Pirinç Kabuğu Külü İçeren Betonların Basınç Dayanımının Yapay Sinir Ağları ile Tahmin Edilmesi

İlker Bekir Topçu[1], Mustafa Sarıdemir[2]

[1]Eskişehir Osmangazi Üniversitesi, İnşaat Mühendisliği Bölümü, 26480 Eskişehir
ilkerbt@ogu.edu.tr
[2]Niğde Üniversitesi, İnşaat Mühendisliği Bölümü, 51100 Niğde
msdemir@nigde.edu.tr

ÖZET

Betonun fiziksel ve mekanik özeliklerinin tahmin edilmesinde yapay sinir ağları yöntemi son yıllarda yaygın olarak kullanılmaktadır. Bu çalışmada da, % 5, 10, 15, 20 ve 35 pirinç kabuğu külü içeren betonların 1, 3, 7, 14, 28 ve 90 günlük basınç dayanımı değerlerini tahmin etmek için yapay sinir ağlarında model geliştirilmiştir. Bu modeli oluşturmak amacıyla, 32 farklı karışım oranlarında üretilen 152 numunenin deneysel sonuçları literatürden elde edilmiştir. Yapay sinir ağlarında 8 farklı girdi değişkeni kullanılarak bu model oluşturulmuştur. Bu girdi değişkenlerine göre, yapay sinir ağları modellinde pirinç kabuğu külü içeren betonların mekanik özeliklerinden basınç dayanımı değerleri tahmin edilmiştir. Modelden elde edilen eğitim ve test sonuçları sinir ağlarının, pirinç kabuğu külü içeren betonların farklı günlerdeki basınç dayanımı değerlerini tahmin etmek için güçlü potansiyele sahip olduğunu göstermiştir.

Anahtar Kelimeler: *Pirinç kabuğu külü; Basınç dayanımı; Sinir ağları*

Prediction of Compressive Strength of Concretes Containing Rice Husk Ash with Artificial Neural Networks

ABSTRACT

Artificial neural networks method has been widely used in the predicted physical and mechanical properties of concrete in the recent years. In this study, the model in the artificial neural networks method for predicting 1, 3, 7, 14, 28 and 90-day compressive strength values of concretes containing 5, 10, 15, 20 and 35 % rice husk ash has been developed. For the purpose of constructing this model, experimental results for 152 specimens produced with 32 different mixture proportions were obtained from the literature. This model was constituted by using 8 different input variables in the artificial neural networks. According to these input variables, the compressive strength values from mechanical properties of concretes containing rice husk ash were predicted in the artificial neural networks model. The training and testing results obtained from the model has shown that neural networks method has strong potential for predicting the compressive strength values of concretes containing rice husk ash at different ages.

Key Words: *Rice husk ash; Compressive strength; Neural network*

1. GİRİŞ

Genellikle, basınç dayanımı (f_c) 50 MPa değerinin üzerinde olan betonlar yüksek dayanımlı beton olarak tanımlanmaktadır [1]. Yüksek dayanımlı betonda çimento pastası ve agrega arasındaki ara yüzeyle ilgili geçiş bölgesinin mikro yapısı, malzemenin dayanım ve dayanıklılığı için büyük öneme sahiptir. Bu ara yüz ile ilgili geçiş bölgesindeki çimento pastasının mikro yapısı uçucu kül, silis dumanı, granüle yüksek fırın cürufu, pirinç kabuğu külü ve metakaolin gibi ince puzzolanik malzemelerin karışımlarda kullanılmasıyla önemli derecede geliştirilebilir [2]. Ayrıca, son yıllarda bu puzzolan katı atıkların yok edilmesiyle ilgili çevresel düzenlemelerdeki yeni eğilimler, bu katı atıkları betonda portland çimento yerine yapı malzemesi olarak kullanılmasına ilgiyi de arttırmaya başlamıştır [3]. Puzzolanik özelik gösteren PK, pirinç kabuğunun 700 ^{o}C'den daha düşük sıcaklıkta yakılmasıyla elde edilir. Pirinç kabuğu külü kristal olmayan veya amorf silis biçiminde yüksek miktarda silis içermektedir. Bu yüzden, pirinç kabuğu külü puzzolanik bir malzemedir ve çimento esaslı malzeme olarak kullanılabilir [4]. Ancak pirinç kabuğu külünün çimentoya katılmadan önce, ezilmesi veya uygun bir biçimde öğütülmesi gerekmektedir [5].

Pirinç kabuğu külü kullanılarak üretilen harç ve betonların performansı üzerine birçok çalışma yapılmıştır. Bui ve diğerleri [2] iki farklı çimento tipinde ve 0.3, 0.32 ve 0.34 su-bağlayıcı oranında pirinç kabuğu külünü % 0, 10, 15 ve 20 oranlarında çimento yerine kullanmışlardır. Pirinç kabuğu külü kullanılan betonların farklı kür günlerindeki f_c gelişimini belirlemişlerdir. En yüksek f_c değerlerini 0.3 su-bağlayıcı oranında ve % 20 oranında pirinç kabuğu külü içeren 7, 28 ve 90 günlük numunelerde gözlemişlerdir. Ganesan ve diğerleri [5] pirinç kabuğu külünü mineral katkı olarak % 0, 5, 10, 15, 20, 25, 30 ve 35 oranlarında çimento yerine ağırlıkça kullanmışlardır. Üretilen betonların dayanım ve geçirimlilik özeliklerini incelemişlerdir. En yüksek f_c ve en düşük geçirimsizlik özeliklerini % 20 oranında pirinç kabuğu külü içeren karışımlardan elde etmişlerdir. Rodrıguez de Sensale [6] 0.32, 0.40 ve 0.50 su-bağlayıcı oranında Uruguay ve ABD pirinç kabuğu külünü % 0, 10 ve 20 oranlarında çimento yerine kullanmıştır. Numunelerde 7, 28 ve 91 gün sonra f_c deneyleri yapmıştır. En yüksek f_c değerlerini 0.32 su-bağlayıcı oranındaki 28 günlük Uruguay pirinç kabuğu külü ve 90 günlük ABD pirinç kabuğu külü kullanılan numunelerde gözlemiştir. Gastaldini ve diğerleri [7] çimento yerine ağırlıkça % 20 pirinç kabuğu külü ve üç farklı kimyasal aktivatör kullanarak beton numuneler üretmişlerdir. En yüksek f_c değerlerini pirinç kabuğu külü ve farklı kimyasal aktivatör içeren 0.35 su-bağlayıcı oranındaki numunelerde gözlemişlerdir.

Beton teknolojisinde yapay sinir ağları (YSA) yöntemi birçok araştırmacı tarafından son yıllarda yaygın olarak kullanılmaya başlanmıştır. Bu çalışmada da, betonun f_c üzerine pirinç kabuğu külünün etkisini değerlendirmek için YSA yönteminde model oluşturulmuştur. Bu modelin eğitim ve testinde kullanılan 32 farklı karışımdaki 152 adet pirinç kabuğu külü içeren betonların 1, 3, 7, 14, 28 ve 90 günlük f_c deney sonuçları bilimsel literatürden elde edilmiştir [2,5]. YSA modelinin eğitim ve testinde f_c değerlerinin tahmin edilmesi için numunenin yaşı (NY), çimento tipleri (PC30 ve PC40), pirinç kabuğu külü (PK), su (S), süper akışkanlaştırıcı (SA), kum (K) ve agrega (A) olmak üzere 8 farklı girdi değişkeni kullanılmıştır. Deneysel sonuçların 101 tanesi ile YSA modeli eğitilmiş ve geri kalan 51 tanesinin sadece deney girdi değişkenleri kullanılarak model test edilmiştir.

2. YAPAY SİNİR AĞLARI

Sinir sisteminden yararlanılarak ortaya çıkarılan yapay sinir ağları (YSA) paralel çalışma ve eğitilebilme yetenekleri bakımından biyolojik sinir sisteminin çalışma özeliğini göstermektedir. Birçok özeliklerinin yanında paralel çalışmasından dolayı bilgileri hızlı bir şekilde işleyebilmesi ve donanımının kolayca gerçeklenebilir olması YSA yöntemini başka yöntemlere göre daha cazip duruma getirmektedir [7]. YSA yönteminde, girdiler ve çıktılar arasında pek çok hücre ve çok sayıda bağ vardır. Sinir hücreleri arasındaki bu bağlar ilişkiye göre bir aktarım değeri almaktadır ve bu değere ağırlık denmektedir. Bu ağırlıklar girilen tüm yeni verilere göre değişerek yenilenmektedir.

Basit bir yapay sinir hücresi; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş ana kısımdan oluşmaktadır. Girdiler, diğer hücrelerden ya da dış ortamlardan hücreye girilen bilgilerdir. Ağırlıklar, girdi seti veya kendinden önceki tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Toplama fonksiyonu girdiler ve ağırlıkların tamamının bu işlem elemanına etkisini hesaplayan bir fonksiyondur. Bu fonksiyon bir hücreye gelen net girdiyi hesaplar [8,9]. Girdi bileşenlerindeki ağırlıkların tümü Denklem (1) ile hesaplanır [10-14].

$$(\text{net})_j = \sum_{i=1}^{n} w_{ij} x_i + b \qquad (1)$$

Burada; $(net)_j$, n sinir hücresi ile önceki tabakadan alınan girdinin j. sinir hücresinin toplam ağırlığı, w_{ij} önceki tabakadaki i. sinir hücresi ve j. sinir hücresi arasındaki ağırlık, x_i önceki tabakadaki i. sinir hücresinin çıktısıdır [10]. Aktivasyon fonksiyonu ise toplama fonksiyonundan elde edilen net girdiyi bir işlemden geçirerek hücre çıktısını belirleyen bir

fonksiyondur. Genel olarak çok tabakalı algılayıcı modellerde aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmaktadır. Sigmoid fonksiyonu kullanılarak hesaplanan sinir hücresinin çıktısı Denklem (2)'deki gibi gösterilmektedir [9-15].

$$(\text{çıktı})_j = f(\text{net})_j = \frac{1}{1 + e^{-\alpha(\text{net})_j}} \tag{2}$$

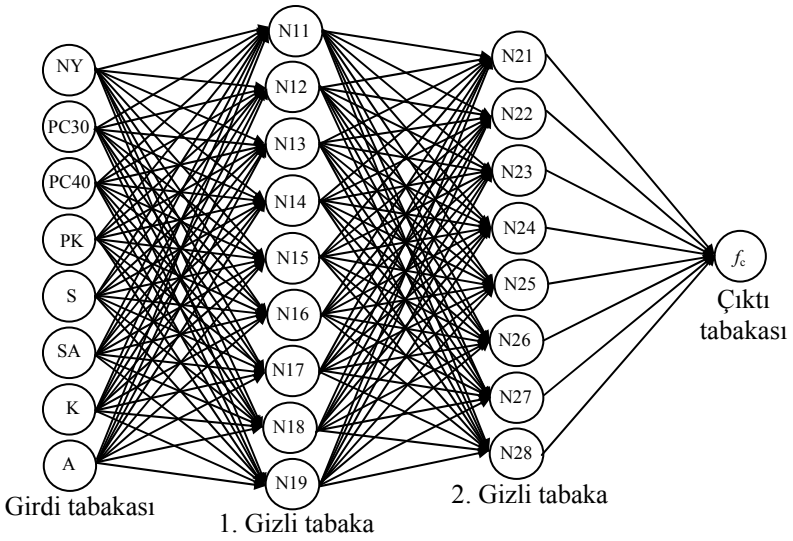
Burada; α yarı doğrusal bölgenin eğimini kontrol etmek için kullanılan bir sabittir. Sigmoid doğrusal olmayan aktivasyon fonksiyonu her tabakayı girdi tabakasından ayırmaktadır [10-15]. Denklem (2) şeklinde ifade edilen Sigmoid fonksiyonu (0, 1) arasında çıkışlar verir. Sigmoid işlemcisi sürekli bir fonksiyonu gösterdiğinden dolayı özellikle doğrusal olmayan tasvirlerde kullanılır. Bunun nedeni $(net)_j$ değişkeni bünyesinde bulunan parametrelere göre türevinin kolayca alınabilmesidir [8,11,16].

2.1. Yapay Sinir ağaları modeli

Bu çalışmada, YSA yönteminde çok tabakalı ileri beslemeli sinir ağı ile geri yayılma algoritması kullanılmıştır. Gizli tabaka ve çıkış tabakasındaki hücre çıkışlarında doğrusal olmayan Sigmoid fonksiyonu kullanılmıştır. PK içeren betonların f_c değerlerinin tahmini için sinir ağı modelinin eğitim ve testinde girdi olarak; NY, PC30, PC40, PK, S, SA, K ve A çıktı olarak; f_c değerleri kullanılmıştır. Burada, deney sonuçlarının 101 tanesi eğitim için kullanılırken 51 tanesi de test için kullanılmıştır. YSA yönteminde Şekil 1'de görüldüğü gibi girdi tabakasında 8 hücreye ve çıktı tabakasında 1 hücreye sahip bir model geliştirilmiştir. Eğitim ve test kümelerinin en küçük yüzdelik mutlak hata değerlerinden dolayı, çok tabakalı sinirsel ağda, iki gizli tabaka belirlenmiştir. Bu modelin birinci gizli tabakasında 9 ve ikinci gizli tabakasında 8 hücre kullanılmıştır. f_c değerlerini tahmin etmek için momentum oranı ve öğrenme oranı değerleri bulunarak öğrenme döngüleriyle model eğitilmiştir. Eğitilen model sadece deney girdi değerleri kullanılarak test edilmiş ve deney sonuçlarına yakın değerler tahmin edilmiştir. Modelin eğitiminde kullanılan parametre değerleri Tablo 1'de verilmiştir.

Tablo 1. Modelde kullanılan parametre değerleri.

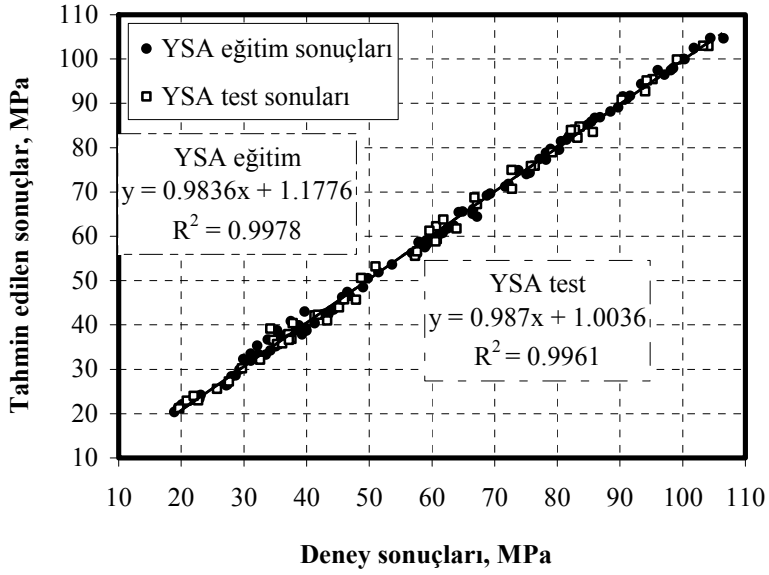
Parametreler	ANN
Girdi tabakası hücre sayısı	8
Birinci gizli tabaka hücre sayısı	9
İkinci gizli tabaka hücre sayısı	8
Momentum oranı	0.9
Öğrenme oranı	0.7
Öğrenme sonundaki hata	0.000031
Öğrenme döngüsü	10.000



Şekil 1. YSA modelinde kullanılan sistem.

3. MODEL SONUÇLARININ DEĞERLENDİRİLMESİ ve İRDELENMESİ

Deneysel çalışmalar ile YSA yönteminde geliştirilen modeldeki eğitim ve testten elde edilen 1, 3, 7, 28 ve 90 günlük PK içeren betonların f_c değerleri sırasıyla Şekil 2'de verilmiştir. Ayrıca, deneysel çalışmalar ile YSA modellinden elde edilen test sonuçları Tablo 2'de verilmiştir. YSA modelindeki testten elde edilen değerler Şekil 2 ve Tablo 2'de görüldüğü gibi deneysel sonuçlara çok yakındır. Bu durum, deneysel sonuçlar ile YSA modelinden elde edilen sonuçlarının uyum içinde olduğunu göstermektedir.



Şekil 2. YSA eğitim ve test sonuçlarının f_c deney sonuçları ile karşılaştırması.

Tablo 2. Deney sonuçları ile model test sonuçlarının karşılaştırması.

Girdi değişkenleri, kg/m^3								Deneysel	YSA
NY, gün	PC30	PC40	PK	S	SA	K	A	f_c, MPa	
1	495	0	55	165	5.80	546	1273	22.70	22.94
1	500	0	0	160	5.50	567	1324	20.90	22.87
1	400	0	100	160	6.22	558	1301	22.00	23.98
1	425	0	75	170	5.00	553	1290	19.70	21.17
1	0	495	55	165	6.80	546	1273	34.70	36.64
1	0	500	0	160	6.50	567	1324	37.80	40.41
1	0	400	100	160	7.36	558	1301	34.20	39.14
1	0	425	75	170	6.40	553	1290	32.60	32.11
3	495	0	55	165	5.80	546	1273	47.90	45.66
3	500	0	0	160	5.50	567	1324	41.30	42.14
3	400	0	100	160	6.22	558	1301	48.70	50.63
3	425	0	75	170	5.00	553	1290	45.20	43.93
3	0	495	55	165	6.80	546	1273	60.80	59.31
3	0	500	0	160	6.50	567	1324	63.90	61.74
3	0	400	100	160	7.36	558	1301	60.70	62.26
3	0	425	75	170	6.40	553	1290	57.30	55.57
7	495	0	55	165	5.80	546	1273	60.60	58.81
7	500	0	0	160	5.50	567	1324	51.00	53.20
7	400	0	100	160	6.22	558	1301	61.80	63.79
7	425	0	75	170	5.00	553	1290	57.60	56.62
7	0	495	55	165	6.80	546	1273	83.60	84.72
7	0	500	0	160	6.50	567	1324	76.40	75.93
7	0	400	100	160	7.36	558	1301	82.80	83.99
7	0	425	75	170	6.40	553	1290	79.20	78.96
28	495	0	55	165	5.80	546	1273	72.80	70.71
28	500	0	0	160	5.50	567	1324	59.60	61.26
28	400	0	100	160	6.22	558	1301	72.70	74.98
28	425	0	75	170	5.00	553	1290	67.20	67.23
28	0	495	55	165	6.80	546	1273	95.20	95.49
28	0	500	0	160	6.50	567	1324	85.70	83.54
28	0	400	100	160	7.36	558	1301	94.30	95.13
28	0	425	75	170	6.40	553	1290	90.30	90.80
90	495	0	55	165	5.80	546	1273	83.20	82.23
90	500	0	0	160	5.50	567	1324	66.80	68.73
90	400	0	100	160	6.22	558	1301	82.20	83.98
90	425	0	75	170	5.00	553	1290	75.80	75.83
90	0	495	55	165	6.80	546	1273	104.10	102.93
90	0	500	0	160	6.50	567	1324	94.00	92.71
90	0	400	100	160	7.36	558	1301	103.30	102.97
90	0	425	75	170	6.40	553	1290	99.10	99.90
7	364	0	19	203	0.00	575	1150	27.60	27.22
7	306	0	77	203	0.00	575	1150	29.70	30.22
7	249	0	134	203	0.00	575	1150	25.70	25.58
14	345	0	38	203	0.00	575	1150	35.30	35.70
14	287	0	96	203	0.00	575	1150	36.10	35.85
28	383	0	0	203	0.00	575	1150	37.10	37.92
28	326	0	57	203	0.00	575	1150	41.80	42.28
28	268	0	115	203	0.00	575	1150	37.60	36.88
90	364	0	19	203	0.00	575	1150	43.30	40.96
90	306	0	77	203	0.00	575	1150	46.00	45.74
90	249	0	134	203	0.00	575	1150	37.20	36.61

Bu çalışmada, YSA modelinin eğitim ve testi sırasındaki hataları ortaya çıkarmak için karesel ortalamanın kökü (*RMS*) Denklem (3) kullanılarak hesaplanmıştır. Buna ek olarak hatalar, mutlak kesir varyansı (R^2) ve ortalama mutlak yüzdelik hata (*MAPE*) sırasıyla Denklem (4) ve (5) kullanılarak hesaplanmıştır.

$$RMS = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(t_i - o_i)^2} \tag{3}$$

$$R^2 = \frac{(n\sum t_i o_i - \sum t_i \sum o_i)^2}{(n\sum t_i^{\,2} - (\sum t_i)^2)(n\sum o_i^{\,2} - (\sum o_i)^2)} \tag{4}$$

$$MAPE = \frac{1}{n}\left[\frac{\sum_{i=1}^{n}|t_i - o_i|}{\sum_{i=1}^{n} t_i} x100\right] \tag{5}$$

Burada *t* hedeflenen değeri, *o* model çıktı değerini ve *n* numune sayısını göstermektedir.

PK içeren betonların f_c değerlerini tahmin etmek için oluşturulan YSA modelindeki eğitimde *RMS*, R^2 ve *MAPE* istatistiksel parametre değerleri sırasıyla 1.2061, 0.9978 ve % 2.2316 olarak elde edilirken, testte sırasıyla 1.5467, 0.9961 ve % 2.2316 olarak elde edilmiştir. Tüm istatistiksel değerler, önerilen YSA modelinin uygun olduğunu ve PK içeren betonların f_c değerlerinin deneysel değerlere yakın olarak tahmin edilebileceğini göstermektedir. Ayrıca, eğitim ve test verileri için doğrusal en küçük kareler çizgisi, denklemi ve R^2 değerleri Şekil 2 üzerinde gösterilmiştir. İstatistiksel R^2 değerleri de tahmin edilen sonuçlar ile deneysel sonuçların birbirine çok yakın olduğunu göstermektedir.

4. SONUÇLAR

Pirinç kabuğu külü içeren betonların 1, 3, 7, 28 ve 90 günlük basınç dayanımı değerlerini tahmin edebilmek için yapay sinir ağları yönteminde model oluşturulmuştur. Bu modeli oluşturmak için yapay sinir ağları modelinde çok tabakalı ileri beslemeli ağ yapısı kullanılmıştır. Önce model deney girdi değişkenleri ve çıktı verileriyle eğitilmiştir. Daha sonra, eğitilen modelde sadece deney girdi değişkenleri kullanılarak pirinç kabuğu külü içeren betonların 1, 3, 7, 28 ve 90 günlük basınç dayanımı değerleri tahmin edilmiştir. Modeldeki eğitim ve test kümelerinden tahmin edilen değerler deney sonuçlarına çok yakındır. Bu durumu, deneysel sonuçlar ile model sonuçlarını karşılaştırmak için hesaplanan *RMS,* R^2 ve *MAPE* istatistiksel parametre değerleri açıkça göstermektedir. Sonuç olarak, pirinç kabuğu külü içeren betonların basınç dayanımı değerlerinin, yapay sinir ağları yönteminde model

geliştirilerek çok küçük hata oranlarıyla kısa sürede tahmin edilebileceği gözlenmiştir. Dahası beton özeliklerinin tahmin edilmesinde ve deneysel çalışmalarda ortaya çıkabilecek hataları azaltmak için yapay sinir ağları yönteminin kullanılabileceği bu çalışmada gözlenmiştir.

5. KAYNAKLAR

1. Giaccio, G., Rodríguez de Sensale, G. and Zerbino, R. "Failure mechanism of normal and high-strength concrete with rice-husk ash". Cement and Concrete Composites, 29(7): 566-574, 2007.
2. Bui, D.D., Hu, J. and Stroeven, P. "Particle size effect on the strength of rice husk ash blended gap-graded Portland cement concrete". Cement and Concrete Composites, 27(3): 357-366, 2005.
3. Han, S.-H., Kim, J.-K. Park and Y.-D. "Prediction of compressive strength of fly ash concrete by new apparent activation energy function". Cement and Concrete Research, 33: 965-971, 2003.
4. Chindaprasirt, P. and Rukzon, S. "Strength, porosity and corrosion resistance of ternary blend Portland cement, rice husk ash and fly ash mortar". Construction and Building Materials, , 22(8): 1601-1606, 2008.
5. Ganesan, K., Rajagopal, K. and Thangavel, K. "Rice husk ash blended cement: Assessment of optimal level of replacement for strength and permeability properties of concrete". Construction and Building Materials, 22(8): 1675-1683, 2008.
6. Rodríguez de Sensale, G. "Strength development of concrete with rice-husk ash". Cement and Concrete Composites, 28(2): 158-160, 2006.
7. Şen, Z. "Yapay sinir ağları ilkeleri". Su Vakfı Yayınları, s.s. 183, 2004.
8. Akkurt, S., Ozdemir, S., Tayfur, G. and Akyol, B. "The use of GA-ANNs in the modelling of compressive strength of cement mortar". Cement and Concrete Research, 33(7): 973-979, 2003.
9. Anderson, J.A. "Cognitive and psychological computation with neural models". IEEE Transactions on Systems, Man and Cybernetics, Vol. SMC-13, No. 5: 799-814, 1983.
10. Liu, S.W., Huang, J.H., Sung, J.C. and Lee, C.C. "Detection of cracks using neural networks and computational mechanics". Computer Methods in Applied Mechanics Engineering, 191(25-26): 2831-2845, 2002.
11. Topçu, İ.B. and Sarıdemir, M. "Prediction of properties of waste AAC aggregate concrete using artificial neural networks". Computational Materials Science, 41(1): 117-125, 2007.
12. Topçu, İ.B. and Sarıdemir, M. "Prediction of compressive strength of concrete containing fly ash using artificial neural network and fuzzy logic". Computational Materials Science, 41(3): 305-311, 2008.
13. Topçu, İ.B. and Sarıdemir, M. "Prediction of mechanical properties of recycled aggregate concretes containing silica fume using artificial neural networks and fuzzy logic". Computational Materials Science, 41(1): 74-82, 2008.
14. Topçu, İ.B. and Sarıdemir, M. "Prediction of rubberized mortar properties using artificial neural network and fuzzy logic". Journal of Materials Processing Technology, 199(1-3): 108-118, 2008.
15. Pala, M., Özbay, E., Öztaş, A. and Yuce, M.I. "Appraisal of long-term effects of fly ash and silica fume on compressive strength of concrete by neural networks". Construction and Building Materials, 21(2): 384-394, 2007.
16. Arbib, M.A. "The handbook of brain theory and neural networks". Cambridge (MA): MIT Press, 738-741, 1995.