemlerdir. Yani, bu ağlar insan beyninin biyolojik fonksiyonlarının matematiksel olarak modellenmiş şeklidir. YSA, kendisine sunulan veriler arasında bağlantılar kurarak problemi öğrenmekte, ağırlık katsayılarını saklamakta ve bunları kullanıma hazırlamaktadır [9].



Sinir sisteminin modellenmesi için yapılan çalışmalar sonucu oluşturulan YSA, biyolojik sinir sisteminin üstünlüklerine de sahiptir. YSA'nın bu üstünlükleri paralellik, öğrenebilme ve karışık işlevler gerektirmemesi, basit işlemleri içermesidir. YSA'nın bir başka üstünlüğü de ayrı ayrı elemanlarda meydana gelen hasarın, başarımda ciddi bir düşüşe yol açmamasıdır. Hâlbuki bilgisayarın herhangi bir işlem elemanını yerinden almak onu etkisiz bir makineye dönüştürmektedir [10].

3.1. Ağın Eğitilmesi (Training of the Network)

İnsan beyni doğumdan sonraki gelişme sürecinde çevresinden duyu organlarıyla algıladığı davranışları yorumlar ve bu bilgileri diğer davranışlarında kullanır. YSA'nın öğrenme sürecinde de, tıpkı dış ortamdan gözle veya vücudun diğer organlarıyla uyarıların alınması gibi dış ortamdan girişler alınır. Bu girişlerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesi gibi yapay sinir ağında da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir. Bu çıkış yine tecrübeyle verilen çıkışla karşılaştırılarak hata bulunur. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılır.

YSA insan zekâsı gibi örneklerle eğitilirler. Ağlar ne kadar çok örnekle eğitilirse problem üzerindeki teşhisi o kadar doğru olur. Öğrenme, genel olarak denetimli ve denetimsiz öğrenme olarak iki grupta sınıflandırılabilir [11].

Denetimli öğrenmede, giriş ve çıkış veri setleri sinir ağına verilir ve eğitim işlemi gerçekleştirilir. Örneğe ait çıkış değeri ile ağ çıkış değeri karşılaştırılarak ağın hatası bulunur. Ağırlık matrisi, toplam ağ hatasının kabul edilebilir hatadan daha büyük olduğu sürece güncelleştirilir. Denetimsiz öğrenme de ise, ağa sadece giriş veri grubu verilerek ağdan bu veri grubuna uyumlu bir çıkış değeri üretecek şekilde kendisini uygun ağırlıklarla düzenlemesi istenir [12 ve 13].

3.2. İleri Beslemeli Yapay Sinir Ağları (Feedforward Artificial Neural Networks)

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

İleri beslemeli YSA'nın eğitiminde en çok kullanılan algoritma geriye yayılım öğrenme algoritmasıdır. Bundan dolayı bazen ileri beslemeli sinir ağları geriye yayımlı ağ olarak da bilinir. Şekil 1'de giriş, gizli ve çıkış katmanı olmak üzere 3 katmanlı ileri beslemeli YSA yapısı verilmiştir.

Q katmanlı ileri beslemeli bir ağ için geri yayılım algoritması;
 $q=1,2,3,\dots,Q$ katman numarası,

X_i^p : q' inci katmandaki i biriminin girdisi,

y_i^q : q' inci katmandaki i biriminin çıktısı,



w_{ij}^q : $(q-1)$ 'inci katmandaki i birimini, q 'ncu katmandaki j birimine bağlayan ağırlık olmak üzere;

1. Adım: w 'ye reel değerli küçük rastlantısal sayıları başlangıç değeri olarak atanır.

2. Adım: Rasgele bir (giriş-hedef) çalışma modeli seçilir ve q katmanındaki her bir j birimi için ileri yönde 'çıktı' değerleri hesaplanır. Böylece çıkış,

$$y_i^q = f\left(\sum_i y_i^{q-1} w_{ij}^q\right) \quad (1)$$

olur.

3. Adım: Çıkış birimleri için hata terimleri hesaplanır.

$$\delta_i^q = (y_i^q - y_i^p) f'(X_i^q) \quad (2)$$

4. Adım: $q = Q, Q-1, \dots, 2$ katmanlarındaki tüm i birimleri için geriye yayılımla deltaları yani gizli katman birimleri için hata terimleri hesaplanır.


$$\delta_i^{q-1} = f'(X_i^{q-1}) \sum_j \delta_j^q w_{ij}^q \quad (3)$$

5. Adım: Bütün bu ağırlıklar w_{ij} 'leri kullanılarak güncellenir.

$$w_{ij}^{\text{yeni}} = w_{ij}^{\text{eski}} + \Delta w_{ij}^q \quad (4)$$

$$\Delta w_{ij}^q = \eta \delta_i^q y_i^{q-1} \quad (5)$$

6. Adım: 2. adıma dönüp, toplam hata kabul edilebilir bir düzeye gelene kadar her bir p modeli için işlemler tekrarlanır.



Şekil 1. İleri beslemeli yapay sinir ağı
(Figure 1. Feedforward artificial neural network)

Geriye yayılma algoritması birbirine bağlı sabit üniteli ve çok katmanlı ağlar için ağırlıkların güncellenmesinde kullanılan bir algoritmadır. Bu algoritmanın temel prensibi, hedef değerleri ile ağ çıkışındaki değerler arasındaki hatayı minimize etmeye çalışmaktır. Geri yayılım algoritması denetimli öğrenmede kullanılan en genel algoritmadır. Sürekli ve türevi alınabilen aktivasyon fonksiyonu ile birçok alanda başarılı bir şekilde uygulanmıştır.

Geri yayımlı bir yapay sinir ağında aynı katmandaki nöronlar arasında bir bağlantıya izin verilmemektedir. Buna karşılık her bir nöron bir sonraki katmandaki nöronların her birine bir girdi değeri göndermektedir. Geri yayımlı sinir ağlarında tüm dataların girdi ve çıktı değerleri verilmelidir [10].



4. KISA KONSOLLAR (SHORT CANTILEVERS)

Kısa konsollarda yükleme noktasından mesnet yüzüne olan uzaklığın (a_v), mesnetteki faydalı yüksekliğe oranı 1.0'den büyük olmayan konsollar, kısa konsol olarak adlandırılmaktadır. Kısa konsollar genellikle sanayi yapılarında ve köprülerde kullanılmaktadır. Taşıma gücü hesapları ve donatı detayları ise normal konsollardan farklıdır. Kısa konsola uygulanan yükün büyük bir bölümü konsolda kurgusal (fiktif) olarak oluştuğu kabul edilen beton basınç çubuğu ile mesnede aktarılmaktadır [14].

Özel önlemler alınmayan durumlarda, konsola oturan kirişlerde sıcaklık değişimi ve büzülme gibi olaylar nedeni ile oluşan kısalma ve uzamalar, konsol üzerinde yatay kuvvetler oluştururlar. Her zaman çekme olarak hesaba katılacak olan bu yatay kuvvet aşağıdaki şartı sağlamalıdır.

$$H_d \geq 0.2V_d \quad (6)$$

burada H_d yatay kuvvet, V_d kesme kuvvetidir. Beton basınç gerilmelerini sınıflandırmak için kesme kuvveti

$$V_d \leq 0.22f_{cd}b_wd \quad (7)$$

üst sınırı ön görülmüştür. Yatay çekme donatısından başka yükseklik boyunca dağıtılacak ve kesme sürtünme donatısı

$$A_{wf} = \frac{V_d}{f_{yd}\mu} \quad (8)$$

ile hesaplanacak. A_{wf} kesme sürtünme donatısı, μ kesme sürtünme katsayısıdır. Eğilme donatı alanı

$$A_s = \frac{V_d a_v + H_d (h - d)}{0.8f_{yd}d} \quad (9)$$

ile kısa konsolda yatay kuvvet için gerekli donatı alanı

$$A_n = \frac{H_d}{f_{yd}} \quad (10)$$


olarak hesaplanır. Burada A_s eğilme donatı alanı ve A_n yatay kuvvet için gerekli donatı alanıdır. Toplam çekme donatısı da eğilme ve eksenel kuvvet donatılarının toplamına eşittir.

$$A_{st} = A_s + A_n \geq \max \left[\frac{2}{3} A_{wf} + A_n; 0.05 \frac{f_{cd}}{f_{yd}} b_w d \right] \quad (11)$$

Kapalı ve açık yatay etriyelerin kesit alanı

$$A_{sv} = 0.5(A_{st} - A_n) \quad (12)$$


olarak hesaplanacaktır [15 ve 16].



Şekil 2. Kısa konsolda boyutlandırma
(Figure 2. Design of short cantilever)

4. UYGULAMA (APPLICATION)


Bu uygulamada, kısa konsoldaki eğilme donatısı alanı ile yatay kuvvet için gerekli olan donatı alanı YSA kullanarak tespit edilmeye çalışılmıştır. Şekil 3'de görülen kısa konsolun genişliği 300 mm , konsol yüksekliği $h=500\text{ mm}$, faydalı yüksekliği $d=450\text{ mm}$, kirişe gelen yatay yük $H=40\text{ kN}$, yükleme noktasından mesnet yüzüne olan uzaklık $a_v=200\text{ mm}$, kirişe gelen hareketli yük $P_g=100\text{ kN}$, sabit yük ise $P_q=150\text{ kN}$ olarak verilmiştir.



Şekil 3. Uygulamada kullanılan kısa konsol
(Figure 3. Short cantilever used in application)

Problem için ileri beslemeli yapay sinir ağı kullanılmıştır. Bu ağda 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı kullanılmıştır. Girdi katmanında yedi işlem elemanı bulunmaktadır:

- Konsol giriş genişliği (mm)
- Konsol giriş yüksekliği (mm)
- Konsol girişin faydalı yüksekliği (mm)
- Konsol girişe gelen yatay yük (kN)
- Yükleme noktasından mesnet yüzüne olan uzaklık (mm)
- Konsol girişe gelen hareketli yük (kN)
- Konsol girişe gelen sabit yük (kN)



Şekil 4. Kısa konsol giriş için kullanılan yapay sinir ağı mimarisi
(Figure 4. The architecture of the network used for short cantilever beam)

Şekil 4'de görüldüğü gibi ara katmanda 10 adet yapay nöron kullanılmıştır. Ağın çıkışları ise eğilme donatısı alanı ve kısa konsolda yatay kuvvet için gerekli olan donatı alanı olup her iki çıkış aynı anda tahmin edilmiştir. Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 36 adet örnek bulunmaktadır. Giriş ve çıkış değerleri normalize edilerek ağa sunulmuştur.

Tablo 1. Ağ yapısı ve öğrenme oranının deneme yoluyla bulunması
(Table 1. Structure of the network and determination of training rate by testing)

Ağ yapısı	Öğrenme oranı	İterasyon sayısı	1. Çıkışın hatası	2. Çıkışın hatası
7-10-2	0.80	1418	% 0.09	% 0.01
7-10-2	0.60	164	% 0.56	% 1.33
7-10-2	0.90	64	% 1.17	% 3.30
7-5-2	0.80	5000	% 0.24	% 0.03
7-5-2	0.60	5000	% 0.36	% 0.05
7-5-2	0.90	5000	% 1.01	% 0.71
7-15-2	0.80	14	% 0.85	% 3.14
7-15-2	0.60	88	% 0.72	% 1.85
7-15-2	0.90	102	% 0.67	% 0.88



Tablo 1’de de görüldüğü gibi yapılan denemeler sonucunda eğitim için 10 nörondan oluşan bir ara katman uygun görülmüş ve öğrenme oranı 0.8 alındığında ağ daha uygun sonuçlar vermiştir. Tablodaki diğer sütunlarda; ağın iterasyon sayısı, ağdan elde edilen çıktı değerlerinin gerçek sonuçla arasındaki hata yüzdeleri verilmiştir. Gerçek sonuçlara en yakın değerleri veren ağ yapısı ve öğrenme oranı dikkate alınmıştır. Aktivasyon fonksiyonu olarak çift yönlü sigmoid fonksiyonu, ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır. Momentum katsayısı 0.75 olarak alınmıştır.

Tablo 2. Hazırlanan eğitim setinde kullanılan değerler
(Table 2. Used values of the training set)


Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X ₁	Konsol kiriş genişliği	250-480 mm
X ₂	Konsol kiriş yüksekliği	350-560 mm
X ₃	Konsol kirişin faydalı yüksekliği	300-510 mm
X ₄	Konsol kirişe gelen yatay yük	25-55 kN
X ₅	Yükleme noktasından mesnet yüzüne olan uzaklık	175-230 mm
X ₆	Konsol kirişe gelen hareketli yük	75-130 kN
X ₇	Konsol kirişe gelen sabit yük	120-180 kN
Y ₁	Konsol kirişin eğilme donatısı alanı	456.22-904.05 mm ²
Y ₂	Kısa konsolda yatay kuvvet için gerekli olan donatı alanı	166.57-249.86 mm ²

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağ test edilmiş ve elde edilen sonuçlar Tablo 3’de karşılaştırılmıştır.

Tablo 3. Hazırlanan test seti
(Table 3. The test set prepared)

Test No	Giriş							Çıkış			
	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	Y ₁		Y ₂	
								Sayısal Sonuç	YSA	Sayısal Sonuç	YSA
1	400	520	470	45	180	95	145	505.31	503.97	200	200
2	450	450	400	30	215	125	175	876.49	876.32	249.32	249.40
3	420	530	480	55	190	110	175	619.29	620.95	237.80	237.62
4	475	550	500	30	205	100	130	512.46	511.78	190.68	190.52
5	350	420	370	40	210	115	160	849.13	851.28	228.49	228.52

Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağa sunulursa elde edilen eğilme donatısı alanı 607.87 mm², yatay kuvvet için gerekli donatı alanı ise 208.26 mm² olarak bulunur. Bu problemin sayısal çözümü [14] sonucunda elde edilen eğilme donatısı alanı 607.30 mm², yatay kuvvet için gerekli donatı alanı ise 208.22 mm²’dir.



Şekil 5. Yapay sinir ağının iterasyona bağlı hata değişim grafiği
(Figure 5. The fault variation graph of the neural network due to iteration)

5. SONUÇLAR (CONCLUSIONS)

Yapay sinir ağları sonuçlara kısa zamanda ve hızlı bir şekilde ulaşabilme özelliği ile en çok tercih edilen yapay zekâ yöntemlerinin başında gelmektedir. Yapay sinir ağlarının problemlere yaklaşımı insan zekâsı gibi edinilen tecrübeye bağlıdır. Yapay sinir ağları, insanlar gibi örneklerle eğitildikleri için eğitim sırasında yeterli sayıda veri grubunun kullanılması ile çok iyi sonuçlar elde edilmektedir.

Bu çalışmada, genellikle sanayi yapılarında ve köprülerde kullanılmakta olan kısa konsolların eğilme donatısı ve yatay kuvvete karşılık gelen donatı alanları yapay sinir ağları kullanılarak tespit edilmiştir. Yapay sinir ağları ile çözüm yaparken aktivasyon fonksiyonu olarak çift yönlü sigmoid fonksiyonu ile veri grupları normalize edilerek eğitim aşamasına geçilmiştir. Eğitim sırasında en uygun sonucu elde edene kadar ağın mimarisi, momentum katsayısı 0.75 olarak alınmış ve eğitim sırasında öğrenme oranı 0.8 seçilerek daha uygun sonuç elde edildiği görülmüştür. Eğitim tamamlandıktan sonra daha önceden eğitim sırasında kullanılmayan veri grupları ile test işlemine geçilmiştir. Hazırlanan test setinde görüldüğü gibi yapay sinir ağları sayısal analize göre iyi sonuçlar vermiştir. Ayrıca sayısal analiz ile çok uzun sürede çözülebilecek problemler daha hızlı ve kısa sürede çözülebileceği görülmüştür.

Gerek bu çalışmadan elde edilen sonuçlar gerekse daha önce yapılmış olan çalışmalardan elde edilen sonuçlar ışığında yapay zekânın alt kollarından biri olan yapay sinir ağlarının mühendislik problemlerinde başarılı sonuçlar verdiği gözlenmiştir.

KAYNAKLAR (REFERENCES)

1. Arslan, A. ve İnce, R., (1995). Geriye yayılma sinir ağı kullanılarak betonarme kolonların tasarımı, Tr. Journal of Engineering and Environmental Sciences, 19, pp:127-135.
2. Basheer, I.A. and Hajmeer, M., (2000). Artificial neural networks: Fundamentals, computing, design and application, Journal of Microbiological Methods, 43, pp:3-31.
3. Bildik, A.T., (1998). Normal basınç dayanımlı beton karışımlarının yapay sinir ağları ile hesaplanması, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 1998.



4. Celep, Z. ve Kumbasar, N., (2005). Betonarme Yapılar, Beta Dağıtım, İstanbul.
5. Civalek, Ö., (1997). The analysis of time dependent deformation in R.C members by artificial neural network, Journal of Pamukkale University Engineering Sci. 3(2), pp:331-335.
6. Dias, W.P.S. and Pooliyadda, S.P., (2001). Neural networks for predicting properties of concrete with admixtures, Construction and Building Materials, 15, 371-379.
7. Doğangün, A., Betonarme yapıların hesap ve tasarımı, Birsen Yayınevi İstanbul.
8. Efe, Ö. ve Kaynak, O., (2002). Yapay sinir ağları ve uygulamaları, Boğaziçi Üniversitesi.
9. Fırat, M., (2002). Doğrusal ve kıvrımlı akarsulara yerleştirilen köprü ayakları etrafında meydana gelen oyulma derinliğinin yapay sinir ağları ile belirlenmesi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Denizli.
10. Ghaboussi, J., Garrett, Jr., and Wu, X., (1991). Knowledge-based modeling of material behavior with neural networks, Journal of Structural Engineering, ASCE; 117(1), pp:132-53.
11. <http://www.backpropagation.netfirms.com> (Erişim: 14/09/2008)
12. Keleşoğlu, Ö., Ekinci C.E. ve Fırat, A., (2005). Yalıtım Hesaplarında Yapay Sinir Ağlarının Kullanımı, Sigma Dergisi, 3, 58-66.
13. Oreta, A.W.C. and Kawashima, K., (2003.) Neural network modeling of confined compressive strength and strain of circular concrete columns, Journal of Structural Engineering, 129(4), pp. 554-561.
14. Ekinci, C.E., (2008). Bordo Kitap: Yapı ve Tasarımcının İnşaat El Kitabı, Elazığ: Data Üniversite Kitapevi, ss:1200.
15. Sanad, A. and Saka, M.P., (2001). Shear strength of reinforced-concrete deep beams using neural Networks, Journal of Structural Engineering, 127(7), pp:818-828.
16. Vanluchene, R.D. and Roufei, S., (1990). Neural networks in structural engineering, Microcomputers in Civil Eng., 207-215.