



Makale

PUZOLANLARIN BETON BASINÇ DAYANIMINA ETKİSİNİN YAPAY SİNİR AĞLARIYLA İNCELENMESİ

İlker Bekir TOPÇU^a, Tayfun UYGUNOĞLU^b, Mustafa SİVRİ^c

^aEskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fak., İnşaat Mühendisliği Böl., 26480 Eskişehir

^bAfyon Kocatepe Üniversitesi, Teknik Eğitim Fakültesi, Yapı Eğitimi Böl., 03200 Afyonkarahisar

^cSüleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, 32240 Isparta

ÖZET

Bu çalışmada puzolan katkılardan uçucu külün betonun basınç dayanımı üzerindeki etkisi yapay sinir ağı (YSA) ile modellenmeye çalışılmıştır. Bu yöntem diğer sektörlerde olduğu gibi inşaat sektöründe de son yıllarda önem kazanmaya başlamıştır. Modelleme için Matlab paket programlama dili kullanılmıştır. YSA ile modelleme yaklaşımında farklı su-çimento oranlarında, uçucu kül ikameli betonun 7, 28, 90 ve 365 günlük yaşı, çimento ile ikame edilen % 0 (kontrol), 10, 20 ve 30 uçucu kül miktarı ve bunlara göre elde edilen beton numunelerin basınç dayanımları dikkate alınmıştır. YSA yaklaşımı ile deneysel olarak elde edilmiş veriler karşılaştırılmış ve sonuçların birbirine çok yakın olduğu görülmüştür. YSA yaklaşımı ile betona en iyi basınç dayanımını kazandıracak olan optimum uçucu kül miktarı belirlenmiş olacaktır.

Anahtar Kelimeler: Uçucu kül, beton yaşı, basınç dayanımı, yapay sinir ağı


1. GİRİŞ

Mineral katkıları gibi düşük enerjili yoğun malzemelerin, Portland çimentosuna daha fazla enerji kazandırmak amacıyla ya doğrudan ya da çimentoyla ikame edilmesi teşvik edilmektedir. Mineral karışımlardan olan uçucu kül, betonun dayanıklılık karakteristikleri üzerinde önemli bir etkiye sahiptir [1].

Uçucu kül veya taban külü gibi çevresel düzenlemeyle ilişkili olan atıkların değerlendirilmesinde yeni bir eğilim olarak, kısmen Portland çimentosuyla yer değiştirilerek beton üretiminde kullanılma yoluna gidilmektedir. Özellikle uçucu kül, hidrasyon ısısını azaltmak ve erken yaşlardaki çatlama riskini önlemek için kütle betonlarında kullanılmaktadır [2].

Uçucu küller, Portland çimentosu klinkerindeki kadar olmasa da az bir miktarda çimento mineralleri içermektedir. Bu da, termik santrallerde büyük miktarda açığa çıkan uçucu küllerin çimentolu malzemelerde, çimentonun belirli bir miktarıyla yer değiştirmesi sonucunda kullanılabilmesi anlamına gelmektedir [3].

Hem betonun bazı özelliklerini iyileştirmek, hem de üretimde ekonomikliği sağlamak amacıyla betonda çimentonun bir kısmı yerine uçucu kül kullanımı oldukça yaygınlaşmıştır. Genel olarak küresel tane şekliyle (Şekil 1) taze betonda işlenebilmeyi iyileştiren, pompalanabilme ve kohezyonu artıran uçucu kül, puzolanik özeliği nedeniyle de sertleşmiş betonda dayanım ve dayanıklılığı arttırmakta ve terlemeyi azaltmaktadır. Ayrıca, betonda klor geçirimsizliğini önemli ölçüde azaltmaktadır [4-6].



Şekil1. Uçucu külün mikro yapısının genel görünümü

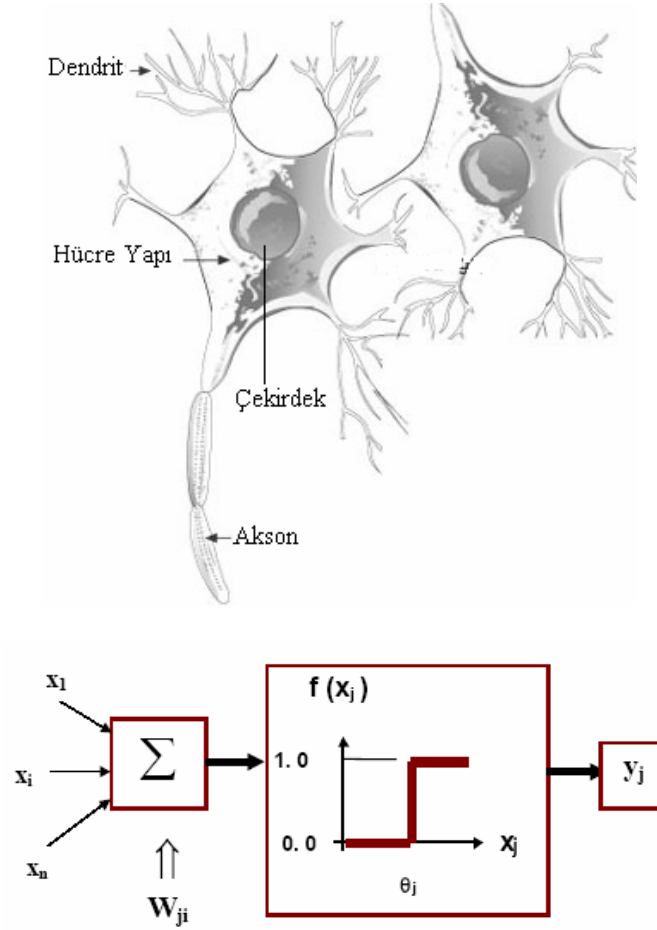
Beton kalıba döküldüğü ilk andan itibaren dayanım kazanmaya başlar ve gün geçtikçe kazandığı dayanım artma eğilimindedir. Beton çeşitli bileşenlerden meydana gelen bir kompozit olduğu için içerisindeki bileşenlerin değiştirilmesi ile bileşenler arasındaki belirsiz davranışlar nedeniyle değişen özellikleri matematiksel olarak ifade etmek çok güçtür. Bu çalışmada matematiksel modelleme gerektirmeden kullanılabilen ve deneysel verilerle çok yakın sonuçlara götüren *yapay sinir ağları* yaklaşımı, uçucu kül içeren betonun uçucu kül miktarına, su-çimento oranına ve betonun yaşına göre basınç dayanımındaki değişimi modellemek için kullanılmıştır.

2. YAPAY SİNİR AĞLARI (YSA)

Son yıllarda gelişen bilgisayar teknolojisi ile beraber geniş bir kullanım alanı bulan yapay zeka teknikleri, mühendislik alanında en çok optimizasyon amaçlı olarak kullanılmakta ve diğer klasik yöntemlere göre daha iyi sonuç vermektedir. İnşaat mühendisliği problemlerinin çözümünde yaygın olarak kullanılan yapay zeka tekniklerinden birisi yapay sinir ağlarıdır.

Yapay sinir ağları (YSA), insan beyninin temel birimi olan nöronlara benzer olarak teşkil edilen yapay nöronların farklı topoloji ve ağ modelleriyle birbirine bağlanmasıyla oluşan karmaşık sistemlerdir. Bir YSA, bir biriyle etkileşim içindeki pek çok yapay nöronun paralel bağlı bir hiyerarşik organizasyonudur. YSA'da hesaplama algoritmik programlamaya bir seçenek oluşturan, temel olarak yeni ve farklı bir bilgi işleme tekniğidir.

En genel anlamda YSA ileri beslemeli ve geri beslemeli ağlar şeklinde iki ana grup ta düşünülebilir. İleri beslemeli ağlarda nöronlar; girdi, saklı ve çıktı olarak adlandırılan katmanlar vasıtasıyla organize edilir. Her bir katmandaki nöronlar; bir sonraki katman nöronları ile bağlantı ağırlıkları vasıtasıyla ilişkilidir. Ancak katmanların kendi aralarında her hangi bir bağlantı yoktur. Bilgi, girdi katmanından çıktı katmanına doğru ilerler. Buna aktivasyon yönü de denilir. Bu tür yapay sinir ağına örnek olarak tek ve çok katmanlı perceptron ağları verilebilir. Bu tür ağlar denetimli öğrenme teknikleriyle eğitilir. Geri beslemeli ağların en belirgin özelliği; katmanlar arasındaki nöronlar birbiriyle bağlantılı olup ayrıca bir dinamik hafızaya sahiplerdir. Bu tür ağların eğitilmesi takviyesiz öğrenmeye bir örnek oluşturur. Hopfield ağları daha çok bir içerikli adreslenebilir bellek olarak veya optimizasyon tipi problemlerde başarılıdır. YSA'daki işleme elemanları biyolojik olarak insan beynindeki nöronlara karşılık gelmektedir (Şekil 2).



Şekil 2. Biyolojik ve Yapay Sinir Ağı Modeli [7]

YSA'nın işleyişi de buna benzer olarak gelişmektedir. 1940 yılında McCulloch ve Pitts nöronun, mantık sistemlerinde basit eş değer yapısıyla modellenebileceğini ortaya atmışlardır [7]. Bu amaçla yaptıkları çalışmalar sonunda Şekil 2'de görüldüğü gibi bir yapay sinir ağı modeli geliştirmişlerdir. Bu modele göre, bir sinir N tane ağırlıklandırılmış girişi toplamakta ve sonucu lineer olmayan bir fonksiyondan geçirmektedir. Herhangi bir katmandaki j . birime gelen toplam giriş, önceki katmandaki birimlerin y_i çıkışlarının (ilk katman için girişlerin) bağlantılar üzerindeki w_{ij} ağırlıkları ile hesaplanmış bir ağırlıklı toplamdır.

$$net_j = \sum_i w_{ij} y_j \quad (1)$$

Birimin çıkışı, bu değer bir eşik değerden çıkartılıp lineer olmayan bir fonksiyondan geçirilmesiyle hesaplanır. Çıkış değerleri

$$f(x) = \frac{1}{1 + \exp(-\sum_i w_{ij} y_j)} \quad (2)$$

fonksiyonu ile hesaplanır [8].

YSA'da Öğrenme ve Ağıın Eğitilmesi

YSA konvansiyonel programlama gibi belirli bir algoritma çerçevesinde programlanmazlar. Sinir ağları insanlar gibi örnekler ile eğitilirler. YSA'nın öğrenmesi bir çocuğun öğrenmesi gibidir. Sıcak bir nesneye dokunmaması gerektiğini deneyerek öğrenen çocuklar zamanla daha az sıcak olan bir cisme dokunabilme cesaretini gösterirler ve sıcak süt dolu bardağı elleriyle tutarlar. Yani çocuk sıcaklık bilgisini öğrenmiş olmaktadır. Günümüze kadar çeşitli öğrenme algoritmaları geliştirilmiştir. Bunlar temel olarak denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olarak üç ana gruba ayrılır.

Denetimli öğrenmede sinir ağına hem girdi hem de çıktı değerleri sunulur. Ağıın ürettiğı çıktı ile istenen çıktı arasındaki fark sıfır veya ona yakın bir değere gelinceye kadar ağırlıklar değiştirilir. Bu tür öğrenme modelini kullanan ağlar; Perceptron ve ilişkili hafızalar, takviyeli öğrenme, stokastik öğrenme, vektör nicelik öğrenmesi, delta ve genelleştirilmiş delta kuralı, geri yayılma algoritması, bu grup öğrenmede kullanılan etkin metotlardır.

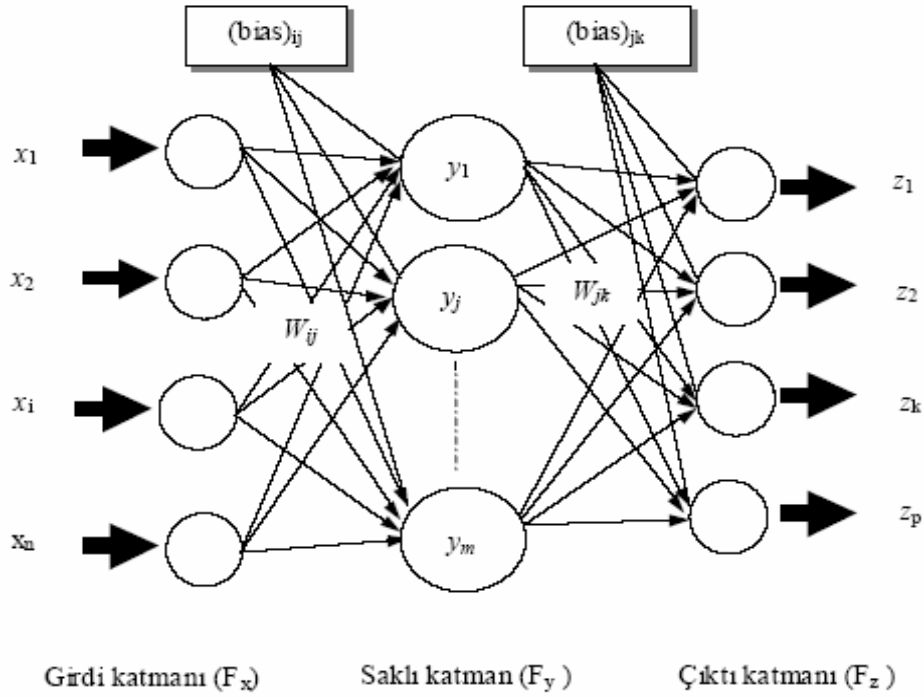
Denetimsiz öğrenmede ağı sadece girdi vektörü uygulanır. Girdi değerlerine uygun bir çıktı üretilinceye kadar bağlantı ağırlıkları değiştirilir. Bu metot görüntü işleme, işaret işleme ve kontrol problemlerinde etkin olarak kullanılır. Kohonen'in kendini düzenleyen uzaylar, ve adaptif rezonans teorisi (ART) denetimsiz öğrenmeye örnek olarak verilebilir. Takviyeli öğrenmede ise giriş değerlerine karşılık gelecek uygun çıktılardan elde edilmesi sırasında ağırlıkların en uygun değerlerinin bulunmasında genetik algoritmalar veya en iyilime yöntemleri kullanılır. Böylece ağırlıklar optimize edilmektedir. Bu şekilde ağı, kendisini istenen cevaplara uyarlayabilir ve kendi içinde bilgiyi düzenleyebilir.

YSA'nın öğrenme mekanizması, girdi vektörü ve transfer fonksiyonu tarafından sağlanan değerlere karşılık olarak bağlantı ağırlıklarının hepsinin veya bir kısmının değiştirilmesidir. YSA ne kadar çok örnekle eğitilirse hem öğrenebilecekleri olay ve tanıyabilecekleri obje sayısı artar, hem de hata oranı azalarak daha hassas sonuçlar elde edilir. En genel anlamda nöral ağlar; kullanılan nöron modeli, bu nöronların ağı yapısında bir arada bulunma şekli, yani ağı mimarisi, ağırlıkların ayarlanması için öğrenme kuralının belirlenmesi ve kullanılan aktivasyon fonksiyonu gibi dört farklı özellik ile karakterize edilir. Ağıdaki her bir katman işleme elemanının bir toplamından oluşur. Her bir işleme elemanı kendi girdi bağlantılarındaki değerlerin ağırlıklı toplamını bir eşik fonksiyonundan geçirerek bir çıktı değeri üretir. Bilginin ağı içerisinde saklanması bağlantı ağırlıklarının ayarlanarak uygun değerleri almasıyla sağlanır. Bu ağırlık değerleri eğitim işlemi başlangıcında rasgele küçük sayılara atanır. İstenen çıktı ile ağı çıktısı arasındaki fark yeterince küçük oluncaya kadar yapılan eğitim işlemi sırasında öğrenme kuralına bağlı olarak ağırlıklar düzenlenerek sonuç değerleri elde edilir [8].

Tekniğin inşaat mühendisliğinde kullanımı daha çok malzeme modellenmesi [9], boyutlandırma [10], optimizasyon [11], hasar analizi [12], deprem mühendisliği [13] gibi konuları içermektedir. Daha önce yapılan bu çalışmalarda genellikle geri-yayılma ve Hopfield sinir ağları kullanılmıştır. Betonun farklı yüklemeler altındaki gerilme-şekil değiştirme bağıntılarının belirlenmesinde başarıyla uygulanmış ve çalışmada malzeme davranışı ile ilgili herhangi bir kabul yapılmamıştır [14-16].

2.2. Geriye Yayılma Öğrenme Algoritması

Sinir ağlarında öğrenme girdi ve çıktı kümesi için test edilen ağıın, istenilen çıktıyı verecek ağırlık kümesinin belirlenmesidir. Bu ağırlık vektörü istenen çıktı ile ağı çıktısı arasındaki fark minimum oluncaya kadar 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 3'te bir adet saklı katmandan oluşan çok katmanlı bir ağı görülmektedir [15,17].



Şekil 3. Tek Saklı Katmana Sahip Bir Geri-Yayımla Ağ Mimarisi

3. DENEYSEL ÇALIŞMA

Çalışmada F sınıfı uçucu külün erken ve ileriki yaşlardaki sertleşmiş betonun özelliklerine etkisinin araştırıldığı [2,18,19] nolu kaynaklardan elde edilen sonuçlar YSA yaklaşımı ile modellenerek karşılaştırılmıştır. Deneysel çalışmalarda, uçucu külün betonun basınç dayanımına etkisinin araştırılması için yer değiştirme yöntemiyle uçucu kül ile çimento % 0 (kontrol), 10, 20 ve 30 oranlarında yer değiştirilmiştir ve su-çimento (s-ç) oranı 0.35 ile 0.6 arasında dört farklı oran seçilmiştir. Numuneler üzerinde 7, 28, 90 ve 365 günlük basınç dayanımları belirlenmiştir (Çizelge 1).

Çizelge 1. Uçucu Kül oranı ile s-ç oranının zamana bağlı olarak basınç dayanımına etkisi


s-ç	Uçucu kül (%)	Beton yaşı (gün)			
		7	28	90	365
0.35	0	49.1	56.3	59.7	68.8
	10	50.2	55.7	64.3	74.8
	20	44.9	56	61.3	75.3
	30	39.1	51.8	59.5	73.9
0.4	0	43.6	49.7	54.6	61.9
	10	42.1	50.3	57.5	66.5
	20	38	48	56.1	65.4
	30	33.7	42.7	53.5	61.3
0.55	0	26.6	36.1	40.2	46.5
	10	25.4	38.3	45.8	51.8
	20	22.6	33.8	43.5	52.1
	30	18.3	30.9	39.3	48.2
0.6	0	23.6	32.9	38.6	42.5
	10	21.8	33.8	40.3	47.6
	20	18	28	37.2	44.8
	30	13.5	25	36	43.2

Uçucu kül oranı ile su-çimento oranının zamana baęlı olarak basınç dayanımını etkisini incelemek amacıyla deney verileri YSA'nı eğitmek için kullanılmıştır. Uçucu kül oranı, su-çimento oranı ve zaman girdi deęişkenleri olarak seçilmiş ve basınç dayanımı çıktı olarak alınmıştır. Ağın eğitilmesinde geriye yayılma ağ mimarisi kullanılmıştır. Ağ mimarisi Şekil 4'te görölmektedir.

Ayrıca deneysel olarak elde edilen basınç dayanımı deęerleri ile YSA yaklaşımından elde edilen deęerler arasındaki hata (E) oranları (3) nolu denklem yardımıyla % olarak hesaplanmıştır.

$$E (\%) = \frac{D_i - YSA_i}{D_i} \times 100 \quad (3)$$

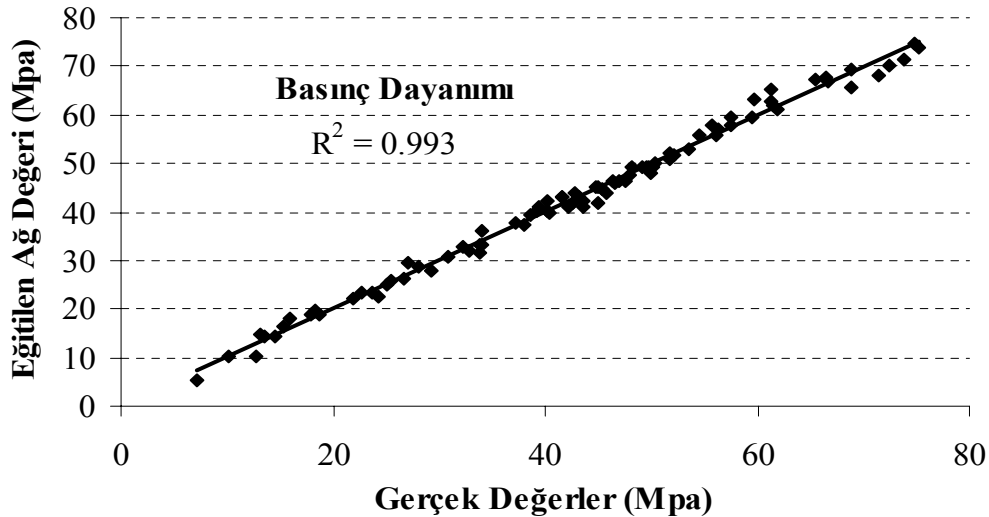
Denklemde; D, deneysel veri; YSA, YSA'dan alınan veriyi ifade etmektedir.



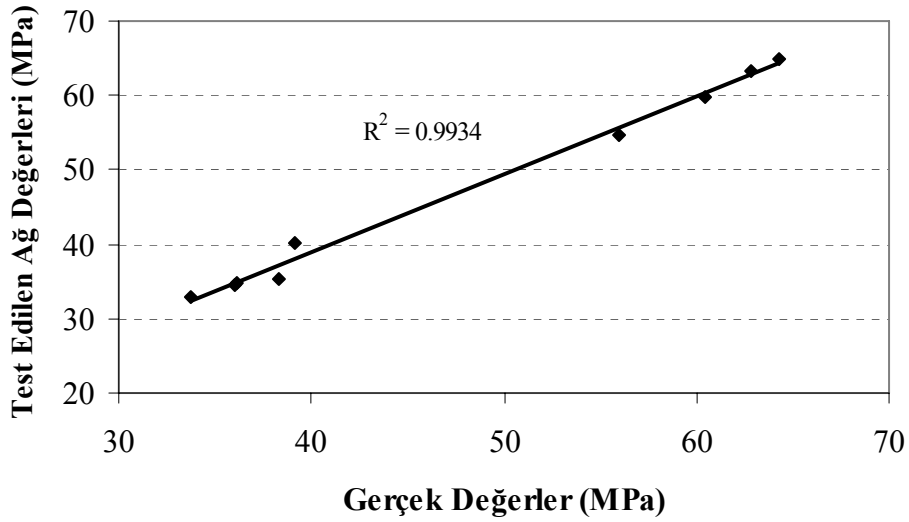
Şekil 4. Geriye Yayılma Ağ mimarisi

DENEY SONUÇLARI VE DEęERLENDİRİLMESİ

Geriye yayılma ağ algoritması deney verileri için 10^{-4} hata deęerinde eğitilmiş ve test edilmiştir. Buna göre Şekil 5-6'da verilen ağın eğitilme ve test deęerleri yakınsama deęeri % 99 olarak elde edilmiştir.



Şekil 5. Deney Verilerinin Eğitilme Deęeri




Şekil 6. Test Verilerinin Eğitilme Değeri

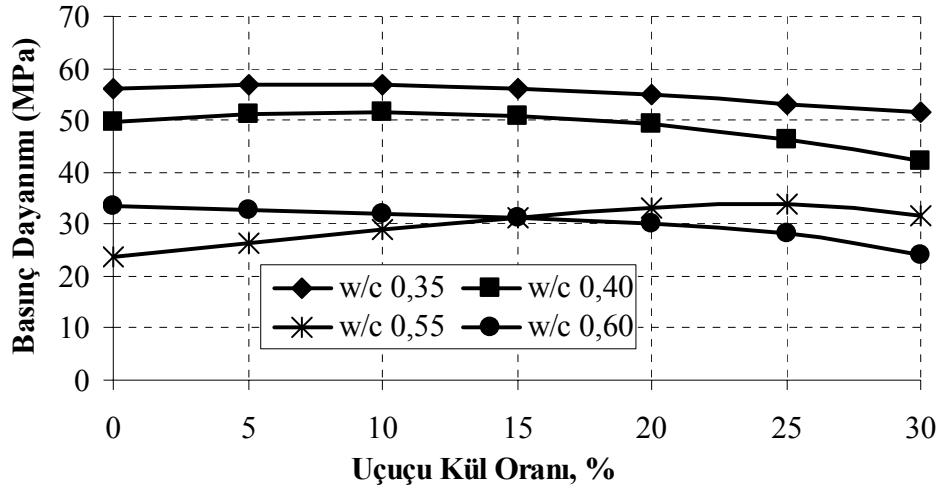
Ağın eğitilen değerlerinin güvenilirlik derecesinin yüksek olmasından dolayı % 0-30 uçucu kül oranları için her s-ç oranı ve beton yaşı için basınç dayanım değerleri test edilmiş ve bu değerlerin de yakınsama derecelerinin % 99 olduğu yine Şekil 5 ve 6'da görülmektedir.

Elde edilen modelleme ile birlikte deneysel veriler uçucu kül içeriğine, beton yaşına ve s-ç oranlarına göre çok yakın olduğundan, % 0-30 uçucu kül içeriği arasındaki % 5, 15 ve 25 uçucu kül oranları içeren her beton için beton yaşı ve s-ç oranına bağlı olarak basınç dayanımları tahmin edilmiş ve grafik ortamında verilmiştir. Eğitilen ağ kullanılarak test edilen verilerle birlikte uçucu kül ve s-ç oranının değişiminin beton basınç dayanımına etkisi beton yaşına göre belirlenmiş ve Şekil 7-10'da verilmiştir.


Şekillerden de görüldüğü gibi genel olarak sabit uçucu kül ve beton yaşında, s-ç oranı arttıkça basınç dayanımının azaldığı görülmektedir. Betonun karıştırılması esnasında s-ç oranını artırılmasının, betonun kolay yerleştirilmesini sağladığı ancak beton prizini aldıktan sonra betonun içerisindeki serbest suyun buharlaşarak ortamı terk etmesi sonucu gözenekli bir ortam oluşturması; ve bu nedenle betonun dayanımının azaldığı belirtilebilir.




Şekil 7. Uçucu Kül ve s-ç Oranının Değişimiyle 7 Günlük Beton Basınç Dayanımının Değişimi



Şekil 8. Uçucu Kül ve s-ç Oranı Değişimiyle 28 Günlük Beton Basınç Dayanımının Değişimi



Şekil 9. Uçucu Kül ve s-ç Oranı Değişimiyle 90 Günlük Beton Basınç Dayanımının Değişimi

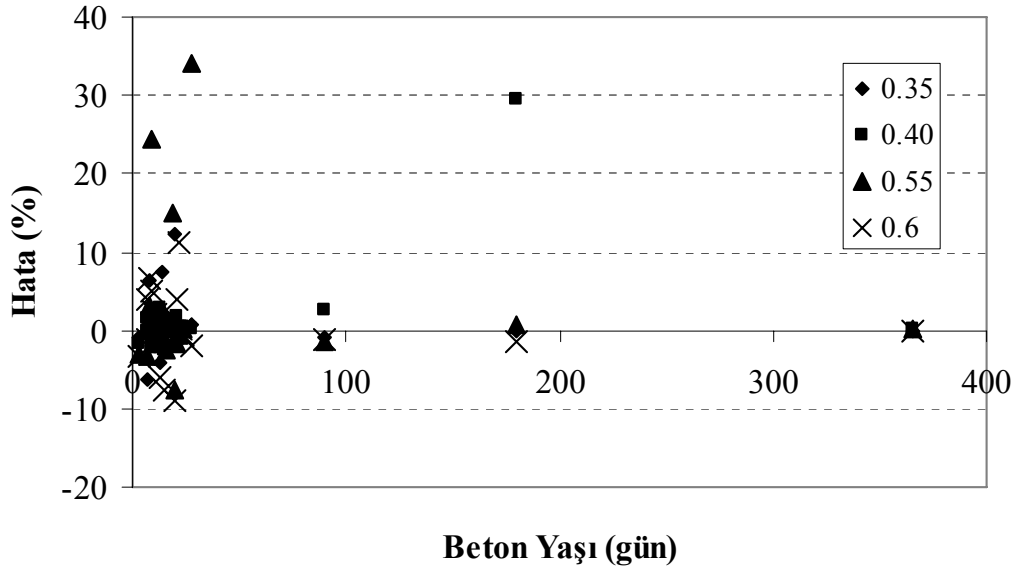


Şekil 10. Uçucu Kül ve s-ç Oranı Değişimiyle 365 Günlük Beton Basınç Dayanımının Değişimi

Sabit s-ç oranındaki betonların durumu incelendiğinde, betonun içerisine katılan uçucu kül ile betonların basınç dayanımlarında genel olarak % 15 uçucu kül oranına kadar artış görülmüştür. Betonun ilk

yaşlarına bakıldığında uçucu külün betona ilavesiyle birlikte dayanım değerlerinde düşüş elde edilmiş; betonun yaşı ilerledikçe uçucu külün puzolanik aktivitesi nedeniyle betonun basınç dayanımını arttırmıştır. Betonun içerisine ilave edilen uçucu kül miktarı ileri yaşlarda da % 15 oranından sonra, betonun dayanımı üzerinde olumsuz etki yaptığı görülmüştür. dolayısıyla ileriki yaşlarda betonun dayanımı üzerinde olumlu etki yapan optimum uçucu kül miktarının % 15 oranında olduğu belirtilebilir.

Tahmin edilen değerle deneysel veriler arasındaki hata miktarı da Şekil 11’de verilmiştir. Şekilden de görüldüğü gibi en fazla hata miktarı 0.55 s-ç oranında % 35 olduğu görülmüştür. Diğer s-ç oranındaki veriler arasındaki hata miktarı da \pm % 10 arasında değişmektedir. Buradan da görüldüğü gibi oluşturulan model oldukça güvenilirdir.



Şekil 11. Tahmini değerlerle gerçek değerler arasındaki hata miktarı

SONUÇLAR

Yapay sinir ağları yaklaşım modeli ile elde edilen basınç dayanımı değişiminin, beton karışımındaki farklı uçucu kül ikamesi oranlarına bağlı olarak elde edilen deneysel basınç dayanımı değerleri ile uyumlu olduğu görülmüştür. Deneysel çalışmalar, uzun zaman gerektiren, malzeme harcanarak çevresel olumsuzluklara ve ekonomik giderlere yol açabilen ve aynı zamanda teknik personel gerektiren çalışmalardır. Bundan dolayı, yapay sinir ağları gibi yapay zeka modellerinin kullanılmasıyla, deneysel çalışmalardan elde edilen sonuçlara çok yakın sonuçlar elde edilerek deneysel çalışmalardaki bu kayıplar ve gereksinimler daha aza indirgenebilir.

Bununla birlikte, farklı beton karışımları ve farklı uçucu kül ikame oranları için de aksel basınç etkisinde basınç dayanımları benzer şekilde elde edilebileceği söylenebilir. Böylece betonun en iyi basınç dayanımı açısından kullanılması gereken optimum mineral katkılardan uçucu kül gereksinimi de belirlenmiş olacaktır.

KAYNAKLAR

- [1] Dolch, W.L., Diamond, S., "Durability of concrete", Part 39 of Civil Engineering Handbook, Editor-in-chief, W.F. Chen. Boca Raton: CRC, 1995.
- [2] Han, S.H., Kim, J.K., Park, Y.D. "Prediction of compressive strength of fly ash concrete by new apparent activation energy function, Cement and Concrete Research 33 (2003) 965–971.

- [3] Ferreira,C., Ribeiro,A., Ottosen, L., “Possible Applications For Municipal Solid Waste Fly Ash”, *Journal of Hazardous Materials*, B96, 201-216, 2003.
- [4] Atış, C.D., “Heat evolution of high-volume fly ash concrete, *Cement and Concrete Research* 32 (2002) 751–756.
- [5] Şengül, Ö., Taşdemir, M.A., Sönmez, R., “Yüksek oranda uçucu kül içeren normal ve yüksek dayanımlı betonların klor geçirirnililiği”, 5. Ulusal Beton Kongresi, İstanbul, 1-2-3 Ekim, 2003.
- [6] Papadakis, V.G., Effect of supplementary cementing materials on concrete resistance against carbonation and chloride ingress, *Cement and Concrete Research* 30 (2000) 291–299.
- [7] McCullogh, WS., and Pitts, W., A logical calculus of ideas imminent in nervous activity, *Bull. Math. Biophysics*, 1943;5: 115-33.
- [8] Rio L.M., Jimenez A., Lopez F., Rosa F.J., Rufo M.M., Paniaqua J. M.; “Charaterizarion and hardening of concrete with ultrasonic testing”, *Ultrasonics*, 42 (2004), pp. 527-530
- [9] Ghaboussi, J., Garrett, Jr., Wu, X., Knowledge- based modeling of material behavior with neural networks, *Journal of Structural Engineering*, ASCE, 1991; 117: 1, 132-53.
- [10] Kang, HT., Yoon, C J., Neural networks approaches to aid simple truss design problems, *Microcomputers in Civil Eng.*, 1994; 9:211-18.
- [11] Erbatur, F., Hasançebi, O., Tütüncü, İ., and, Kılıç, H., Optimal design of planer and space structures with genetic algorithms., *Computers and Structures*, 75, 209-224, 2000.
- [12] Szewczyk, ZP., Hajela, P., Damage detection in structures based on feature sensitive neural networks, *J Computing Civil Eng.*, ASCE, 1994; 8(2):163-78.
- [13] Civalek, Ö., The design of structures under earthquake effects by using neuro-fuzzy method., *Fourth National Earthquake Engineering Conferences*, Ankara, 1997:431-38.
- [14] Ghaboussi, J., Garrett, Jr., Wu, X., Knowledge- based modeling of material behavior with neural networks, *Journal of Structural Engineering*, ASCE, 1991; 117: 1, 132-53.
- [15]Uygunoğlu T., Yurtcu Ş., “Yapay Zeka Tekniklerinin İnşaat Mühendisliği Problemlerinde Kullanımı”, *Yapı Teknolojileri Elektronik Dergisi (YTED)*, 2006 (1) 61-70.
- [16] Ahmet Öztas, Murat Pala, Erdoğan Özbay, Erdoğan Kanca, Naci Çağlar, M. Asghar Bhatti, Predicting the compressive strength and slump of high strength concrete using neural network, *Construction and Building Materials*, 2005 (In press).
- [17] Civalek, Ö., Çatal, H.H., ve Demirdağ, O., Geriye Yayılma Yapay Sinir Ağları ile Düzlem Çerçeve ve Kirişlerin Titreşim Frekanslarının Tahmini, *İMO Teknik Dergi Cilt* 13(3), 2709-2726,2002.
- [18] Nassif, H.H., Najm, H. Suksawang, N., “Effect of pozzolanic materials and curing methods on the elastic modulus of HPC”, *Cement & Concrete Composites* 27 (2005) 661–670.
- [19] Chevrier, R., Bilodeau, A., “Effect of Low-curing Temperatures on Selected Properties of Concrete Incorporating Large Volumes of Fly Ash”, *Materials Technology Laboratory, International Center for Sustainable Development of Cement and Concrete (Icon)*, Canmet, Natural Resources Canada, 2001.