

Polipropilen Lifli Betonların Yüksek Sıcaklık Sonrası Basınç Dayanımlarının Yapay Sinir Ağları ile Tahmini

Hasbi YAPRAK ve Abdulkadir KARACI

Kastamonu University, Kastamonu, 37100 Türkiye,
Kastamonu University, Kastamonu, 37100 Türkiye,
hyaprak@kastamonu.edu.tr, akaraci@kastamonu.edu.tr

Özet— Beton yüksek sıcaklık etkisinde kaldığında önemli ölçüde hasara uğrar. Bu durum istenilmeyen yapısal kusurlara neden olabilir. Polipropilen liflerin ilavesi bu hasarın azaltılmasında kullanılan yöntemlerden biridir. Bu çalışmada lif katkısız, 0.9, 1.35 ve 1.8 kg/m³ polipropilen lif katkılı beton numuneler üretilmiş, numuneler laboratuvar ortamında olgunlaştırılmış, 28. günün sonunda tüm numuneler 20, 400, 600 ve 800 °C sıcaklık etkisinde bırakılmıştır. Yüksek sıcaklık etkisinde kalan numunelerin basınç dayanımları test edilmiştir. Deneysel olarak bulunan test sonuçlarının yapay sinir ağları (YSA) kullanılarak bulunması amaçlanmıştır. YSA yaklaşımı ile deneysel olarak elde edilmiş veriler karşılaştırıldığında değerlerin birbirine en çok % 3.5 en az % 0.0 hata ile yakın olduğu görülmüştür

Anahtar Kelimeler— Yüksek Sıcaklık, Polipropilen Lif, Basınç Dayanımı, Yapay Sinir Ağları

Abstract— Concrete, when under the impact of high temperatures, is considerably damaged. This may result in undesirable structural failures. One of the ways to reduce this damage is to incorporate polypropylene fibers. In this study, first, concrete samples- both without fibers, and with polypropylene fibers in three different amounts - 0.9, 1.35, 1.8 kg/m³ - were produced, and then, these samples were matured in laboratory conditions, and all samples were exposed to high temperatures of 20, 400, 600, and 800 °C respectively at the end of the 28th day. The compressive strengths of the samples exposed to higher temperatures were tested. It was aimed to obtain the same laboratory test results by using Neural Network. When the data from the laboratory testing and from the Neural Network applications were compared, it was found that the values were very identical. When the data obtained empirically through the ANN approach were compared, it was noted that the values were close to each other with a margin of error of 3.5 % (maximum) and 0 % 0.0 (minimum).

Key Words— High Temperature, Polypropylene Fiber, Compressive Strength, Artificial Neural Network

I. GİRİŞ

Beton yüksek sıcaklık etkisinde kaldığında; dayanım, elastisite modülü ve hacim sabitliği önemli ölçüde azalır. Bu durum istenilmeyen yapısal kusurlara neden olabilir [1]. Bu nedenle, yangın sonrası beton özellikleri, yük taşıma kapasitesinin belirlenmesi ve yangından zarar görmüş yapı için daha da önemlidir [2].

Yüksek sıcaklığın etkileri genellikle beton yüzeyinde çatlak ve parçalanma olarak görülür [3, 4]. Yangın etkisinde kalmış betonun parçalanması özellikle sıcaklık değişimi ve boşluk basıncı artışına bağlıdır [5]. Parçalanmaya karşı aktif ve pasif koruma sağlamak için teknolojik çözümler geliştirilmiş ve son zamanlarda yüksek sıcaklığa maruz kalmış betonun arta kalan özelliklerini iyileştirmek amacıyla çok sayıda lif kullanılmıştır. Polipropilen ve çelik lifler çatlama ve parçalanmayı azaltmak, betonun kalan dayanımını yükseltmek için kullanılmaktadır [6, 7].

Polipropilen lifler 170 °C'de eriyerek kanallar oluşturur, bu kanallar gazların dışarı çıkmasını sağlar ve boşluk basıncını azaltarak betonda oluşan hasarın derecesini azaltır [8].

Yapay Sinir Ağları(YSA), insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. YSA'ları, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır [9].

Yapay zekanın alt dalı olan YSA'ları teknolojsi son yıllarda inşaat mühendisliği uygulamalarındaki problemlerin geniş kapsamlı çözümü için kullanılmaktadır. YSA'larının inşaat mühendisliği uygulamalarındaki en önemli özelliği direkt olarak örneklerden öğrenebilme yeteneğinin olmasıdır. YSA'larının bir diğer önemli özelliği tamamlanmamış görevleri doğru veya doğruya yakınlıkta yanıtlaması, eksik verilerden doğru bilgiyi çıkarması, yeni durumlardan genelleştirilmiş sonuçlar üretmesidir [10].

YSA'ları spesifik bir eşitliğe ihtiyaç duymaz. Bunun yerine yeterli miktarda giriş-çıkış verisine ihtiyaç duyar. Ayrıca, yeni veriye uygun olması için sürekli olarak yeni veri

eğitebilir. Eksik veya kesin olmayan bilgi içeren problemlerin çözümü amacıyla YSA'ları araştırılmaktadır [11].

Genel olarak YSA'ları, model seçimi ve sınıflandırılması, işlev tahmini, en uygun değeri bulma ve veri sınıflandırılması gibi işlerde başarılıdır [9]. Bu çalışmada YSA'nın işlev tahmin özelliği kullanılmıştır.

YSA'nın en belirgin özelliği öğrenme yeteneklerinin olmasıdır. YSA'ları çevresel değişimlere adapte olabilir. Mühendislik açısından bakıldığında ağın optimum durumunun kararlılığı sürdürülürken adaptasyon süreci için gereksinim duyulan zamanın azaltılması istenir [12].

Malzeme davranışı ile ilgili sinir ağı tabanlı bir model geliştirmek için temel strateji, bu malzemenin kullanıldığı bir dizi deney sonuçları üzerinden sinir ağını eğitmektir. Eğer deneysel sonuçlar malzeme davranışı hakkında anlamlı bilgi içeriyorsa, o zaman eğitilmiş yapay ağ bir malzeme modeli olarak nitelendirilen malzemenin davranışı hakkında yeterli bilgi içerecektir. Böyle eğitilmiş yapay ağ yalnızca deneysel sonuçları yeniden üretmekle kalmayacak, diğer deneysel sonuçları da aynı zamanda genelleştirme yeteneği yoluyla yaklaşık olarak belirleyebilecektir [13].

Bu çalışmanın amacı farklı oranlarda polipropilen lif katkılı ve değişik sıcaklık etkisinde bırakılan polipropilen lifli betonların deneysel olarak belirlenen basınç dayanımlarını, YSA kullanarak tahmin etmektir. Bu amaçla MATLAB programının "NFTTool" aracı vasıtasıyla, polipropilen lif oranına ve sıcaklığa bağlı olarak betonun basınç dayanımı değişimini verecek şekilde; 2 girişli, 1 çıkışlı, 10 nörona sahip 1 gizli katmanlı bir YSA oluşturulmuştur. Daha önceki deneysel sonuçlardan elde edilen verilerin bir kısmı ağa eğitim seti olarak verilerek, ağ eğitilmiştir. Ağın eğitimi tamamlandıktan sonra eğitim sırasında ağa hiç verilmeyen deneysel veriler ağa girdi olarak verilmiştir. Deneysel verilerle YSA'dan alınan çıktılar karşılaştırılmıştır.

II. DENEYSEL ÇALIŞMA

Çalışmada çimento olarak CEM I 42.5 çimento, doğal kum, kırma taş, polipropilen lif (PP) ve akışkanlaştırıcı kullanılmıştır. Kullanılan malzeme miktarları Tablo 1'de verilmiştir. Su/çimento oranı 0.53 olarak belirlenmiş, çökme 12-14 cm olarak sabit tutulmaya çalışılmıştır. 150x300 mm boyutunda 3x16 adet silindir numune üretilmiştir.

Deneysel çalışmada beton numuneler 20, 400, 600 ve 800 °C sıcaklık etkisinde bırakılmış, ortam sıcaklığında soğutulmuş numunelerin basınç dayanımları test edilmiştir.

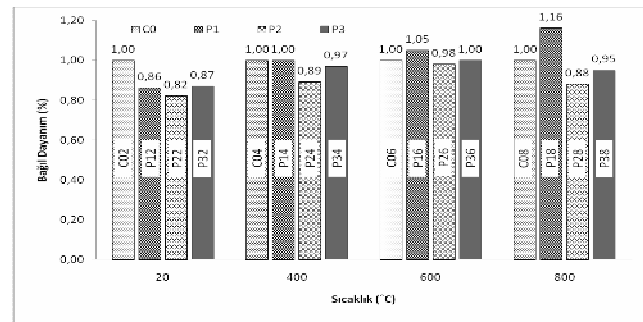
TABLO I
BETON KARIŞIM MALZEMELERİ (kg/m³)

Malzeme	Kod			
	C0	P1	P2	P3
Su	185.5	185.5	185.5	185.5
Çimento	350	350	350	350
Kum	768	768	768	768
Çakıl	1067	1067	1067	1067

PP lif	0	0.9	1.35	1.9
Kim. Katkı	4.6	4.9	5.1	5.3

III. DENEYSEL SONUÇLAR

20, 400, 600 ve 800 °C sıcaklıkta işlem uygulanan beton numunelerin basınç dayanımları belirlenmiş ve bağlı dayanımları Şekil 1'de verilmiştir. Polipropilen lif katkısı beton numunelerin dayanımını düşürmüştür. C0 kodlu numunelerle karşılaştırıldığında P2 kodlu numunelerde bağlı dayanım %82 olarak gerçekleşmiştir. Polipropilen lif katkısı yüksek sıcaklık etkisindeki beton numunelerde oluşan dayanım kaybını azaltmada etkili olmamış, aksine P24 ve P28 kodlu numunelerde artırmıştır. P14 ve P36 kodlu numunelerde bağlı dayanım 1.00, P16'da 1.05, P18'de 1.16 olarak belirlenmiştir.



Şekil 1. Polipropilen lifli betonların bağıl dayanımları

IV. YAPAY SİNİR AĞI MODELİ

Biyolojik sinir sistemleri nöronlar arasındaki sinaptik bağlantıları tek tek ayarlayarak öğrenme yeteneğine sahiptir. YSA biyolojik sinir sistemine benzer şekilde modellenmiştir. Bu model, çıktısı bilinen bir dizi giriş verisi seti ile ağın eğitilmesine izin vermektedir.

YSA bağlantılarının ağırlıkları, son olarak işlenmiş çıktılarının düzeltilmesi ve bilinen değerlerle eşleştirilmesi çabasıyla sürekli olarak ayarlanmaktadır. Bir sinir ağı yeterli düzeyde eğitildiğinde, öğrenme süreci yoluyla kazanılan bilgi bağlantı ağırlıklarında depolanır ve bu işlem eğitilmiş bir ağın daha önceden üzerinde eğitim aldığı görevlere benzer yeni problemlerle karşılaştığında, bunların çözülebilmeye olanak sağlar [14].

YSA genellikle düğüm ya da işlem elemanı da denilen nöronlardan oluşan bir giriş katmanı, bir veya daha fazla gizli katman ve çıktı katmanlarından oluşur. Komşu katmanlar ağırlıklı bağlantılarla tamamen birbirine bağlıdır. Giriş katmanı nöronları dış ortamdan bilgileri alır ve hesaplama işlemi yapmaksızın gizli katman nöronlarına iletir. Daha sonra, gizli katman nöronları bu bilgileri işler ve faydalı özellikleri girdi uzayından çıktı uzayına haritalandırma

yapabilmek amacıyla alır. Son olarak çıktı katmanı nöronları, ağ tahminlerini dış dünyaya verir [15].

A. YSA Modelinin Yapısı ve Parametreleri

Bu çalışmada yüksek sıcaklık etkisindeki polipropilen lif katkılı betonların basınç dayanımlarının belirlenmesi amacıyla öğrenme algoritması olarak geri yayılım algoritmasını kullanan 2 girişli 1 çıkışlı ve bir gizli katmana sahip olan bir ileri beslemeli (Feed Forward) YSA oluşturulmuştur. Gizli katmandaki nöron sayısı 10 olarak seçilmiştir. Geriye yayılma (Back Propagation) algoritması, günümüzde pek çok disiplinde, özellikle mühendislikte en çok kullanılan öğrenme algoritmasıdır. Bunun en büyük nedeni öğrenme kapasitesinin yüksek ve algoritmasının basit olmasıdır [9].

Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım adını almıştır. Geri yayımlı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir katmandaki ağırlıkları yeniden hesaplamaktadır. Bir geri yayımlı ağ modelinde giriş, gizli ve çıkış olmak üzere 3 katman bulunmakla birlikte, problemin özelliklerine göre gizli katman sayısını artırabilmek mümkündür [16].

Geri yayımlı öğrenme (Back Propagation) danışmanlı öğrenmedir (Supervised Learning). Danışmanlı öğrenme modelleri, eğitim verileri, veri özellikleri ve gözlemlenebilir sonuçlar hakkında tam bilgi içerir. Girdiler ve çıktılar arasındaki ilişkiyi öğrenen modeller geliştirilebilir [17].

Bu çalışmada kullanılan YSA yapısı ve parametreleri Şekil 2'de gösterilmektedir.

A.1. Giriş katmanı (Input layer)

Giriş katmanı 2 nörondan oluşmaktadır. Bu nöronlara Tablo 2'deki bilgiler giriş olarak aktarılmaktadır.

Polipropilen Lif Miktarı (kg/m ³)
Sıcaklık Değişimleri (°C)

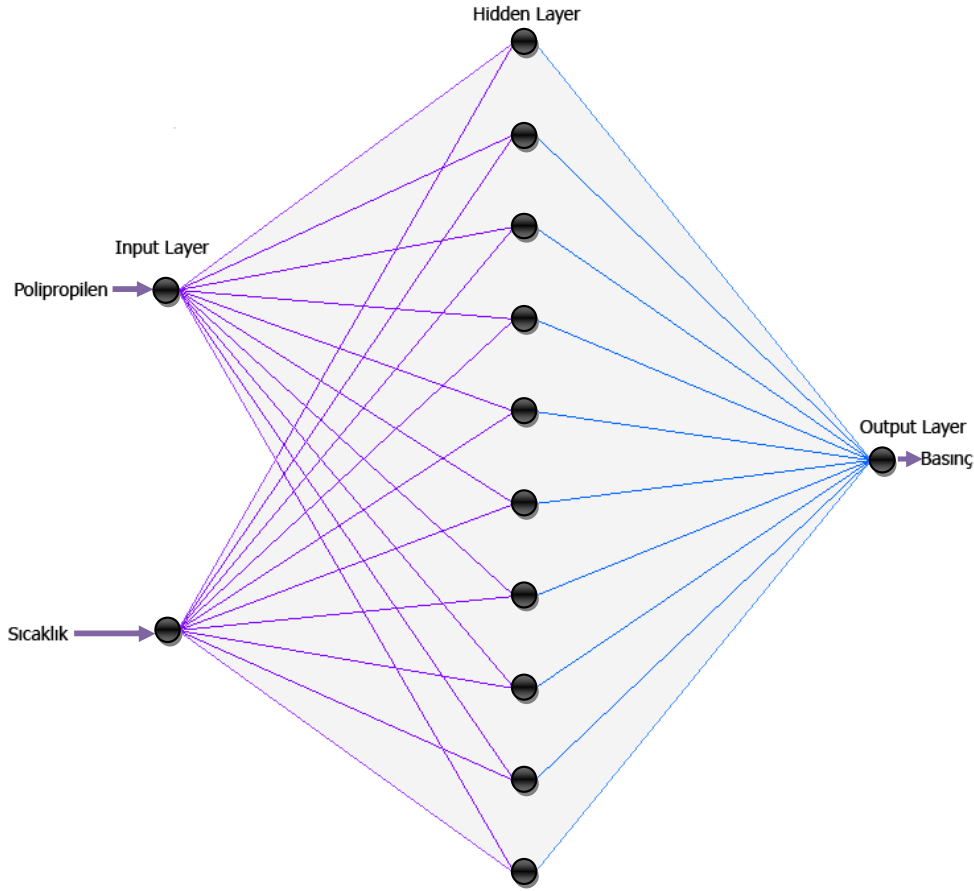
A.2. Gizli katman (Hidden layer)

Oluşturulan YSA tek gizli katmana sahiptir. Gizli katmandaki nöron sayısı öğrenme performansını etkileyen bir parametredir. Eğer gizli katmandaki nöronların sayısı çok azsa, ağı öğrenme işlemi optimum değere yaklaşmaz ve hata fonksiyonun dalgalı bir davranışı ortaya çıkar. Bundan dolayı girdi-çıkış tasarımları arasındaki ilişkiyi öğrenemez. Eğer nöronların sayısı çoksa, ağ sadece girdi-çıkış listesini depolayacak ve zayıf bir genelleme performansı sergileyecektir. Bu durum, optimal YSA boyutunun veri yapısına uygun olması ve problemle tam anlamıyla bağlantılı bir model inşa etmesi gerektiği anlamına gelmektedir [18].

Yapılan denemeler sonucunda gizli katmandaki nöron sayısı 10 olarak belirlenmiştir. Çünkü en iyi sonuç gizli katmandaki nöron sayısı 10 olduğunda elde edilmiştir.

A.3. Çıkış katmanı (Output layer)

Çalışmaya ve deneysel verilere uygun olarak ağ tek nöronlu çıkıştan oluşmaktadır ve çıkış olarak betonun basınç dayanımını vermektedir.



Şekil 2. Çalışmada kullanılan YSA'nın Yapısı

B. Yapay Sinir Ağının Eğitilmesi

Bu çalışmada YSA'nı oluşturmak ve eğitimini gerçekleştirmek için MATLAB programı kullanılmıştır. Ağa 32 adet deneysel veri yüklenmiştir. Ancak eğitim için 20 veri kullanılmıştır. Geriye kalan 12 veri test ve doğrulama için kullanılmıştır. Bu veriler MATLAB programı tarafından rastgele olarak belirlenmiştir. Eğitim için kullanılan deneysel veriler Çizelge 2'de verilmektedir. Test ve doğrulama için kullanılan ve ağı eğitimi sırasında kullanmadığı deneysel veriler ise Tablo 3'de verilmektedir.

YSA bu deneysel verilerle birçok kez eğitilerek en iyi sonuca ulaşmaya çalışılmıştır. Eğitim işleminin sonucu, Şekil 3'deki gibi bir bilgi penceresindeki Mean Squared Error (MSE) ve Regression Value (R) katsayılarına bakılarak değerlendirilmiştir. MSE katsayısı sıfıra yakınsa, ağı çıkışıyla, istenen çıktı arasındaki fark az demektir. MSE'nin sıfır olması, ağı çıkışıyla istenen çıktı arasında fark olmadığı yani hatasız olduğu anlamına gelir. R ise ağı çıkışıyla istenen çıktı arasındaki ilişkinin düzeyini belirler. R'nin 1'e yakın değerler alması ağı çıkışıyla istenen çıktı arasındaki ilişkinin doğruluğunu gösterir.

C. YSA Bulguları

Ağ çıkışı ile istenen çıktı arasındaki regresyon analizi grafiği eğitim, test ve doğrulama için Şekil 4, 5 ve 6'da gösterilmektedir.

TABLO II
EĞİTİM İÇİN KULLANILAN DENEYSEL VERİLER

Girişler		Çıkış
Polipropilen lif (kg/m ³)	Sıcaklık (°C)	Basınc (Mpa)
0	20	38.4
0.9	20	33.2
1.35	20	31.0
1.35	20	32.9
1.8	20	34.2
1.8	20	33.6
0	400	28.8
0	600	19.2
0	800	12.4
0	800	13.2
1.35	400	26.6
1.8	400	29.1
1.8	400	27.3
0.9	600	20.6
1.35	600	19.2
1.8	600	19.7
1.8	600	19.6
0.9	800	14.5
1.8	800	11.5
1.8	800	12.8

TABLO III
TEST VE DOĞRULAMA İÇİN KULLANILAN DENEYSEL VERİLER


Girişler		Çıkış
Polipropilen (kg/m ³)	Sıcaklık (°C)	Basınc (Mpa)
0	20	39.7
0.9	20	34.0
0	400	29.4

0	600	20.3
0.9	400	29.0
0.9	400	29.3
1.35	400	25.4
0.9	600	20.9
1.35	600	19.4
0.9	800	15.3
1.35	800	11.0
1.35	800	11.5

Results			
	Samples	MSE	R
Training:	20	2.38749e-1	0.998295
Validation:	6	9.43044e-1	0.996655
Testing:	6	5.20079e-1	0.998992

View Regression

Şekil 3. YSA Eğitim Sonucu Bilgi Penceresi



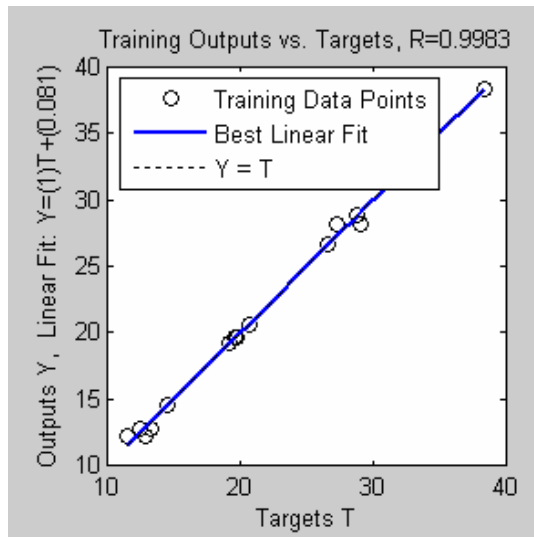
Şekil 6. Test Verileri Regresyon Analiz Grafiği

YSA'nın çıkışı, deneysel ortalama çıkışlar ve aralarındaki farklar Tablo 4'de gösterilmektedir. Bu tabloda deneysel çıkış olarak ortalama çıkış verildiğinden tekrarlayan girişler tabloda tekrar gösterilmemektedir. Bu nedenle veri sayısı 16'dır.

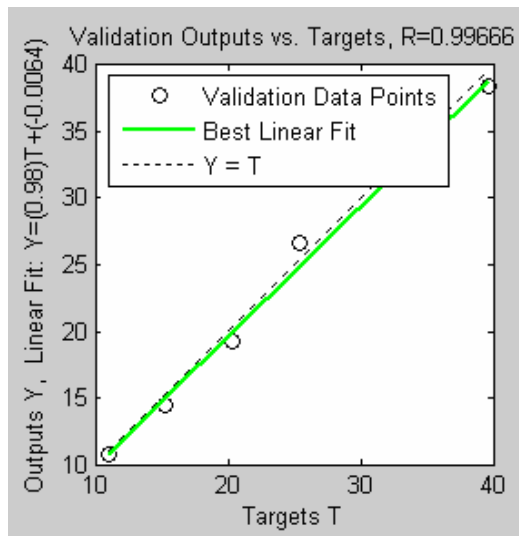
TABLO IV
YSA'NIN ÇIKIŞLARI

Deney No	Girişler		Çıkışlar		
	Polipropilen (kg/m ³)	Sıcaklık (°C)	Ağın Çıkışı	Deneysel Ortalama Çıkış	Fark
1	0.0	20	38.40	39.0	0.64
2	0.9	20	33.20	33.6	0.42
3	1.35	20	31.95	31.9	0.01
4	1.8	20	33.90	33.9	0.02
5	0	400	28.80	29.1	0.32
6	0	600	19.20	19.8	0.56
7	0	800	12.80	12.8	0.01
8	0.9	400	28.12	29.2	1.05*
9	1.35	400	26.60	26.0	0.59
10	1.8	400	28.20	28.2	0.00*
11	0.9	600	20.60	20.7	0.15
12	1.35	600	19.20	19.3	0.09
13	1.8	600	19.65	19.7	0.03
14	0.9	800	14.50	14.9	0.42
15	1.35	800	10.80	11.2	0.44
16	1.8	800	12.15	12.2	0.02


* Ağ çıkışı ile deneysel ortalama çıkış arasındaki en büyük ve en küçük fark



Şekil 4. Eğitim verileri regresyon analiz grafiği



Şekil 5. Doğrulama verileri regresyon analiz grafiği



Şekil 7. YSA çıkışı ile deneysel verilerin karşılaştırma grafiği

IV SONUÇLAR

Deneysel olarak laboratuvarında yapılan ve YSA ile yapılan çalışmalar sonucunda aşağıda belirtilen sonuçlara varılmıştır.

1. PP lifler betonun basınç dayanımını olumsuz olarak etkilemiştir.

2. PP lifler yüksek sıcaklığa maruz bırakılan betonların basınç dayanımlarını 0.9 kg/m^3 miktarında kullanıldığında çok az da olsa artırmış, diğer katkı miktarlarında ise düşürmüştür.

3. Deneysel olarak oldukça uzun bir sürede çözülebilecek problemlerin YSA ile çok kısa bir sürede ve çok az hata oranıyla çözümlendiği gözlenmiştir.

4. YSA'dan alınan sonuçlar irdelendiğinde maksimum hata miktarının "1,05", minimumunun ise "0" olduğu görülmüştür.

V. KAYNAKLAR

- [1] F.Ali, A.Nadjai, G.Silcock, A.Abu-Tair, "Outcomes of a Major Research on Fire Resistance of Concrete Columns", *Fire Saf. J.*, 39, pp. 433-445, 2004.
- [2] KD. Hertz, "Concrete Strength for Fire Safety Design", *Mag Concrete. Res.*, 57(8), pp. 445-453, 2005.
- [3] Y Ichikawa, GL England, "Prediction of Moisture Migration and Pore Pressure Build-up in Concrete at High Temperatures", *Nucl. Eng. Des.*, 59, pp. 228-245, 2004.
- [4] KD Hertz, LS Sorensen, "Test Method for Spalling of Fire Exposed Concrete", *Fire Saf. J.*, 40, pp. 466-476, 2005.
- [5] P. Kalifa, F.D. Menneteau, D. Quenard, "Spalling and Pore Pressure in HPC at High Temperatures", *Cement and Concrete Research*, 30 (12), pp. 1915-1927, 2000.
- [6] K Sakr, E EL-Hakim, "Effect of High Temperature or Fire on Heavy Weight Concrete Properties", *Cement Concrete Res.*, 35(3), pp. 590-596, 2005.

- [7] P. Kalifa, G. Chene, Ch. Galle, "High-temperature Behaviour of HPC with Polypropylene Fibers from Spalling to Microstructure", *Cem. Concr. Res.*, 31, pp. 1487-1499, 2001.
- [8] M.S. Cülfik, T.Özturan, "Effect of Elevated Temperatures on The Residual Mechanical Properties of High-performance Mortar", *Cement Concrete Res.*, 32(5), pp. 809-816, 2002.
- [9] Ç. Elmas, "Yapay Zeka Uygulamaları", *Seçkin Yayıncılık*, Ankara, 2007.
- [10] M. Sarıdemir, "Prediction of Compressive Strength of Concretes Containing Metakaolin and Silica Fume by Artificial Neural Networks", *Advances in Engineering Software*, 40, pp. 350-355, 2009.
- [11] S.C. Lee, "Prediction of Concrete Strength Using Artificial Neural Networks", *Engineering Structures*, 25, pp. 849-857, 2003.
- [12] J. Hertz, A. Krogh, and R. Palmer, "Introduction to the Theory of Neural Networks", *Addison-Wesley*, Redwood City, CA., 1991.
- [13] A. Öztaş, "Predicting the Compressive Strength and Slump of High Strength Concrete Using Neural Network", *Construction and Building Materials*, 20, pp.769-775, 2006.
- [14] R. Begg, (Editor), "Computational Intelligence for Movement Sciences : Neural Networks and Other Emerging Techniques." *Idea Group Publishing*, pp. 220, 2006.
- [15] F. Demir, "Prediction of Elastic Modulus of Normal and High Strength Concrete by Artificial Neural Networks", *Construction and Building Materials*, 22, pp. 1428-1435, 2008.
- [16] Ö. Keleşoğlu, "Silis Dumanı Katkılı Betonların Çarpma Dayanımının Yapay Sinir Ağı İle Belirlenmesi", *e-Journal of New World Sciences Academy*, 3, p.1, 2008.
- [17] K. Smith, (Editor), "Neural Networks in Business: Techniques and Applications", *Hershey, PA, USA: Idea Group Publishing*, p.2, 2002.
- [18] A. Tortum, N. Yayla, C. Çelik, M. Gökdağ, "The Investigation of Model Selection Criteria in Artificial Neural Networks by The Taguchi Method", *Physica A*, 386, pp. 446-468, 2007.