

## **YÜKSEK-DÜŞÜK KİREÇLİ UÇUCU KÜL İÇEREN BETONLARIN BASINÇ DAYANIMININ YSA VE BM KULLANARAK TAHMİNİ**

İlker Bekir TOPÇU<sup>1</sup>, Mustafa SARIDEMİR<sup>2</sup>

**ÖZET:** Bu çalışmada, yüksek ve düşük kireçli uçucu küller içeren betonların 7, 28 ve 90 günlük basınç dayanımını tahmin etmek için yapay sinir ağları ve bulanık mantıkta modeller oluşturulmuştur. Bu modelleri oluşturmak amacıyla 52 farklı karışımda 180 numune literatürden elde edilmiştir. Yapay sinir ağları ve bulanık mantık modellerinde kullanılan veriler; gün, Portland çimento, su, kum, kırmataş-I, kırmataş-II, yüksek oranda su azaltıcı katkı yer değişim oranı, uçucu kül yer değişim oranı ve CaO içerecek bir formatta 9 girdi parametrelili; çıktı parametresi betonun basınç dayanımı olarak düzenlenmiştir. Modellerdeki eğitim ve test sonuçları, yapay sinir ağları ve bulanık mantık sistemlerinin, uçucu kül içeren betonların 7, 28 ve 90 günlük basınç dayanımını tahmin etmek için güçlü potansiyele sahip olduğunu göstermiştir.

**ANAHTAR KELİMELELER:** Dayanım, uçucu kül, yapay sinir ağları, bulanık mantık.

### **PREDICTION OF COMPRESSIVE STRENGTH OF CONCRETE CONTAINING HIGH-LOW FLY ASH USING ANN AND FL**

**ABSTRACT:** In this study, artificial neural networks and fuzzy logic models for predicting the 7, 28 and 90-day compressive strength of concretes containing high-lime and low-lime fly ashes have been developed. For purpose of constructing these models, 52 different mixes with 180 specimens were gathered from the literature. The data used in the artificial neural networks and fuzzy logic models are arranged in a format of nine input parameters that cover the day, Portland cement, water, sand, crushed stone-I, crushed stone-II, high range water reducing agent replacement ratio, fly ash replacement ratio and CaO, and an output parameter which is compressive strength of concrete. In the models of the training and testing results have shown that artificial neural networks and fuzzy logic systems have strong potential for predicting 7, 28 and 90-day compressive strength of concretes containing fly ash.

**KEYWORDS:** Strength, fly ash, artificial neural networks, fuzzy logic.

<sup>1,2</sup> Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi,  
İnşaat Mühendisliği Bölümü, Batı Meşelik Kampüsü, 26480 ESKİŞEHİR

## ***I. GİRİŞ***

Uçucu kül (UK) veya öğütülmüş granüle yüksek fırın cürufu gibi atıkların yok edilmesiyle ilgili çevresel düzenlemelerdeki yeni eğilimler, bu atıkları betonda Portland çimento yerine kısmen yapı malzemesi olarak kullanılmasına ilgiyi arttırmaya başlamıştır [1]. UK betonda çimentonun kısmi yer değişim oranlarında yaygın olarak kullanılmaktadır ve yüzde yer değişimi toplam çimento esaslı malzemelerin yaklaşık % 20'si (düşük hacimli UK) ile % 50'si (büyük hacimli UK) arasında değişmektedir [2,3]. Ayrıca, erken dayanım önemli bir faktör değilse, UK çimento esaslı malzemenin % 60'ı oranında kullanılabilir. Erken yaşlarda beton dayanımı üzerinde uçucu küllerin genellikle olumsuz etkilere sahip olduğu bilinen bir gerçektir [4]. Özellikle, elektrik santrallerinde yanan kömürün egzoz gazlarından mekanik olarak veya elektro-statik olarak çökelmiş külden elde edilen UK, kütle betonlarda erken yaşlarda çatlama ve hidratasyon ısını azaltmak için kullanılmaktadır. Aynı zamanda, Uçucu külün beton yapıların basınç dayanımı ve dayanıklılığını uzun dönemde arttırdığı bilinmektedir [1]. Daha düşük su çimento oranında hazırlandığında UK içeren betonlar daha iyi dayanım ve dayanıklılık performansına sahip olabilmektedir.

Son 20 yıldan beri, yapay sinir ağları (YSA) ve bulanık mantık (BM) sistemlerine dayanan farklı modelleme yöntemleri yaygınlaşmıştır ve çeşitli mühendislik uygulamaları için birçok araştırmacı tarafından kullanılmaktadır. Malzeme davranışı için YSA ve BM sistemlerine dayanan modeller geliştirmenin temel stratejisi, bu malzemeyi kullanarak deney serilerinin sonuçlarından YSA ve BM sistemlerinin eğitilmesidir. Eğer deneysel sonuçlar malzeme davranışı hakkında bilgi içeriyorsa, o zaman eğitilen YSA ve BM sistemleri malzeme modeli olarak malzemenin davranışını nitelendirmek için yeterli bilgiyi içerecektir. Böyle eğitilen YSA ve BM sistemleri sadece deneysel sonuçlar üretmeyecek, aynı zamanda da onların genelleştirme yetenekleriyle diğer deneylerdeki sonuçlara yaklaşabileceklerdir [5].

Bu çalışmanın amacı, betonun basınç dayanımı üzerine uçucu külün etkisini değerlendirmek için YSA ve BM sistemlerinde modeller oluşturmaktır. Bu modelleri oluşturmak amacıyla, YSA ve BM sistemlerindeki eğitim ve testlerde kullanılan 52 farklı karışımdaki 180 adet uçucu kül içeren betonların 7, 28 ve 90 günlük basınç dayanımı deney sonuçları bilimsel literatürden elde edilmiştir [6]. Normal Portland çimentosu ve uçucu kül içeren 52 farklı karışımdan elde edilen bu

betonlar, iki farklı yüksek kireçli ve iki farklı düşük kireçli uçucu küller kullanılarak üç farklı kısmi uçucu kül yer değişim oranlarında ( % 10, 20 ve 40) üretilmiştir. Modellerin eğitilmesinde gün (G), çimento (C), su (S), kum (K), kırmataş-I (KT-I), kırmataş-II (KT-II), yüksek oranda su azaltıcı katkı (SAK), uçucu kül (UK) ve CaO girdi olarak; basınç dayanımı (BD) değerleri çıktı olarak kullanılmıştır. Deneysel sonuçların 120 tanesi ile modeller eğitilmiş ve geri kalan 60 tanesinin sadece deney girdi değerleri kullanılarak testler yapılmış ve gerçek değerlere yakın BD değerleri elde edilmiştir.

## ***II. YAPAY SİNİR AĞLARI***

YSA insan beyni model alınarak geliştirilmiştir. Oldukça basit ve küçük boyuttaki YSA, insan beyniyle karşılaştırıldığı zaman bile, insan beynine benzerliğinden dolayı bilgi ve bilgi işlemede birtakım güçlü özelliklere sahiptir. Bu yüzden, YSA mühendislik uygulamalarında kullanılan güçlü bir araçtır [7]. YSA üzerindeki ilk çalışmaların 1943 yılında başladığı kabul edilir. Daha sonra ikinci büyük çıkışı 1958’de Frank Rosenblatt [10] çoğu yönüyle insan beynine benzer şekilde işleyen tekli doğrusal algılayıcı adı verilen bir makine tasarlamıştır. Rosenblatt [8] tekli doğrusal algılayıcı, tek tabakalı McCulloch and Pitts [9] sinir hücrelerine bağlanmış “duyusal” birimlerden oluşmaktadır. Rumenhardt ve diğerleri [10] tekli doğrusal algılayıcı ağlar için gizli birimlerden oluşan bir öğrenme algoritması tasarladılar. Bu öğrenme algoritması, geri yayılma olarak adlandırıldı ve günümüzde en çok kullanılan öğrenme algoritmasıdır. Bu çalışmalar doğrultusunda YSA kullanımı bilgisayar teknolojisinin gelişmesiyle 1980 yılından sonra daha verimli hale getirilmiştir [11,12].

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 kümesi veya kendinden önceki tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Toplama fonksiyonu girdiler ve ağırlıkların tamamının bu işlem elemanı üzerine etkisini hesaplayan bir fonksiyondur. Bu fonksiyon bir hücreye gelen net girdiyi hesaplar [12,13]. Net girdi bileşenlerindeki ağırlıkların tümü (*net*), aşağıdaki Denklem (1) kullanılarak hesaplanır.

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

Burada;  $(net)_j$ ,  $n$  sinir hücresi ile önceki tabakadan alınan girdinin  $j$ nci sinir hücresinin toplam ağırlığı,  $w_{ij}$  önceki tabakadaki  $i$ nci sinir hücresi ve  $j$ nci sinir hücresi arasındaki ağırlık,  $x_i$  önceki tabakadaki  $i$ nci sinir hücresinin çıktısıdır [11,14].  $b$  içsel katkı olarak sabit bir değeri ve  $\Sigma$  toplama fonksiyonudur. Aktivasyon fonksiyonu ise toplama fonksiyonundan elde edilen net girdiyi bir işlemde geçirerek hücre çıktısını belirleyen bir fonksiyondur. Genelde çok tabakalı algılayıcı modellerde aktivasyon fonksiyonu ( $f(.)$ ) olarak Sigmoid fonksiyonu kullanılır. Sigmoid aktivasyon fonksiyonu kullanılarak hesaplanan sinir hücresinin çıktısı Denklem (2)'deki gibi gösterilmektedir [5,11,14].

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

Burada;  $\alpha$  yarı doğrusal bölgenin eğimini kontrol etmek için kullanılan bir sabittir. Sigmoid doğrusal olmayan aktivasyon her tabakayı girdi tabakasından ayırmaktadır [12]. Denklem (2) şeklinde ifade edilen sigmoid fonksiyonu (0, 1) arasında çıkışlar verir. Sigmoid işlemcisi sürekli bir fonksiyonu gösterdiğinden dolayı özellikle doğrusal olmayan gösterimlerde kullanılır. Bunun nedeni  $(net)_j$  değişkeni bünyesinde bulunan parametrelere göre türevinin kolayca alınabilmesidir [5,11,14].

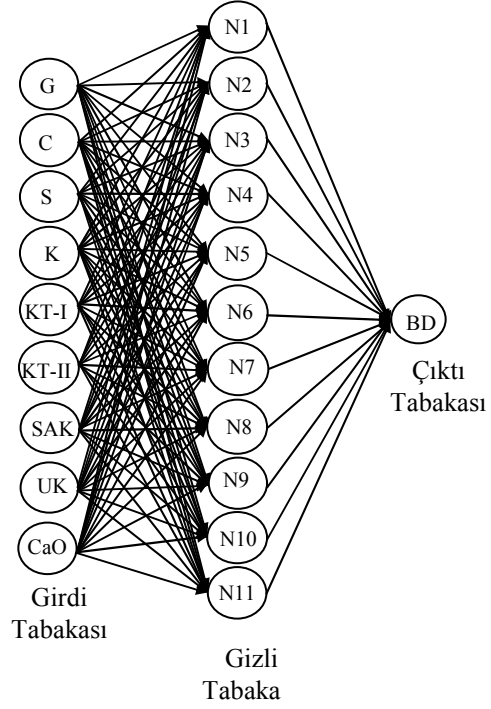
### ***II.1. Sinir ağırları model yapısı ve parametreler***

Bu çalışmada, Şekil 1'de gösterildiği gibi girdi tabakasından 9 nöron ve çıktı tabakasından bir nörona sahip bir YSA modeli geliştirilmiştir. YSA modelinde kullanılan girdi ve çıktı değişkenlerinin sınır değerleri Çizelge 1'de verilmiştir. Eğitim ve test kümelerinin en küçük yüzdelik mutlak hata değerlerinden dolayı, çok tabakalı sinirsel ağda, bir gizli tabakada 11 nöron belirlenmiştir. Komşu tabakaların nöronları birbirine ağırlıklarla tam olarak bağlantılıdır. En sonunda, ağda tahmin edilen sonucu çıktı tabakasındaki nöronlar üretmektedir. Bu çalışmada, ileri

beslenmeli bir gizli tabakalı geri yayılma eğitim algoritması kullanılmıştır. 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  $\epsilon$  hatasını en küçükleyen bir rampa düşüş tekniğidir [5]. Gizli tabaka ve çıkış tabakasındaki hücre çıkışlarında doğrusal olmayan Sigmoid fonksiyonu kullanılmıştır. Momentum oranı ve öğrenme oranı değerleri bulunarak iterasyonlarla model eğitilmiştir. Eğitilen model sadece girdi değerleriyle test edilmiş ve deney sonuçlarına yakın değerler elde edilmiştir.

**Çizelge1.** Modellerde kullanılan girdi ve çıktı miktarları

Girdi değişkenleri	Modellerin eğitim ve testinde kullanılan veriler	
	En küçük	En büyük
Çimento, kg/m <sup>3</sup>	232.20	512.00
Su, kg/m <sup>3</sup>	115.00	184.00
Kum, kg/m <sup>3</sup>	500.00	551.00
Kırmataş-I, kg/m <sup>3</sup>	256.00	282.00
Kırmataş-II, kg/m <sup>3</sup>	877.00	964.00
Su azaltıcı katkı, kg/m <sup>3</sup>	30.00	35.80
Uçucu kül, kg/m <sup>3</sup>	0.00	204.80
CaO, %	2.00	20.30
Çıktı değişkeni		
Basınç dayanımı, MPa	7.10	87.10



**Şekil 1.** YSA modelinde kullanılan sistem.

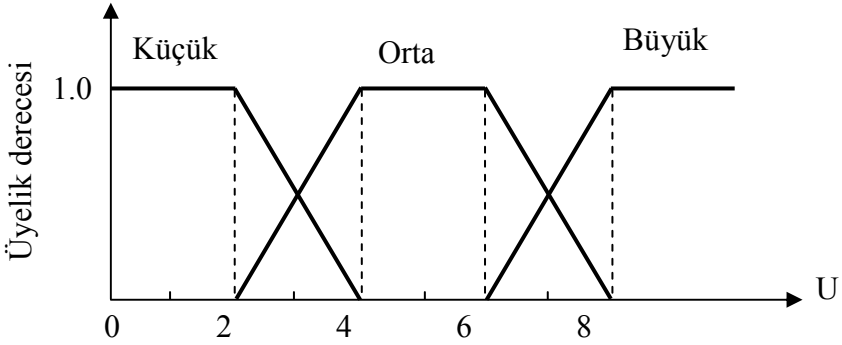
Bu çalışmada kullanılan parametre değerleri aşağıdaki gibidir:

- Girdi tabakası birim sayısı = 9
- Gizli tabaka sayısı = 1
- Gizli tabaka birim sayısı = 7
- Çıktı tabakası birim sayısı = 1
- Momentum oranı = 0.9
- Öğrenme oranı = 0.75
- Eğitim sonundaki hata = 0.000163
- Öğrenme döngüsü = 10.000

### **III. BULANIK MANTIK**

Bulanık küme fikrini ilk olarak, sadece iki olasılığa sahip Aristo mantığı yerine bulanık mantığı geliştirerek öncülük eden Zadeh [15] ortaya çıkarmıştır. Bulanık mantık (BM) fikri, rastgele değişkenlerin bulunmasından daha çok keskin sınırla tanımlı belirsiz kaynak problemleriyle ilgili doğal bir yol sağlamaktadır [16,17]. Burada belirtilen, olasılık ve stokastik değerlerin hepsi sayısal verilere dayanan rastgele belirsizlikler anlamına gelmemektedir. Bulanık küme teorisi sözel olarak bilgilerle ilgili sistematik hesaplar gerçekleştirmektedir. Bulanık yaklaşım, üyelik fonksiyonlarıyla uyarılmış sözel etiketleri kullanarak sayısal hesap yapmaktadır. Bu yüzden, Zadeh [15] doğal veya yapay dildeki cümlelerin değerlerini değişkenler gibi sözel değişkenlerle tanımlamıştır [17]. BM 1965 yılında Zadeh [15] tarafından ortaya atılmasına rağmen, bulanık kavram ve bulanık sistemlerin dünyada dikkat çekmesi 1975 yılında Mamdani ve Assilian tarafından yapılan gerçek bir kontrol uygulaması ile olmuştur [18-19].

Aslında bulanık mantıktaki ana fikir, tamamıyla tek bir kümeye ait olma yerine, herhangi bir evrensel küme nesnelere, farklı alt kümelere ait olmalarına kısmen izin verilmesidir. Bir kümeye kısmen ait olma 0 ve 1 de dahil bu sayılar arasındaki değerleri kapsayan üyelik fonksiyonu ile sayısal olarak açıklanabilir. Örneğin, evrende küçük, orta ve büyük sınıf boyutlamaları için Şekil 2 tipik bir üyelik fonksiyonunu göstermektedir. U. Hence'ye göre bu sözel sınıflandırma evrensel kümenin bulanık altkümeleridir. Bu şekildeki, küme değerleri 2'den daha az ise kesinlikle "küçük"; bunlar 4 ve 6 arasında ise kesinlikle "orta"; değerler 8'den büyük ise kesinlikle "büyük" olmaktadır. Ancak, arada bulunan değerler örneğin 2.2 kısmen "küçük" ve "orta" altkümelerine aittir. Bulanık terminolojisinde 2.2, 0.9 ise "küçük" de ve 0.1 ise "orta" da, fakat 0.0 ise "büyük" altkümelerde üyelik değerine sahiptir [17,20].



Şekil 2. Bulanık altkümeler.

### III.1. Bulanık mantık sonuç çıkarma sistemi

Genel bir bulanık sonuç çıkarma sistemi temel olarak 4 bileşene sahiptir: bunlar bulanıklaştırma, bulanık kural tabanı, bulanık çıkarım motoru ve durulaştırma [12,21]. Ayrıca giriş verileri ve çıkış verileri de vardır. *Bulanıklaştırma* her parça girdi verisinin üyelik fonksiyonlarını bir veya daha fazla üyelik fonksiyonlarına dönüştürür [21]. *Bulanık kural tabanı* girdiler ve çıktılar arasındaki bulanık ilişkilerin tüm olasılıklarını kapsayan kuralları içermektedir. Bu kurallar Eğer-ise formatında ifade edilmektedir. Temel olarak iki tür bulanık kural vardır. Bu çalışmada Sugeno tipi bulanık kuralları oluşturulmuştur. *Bulanık çıkarım motoru* transfer edilen kümedeki girdilerden doğru sonucu çıkarmak için bulanık kural tabanı ve öğrenmelerdeki tüm bulanık kuralları hesaba katmaktadır. Temel olarak iki tür sonuç çıkarma operatörü vardır: azaltma (min) ve sonuç (prod) [12,21]. Bu çalışmada, daha iyi performans gösterdiğinden dolayı prod yöntemi kullanılmıştır. *Durulaştırma* bulanık sonuç çıkarma motorunda sonuçlanan bulanık çıktılarının bir sayıya dönüştürülmesidir [21]. Birçok durulaştırma yöntemi vardır: örneğin ağırlıkların ortalaması, ağırlıkların toplamı vb. Bu çalışmada, ağırlıkların ortalaması yöntemi kullanılmıştır.

Bulanık sonuç çıkarma sistemleri, BM ve sözel bulanık kuralları yardımıyla doğrusal olmayan davranışları taklit etmek için güçlü bir araçtır [22]. Bulanık “Eğer-ise” kurallarını kullanan bulanık sonuç çıkarma sistemi, insana ait bilgi ve mantıklı düşünme işlemlerini tam nicel analiz kullanmadan nitel bakış açısı olarak



modelleyebilir [19-26]. Bulanık sonuç çıkarma sistemlerinin çeşitli yöntemleri vardır: Örneğin, Mamdani ve Sugeno [18-24]. Bulanık modelleme veya bulanık tanımlamayı, sistematik olarak ilk Takagi, Sugeno ve Kang [23,24] araştırmış, kontrol, tahmin ve bulanık sonuç çıkarma sisteminde çok sayıda pratik uygulamalar ortaya koymuşlardır [23-26].

Sugeno tipi sonuç çıkarma sistemlerinde, bulanık kuralların sonuçları hızlı fonksiyon üretilmesiyle çıktı olarak tanımlanabilmektedir. Matematiksel açıdan, eğer  $F$  kapalı aralık içerisinde sürekli gerçek eşleme ise, o zaman Sugeno tipi bulanık sonuç çıkarma sisteminde doğrusal olmayan eşleme parametresi Denklem (3)'teki gibi verilebilir.

$$F = \frac{\sum_{i=1}^m w_i \prod_{j=1}^n \mu_{A_j^i}(x_j)}{\sum_{i=1}^m \prod_{j=1}^n \mu_{A_j^i}(x_j)} \quad (3)$$

Burada,  $m$  kural sayısını gösterir,  $n$  veri göstergelerinin sayısını belirtir ve  $\mu_A$   $A$  bulanık kümesinin üyelik fonksiyonudur. Bulanık sonuç çıkarma sisteminin performansını etkileyen bir başka önemli konu, girdi aralığının paylaşılmasıdır. Bu bağlamda, birçok paylaşma teknikleri vardır: Örneğin ızgara şeklinde paylaşma ve ağaç şeklinde paylaşma [12,22,25]. İlk düzenlenen Sugeno tipi bulanık sonuç çıkarma sistemine göre, bir bulanık model iki kural içermektedir [23,26].

Kural1: Eğer  $x$  is  $A_1$  ve  $y$  is  $B_1$ , ise  $z_1 = p_1x + q_1y + r_1$

Kural2: Eğer  $x$  is  $A_2$  ve  $y$  is  $B_2$ , ise  $z_2 = p_2x + q_2y + r_2$ .

Eğer  $z_1$  ve  $z_2$  lineer denklemlerin yerine geçen sabitler ise, o zaman ilk düzenlenen Takagi, Sugeno and Kang modeline dönüşür [22-26]. Uyarlamalı bulanık sinir sisteminin temel öğrenme kuralı, çıktı tabakasından geriye giderek girdi düğümlerine, tekrarlamalı olarak hata sinyalleri göndererek hesap yapan geri

yayılmalı rampa düşüştür. Bu öğrenme kuralı, ileri beslemeli sinir ağlarında yaygın kullanılan geri yayılma öğrenme kuralına benzemektedir [12,21-23].

### ***III.2. Bulanık mantık sonuç çıkarma sistemi modeli***

Bulanık modelleme iki aşama içeren sistem tanımlama işidir: Bu iki aşama, yapının tanımlanması ve parametrelerin belirlenmesidir. Yapı tanımlanması, konu ile ilgili girdi verilerinin seçilmesi, özel tip bulanık sonuç çıkarma sisteminin seçilmesi, önce gelen ve sonra gelen kural sayısının belirlenmesi, tip ve üyelik fonksiyonlarının belirlenmesi gibi konuları içermektedir [26]. Parametre belirlenmesi, oluşturulan modelin belli girdi değerlerine karşı hedeflenen değerlerin elde edilmesidir. Bu amaçla, çalışmada 180 tane deney sonucu bulanık mantık sisteminde Sugeno tipi bulanık sonuç çıkarma modelindeki işlemlerde kullanılmıştır. Sugeno tipi bulanık sonuç çıkarma modelinde kullanılan girdi ve çıktı değişkenlerinin sınır değerleri Çizelge 1’de listelenmiştir.

Bulanık kural tabanını temsil eden kısa özlü grafiksel gösterim, bulanık hafıza tablosu olarak adlandırılmaktadır. Kural tabanında, bulanık veriler “prod” operatörüyle bağlantılıdır ve kurallar “max-min” ayrışım tekniği kullanılarak birleştirilmiştir. Ayrıca, hata azalmasındaki istikrarın gözlenmesiyle 1000 devir sürdürülmüş ve eğitim süreci sonlandırılmıştır. Basınç dayanımı girdi verileri için eğitim veri seti üyelik fonksiyonları üçgensel tiptir ve parametre terimi alt-uzay eğitim veri seti kümelemesi kullanılarak belirlenmiştir. Böylece aşağıdaki gibi 5 kural elde edilmiştir.

K1. Eğer (G1 is G1mf1) ve ... (CaO9 is CaO9mf1) ise (BD1 is BD1mf1)

K2. Eğer (G1 is G1mf2) ve ... (CaO9 is CaO9mf2) ise (BD1 is BD1mf2)

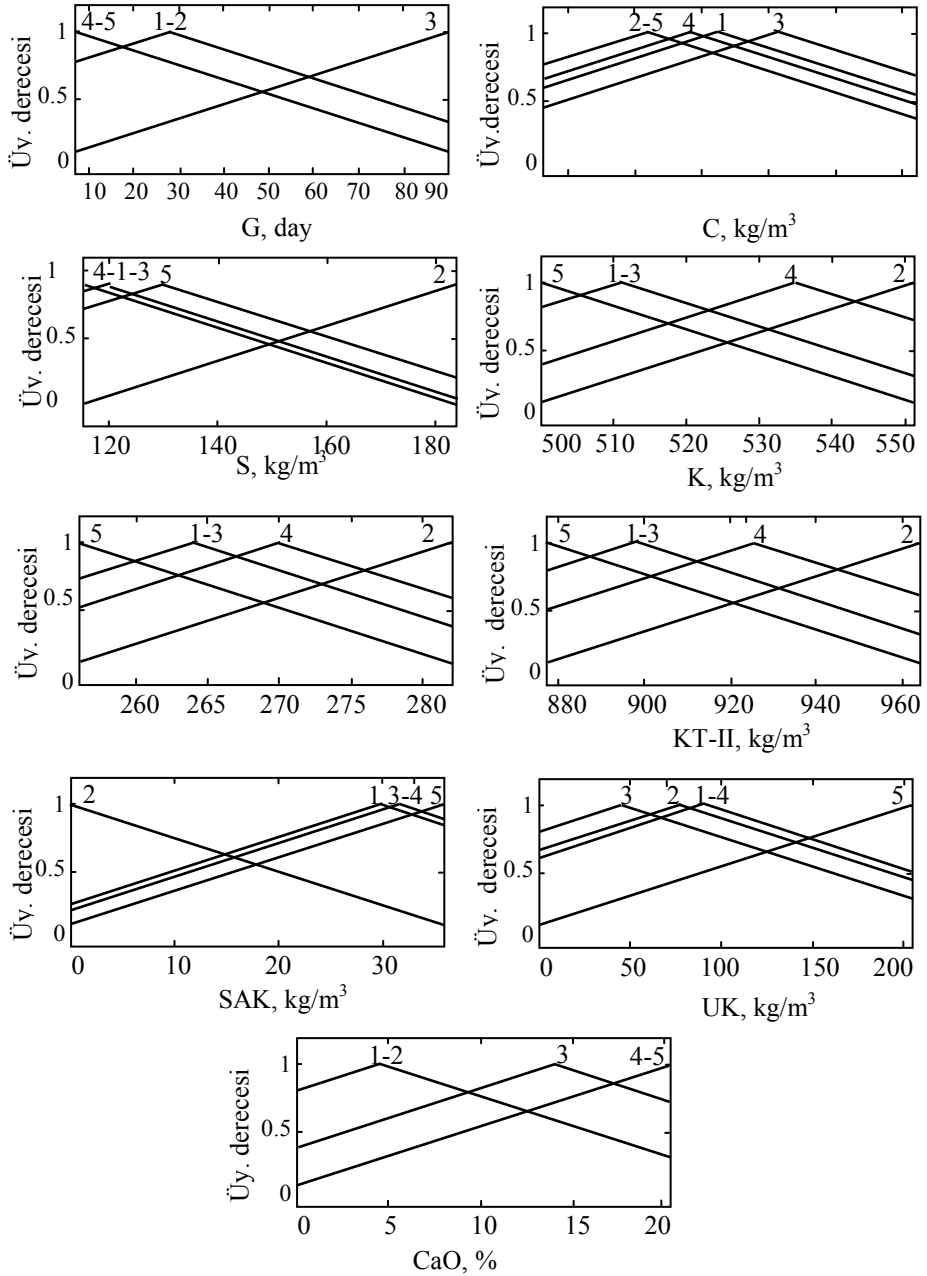
K3. Eğer (G1 is G1mf3) ve ... (CaO9 is CaO9mf3) ise (BD1 is BD1mf3)

K4. Eğer (G1 is G1mf4) ve ... (CaO9 is CaO9mf4) ise (BD1 is BD1mf4)

K5. Eğer (G1 is G1mf5) ve ... (CaO9 is CaO9mf5) ise (BD1 is BD1mf5).

Bulanık mantık sistemindeki Sugeno tipi bulanık sonuç çıkarma yönteminde uygulamak amacıyla, literatürden elde edilen BD sonuçları eğitim ve test parçalarına bölünmüştür. Burada, deney sonuçlarının 120 tanesi eğitim, 60 tanesi ise test için kullanılmıştır. Testte sadece deney girdi değerleri kullanılarak BD değerleri Sugeno tipi bulanık sonuç çıkarma yönteminde tahmin edilebileceği gösterilmiştir. Bu

çalışmadaki üyelik fonksiyonlarının hepsi 9 girdi ve 1 çıktıdan oluşmaktadır. Eğitimde kullanılan üyelik fonksiyonlarının girdi değişkenleri Şekil 3'te görüldüğü gibi oluşturulmuştur.



Şekil 3. Üyelik fonksiyonlarının girdi değişkenleri.

#### ***IV. SİNİR AĞLARI VE BULANIK MANTIK SONUÇ ÇIKARMA SİSTEMİ BASINÇ DAYANIMI SONUÇLARI***

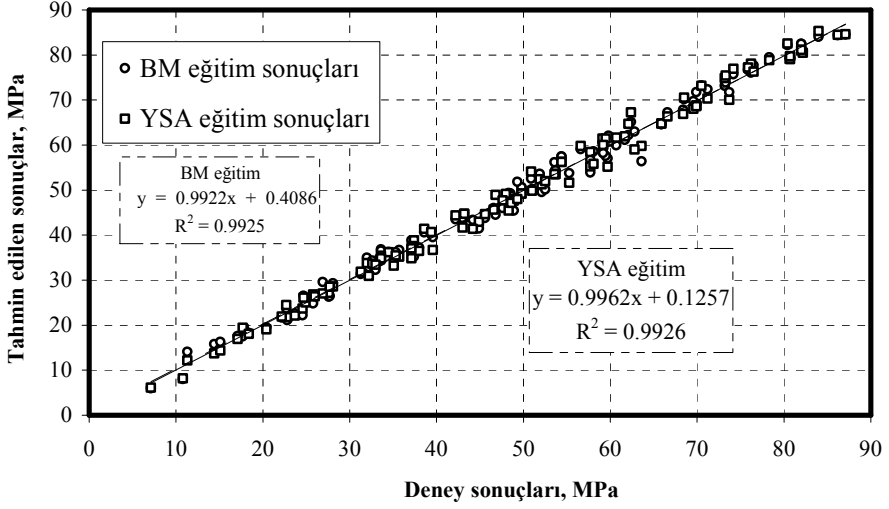
Bu çalışmada, YSA ve BM modellerindeki eğitim ve test sırasında ortaya çıkan hatalar karesel ortalamanın kökü (*RMS*) olarak ifade edilen Denklem (4) kullanılarak hesaplanmıştır [5,16]. Ek olarak, mutlak kesir varyansı ( $R^2$ ) ve ortalama mutlak yüzdelik hata (*MAPE*) sırasıyla Denklem (5) ve (6) kullanılarak hesaplanmıştır [5,12].

$$RMS = \sqrt{\frac{1}{p} \sum_i |t_i - o_i|^2} \quad (4)$$

$$R^2 = 1 - \left( \frac{\sum_i (t_i - o_i)^2}{\sum_i (o_i)^2} \right) \quad (5)$$

$$MAPE = \left| \frac{t_i - o_i}{o_i} \right| * 100 \quad (6)$$

Burada  $t$  hedef değer,  $o$  çıktı değeri,  $p$  numune sayısıdır. Hem deneysel çalışmalarından hem de YSA ve BM sistemlerinde oluşturulan modellerdeki eğitim ve testten elde edilen 7, 28 ve 90 günlük basınç dayanımı sonuçları Şekil 5 ve 6'da verilmiştir.



Şekil 5. YSA ve BM eğitim sonuçlarının BD deney sonuçlarıyla karşılaştırması.

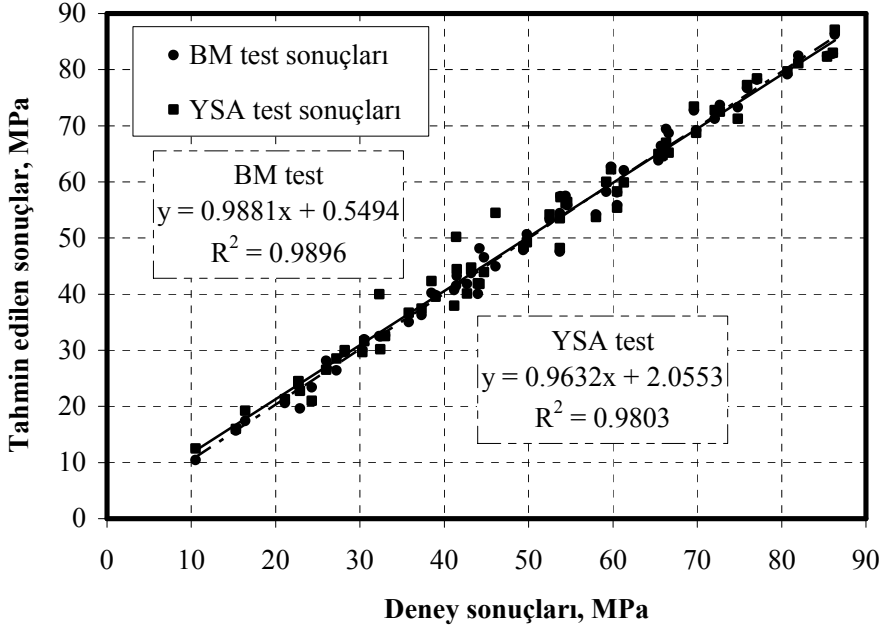
Eğitim ve test verileri için doğrusal en küçük kare çizgisi, denklemi ve  $R^2$  değerleri bu şekiller üzerinde gösterilmiştir. Ayrıca deneysel çalışmalardan ve YSA ve BM modellerinden elde edilen test sonuçları Çizelge 2’de verilmiştir. YSA ve BM modellerindeki eğitim ve testlerden elde edilen değerler Şekil 5 ve 6 ile Çizelge 2’de görüldüğü gibi deney sonuçlarına çok yakındır. Bu durum, deney sonuçları ile YSA ve BM model sonuçlarının uyum içinde olduğunu göstermektedir.

**Çizelge 2.** BD deney sonuçları ile YSA ve BM test sonuçlarının karşılaştırması

7 günlük basınç dayanımı			28 günlük basınç dayanımı			90 günlük basınç dayanımı		
Deneysel	YSA modeli	BM modeli	Deneysel	YSA modeli	BM modeli	Deneysel	YSA modeli	BM modeli
22.70	24.47	23.70	38.50	42.32	40.20	46.10	54.47	44.96
22.90	22.77	19.63	32.30	40.00	32.51	41.40	50.19	41.48
44.20	41.82	48.13	53.80	57.28	57.44	69.60	73.41	72.74
53.70	53.51	54.41	65.90	64.76	64.64	80.70	79.68	79.18
58.00	53.72	54.17	66.30	66.96	69.42	86.10	82.98	82.80
60.50	55.37	58.12	72.70	72.48	73.67	86.30	87.07	86.26
53.70	48.22	47.55	59.80	62.24	62.69	77.10	78.39	78.20
15.30	15.99	15.69	33.00	32.49	32.62	41.20	37.92	40.73
49.80	49.23	50.63	59.20	60.02	58.21	75.90	77.22	76.71
30.50	31.62	31.96	44.70	43.91	46.52	66.60	65.17	68.65
41.50	44.46	43.24	65.40	64.96	63.83	85.40	82.29	82.39
27.20	28.52	26.41	42.70	40.08	41.81	61.30	59.91	62.06
35.80	36.65	34.99	60.50	58.27	55.85	74.80	71.21	73.27
22.70	24.47	23.70	37.30	37.40	36.28	43.20	44.73	43.76
10.50	12.49	10.44	21.10	21.29	20.59	30.30	29.67	29.92
32.40	30.15	32.43	52.50	54.19	53.25	72.10	72.78	71.24
16.40	19.22	17.40	28.20	30.00	29.65	44.00	41.93	40.05
26.00	26.51	28.12	49.40	48.45	47.87	65.70	64.56	66.41
54.40	56.20	57.46	69.90	68.71	69.16	82.00	81.12	82.46
24.30	21.01	23.38	39.00	39.53	39.82	54.60	56.41	55.83

*RMS*,  $R^2$  ve *MAPE* olarak YSA ve BM modellerindeki eğitim ve testlerden bulunan BD değerlerinin istatistiksel değerleri Çizelge 3'te verilmiştir. YSA modelindeki eğitimde *RMS*,  $R^2$  ve *MAPE* istatistiksel değerleri sırasıyla 1.7099, % 99.90 ve % 3.3325 olarak bulunurken, testte sırasıyla 2.8109, % 99.72 ve 5.0672 % olarak bulunmuştur. Benzer şekilde, BM modelindeki eğitimde *RMS*,  $R^2$  ve *MAPE* istatistiksel değerleri sırasıyla 1.7221, % 99.89 ve % 3.6044 olarak bulunurken,

testte sırasıyla 2.0206, % 99.86 ve % 3.3772 olarak bulunmuştur. Önerilen YSA ve BM modellerinin Çizelge 3'teki tüm istatistiksel değerleri, BD değerlerinin deney sonuçlarına çok yakın ve uygun olduğunu göstermektedir. Hesaplanan değerlerde küçük sayılabilecek sapmalar gözlenmiştir.



Şekil 6. YSA ve BM test sonuçlarının BD deney sonuçlarıyla karşılaştırması.

Çizelge 3. Önerilen YSA ve BM modellerinin BD istatistiksel değerleri

İstatistiksel Parametreler	YSA		BM	
	Eğitim kümesi	Test kümesi	Eğitim kümesi	Test kümesi
<i>RMS</i>	1.7099	2.8109	1.7221	2.0206
<i>R<sup>2</sup></i>	0.9990	0.9972	0.9989	0.9986
<i>MAPE</i>	3.3325	5.0672	3.6044	3.3772

## **V. SONUÇ**

Yüksek ve düşük kireçli uçucu kül içeren betonların 7, 28 ve 90 günlük basınç dayanımı değerlerini deney yapmadan tahmin edebilmek için YSA ve BM yöntemlerinde modeller oluşturulmuştur. Modeller girdi ve çıktı verileriyle eğitilmiştir. Eğitilen modellerde sadece girdi verileri kullanılarak uçucu kül içeren betonların 7, 28 ve 90 günlük basınç dayanımı değerleri bulunmuştur. Yapay sinir ağları ve bulanık mantık modellerindeki eğitim ve testlerden elde edilen değerler deney sonuçlarına çok yakındır. Bu durumu deneysel sonuçlar ile YSA ve BM model sonuçlarını karşılaştırmak için hesaplanan *RMS*, *R<sup>2</sup>* ve *MAPE* istatistiksel değerleri göstermektedir. Sonuç olarak, deney yapmadan uçucu küllü betonların basınç dayanımı değerleri, yapay sinir ağları ve bulanık mantık modellerinde çok küçük hata oranlarıyla kısa sürede tahmin edilebilmektedir. Bu sonuçlar betonun basınç dayanımını tahmin etmede yapay sinir ağları ve bulanık mantığın kullanışlı yöntemler olduğunu göstermektedir.

## **KAYNAKLAR**

- [1] S.-H. Han, J.-K. Kim, Y.-D. Park, "Prediction of compressive strength of fly ash concrete by new apparent activation energy function", *Cement and Concrete Research*, Vol.33, pp. 965-971, 2003.
- [2] L. Lam, Y.L. Wong, C.S. Poon, "Effect of FA and SF on compressive and fracture behaviors of concrete", *Cement and Concrete Research*, Vol.28, pp.271-83, 1998.
- [3] R. Siddique, "Performance characteristics of high-volume Class F fly ash concrete", *Cement and Concrete Research*, Vol.34, pp. 487-493, 2004.
- [4] K.G. Babu, G.S.N. Rao, "Early strength of FA concrete", *Cement and Concrete Research*, Vol.24, pp.277-84, 1994.
- [5] M. Pala, E. Özbay, A. Öztaş, M.I. Yüce, "Appraisal of long-term effects of fly ash and silika fume on compressive strength of concrete by neural networks", *Construction and Building Materials*, Vol.12, No.2, pp. 384-394, 2007.
- [6] M. Tokyay, "Strength prediction of fly ash concretes by accelerated testing", *Cement and Concrete Research*, Vol. 29, pp.1737-1741, 1999.



- [7] R. İnce, "Prediction of fracture parameters of concrete by artificial neural networks", *Engineering Fracture Mechanics*, Vol.71, pp. 2143-2159, 2004.
- [8] F. Rosenblatt, "Principles of neuro dynamics: Perceptrons and the theory of brain mechanisms", Washington, DC: Spartan Books, 1962.
- [9] W.S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in neural nets", *Bulletin of Mathematical Biophysics*, Vol.5, pp.115-137, 1943.
- [10] D.E. Rumelhart, G.E. Hinton, R.J. William, "Learning internal representation by error propagation", In: Rumelhart DE, McClelland JL, editors. *Proceeding Parallel Distributed Processing. Foundation*, Vol. 1. Cambridge: MIT Press; 1986.
- [11] S.W. Liu, J.H. Huang, J.C. Sung, C.C. Lee, "Detection of cracks using neural networks and computational mechanics", *Computer Methods in Applied Mechanics Engineering*, Vol.191, pp. 2831-2845, 2002.
- [12] İ.B. Topçu, M. Sarıdemir, "Prediction of rubberized concrete properties using artificial neural network and fuzzy logic", *Construction and Building Materials*, 2007 (in press).
- [13] H.M. Günaydın, S.Z. Doğan, "A neural network approach for early cost estimation of structural systems of building", *International Journal of Project Management*, Vol.22, No.7, pp. 595-602, 2004.
- [14] İ.B. Topçu, M. Sarıdemir, "Prediction of properties of waste AAC aggregate concrete using ANN", *Computational Materials Science*, Vol. 41, No.1, pp.117-125, 2007.
- [15] L.A. Zadeh, "Fuzzy sets", *Information and Control*, Vol.8, pp.338-353, 1967.
- [16] F. Demir, "A new way of prediction elastic modulus of normal and high strength concrete-fuzzy logic", *Cement and Concrete Res.*, Vol.35, pp.1531-1538, 2005.
- [17] Z. Şen, "Fuzzy algorithm for estimation of solar irradiation from sunshine duration", *Solar Energy*, Vol.63, No.1, pp. 39-49, 1998.
- [18] E.H. Mamdani, S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller", *Int. Journal of Man-Machine Studies*, Vol.7, pp.1-13, 1975.
- [19] K.M. Passino and S. Yurkovich, "Fuzzy Control", Addison-Wesley, 1998.

- [20] F.M. McNeill, E. Thro, "Fuzzy Logic: A practical approach", AP Professional, Boston, MA, 1994.
- [21] S. Akkurt, G. Tayfur, S. Can, "Fuzzy logic model for the prediction of cement compressive strength", *Cement and Concrete Research*, Vol.34, No.8, pp. 1429-1433, 2004.
- [22] G. İnan, A.B. Göktepe, K. Ramyar, A. Sezer, "Prediction of sulfate expansion of PC mortar using adaptive neuro-fuzzy methodology", *Building and Environment*, 2005 (in press).
- [23] M. Sugeno, G.T. "Kang Structure identification of fuzzy model", *Fuzzy Sets Syst Man Cybern*, Vol.23, No.3, pp. 665-685, 1993.
- [24] T. Takagi, M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control", *IEEE Transactions on Systems Man and Cybernetics*, Vol.15, pp. 116-132, 1985.
- [25] J.S.R. Jang, C.T. Sun, "Neuro-fuzzy modeling and control", In: *Proceeding of the IEEE*, Vol.83, pp. 378-405, 1995.
- [26] S. Akbulut, AS, Hasiloğlu, S. Pamukcu, "Data generation for shear modulus and damping ratio in reinforced sands using adaptive neuro-fuzzy inference system", *Soil Dynamics and Earthquake Engineering*, Vol.24, pp. 805-814, 2004.