

# YÜKSEK ALÜMİNALI REFRAKTERLERİN BASMA MUKAVEMETLERİNİN YAPAY SİNİR AĞLARI YOLUYLA TAHMİNİ

**M. Oğuz GÜLER ve Recep ARTIR**

Sakarya Üniversitesi, Mühendislik Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü,  
Esentepe Kampüsü, 54187, Serdivan -ADAPAZARI  
E-mail:guler@sakarya.edu.tr, rartir@sakarya.edu.tr

## ÖZET

Bu çalışmanın amacı, yüksek alüminalı tuğlaların üretiminde standart olarak test edilerek takip edilen basma mukavemetinin yapay sinir ağları yardımıyla modellenmesidir. Model oluşumu ve testi için kullanılan refrakter tuğlaların kimyasal ve fiziksel özelliklerinden elde edilebilenlerden 300 adet fabrika verisi toplanmıştır. Model oluşumu işleminde girdi parametreleri olarak kimyasal bileşim (%SiO<sub>2</sub>, %Al<sub>2</sub>O<sub>3</sub>, %TiO<sub>2</sub>, %Fe<sub>2</sub>O<sub>3</sub>, %CaO, %MgO, %Na<sub>2</sub>O ve %K<sub>2</sub>O), tuğla hacmi, sıcaklık, bulk yoğunluk, ve görünür porozite kullanılmıştır. Modelin oluşumunda transfer fonksiyonu olarak ise sigmoid fonksiyonu kullanılmıştır. Hataların model içerisine beslenmesi ise geriye yayılım algoritması ile gerçekleştirilmiştir (GYA). 100.000 iterasyon sonunda optimal sonuçlara ulaşılmış ve ortalama mutlak hata % 2,74 olarak elde edilmiştir. Yüksek alüminalı refrakterlerin bazı özelliklerini kullanarak yapılan modellemeyle başarılı bir şekilde elde edilen tahmini basma mukavemetleri değerleri; benzeri sistemlerin anlaşılmasında ve benzer malzemeler için bazı özelliklerin tahmininde yapay sinir ağlarının çok kullanışlı araçlar olduğunu göstermiştir.

**Anahtar kelimeler:** Refrakter, Yüksek Alüminalı Tuğla, Basma Mukavemeti, Yapay Sinir Ağları, Sigmoid Fonksiyonu.

## ABSTRACT

The aim of this study is to modelling of high alumina refractory brick's compressive strength, which is frequently tested during the refractory production, by Artificial Neural Networks. 300 physical and chemical data, which is available for refractory bricks was collected from a domestic refractory plant in Turkey in order to use for modelling and to test the validity of the results. The parameters used as inputs for modelling include chemical composition (SiO<sub>2</sub>%, Al<sub>2</sub>O<sub>3</sub>%, TiO<sub>2</sub>%, Fe<sub>2</sub>O<sub>3</sub>%, CaO%, MgO%, Na<sub>2</sub>O% and K<sub>2</sub>O%), brick volume, sintering temperature, bulk density and apparent porosity. Sigmoid function used as the transfer function in the model. The feedbacks of the errors were done by using back propagation algorithms (BPA). The optimal results were gained after 100.000 iterations and the average mean error obtained as 2.74%. It was emphasized that modelling of some properties of high alumina refractory bricks accomplished by artificial neural networks leads to successfully estimation of compressive strength. Therefore, this study could suggest that modelling by artificial neural networks is very useful method for the estimation of some vital properties of resembling material that may be realised through modelling of artificial neural networks.

**Keywords:** Refractory, High Alumina Bricks, Compressive Strength, Artificial Neural Network, Sigmoid Function.

## 1. GİRİŞ

Alümina-Silika grubu içerisine dahil olan “Yüksek Alüminalı Refrakterler” yüzde 45’den daha fazla alümina içerirler. Piyasada mevcut alümina refrakterler % 45 ile % 99 arasında alümina içeriğine sahiptir. Çok amaçlı refrakterler olup 1817 °C’ye kadar olan sıcaklıklarda rahatlıkla kullanılabilirler. Refrakterlik özellikleri alümina içeriğine bağlı olarak değişkenlik gösterir. Yüksek mukavemet, sürünme ve yük dayanımları oldukça yüksek olan refrakterlerdir. Bu yüksek niteliklerinden dolayı yüksek sıcaklık uygulamalarında gittikçe artan bir kullanım alanına sahiptirler [1]. Bu tür refrakterlerin ana kullanıcıları demir-çelik endüstrisi olmasına rağmen demir dışı metal üretimi, cam ve kireç üretimi endüstrilerinde de gitgide önem kazanmaktadır. İşletme faktörleri göz önüne alındığında daha yüksek kalitede ve sağlam refrakter üretebilmek için bir takım faktörlerin çok iyi bir şekilde belirlenmesi zorunludur. Bu tür refrakterler içinse bu faktörlerden en önemlisi “Basma Mukavemeti”dir. Bu çalışmada yapay sinir ağları yoluyla basma mukavemetinin verilen girdilerle modellenerek hata oranı en az olacak bir şekilde tahmin edilmesi amaçlanmıştır.

YSA modelleri, betonun basma mukavemetinin tahmini konusunda farklı modeller ve veriler kullanılarak daha önceden bir takım araştırmacılar tarafından kullanılmış olsa da [2]; refrakter ve seramik ürünler konusunda literatürde henüz bu tür bir uygulama yayımlanmamıştır.

Çimentonun basma mukavemetinin yapay sinir ağları yoluyla modellenmesi ilk olarak Hong-Guang ve arkadaşları tarafından gerçekleştirilmiştir [2]. Yapmış oldukları çalışmada 28 gün işlem görmüş betonun basma mukavemeti ileri doğru beslemeli bir çok katmanlı sinir ağı yoluyla modellenmiştir. Oluşturulan sinir ağı modeli 3 katmandan oluşmakta; ve girdi katmanı 11 girdi için 11 nöron, gizli katmanı 7 nöron ve çıktı katmanı ise 1 nöron oluşmakta idi. Eğitim prosesi boyunca hataların sisteme geri bildirimi ise geriye yayılım algoritması kullanılarak gerçekleştirilmiştir.

Akkurt ve arkadaşları [3] tarafından gerçekleştirilmiş olan diğer bir çalışmada ise çimento harcının basma mukavemeti benzeri bir model kullanılarak modellenmiştir. Yapay sinir ağının oluşturulmasında 6 aylık fabrika verileri kullanılmıştır. Oluşturulan sinir ağı modeli ise 3 katmandan oluşmakta; girdi ve gizli katmanları 20 girdi için 20 nöron ve çıktı katmanı ise tek bir nöron oluşmakta idi.

YSA’lar malzeme bilimi, seramikler ve kompozitlerin modellenmesinde oldukça yaygın olarak kullanılmaktadır [4-5-6]; ancak refrakterlerin modellenmesinde ise YSA’ların kullanım alanları nerdeyse yok denecek kadar azdır [7].

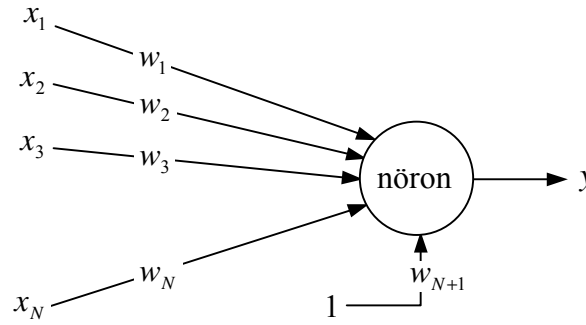
Yapılmış olan bu çalışmada ise yüksek alüminalı refrakterlerin basma mukavemetleri YSA’lar kullanılarak gerçek fabrika verileri ile modellenmiş ve geçerliliklerinin ve hassasiyetlerinin ortaya çıkarılabilmesi için teste tabi tutulmuşlardır.

## 2. YAPAY SİNİR AĞI MODELİ

İnsan beyni nöron adı verilen sinir hücreleri ve bunlar arasındaki bağlantılardan oluşan karmaşık bir sistemdir. İnsan beyinde yaklaşık 100 milyar nöron ve nöron başına düşen bağlantı sayısının ortalama birkaç bin olduğu düşünülürse, insan beyni karmaşık bir ağa benzetilebilir. Nöronlar bu bağlantılar sayesinde birbirleriyle iletişim kurarlar.

Yapay sinir ağı (YSA) algoritmaları insan sinir sistemi mimarisinden esinlenerek geliştirilmiştir. Ancak, beynin çalışma sistemiyle ilgili bilgilerin kısıtlı olması ve bu tür çalışmalara yol gösterememesi araştırmacıları mevcut biyolojik bilgilerden farklılaşarak bazı yararlı fonksiyonlar bulmaya itmiştir. Günümüzde çok sayıda YSA modelleri geliştirilmiştir. Bu modellerin geliştirilmesinde biyolojik sinir sistemlerinin prensiplerinden ve mühendislik biliminin imkanlarından faydalanılmıştır.

YSA'lar lineer olmayan sistemlerin kontrolünde ve modellenmesinde büyük kolaylıklar sağlamaktadırlar. Son yıllarda başta mühendislik olmak üzere pek çok bilim dalında karmaşık problemlere çözümler üretmeleri YSA'lara olan ilgiyi arttırmıştır. Çeşitli meslek gruplarında çalışma yapanlar YSA'ları kendi uzmanlık alanlarına taşıyarak, bu alanda kullanacakları uygulamaları ve yöntemleri arar hale gelmişlerdir. Bu ilgi teorik ve uygulama alanlarındaki başarılarla daha da pekişmiştir. Bir nöronun temel yapısı Şekil 1'de görüldüğü gibidir.



Şekil 1. Nöronun temel yapısı.

$X = [x_1, x_2, x_3, \dots, x_N, 1]$  dizisi giriş değerlerini,  $W = [w_1, w_2, w_3, \dots, w_N, w_{N+1}]$  dizisi ise ağırlık değerlerini gösterir.  $y$  çıkış fonksiyonu olup denklemi aşağıda verilmiştir.

$$y = f(\text{Net}) = f(WX) = f(w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_Nx_N + w_{N+1}) \quad (1)$$

Bu çalışmada ise ileri doğru beslemeli ve geriye yayılım algoritması kullanan bir çok katmanlı sinir ağı modeli oluşturulmuştur. Toplam olarak 4 katmandan oluşan modelin girdi katmanı 12 girdi için 12 nöron, birinci gizli katman 24 nöron, ikinci gizli katman 12 nöron ve çıktı katmanı ise sadece tek bir nöron içermektedir.

Çok zor bir problemle karşılaşıldığında; doğal olarak öncelikle çözülmesi kolay olan benzeri problemlere bakılır. Bir sınıflandırma problemi için; ağırlıkların optimal bir setini bulmada en iyi yöntem ortalama hataların karesini minimize eden ağırlıkları ( $W$ ) bulmaktır. Eğer  $N$  tane  $E^k$  öğrenme örneği ile birlikte bunlara karşılık gelen  $C^k$  tane doğru sonuç mevcutsa; buna bağlı olarak ortalama hataların karesi  $\varepsilon$  aşağıdaki formül yoluyla elde edilebilir;

$$\varepsilon = \frac{1}{N} \sum_{k=1}^N (W.E^k - C^k)^2 \quad (2)$$

Bu hata fonksiyonunun avantajı, herhangi bir yerde ortaya çıkmış olan tüm hatalara bağlı olarak türetilir [8].

Geriye yayılım algoritması çok katmanlı YSA'lar için sistematik bir metottür ve çok güçlü bir matematik esasa sahiptir. Bunun yanında her türlü kısıta rağmen geriye yayılım algoritması

YSA'ların uygulanabildiği problem aralığının genişlemesine yol açmıştır ve çok sayıda başarılı ve güçlü uygulamaların üretilmesine imkan vermiştir. Bir yapay sinirsel ağ'da geriye yayılım algoritmasının çalışması aşağıdaki adımları gerektirir;

1. Öğretme (training) setinin hazırlanması ve GİRDİ (INPUT) vektörünü YSA'ya uygulanması;
2. YSA'nın ÇIKTI (OUTPUT) değerinin hesaplanması;
3. YSA'nın ÇIKTISI ile arzu edilen ÇIKTI arasındaki hatanın (ERROR) hesaplanması;
4. Hataları minimize edecek şekilde hatayı geriye yayılımı ve YSA ağırlıklarının hesaplanması;
5. Hatalar kabul edilebilir seviyede olana kadar iterasyona devam edilmesi.

YSA'lar hakkında daha detaylı bilgi için literatüre de başvurulabilir [9-10-11].


### 3. VERİLERİN TOPLANMASI

Bu çalışmada kullanılmış olan veriler Bilecik'te bulunan Sörmaş Refrakter A.Ş.'den alınmıştır. Basma mukavemetinin YSA'lar yoluyla modellenmesinde toplam olarak 300 adet refrakter tuğla rasgele seçilmiş ve ISO standartlarına göre teste tabi tutulmuştur [12].

Seçilmiş olan refrakter tuğlaların üretimi öncelikle belirli tane boyutlarında sınıflandırılmış olan hammaddelerin kurutulması ile başlar. Kurutma sonrasında da bu hammaddeler mekanik bir karıştırıcı vasıtasıyla karıştırma işlemine tabi tutulur. Karıştırma prosesi esnasında karışım içerisine belirli bağlayıcılar ve bir miktarda su ilavesi yapılır. Su ve bağlayıcı ilavesi miktarları refrakter türüne göre değişkenlik göstermektedir. Hidrolik bir pres vasıtasıyla da şekil verme işlemi tamamlanır. Sonrasında da sinterleme işlemleri gerçekleştirilerek taneler arasında bağ teşekkülü sağlanır. Rasgele seçilmiş olan refrakter tuğlalar ISO standartlarına bağlı olarak çeşitli testlere tabi tutulurlar.

### 4. MODELİN MİMARİSİ

Bu çalışmada ortaya çıkarılmış olan model ileri doğru beslemeli çok katmanlı bir sinir ağı şeklinde olmuştur. 4 katmana sahip olan modelin girdi katmanı her 12 girdi için 12 nöron, birinci gizli katman 24 nöron, ikinci gizli katman 12 nöron ve çıktı katmanı ise tek çıktı için tek nöron şeklinde tasarlanmıştır. Bunun yanı sıra gizli katmanlarda en iyi sonucu elde edebilmek için farklı nöron varyasyonları da denenmiştir. Oluşturulmuş olan modelin girdi ve çıktı değişkenleri Tablo 1'de görülebilir. Oluşturulmuş olan sistemin şematik gösterimi ise Şekil 2'deki gibidir.




Şekil 2. Çok katmanlı yapay sinir ağı.

**Tablo 1.** Model oluşumunda kullanılan değişkenler ve veri aralıkları.

Kod	Girdi Değişkeni	Model Oluşumunda Kullanılan Değerler	
		Minimum	Maksimum
x <sub>1</sub>	SiO <sub>2</sub> (%)	36,63	37,74
x <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub> (%)	56,2	56,61
x <sub>3</sub>	TiO <sub>2</sub> (%)	1,59	1,85
x <sub>4</sub>	Fe <sub>2</sub> O <sub>3</sub> (%)	1,45	1,84
x <sub>5</sub>	CaO (%)	0,22	0,26
x <sub>6</sub>	MgO (%)	0,62	2,12
x <sub>7</sub>	Na <sub>2</sub> O (%)	0,07	0,08
x <sub>8</sub>	K <sub>2</sub> O (%)	0,15	0,16
x <sub>9</sub>	Tuğla Hacmi (cm <sup>3</sup> )	0,84	2,02
x <sub>10</sub>	Sinterleme Sıcaklığı (°C)	1305	1400
x <sub>11</sub>	Bulk Yoğunluk (gr/cm <sup>3</sup> )	2,22	2,51
x <sub>12</sub>	Görünür Porozite (%)	16,62	24,94
y <sub>1</sub>	Basma Mukavemeti (N/mm <sup>2</sup> )	60,4	95

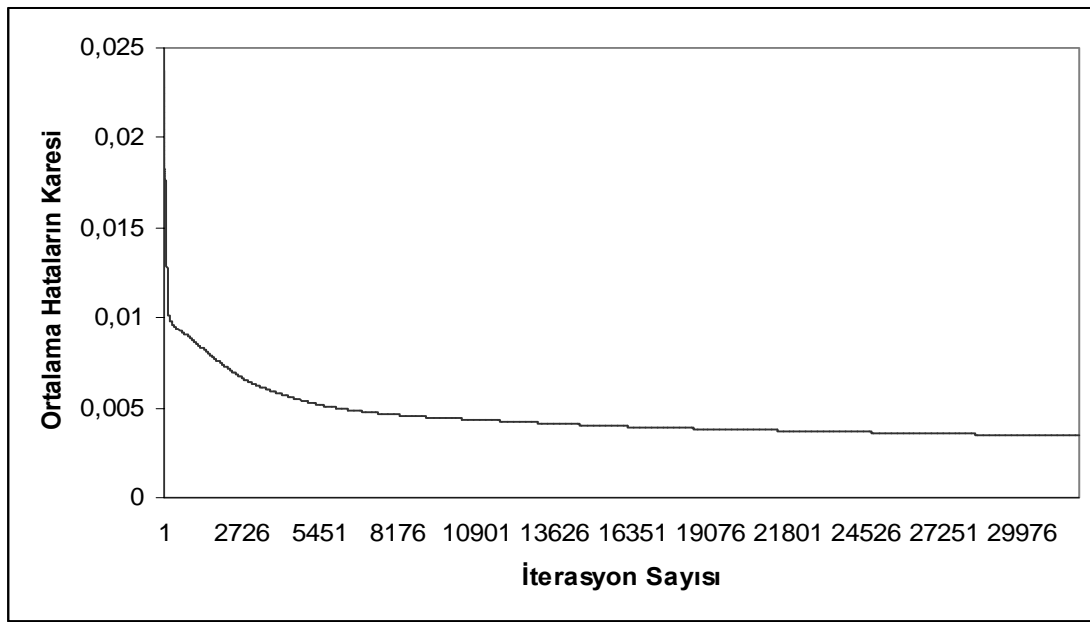
Matlab 7.0 Neural Network Toolbox'ı ve Matlab Simulink programları modelin oluşturulmasında başarılı bir şekilde kullanılmıştır. Öğrenme hızı ağıın büyüklüğüne ve vektör sayısına bağlı olmakla beraber eğitimi hızlandıracak bazı eğitim parametrelerinden de yararlanılmıştır. Bunlar; Eğitim oran ( $\eta$ ), Momentum ( $\alpha$ ) ve Bias ( $b$ ) parametreleridir.  $\eta$  ve  $\alpha$  parametreleri 0 ile 1 arasında uygun değerlerde seçilmelidirler. Bu seçim kullanılan verilere ve transfer fonksiyonuna göre değişebilir. Deneme yanılma ile uygun değerler seçilebilir. Bu parametreler çok küçük seçilirlerse eğitim yavaşlar, büyük seçilirlerse de eğitim gerçekleşmeyebilir. Bias parametreleri ise her bir nörona fazladan bir ağırlık eklemek şeklinde olup eğitimi oldukça hızlandırır. Bu çalışmada  $\eta = 0,1$ ,  $\alpha = 0,7$  ve  $b = 0,5$  alınarak çözüme gidilmiştir. Toplam 100.000 iterasyon sonucunda optimal sonuca ulaşılmıştır. Diğer bir önemli parametre ise fonksiyon seçimidir. Kurulmuş olan modelde sigmoid fonksiyonu kullanılmıştır. Fonksiyonun grafiği ise Şekil 3'de görüldüğü gibidir.

**Şekil 3.** Sigmoid fonksiyonu.

## 5. SONUÇLAR VE TARTIŞMA

Oluşturulan modelde 300 adet verinin 275 tanesi eğitim kalan kısmı ise test için kullanılmıştır. Optimal sonucu 100,000 iterasyon sonunda ulaşılmış; ortalama mutlak hata % 2,74 olarak bulunmuştur. Şekil 4’den de görülebileceği gibi, ortalama hataların karesi 100,000 iterasyon sonunda yüksek oranda bir düşüş göstermiştir. Minimum ortalama hataların karesi son basamakta 0,00268 olarak elde edilmiştir.

Şekil 5 ve Tablo 2’den de görülebileceği gibi model başarılı bir şekilde tamamlanmıştır. Aynı zamanda tahmin edilen değerlerin büyük bir kısmı oldukça hassas olup; bu değerler tablodan da görülebileceği gibi en düşük %0,07 ve en yüksek % 6,68 olarak elde edilmiştir.



Şekil 4. 100,000 iterasyon sonunda elde edilmiş olan MSE değeri

Hong-Guang ve arkadaşlarının çalışmasında [2] test numuneleri iki grubu bölünmüştür. Bu gruplar ise ayrı ayrı eğitilmiş ve teste tabi tutulmuştur. İlk grup için 5000 iterasyon sonunda ortalama mutlak hatalar minimum % 0,57 ve % 5,86 olarak bulunmuştur. İkinci grup içinse 5.000 iterasyon sonunda ortalama mutlak hatalar minimum % 0,13 ve % 12,81 olarak bulunmuştur.

Akkurt ve arkadaşlarının çalışmasında [3] ise 40.000 iterasyon sonunda ortalama mutlak hata % 2,24 olarak bulunmuştur. Çalışma sonunda minimum hata oranı % 1,18 iken maksimum hata oranı % 6,30 olarak bulunmuştur. Sonuç olarak kendi çalışmamızla karşılaştırıldığında Akkurt’un çalışması daha hassas sonuçlar vermiştir. Ancak daha fazla verinin elde edilmesiyle model sonuçlarının daha hassas olacağı düşünülmektedir. Ayrıca alınmış olan değerlerin üreticinin çeşitli ticari kaygılarından dolayı sınırlı olması da göz ardı edilmemelidir.

## 6. GENEL SONUÇLAR

Elde edilen test değerleri göz önüne alındığında yapay sinir ağlarının bu alandaki çalışmalar için ne kadar kullanışlı bir araç olduğunu görülebilir. Her ne kadar aşırı derecede hassas

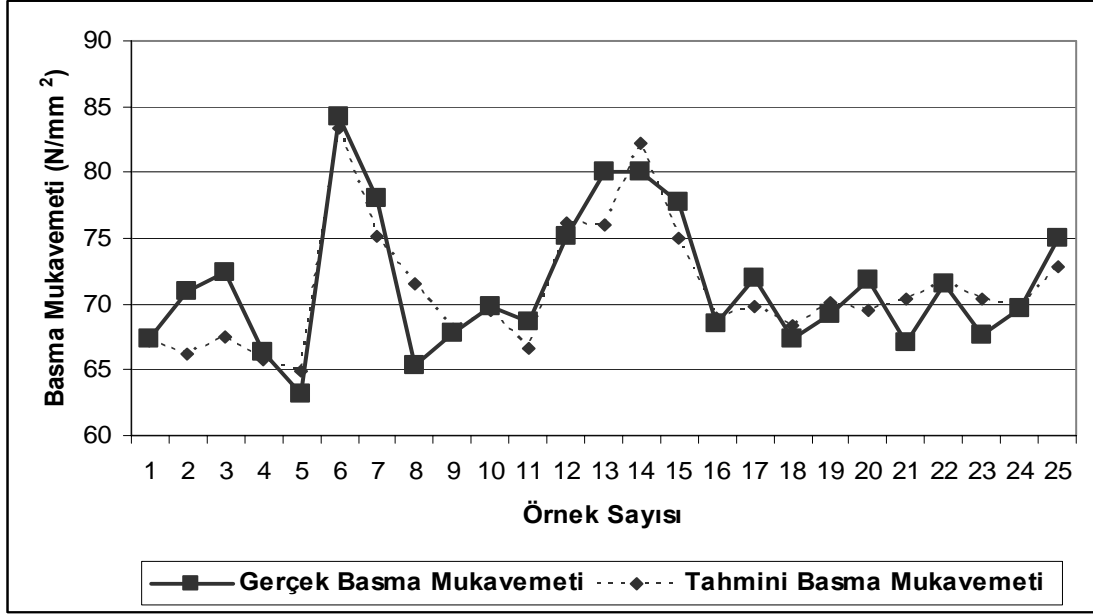
değerler elde edilmemiş olsa da; teste tabi tutulacak olan tuğla sayısının yani gerçek test değerlerinin artırılması ile daha hassas sonuçların elde edileceği açıktır.

**Tablo2.** Tahmin edilen değerlerin gerçek değerlerle karşılaştırılması.

Numune No	Basma Mukavemetinin Gerçek Değerleri (N/mm <sup>2</sup> )	Basma Mukavemetinin Tahmini Değerleri (N/mm <sup>2</sup> )	% Değişim
1	67,3	67,25	% -0,08
2	70,9	66,16	% -6,68
3	72,4	67,57	% -6,67
4	66,3	65,79	% -0,76
5	63,2	64,84	% 2,59
6	84,3	83,37	% -1,10
7	78	75,13	% -3,67
8	65,3	71,50	% 9,49
9	67,8	68,03	% 0,34
10	69,8	69,46	% -0,49
11	68,6	66,68	% -2,80
12	75,1	76,15	% 1,40
13	80,1	76,03	% -5,08
14	80	82,16	% 2,71
15	77,8	75,02	% -3,58
16	68,5	68,95	% 0,65
17	71,9	69,83	% -2,88
18	67,4	68,43	% 1,52
19	69,3	70,05	% 1,08
20	71,8	69,49	% -3,22
21	67,1	70,36	% 4,86
22	71,6	71,66	% 0,09
23	67,7	70,36	% 3,93
24	69,7	69,80	% 0,15
25	75	72,84	% -2,88

Özellikle belirtmek gerekir ki bu tür çalışmalar için ihtiyaç duyulan gerçek verilerin temin edilmesinde seçilen sektördeki fabrika verilerinin saklanmadan ve ticari kaygılardan uzak ve bir biçimde uzun bir dönemi kapsayacak şekilde verilmesi (6 ay-1 yıl gibi) yapay sinir ağları ile tahmin projelerinde sonucun doğruluğu ve geçerliliği açısından hayati önem taşımaktadır. Elde edilen tahmini basma mukavemeti değerlerinin belirlenmesinde girdi olarak sınırlı sayıda girdi kullanılması da diğer bir dezavantajdır. Mesela refrakterlerde basma mukavemeti

direk olarak poroziteden etkilenen özelliklerden birisidir. Poroziteyi etkileyen faktörlerden biriside granülometridir (tane boyut dağılımı). Örnek girdilerin alındığı fabrikanın bu konuda hassas davranarak ticari sır olmasından dolayı granülometri değerlerini vermediğinden elde edilememiştir. Şayet bu değerlerde elde edilebilmiş olsaydı tahmini değerlerdeki hata oranının sıfıra yaklaşabileceği ve daha doğru bir tahminde bulunmanın mümkün olabileceği söylenebilirdi.



Şekil 5. YSA modelinin test sonuçları.

## 7. ÖNERİLER

Bu çalışma sonucunda elde edilen bilgiler ve tecrübeler ışığında gelecekteki çalışmalar için aşağıdaki önerilerin faydalı olacağı düşünülmektedir.

- Gerçek test verilerinin mümkün olduğunca uzun dönemli (6 ay – 1 yıl gibi) daha fazla sayıda alınarak eğitim ve test verisi olarak kullanılması tahmin kalitesini ve hassasiyetini artıracaktır.
- Yapay sinir ağları ile tahmini yapılacak özelliği etkileyen tüm parametrelerin mümkünse saklanmadan araştırmacıya verilmesi bu tür tahmin projelerinin doğruluğunu ve hassasiyetini artıracaktır.
- Yeni bir üretim ve yeni bir malzeme dizaynı yaparken yapay sinir ağları ile tahminin seramik ve refrakter sanayimizde artık öğrenilip uygulamada aktif olarak yararlanılması gereklidir. Tanıtım ve bilgi birikiminden yararlanma sürecinin başlatılması ise ancak üniversite–sanayi işbirliği ile mümkün olacaktır.



**KAYNAKLAR**

1. Turkish Commission of Industrial Raw Materials, "Raw Materials Working Group Report on Ceramic, Refractory, Glass" Vol. 2, Undersecretary of Turkish State Planning Organization, Ankara-Türkiye, Eylül 1995.
2. H.-Guang. Ni, J.-Z. Wang, "Prediction of compressive strength of concrete by neural networks", *Cement & Concrete Research*, 30, 1245–1250, 2000.
3. S. Akkurt, S. Ozdemir, G. Tayfur, B. Akyol, "The Use of GA-ANNs In The Modeling of Compressive Strength of Cement Mortar", *Cement and Concrete Research*, 33, 973-979, 2003.
4. X. Wang, "Synthesis of TiN/AlON Composite Ceramics", *Journal of University of Science and Technology Beijing* V.10, No: 1, 46, Şubat 2003.
5. N. Altinkok, R. Koker, "Mixture and Pore Volume Fraction Estimation in Al<sub>2</sub>O<sub>3</sub>/SiC Ceramic Cake Using Artificial Neural Networks", *Materials and Design*, Basımda, 2004.
6. A.L Molinero, "Classification of Ancient Roman Glazed Ceramics Using The Neural Network of Self-Organizing Maps", *Analytic Chemistry*, 367, 586–589, Mart 2000.
7. S. Akkurt, "Prediction of the Slag Corrosion of MgO-C Ladle Refractories by the Use of Artificial Neural Networks", 8<sup>th</sup> European Ceramic Congress, İstanbul-Türkiye, 29 Haziran-3 Temmuz 2003.
8. J.-S Kwak, Man-Kyung Ha, "Neural Approach for Diagnosis of Grinding Operation by Acoustic Emission and Power Signals", *Journal of Materials Processing Technology*, 147, 65-71, 2004.
9. S. Haykin, *Neural Networks a Comprehensive Foundation*, McMillan, New York, 1994.
10. T. Munakata, *Fundamentals of the New Artificial Intelligence: Beyond Traditional Paradigms*, Springer-Verlag, New York, 1998.
11. I. Pratt, "Artificial Intelligence", The McMillan Press Ltd., 1994.
12. American Society of Testing Materials (ASTM), *Standard Test Methods for Cold Crushing Strength and Modulus of Rupture of Refractories*, C133-97, 2003.