Farklı Puzolanlarla Üretilmiş Çimentoların Dayanım Gelişiminin Yapay Sinir Ağlarıyla Tahmin Edilmesi

İlker Bekir TOPÇU[1], Cenk KARAKURT[1] ve Mustafa SARIDEMİR[2]

[1]Eskişehir Osmangazi Üniversitesi, İnşaat Mühendisliği Bölümü, 26480, Eskişehir
ilkerbt@ogu.edu.tr, ckarakurt@ogu.edu.tr
[2]Niğde Üniversitesi, İnşaat Mühendisliği Bölümü, 51200, Niğde
msdemir@nigde.edu.tr

ÖZET

Bu çalışma çimento üretiminde mineral katkı olarak kullanılan doğal ve yapay puzolanların en uygun kullanım oranının belirlenmesi için yapılmıştır. Bu amaçla laboratuvar ortamında farklı kaynaklardan sağlanan doğal zeolit (klinoptilolit), tras, volkanik tüf, uçucu kül ve yüksek fırın cürufu katkılı çimento üretiminde klinker yerine % 10, 20, 30, 35, 40 ve 45 oranlarında kullanılmıştır. Katkılı çimentolar üzerinde yapılan 2, 7, 28 ve 180 günlük basınç dayanımı deneyleri ile katkılı çimentoların dayanım gelişimi deneysel olarak belirlenmiştir. Daha sonra deneysel çalışmadan elde edilen veriler kullanılarak yapay sinir ağları (YSA) yönteminde model geliştirilmiştir. Modellerden elde edilen eğitim ve test sonuçları, yapay sinir ağları yönteminin, farklı mineral katkı içeren çimentoların farklı günlerdeki basınç dayanımı değerlerini tahmin etmek için güçlü potansiyele sahip olduğunu göstermiştir.

Anahtar Kelimeler: *Katkılı çimento; Puzolanlar; Basınç dayanımı; Yapay sinir ağları.*

ABSTRACT

This study is based on the determination of optimum usage of pozzolans as supplementary cementing material for blended cement production. For this purpose, blended cements were produced under laboratory conditions with natural zeolite (clinoptilolite), trass, volcanic tuff, fly ash and ground granulated blast furnace slag at 10, 20, 30, 40 and 45 % clinker replacement ratios. Strength development of the blended cements was determined with compressive strength tests performed at 2, 7, 28 and 180 days. Experimental results were also obtained by building models according to artificial neural network (ANN) system. It is concluded that the strength development of cement mortars containing different pozzolans can be obtained according to neural network model test results without any experimental study.

Key Words: *Blended cement; Pozzolans; Compressive strength; Artificial neural networks.*

1. GİRİŞ

Beton, inşaat endüstrisinde en yaygın olarak kullanılan yapı malzemesidir. Betonun dayanıklılığı, üretiminin kolaylığı ve üretim giderlerinin düşük olması en önemli tercih nedenidir. Beton üretiminde en pahalı bileşen çimentodur. Çimentoda kullanılan klinkerin üretiminde yüksek enerji gereksinim çimentonun üretim giderlerini artırmaktadır. Betonun geçirimliliğini azaltmaları, ekonomik ve ucuz olmaları, çimentonun hidratasyon ısısını azaltmaları ve betonun ileri yaş dayanım ve dayanıklılığını artırdığı için puzolanik malzemeler çimento üretiminde katkı malzemesi olarak yaygın şekilde kullanılmaktadır [1]. Puzolanik malzemelerde bulunan amorf silis, çimentonun hidratasyonu sonucu oluşan serbest kireçle reaksiyona girerek bağlayıcı özelik kazanır. Bu malzemeler aynı zamanda beton kalıcılığını da önemli oranda artırırlar [2].

Zeolitleşmiş tüfler ve amorf silissi tüfler çimento endüstrisinde en yaygın kullanılan doğal puzolanlardır. Zeolitlerin puzolanik aktivitesi malzemenin fiziksel kimyasal ve mineralojik özeliklerine bağlıdır [3]. Diğer taraftan, uçucu kül ve yüksek fırın cürufu gibi atık malzemeler çimento üretiminde yapay puzolan olarak kullanılmaktadır. Uçucu kül ve yüksek fırın cürufunun puzolanik aktiviteleri, camsı yapıları ve kimyasal kompozisyonlarıyla ilişkilidir. Yapılan çalışmada laboratuvarda üretilen katkılı çimento karışımlarında, üç farklı doğal puzolan (Eskişehir trası, Nevşehir tüfü ve klinoptilolit) ve iki farklı yapay puzolan (uçucu kül ve yüksek fırın cürufu) klinker yerine % 10, 20, 30, 40 ve 45 oranlarında kullanılmıştır. Katkılı çimentolarla üretilen harç numunelerinin 2, 7, 28 ve 180 günlük basınç dayanımları belirlenerek çimentoların dayanım gelişimi deneysel olarak belirlenmiştir. Daha sonra deneysel veriler kullanılarak kurulan yapay sinir ağı (YSA) modeliyle farklı katkılı çimentoların basınç dayanımları tahmin edilmiştir.

2. YÖNTEM

Yapay sinir ağları (YSA), merkezi sinir sisteminin biyolojik yapısının fonksiyonel çıkarımıdır [4]. YSA şaşırtıcı bir şekilde insan beyninin karakteristik özeliklerini göstermektedir. Örneğin, deneyimden öğrenme ve önceki örneklerden genelleştirerek yeni problemler çözmek gibi [5]. YSA üzerindeki ilk çalışmaların 1943 yılında başladığı kabul edilir. YSA kullanımı bilgisayar teknolojisinin gelişmesiyle 1980 yılından sonra daha verimli hale getirilmiştir [6]. Son yıllarda ortaya çıkan teknolojik gelişmelerle YSA inşaat mühendisliği alanında birçok

uygulamada başarıyla kullanılmıştır. Özellikle, inşaat mühendisliğinde YSA yapısal zararların belirlenmesinde, yapısal sistemlerin tanımlanmasında, malzeme davranışının modellenmesinde, yapısal optimizasyonda, yapısal kontrolde, yeraltı suyunun izlenmesinde, deneysel sonuçların değerlendirilmesinde, beton ve harç karışım oranlarının tahmin edilmesinde başarıyla uygulanmıştır [7]. 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 giren 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 ağırlıklar $(net)_j$ (1) ifadesi kullanılarak hesaplanır [10].

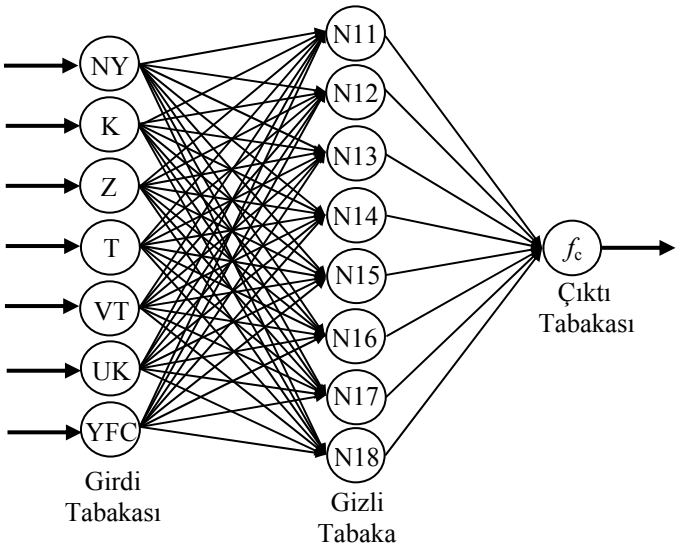
$$(net)_j = \sum_{i=1}^{n} w_{ij} x_i + b \tag{1}$$

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]. b içsel katkı olarak sabit bir değeri ifade eder 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 kullanılır. Sigmoid aktivasyon fonksiyonu kullanılarak hesaplanan sinir hücresinin çıktısı Denklem (2) ile hesaplanır.

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

Burada; α yarı doğrusal bölgenin eğimini kontrol etmek için kullanılan bir sabittir. Sigmoid doğrusal olmayan aktivasyon her tabakayı girdi tabakasından ayırmaktadır ve (0, 1) arasında değişen çıktılar verir [10]. Bu çalışmada, çok tabakalı ileri beslemeli sinir ağı ile geri yayılma algoritması seçilmiştir. İleri beslemeli sinir ağları birçok pratik uygulamada en popüler ve en yaygın olarak kullanılan modellerdir. Çok tabakalı tekli doğrusal algılayıcı gibi çok farklı isimlerle bilinir [4]. Geri yayılma algoritması, çok tabakalı tekli doğrusal algılayıcılar için eğitim algoritmalarının en iyilerinden biri olarak bilinen, kısa zamanda ağırlıkları ayarlayarak

belirli eğitimin kopyasını çıkarmak için hatayı en düşük seviyeye indiren bir rampa düşüş tekniğidir [11]. Sinir ağı modelinin eğitim ve testinde girdi olarak; numune yaşı (NY), klinker (K), zeolit (Z), tras (T) volkanik tüf (VT), uçucu kül (UK) ve yüksek fırın cürufu (YFC) çıktı olarak; harç numunelerinin basınç dayanımları (f_c) kullanılmıştır. Deneysel çalışma verilerinden 163 tanesi modelin eğitilmesi için, 81 tanesi de eğitilen modelin testi için kullanılmıştır. Şekil 1'de gösterildiği gibi girdi tabakasında 7 hücreye, gizli tabakasında 8 hücreye ve çıktı tabakasında 1 hücreye sahip bir sinir ağı modeli geliştirilmiştir. Eğitim ve test kümelerinin en küçük yüzdelik mutlak hata değerlerinden dolayı, çok tabakalı sinirsel ağın kurulumunda tek gizli tabaka kullanılmıştır. Komşu tabakaların hücreleri ağırlıklarla tam olarak birbirine bağlantılandırılmıştır. Momentum oranı ve öğrenme oranı değerleri bulunarak öğrenme döngüleri ile model eğitilmiştir. Eğitilen model sadece girdi değerleriyle test edilmiş ve deney sonuçlarına yakın değerler bulunmuştur. Çok tabakalı ileri beslemeli yapay sinir ağı modelinde kullanılan parametre değerleri Tablo 1'de verilmiştir.



Şekil1 1. Yapay sinir ağı modelinde kullanılan sistem.

Tablo 1. Yapay sinir ağı modelinde kullanılan parametreler.

Parametreler	**YSA**
Girdi tabakası hücre sayısı	7
Gizli tabaka sayısı	1
Gizli tabakadaki hücre sayısı	8
Çıktı tabakası hücre sayısı	1
Momentum oranı	0.9
Öğrenme oranı	0.7
Eğitim sonrası hata	0.0005
Öğrenme döngüsü	15.000

Deneysel çalışmalardan elde edilen sonuçlar ile YSA modelinin eğitimi ve testi sırasında oluşabilecek hataları ortaya çıkarmak için karesel ortalamanın kökü (*RMS*) Denklem (3) kullanılarak hesaplanmıştır [12].

$$RMS = \sqrt{\frac{1}{p}\sum_i \left|t_i - o_i\right|^2} \tag{3}$$

Buna ek olarak, mutlak kesir varyansı (R^2) ve ortalama mutlak yüzdelik hata (*MAPE*) Denklem (4) ve (5) kullanılarak sırasıyla hesaplanmıştır [13].

$$R^2 = 1 - \left(\frac{\sum_i (t_i - o_i)^2}{\sum_i (o_i)^2} \right) \tag{4}$$

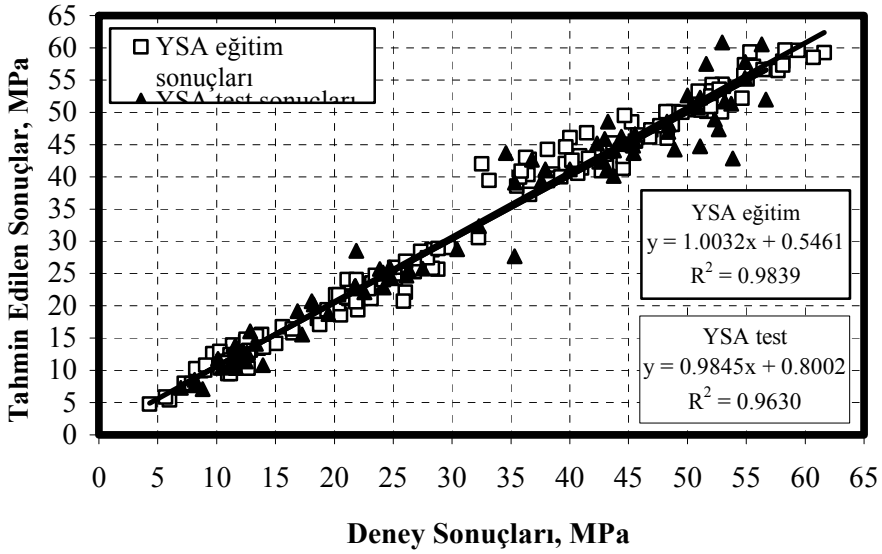
$$MAPE = \frac{1}{p}\left[\frac{\sum_i \left|t_i - o_i\right|}{\sum_i t_i} x100 \right] \tag{5}$$

3. SONUÇLAR

Deneysel girdi ve çıktı verileri ile modeller eğitildikten sonra testler sadece deneysel girdi verileri kullanılarak yapılmıştır. Eğitim sonrası 2, 7, 28 ve 180 günlük basınç dayanımı sonuçlarıyla YSA modelinin test sonuçlarının karşılaştırılması Şekil 2'de verilmiştir. Sonuçlar incelendiğinde YSA modelinden elde edilen tahmini basınç dayanımlarının deneysel basınç dayanımlarına oldukça yakın sonuçlar verdiği görülmüştür. Deneysel sonuçlar ile modelden elde edilen eğitim ve test sonuçları Şekil 2'de karşılaştırılmıştır. Ayrıca, karşılaştırmadan elde edilen en küçük kareler çizgisi, denklemi ve R^2 değerleri de Şekil 2 üzerinde verilmiştir. Sonuçlar incelendiğinde model sonuçlarının deneysel verilere oldukça yakın olduğu görülmüştür. Bu ilişki Tablo 2'de verilen istatistiksel parametrelerden de (*RMS*, R^2 ve *MAPE*) açıkça anlaşılmaktadır. Bu durumda göstermektedir ki iyi şekilde eğitilmiş bir YSA modeli deneysel çalışmalardan ortaya çıkabilecek hata yada sapmalardan kaynaklanan olumsuzlukların giderilmesine yardımcı olabilecektir.

Tablo 2. Önerilen YSA modellerinin basınç dayanımı istatistiksel değerleri.

İstatistiksel parametreler	**ANN**	
	Eğitim serisi	Test serisi
RMS	2.1867	3.1372
R^2	0.9962	0.9922
MAPE	5.7751	7.3929



Şekil 2. YSA ile deneysel basınç dayanımı sonuçlarının karşılaştırılması.

4. ÖNERİLER

Farklı puzolanlarla üretilen çimentoların basınç dayanımlarının YSA modeli kullanılarak tahmin edilebileceği, elde edilen istatistiksel parametrelerden açıkça (*RMS*, R^2 ve *MAPE*) gözlenmiştir. Katkı oranı ve tipine bağlı olarak çimento dayanım sınıfının istenen çimento için önceden belirlenmesi YSA modellemesiyle olasıdır. Ancak burada YSA model yapısının kurulumunda kullanılacak veri sayısının yeterli ve deneysel sonuçların güvenilir olması gerekmektedir. Modelde kullanılan gizili tabaka ve hücre sayısının uygun olarak belirlenmesi elde edilecek sonuçların doğruluğu için önemlidir. Bu şekilde kurulan bir YSA modeli ile farklı çimentoların basınç dayanımları çok küçük hata oranıyla tahmin edebilecektir.

5. KAYNAKLAR

1. Shi, C.,"An Overview on the Activation of Reactivity of Natural Pozzolans", Canadian Journal of Civil Engineering, 28: 778-786, 2001.

2. Khandaker, M. and Hossain, A., "Blended Cement Using Volcanic Ash and Pumice", Cement and Concrete Research, 33: 1601-1605, 2003.
3. Gervais, C. and Ouki, S.K., "Performance Study of Cementitious Systems Containing Zeolite and Silica Fume: Effects of Four Metal Nitrates on the Setting Time", Strength And Leaching Characteristics, Journal of Hazardous Materials, B93: 187-200, 2002.
4. Adhikary, B.B. and Mutsuyoshi, H., "Prediction of Shear Strength of Steel Fiber RC Beams Using Neural Networks", Construction and Building Materials, 20: 801-811, 2006.
5. Öztaş, A., Pala, M., Özbay, E., Kanca, E., Çağlar, N. and Asghar Bhatti, M., "Predicting the Compressive Strength and Slump of High Strength Concrete Using Neural Network", Construction and Building Materials, 20: 769-775, 2005.
6. Topçu, İ.B. and Sarıdemir, M., "Prediction of Rubberized Concrete Properties Using Artificial Neural Networks and Fuzzy Logic", Construction and Building Materials", 22: 532-540, 2008.
7. Kewalramani, A.M. and Gupta, R., "Concrete Compressive Strength Prediction Using Ultrasonic Pulse Velocity Through Artificial Neural Networks", Automation in Construction, 15: 374-379, 2006.
8. Anderson, J.A., "Cognitive and Psychological Computation with Neural Models", IEEE Transactions on Systems, Man and Cybernetics, 5: 799-814, 1983.
9. Günaydın, H.M. and Doğan, S.Z., "A Neural Network Approach for Early Cost Estimation of Structural Systems of Building", International Journal of Project Management, 22: 595-602, 2004.
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: 2831-2845, 2002.
11. Topçu, İ.B. and Sarıdemir, M., "Prediction of Properties of Waste AAC Aggregate Concrete Using ANN", Computational Materials Science, 41: 117-125, 2007.
12. Turatsinze A., Bonnet S. and Granju J.L., "Potential of Rubber Aggregates to Modify Properties of Cement Based-Mortars: İmprovement in Cracking Shrinkage Resistance", Construction and Building Materials, 21: 176-181, 2007.
13. Topçu, İ.B., Karakurt, C. and Sarıdemir, M., 2008, "Predicting the Strength Development of Cements with Different Pozzolans by Neural Network and Fuzzy Logic", Journal of Materials Design, 29: 1986-1991, 2008.