

## Yağış-Akış İlişkisinin Belirlenmesinde Farklı Yapay Sinir Ağı Yöntemlerinin Karşılaştırılması

Veysel GÜMÜŞ<sup>\*1</sup>, N. Göksu SOYDAN<sup>2</sup>, Oğuz ŞİMŞEK<sup>1</sup>,  
M. Sami AKÖZ<sup>1</sup> ve M. Salih KIRKGÖZ<sup>1</sup>

<sup>1</sup>Çukurova Üniversitesi, Mühendislik Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Adana

<sup>2</sup>Çukurova Üniversitesi, Ceyhan Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Adana

### Özet

Bir drenaj havzası üzerindeki yağış-akış ilişkisinin doğru belirlenmesi önemli bir konudur. Son yıllarda Yağış-Akış ilişkisinin modellenmesinde, Yapay Sinir Ağları, Genetik Algoritma ve Bulanık Mantık gibi Yapay Zeka Yöntemleri yaygın bir şekilde kullanılmaktadır. Bu çalışmada, Orta Fırat Havzasında bulunan 2157 numaralı akım gözlem istasyonuna ait aylık ortalama akım verileri ile 17204 numaralı yağış gözlem istasyonuna ait aylık toplam yağış verileri arasındaki ilişki yapay sinir ağları metodlarından İleri Beslemeli Geri Yayılım Sinir Ağı (İBGYSA), Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA) ve Radyal Tabanlı Yapay Sinir Ağı (RTYSA) ile araştırılmış ve ardından bu sonuçlar daha klasik bir yöntem olan Çoklu Doğrusal Regresyon (ÇDR) yöntemi ile karşılaştırılmıştır. Akım ve yağış verilerinin girdi olarak kullanıldığı bu çalışmada yeni akım değerleri tahmin edilmiştir. Çalışma sonunda kullanılan tüm yapay sinir ağı yöntemlerinin ÇDR yöntemine göre daha iyi sonuç verdiği görülmüştür. RTYSA yöntemiyle tahmin edilen akım değerlerinin, kullanılan diğer yapay sinir ağı yöntemleriyle tahmin edilen değerlere kıyasla gözlenen akım değerlerine daha iyi yakınsadığı belirlenmiştir.

**Anahtar Kelimeler:** Aylık akım tahmini, Yapay sinir ağları, Çoklu doğrusal regresyon, Orta Fırat Havzası

### Comparison of Different Artificial Neural Networks for Rainfall-Runoff Modeling

#### Abstract

The correct estimation of rainfall-runoff relationship on a drainage basin is an important issue. In recent years, artificial intelligence methods such as; Artificial Neural Networks (ANN), Genetic Algorithms (GA), and Fuzzy Logic (FL) are used in modeling the rainfall-runoff relations. In this paper the relations between the average monthly flow data from the flow observation station numbered as 2157 and the monthly total rainfall data from the rainfall observation station numbered as 17204 located in the Central Euphrates river basin are investigated by using the feed-forward back-propagation neural network (FFBPNN), generalized regression neural networks (GRNN) and radial based artificial neural networks

\* Yazışmaların yapılacağı yazar: Veysel GÜMÜŞ, Ç.Ü. Mühendislik Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Adana. vgumus@cu.edu.tr

(RBANN). The results are compared using Multi Linear Regression (MLR) method. New flow values are estimated by this procedure that uses the flow and rainfall data as input. Results of the study show that, all the artificial neural networks models used in this study is found to be better results according to MLR results. It is determined that, RBANN model converges the observed flow values better than the other artificial neural networks models used in this study.

**Keywords:** Monthly streamflow estimation, Artificial neural network, Multi linear regression, Middle Part of Euphrates Basin,

## 1. GİRİŞ

Uzun yıllar boyunca hidroloji mühendisleri su temini, taşkın kontrolü, sulama, drenaj, su kalitesi, enerji üretimi ve rekreasyon gibi çalışmalar için akım tahminine gerek duymuşlardır ve bu sebeple yağış ve karın akışa dönüşümünü anlamaya çalışmışlardır. Hidroloji ve su kaynakları mühendisliğinde bir drenaj havzası üzerindeki yağış-akış ilişkisinin doğru tahmini önemli bir konudur. Bu tahmin, sađanıklı tek bir dönem gibi kısa bir zaman aralığı için yapılabildiđi gibi, aylık veya yıllık gibi uzun dönemleri kapsayacak şekilde yapılabilir. Ancak, yersel ve bölgesel özelliklerdeki deđişimler yağış-akış ilişkisinin belirlenmesini zorlaştırmaktadır.

Yağış-akış ilişkisinin belirlenmesinde kullanılan hidrolik modeller, bir akarsu havzasına düşen yağış ve akarsudan çıkan akışı esas almakta olup, parametrik modeller (çok bileşenli, kavramsal) ve kapalı kutu (kara kutu) modeller olmak üzere genellikle iki grup altında değerlendirilmektedir. Parametrik modellere dayanan sürekli hidrolojik simülasyonların, yağış-akış süreçlerini incelemek ve gerekli verileri sağlamak için etkili bir araç olduđu kanıtlanmıştır [1]. Parametrik modellerin temel özelliđi, havzanın büyük alt alanları veya tüm alanları ile fiziksel açıdan ilişkili olan parametrelerle daha basit ve varsayımsal bir yapıya sahip olmalarıdır. Diđer taraftan kapalı kutu modelleri, yağış akış ilişkisinin belirlenmesinde fiziksel veya herhangi bir neden ya da etki gibi bir bilgiye ihtiyaç duymamaktadır.

Hidroloji ve su kaynakları alanında son yıllarda kapalı kutu modelleme yöntemlerinden olan yapay sinir ađları (YSA) yağış akış ilişkisinin modellenmesi konusunda uygun bir alternatif olarak kullanılmaktadır [2-6]. YSA yönteminin

büyük miktardaki bilgi üzerinde işlem yaparak ve “eđitim” adı altında giriş ve çıkış örnek verileri ile karmaşık model fonksiyonlarını öğrenmek gibi bir yeteneđi vardır. Diđer modelleme tekniklerine kıyasla YSA'nın en büyük avantajı, girdi ve çıktı deđişkenleri arasındaki ilişkinin biçimini varsaymak zorunda kalmadan karmaşık ve doğrusal olmayan işlemleri modelleyebilmesidir. Böylece yağış akış modelleme kapsamında YSA, havza özelliklerini ön bilgi girmeden belirleyecek şekilde eđitilebilmektedir.

YSA ile ilgili uygulamalar incelendiđinde, modellemelerde genellikle ileri beslemeli geriye yayımlı yapay sinir ađı algoritmalarının kullanıldıđı görülmektedir. Aynı zamanda bu algoritmalara alternatif olarak geliştirilmiş olan genelleştirilmiş regresyon yapay sinir ađı ve radyal tabanlı yapay sinir ađı gibi algoritmaların kullanımına da rastlanmaktadır [7-9].

Bu çalışmada, Orta Fırat Havzasında bulunan 2157 numaralı akım gözlem istasyonuna ait aylık ortalama akım verileri ile 17204 numaralı yağış gözlem istasyonuna ait aylık toplam yağış verileri arasındaki ilişki yapay sinir ađları metotlarından İleri Beslemeli Geri Yayınım Sinir Ađı (İBGYSA), Genelleştirilmiş Regresyon Yapay Sinir Ađı (GRYSA) ve Radyal Tabanlı Yapay Sinir Ađı (RTYSA) ile belirlenmeye çalışılmış ve bu sonuçlar daha klasik bir yöntem olan Çoklu Doğrusal Regresyon (ÇDR) yöntemi ile karşılaştırılmıştır.

## 2. ÇALIŞMA ALANI

Çalışma kapsamında Şekil 1’ de verilen Orta Fırat Havzasında bulunan 17204 numaralı Yağış Gözlem İstasyonu (YAGİ) ile 2157 numaralı Akım Gözlem İstasyonu’na (AGİ) ait veriler

kullanılmıştır. 17204 numaralı YAGİ'ye ait bilgiler Çizelge 1'de, 2157 numaralı AGİ'ye ait bilgiler ise Çizelge 2'de verilmiştir.

Çizelge 1 ve 2'de istasyonlara ait rasat yılları incelendiğinde bu iki istasyonun veri aralığının aynı olmadığı görülmektedir. Yağış-akış modelinin oluşturulması için veri sayısının aynı olması gerektiğinden, kurulacak modele ait rasat yılları her iki istasyona uygun olan 1969-2000 aralığı seçilmiştir.

Bu verilere ait istatistik özellikler Çizelge 3'te verilmiştir. Çizelgede  $x_{ort}$ ,  $S_x$ ,  $C_{sx}$ ,  $x_{min}$  ve  $x_{max}$  sırasıyla her bir veri setinin ortalamasını, standart sapmasını, çarpıklığını, en küçük ve en büyük değerini ifade etmektedir. Burada, akış verileri oldukça çarpık bir dağılıma sahiptir, ayrıca akış ve yağış verilerinin en büyük değerlerinin, ortalama değerlerine oranlarının çok büyük olması akış ile yağış arasındaki ilişkinin karmaşık bir yapıya sahip olduğunu göstermektedir.

**Çizelge 1.** 17204 nolu yağış gözlem istasyonuna ait bilgiler [10]

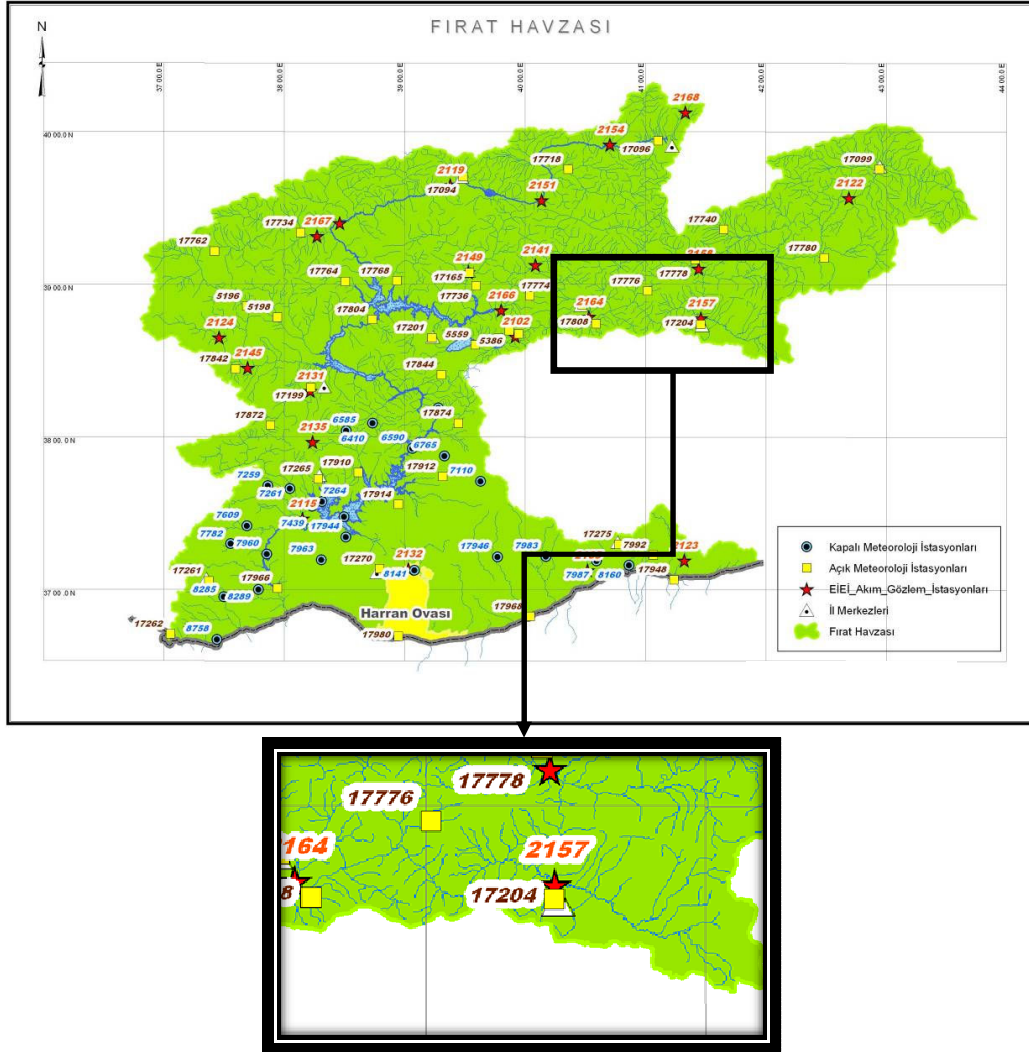
İstasyon No	Adı	Bölge	Yükseklik	Enlem	Boylam	Rasat
17204	MUŞ	VAN	1322 (m)	38,7509 K	41,5023 D	1964-2008

**Çizelge 2.** 2157 nolu akım gözlem istasyonuna ait bilgiler [11]

İstasyon No	Adı	Yağış alanı	Enlem	Boylam	Rasat
2157	Karasu-Karaköprü	2098 (km <sup>2</sup> )	38,784 K	41,4886 D	1969-2000

**Çizelge 3.** Kullanılan verilerin istatistiksel özellikleri

Parametre	Yağış	Akış
$x_{ort}$	61.45 (mm)	24.39 (m <sup>3</sup> /s)
$S_x$	54.09 (mm)	35.43 (m <sup>3</sup> /s)
$C_{sx}$	0.79	2.81
$x_{min}$	0 (mm)	1.11 (m <sup>3</sup> /s)
$x_{max}$	255.30 (mm)	234.00 (m <sup>3</sup> /s)
$x_{max}/x_{ort}$	4.15	9.59



Şekil 1. Çalışma alanı

### 3. YÖNTEM


#### 3.1. Yapay Sinir Ağları (YSA)

Yapay sinir ağları kavramı, beynin çalışma ilkelerinin bilgisayarlar üzerinde benzetimlerinin yapılması fikri ile ortaya çıkmıştır. Yapılan ilk çalışmalar, beyni oluşturan nöronların matematik modellerinin kurulması şeklindedir. Günümüzde yapay sinir ağları olarak isimlendirilen alan, birçok

nöronun belirli biçimlerde bir araya getirilip bir işlevin gerçekleşmesi üzerindeki yapısal olduğu kadar matematiksel sorulara yanıt arayan bir bilim dalı olmuştur.

Yapay sinir ağları, farklı ağlarla birbirine bağlı birçok işlem elemanlarından oluşmuş yoğun paralel sistemlerdir. YSA metotları içerisinde en çok kullanılan hataların geriye yayılma (back-propagation) ilkesine göre çalışandır [12].

Şekil 2, üç tabakalı bir yapay sinir ağını göstermektedir. Burada  $i$  girdi tabakası,  $j$  gizli tabaka ve  $k$  çıktı tabakası,  $A_{ij}$  ve  $A_{jk}$  ise hücre tabakaları arasındaki bağlantı ağırlıklarıdır. Başlangıçta rastgele atanan ağırlık değerleri, eğitme sürecinde tahmin edilen çıktılarla gerçek çıktı değerleri karşılaştırılarak devamlı değiştirilir ve hataları minimum yapan bağlantı ağırlık değerleri ayarlanıncaya kadar hatalar geriye doğru (Şekil 1'de sağdan sola) yayılır. Burada ağırlıkları ayarlamak için Levenberg-Marquardt metodu kullanılmıştır [13].



Şekil 2. Üç tabakalı bir yapay sinir ağı.

$j$  ve  $k$  tabakalarındaki her bir hücre, önceki tabakadan  $NET$  ağırlıklı toplam çıktılarını girdi olarak alır.  $NET$  değeri (1) eşitliği ile hesaplanır.

$$NET_{pj} = \sum_{i=1}^L A_{ij} C_{pi} + \theta_j \quad (1)$$

Burada  $L$  girdi vektörünün boyutu,  $\theta_j$  taraflılık sabiti (bias),  $A_{ij}$   $i$  ve  $j$  tabakaları arasındaki ağırlık kümesi,  $C_{pi}$   $p$  örneği için  $i$  tabakasının çıktı kümesidir.  $j$  ve  $k$  tabakalarındaki herbir hücre,  $NET$  değerini doğrusal olmayan bir tasvir fonksiyonundan geçirerek  $f(NET)$  çıktısını üretir. Yaygın şekilde kullanılan bu tasvir fonksiyonu,

$$f(NET) = \frac{1}{1 + e^{-NET}} \quad (2)$$

şeklinde ifade edilir. Eğitme aşamasında,  $p$  örneği için toplam hata  $H_p$ , tahmin edilen ve gerçek çıktılar arasında kareler farkına bağlı olarak (3) eşitliğiyle hesaplanır.

$$H_p = \sum_{k=1}^N (G_{pk} - C_{pk})^2 \quad (3)$$

Burada  $N$  iterasyon sayısı olmak üzere  $G_{pk}$  ve  $C_{pk}$  sırası ile  $p$  örneği için gerçek ve tahmin edilen çıktı değerleridir. Eğitme işleminin asıl amacı toplam hatayı,  $H$ , minimum yapan bir ağırlıklar kümesi üretmektir.

$$H = \sum_{p=1}^p H_p \quad (4)$$

Her bir bağlantı ağırlığı,  $A_{ij}$ , (5) eşitliği ile yenilenir.

$$A_{ij}^{yeni} = A_{ij}^{eski} - \eta \frac{\partial H_p}{\partial A_{ij}} \quad (5)$$

Burada  $\eta$  öğrenme oranı olarak adlandırılan orantılılık katsayısını,  $\partial H_p / \partial A_{ij}$  ise hata yüzeyinin eğimini göstermektedir [14].

### 3.2. Radyal Tabanlı Yapay Sinir Ağları (RTYSA)

Radyal Tabanlı Fonksiyonlar kavramı 1988 yılında Broomhead ve Lowe [15] tarafından geliştirilerek yapay sinir ağları literatürüne eklenmiştir.

RTYSA modelleme yöntemi yüksek boyutlu uzay için bir veri modelleme tekniğinin ve yapay sinir ağı gibi evrensel bir yaklaşım şemasının, birleşmesi olarak kabul edilebilir. RTYSA, insan sinir sistemindeki nöronlarda görülen yerel etki-tepki davranışlarından esinlenilerek oluşturulmuş ve genel YSA mimarisine benzer şekilde giriş üç katmanlı, gizli katman ve çıktı katmanlı olmak üzere üç katman halinde tanımlanmaktadır. Ancak, klasik YSA yapılarından farklı olarak RTYSA'larda, girdi katmanından gizli katmana geçişte radyal tabanlı aktivasyon fonksiyonları ve doğrusal olmayan bir kümeleme analizi kullanılmaktadır.

RTYSA modellerinde ağın ürettiği çıktı ( $y$ ) ise Denklem 6 yardımıyla hesaplanabilmektedir.

$$y_i = \sum_{k=1}^N w_{ik} \phi_k(x, c_k) = \sum_{k=1}^N w_{ik} \phi_k(\|x - c_k\|_2) \quad (6)$$

$i = 1, 2, \dots, m$

Burada  $x \in R^{n \times 1}$  ağın girdi vektörünü;  $\phi_k(\cdot) \in R^+$  radyal tabanlı aktivasyon fonksiyonunu;  $c_k \in R^{n \times 1}$  girdi vektör uzayının bir alt setinden seçilen radyal tabanlı merkezleri;  $\|\cdot\|_2$  girdi vektörünün merkezden ne kadar uzak olduğunun bir ölçütü olan Öklidyen normunu;  $w_{ik}$  çıktı katmanındaki ağırlıkları;  $N$  ise gizli katmanda bulunan hücre sayısını göstermektedir.

RTYSA modellerinde önem arz eden elemanlar; hücre merkezleri, çıktı katmanındaki ağırlıklar ve kullanılan aktivasyon fonksiyonunun yapısıdır. RTYSA modellerinde en çok kullanılan Gauss tabanlı fonksiyonlardır. Gauss fonksiyonunun matematiksel yapısı,

$$\phi_k(x) = \exp\left(-\|x - c_k\|_2^2 / 2\sigma^2\right) \quad (7)$$

şeklinde. Denklem 7'de  $x$  girdi vektörünü,  $c_k$  merkezleri,  $\sigma$  ise standart sapma değerini simgelemektedir.  $\sigma$  değeri ayrıca RTYSA modelinin performansını önemli ölçüde etkileyen dağılıma (spread) parametresi ( $s$ ) olarak da anılmaktadır.

RTYSA modeli girdi tabakası, gizli hücre ve çıktı tabakası olmak üzere üç tabakadan oluşmaktadır. Girdi tabakası şebekeye giren verilerin yer aldığı tabakadır. Gizli hücre ise nöronların yer aldığı ve temel fonksiyonların çıktılarının hesaplandığı tabakadır. Çıktı tabakasında ise temel fonksiyonlar

$$f'(X, y) = \frac{1}{(2\pi)^{(p+1)/2} s^{(p+1)}} \times \frac{1}{n} \sum_{i=1}^n \exp\left[-\frac{(X - X^i)^T (X - X^i)}{2s^2}\right] \times \exp\left[-\frac{(Y - Y^i)^2}{2s}\right] \quad (9)$$

arasında lineer bir bağıntı veya kombinasyon bulunmaya çalışılır.

### 3.3. Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA)

Spetch [16] tarafından önerilen Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA) geri yayılma yöntemi gibi iteratif bir eğitim prosedürü gerektirmez. Bu model, giriş ve çıkış vektörlerinden yararlanarak rastgele yaklaşık bir tahmini fonksiyonunu, direk olarak eğitim verilerinden oluşturur. Ayrıca, GRYSA modelinde tahmini hata, eğitim verilerinin boyutunun büyük olduğu durumlarda fonksiyonda hafif bir kısıtlamayla sifira yaklaşır.

GRYSA sadece eğitim seti verilen  $x$  ve  $y$  ortak olasılık yoğunluk fonksiyonunu hesaplayan bir yöntemdir. Olasılık yoğunluk fonksiyonunun biçimi hakkında hiçbir önyargı olmadan veri türetilmiş olduğundan, bu sistem mükemmel derecede geneldir diyebiliriz.

Denklem 8,  $f(x, y)$  ortak olasılık yoğunluk fonksiyonunun bilinmesi durumunda, bağımsız  $x$  değişkenine göre bağımlı  $y$  değişkeninin regresyonunu göstermektedir.

$$E[y|X] = \frac{\int_{-\infty}^{\infty} yf(X, y)dy}{\int_{-\infty}^{\infty} f(X, y)dy} \quad (8)$$

Olasılık fonksiyonu  $f(x, y)$  bilinmiyorsa, genellikle gözlenen  $x$  ve  $y$  örneklerinden tahmin edilmesi gerekir. Denklem 9'da gösterilen olasılık tahmin edici fonksiyonu,  $x$  ve  $y$  rastgele değişkenlerinin,  $X^i$  ve  $Y^i$  örnek değerlerinden oluşur. Bu denklemde  $n$  gözlenen veri sayısı,  $p$ ,  $x$  vektörünün boyutu ve  $s$  dağılıma (spread) parametresidir.

$D_i^2$  skaler fonksiyonunu denklem 10'da ki gibi tanımlarsak ve denklem 8'deki integralleri çözersek denklem 11'i elde edebiliriz.

$$D_i^2 = (X - X^i)^T (X - X^i) \quad (10)$$

$$Y'(X) = \frac{\sum_{i=1}^n Y^i \exp\left(-\frac{D_i^2}{2s^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2s^2}\right)} \quad (11)$$

### 3.4. Çoklu Doğrusal Regresyon (ÇDR)

Çoklu doğrusal regresyonda amaç, bağımlı değişkeni etkilediği belirlenen bağımsız değişkenler yardımıyla bağımlı değişkenin değerinin kestirilmesi ve bağımlı değişkeni etkilediği düşünülen bağımsız değişkenlerden hangisi ya da hangilerinin bağımlı değişkeni daha çok etkilediğini bulmaktır.

Çoklu regresyon çözümlemesinde, bağımlı değişken  $y$ , bağımsız değişkenler  $x_1, x_2, \dots, x_p$  ile gösterildiğinde aralarındaki ilişki;

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_j x_j + \dots + \beta_p x_p + \varepsilon \quad (12)$$

olarak yazılabilir.

Burada  $\beta_0, \beta_1, \beta_2, \dots, \beta_j, \dots, \beta_p$  bilinmeyenlerine regresyon katsayıları denir. Herhangi bir  $\beta_j$  regresyon katsayısı, diğer değişkenler sabit tutulduğunda (diğer değişkenlerin etkisi ortadan kaldırıldığında)  $x_j$  değişkeninde ortaya çıkan bir birimlik değişmeğe karşılık  $y$  değişkenindeki beklenen değişiklik miktarını vermektedir. Diğer bir ifadeyle;  $\beta_0, \beta_1, \beta_2, \dots, \beta_j, \dots, \beta_p$ ; bağımsız değişkenlerin  $y$ 'nin saptanmasına yaptıkları göreceli katkıya ilişkin ağırlıklardır. Bu nedenle,  $\beta_j$  ( $j=1, 2, \dots, p$ ) parametreleri genellikle kısmi regresyon katsayıları olarak adlandırılmaktadır.

$\beta_0$  'a ise kesim noktası veya sabit denir ve tüm  $x_j$  değişken değerleri sıfır olduğunda bağımlı değişkenin aldığı değeri gösterir.  $\varepsilon$  ise hata terimidir [17].

## 4. ARAŞTIRMA BULGULARI VE TARTIŞMA

YSA modeli geliştirilirken sigmoid transfer fonksiyonu kullanıldığından, verilerin ağa girilmeden önce normalize edilmesi gereklidir [18,19]. Bunun için her bir değişken, Denklem 13 kullanılarak normalize edilmiştir.

$$X_{ni} = a \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} + b \quad (13)$$

Denklemdaki  $X_{\min}$  ve  $X_{\max}$  sırası ile veri setinin minimum ve maksimum değerini,  $X_i$  ölçülmüş,  $X_{ni}$  ise normalize edilmiş değerleri ifade etmektedir. Denklemdaki  $a$  ve  $b$  değerleri sırasıyla 0.6 ve 0.2 alınmıştır. Beş model için de normalizasyon işlemi yapılmış, elde edilen çıktılar, Denklem 13'ün tersi kullanılarak normalizasyon işlemi tersine çevrilmiştir.

17204 numaralı YAGİ ile 2157 numaralı AGİ arasındaki ilişkinin belirlenmesinde oluşturulan beş farklı durum için girdi verileri verilmiş (Çizelge 4) ve buna bağlı olarak akım tahmini yapılmaya çalışılmıştır. Çizelge 4 içerisinde bulundan (P) yağış girdisini, (P-1), (P-2), (P-3) ve (P-4) sırasıyla bir, iki, üç ve dört ay önceki yağış girdilerini, (Q-1) bir ay önceki akım değerini, Q ise çıktı değerini göstermektedir. Çalışma kapsamında bu istasyonlara ait toplam 380 verinin 266'sı eğitim sürecinde geri kalan 114 veri ise sadece test aşamasında kullanılmıştır. Test aşamasında kullanılan veriler eğitim sürecine dahil edilmemiştir.

Ele alınan farklı durumların korelasyon değerleri Çizelge 5'te verilmiştir. Burada 2157 numaralı AGİ'nin kendinden bir önce gelen akım debisiyle en yüksek korelasyona, dört gün önceki yağış verisi (P-4) ile de en düşük korelasyona sahip

**Çizelge 4.** Yağış-Akış ilişkisinin belirlenmesinde kullanılan model girdileri ve çıktıları

Durum	Girdi	Çıktı
1	P, Q-1	Q
2	P, P-1, Q-1	Q
3	P, P-1,P-2,Q-1	Q
4	P, P-1,P-2,P-3,Q-1	Q
5	P, P-1,P-2,P-3,P-4,Q-1	Q

olduğu görülmektedir.

Modellerin tahmin sonuçları karekök ortalama karesel hata (KOKH) ve belirlilik katsayısı ( $R^2$ ) kriterlerine göre karşılaştırılmıştır. Bunlardan KOKH değerlerinin 0'a,  $R^2$  değerinin 1'e yakın olması, tahmin edilen değer kuvvetli biçimde doğruya yakınsadığını göstermektedir. Buna göre  $N$  toplam veri sayısı olmak üzere,

$$KOKH = \sqrt{\frac{1}{N} \sum_{n=1}^N (Q_{ölç.} - Q_{tah.})^2} \quad (13)$$

$$R^2 = \frac{\sum_{i=1}^N (Q_{ölç.} - Q_{ort.})^2 - \sum_{i=1}^N (Q_{ölç.} - Q_{tah.})^2}{\sum_{i=1}^N (Q_{ölç.} - Q_{ort.})^2} \quad (14)$$

Şeklinde tanımlanırlar. Burada  $Q_{ölç.}$ , gözlenen akım değerini,  $Q_{ort.}$ , ortalama akım değerini,  $Q_{tah.}$  ise model sonucunda elde edilen akım değerini ifade etmektedir. Beş farklı durum için hazırlanan modellere ait eğitim ve test sonuçları Çizelge 6'de verilmiştir.

**Çizelge 5.** Yağış-akış korelasyon katsayıları

	Q	Q-1	P	P-1	P-2	P-3	P-4
Q	1.000	<b>0.546</b>	0.471	0.446	0.377	0.248	0.227
Q-1		1.000	0.142	0.480	0.457	0.378	0.261
P			1.000	0.360	0.176	-0.049	-0.214
P-1				1.000	0.369	0.180	-0.037
P-2					1.000	0.372	0.187
P-3						1.000	0.374
P-4							1.000

**Çizelge 6.** İBGYSA ve GRYSA modellerine göre eğitim ve test sonuçlarının  $R^2$  ve KOKH değerleri

Durum	Girdiler	İBGYSA				GRYSA			
		Eğitim		Test		Eğitim		Test	
		$R^2$	KOKH	$R^2$	KOKH	$R^2$	KOKH	$R^2$	KOKH
1	P, Q-1	0.611	34.886	<b>0.768</b>	23.749	0.685	31.749	0.546	24.960
2	P, P-1, Q-1	0.614	34.756	0.765	26.758	0.490	41.740	0.5919	22.342
3	P, P-1,P-2,Q-1	0.796	25.298	0.659	26.571	0.553	39.724	0.596	21.424
4	P, P-1,P-2,P-3,Q-1	0.711	30.249	0.750	28.723	0.515	41.617	0.568	22.091
5	P, P-1,P-2,P-3,P-4,Q-1	0.715	39.497	0.578	22.913	0.644	48.713	<b>0.642</b>	29.343



**Çizelge 7.** RTGYSA ve ÇDR modellerine göre eğitim ve test sonuçlarının R<sup>2</sup> ve KOKH değerleri

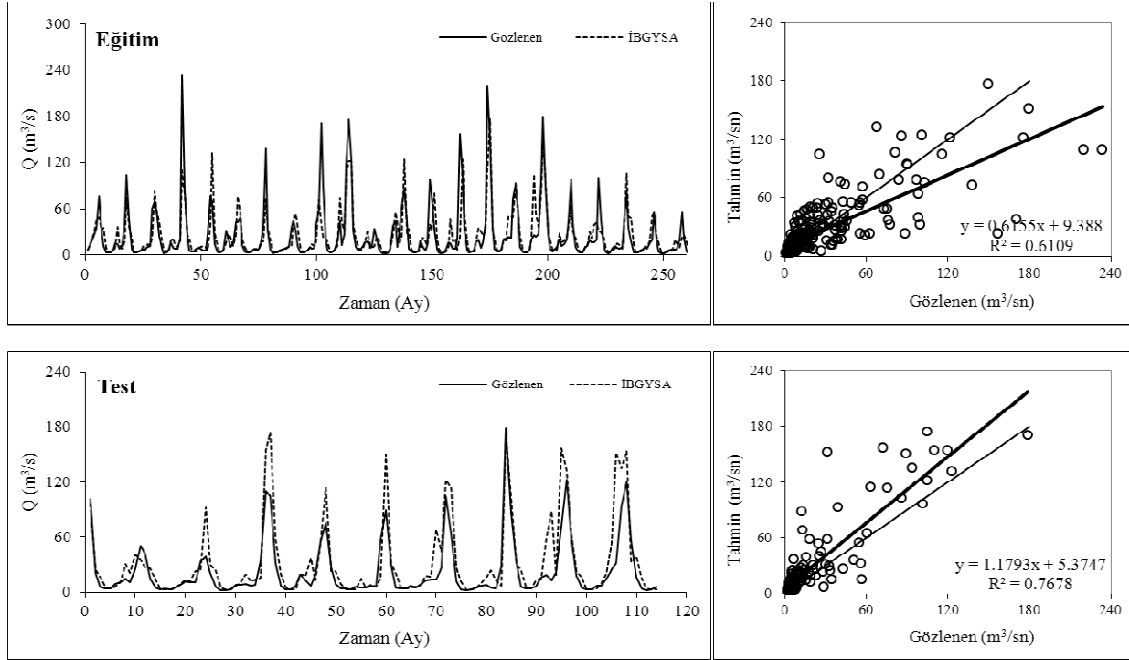
Durum	Girdiler	RTGYSA				ÇDR			
		Eğitim		Test		Eğitim		Test	
		R <sup>2</sup>	KOKH	R <sup>2</sup>	KOKH	R <sup>2</sup>	KOKH	R <sup>2</sup>	KOKH
1	P, Q-1	0.573	36.565	<b>0.789</b>	19.723	0.417	42.778	0.576	23.043
2	P, P-1, Q-1	0.598	35.567	0.704	22.405	0.423	42.673	<b>0.578</b>	23.238
3	P, P-1,P-2,Q-1	0.516	38.897	0.543	22.913	0.433	42.485	0.566	23.917
4	P, P-1,P-2,P-3,Q-1	0.579	36.304	0.575	24.021	0.432	42.485	0.561	23.979
5	P, P-1,P-2,P-3,P-4,Q-1	0.573	36.565	<b>0.789</b>	19.723	0.417	42.778	0.576	23.043

Çizelge 6 ve 7’de verilen sonuçlar incelendiğinde yapay sinir ağı yöntemlerinin ÇDR yöntemine göre daha başarılı olduğu görülmektedir. Ayrıca İBGYSA, RTYSA ve ÇDR modelleri için, t ve t-1 ayındaki yağış girdisi dışında modellere eklenen iki, üç ve dört ay öncesindeki yağış girdileriyle anlamlı değişimler elde edilememiştir. Sadece GRYSA yönteminde t, t-1, t-2, t-3 ve t-4 ayındaki yağış girdileri ile elde edilen tahmin değerleri en uygun korelasyonu vermesine rağmen GRYSA yöntemi üç YSA yöntemi içerisinde hem R<sup>2</sup> hem de KOKH değerleri açısından en kötü sonucu veren yöntem olmuştur. Tüm modellere ait en başarılı sonuçlar Çizelge 8’de verilmiştir. Çizelge 8’de, Durum 1 için RTYSA yöntemine ait KOKH ve R<sup>2</sup> değerlerinin diğer tüm modellere göre daha iyi sonuç verdiği görülmektedir.

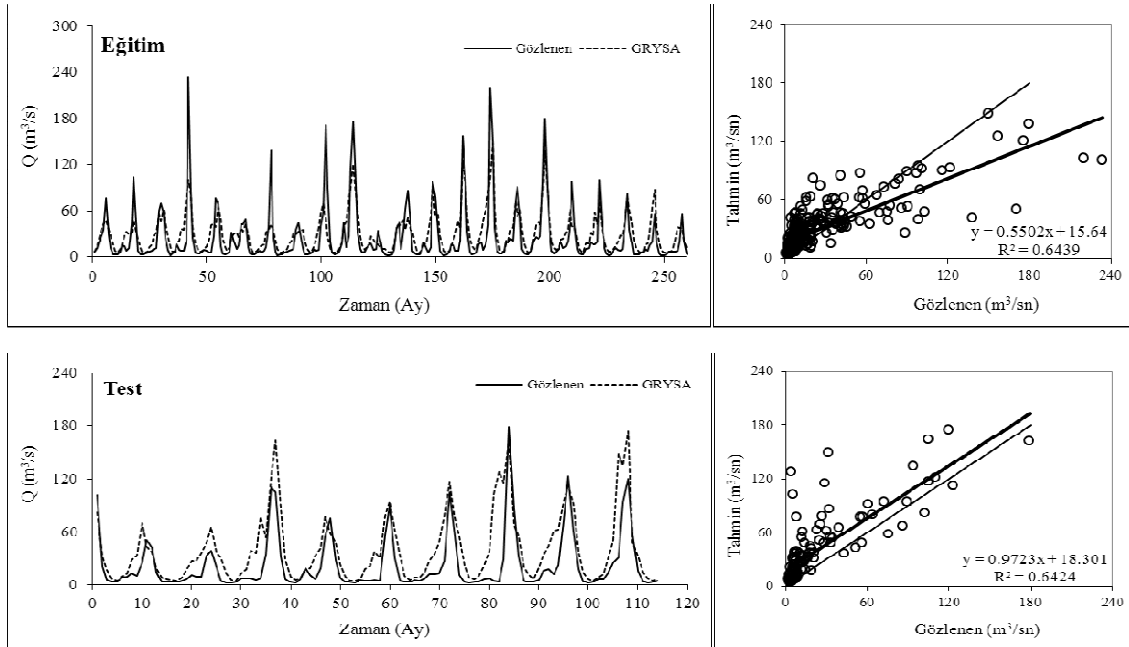
Çizelge 8’de alt indis olarak verilen değerler sırasıyla İBGYSA metodunda kullanılan girdi, ara ve çıktı katmanlarındaki hücre sayılarını; RTYSA metodundakiler sırasıyla dağılma parametresi (s) ve maksimum hücre sayısını, GRYSA’da ise dağılma parametresini temsil etmektedir. Çizelge 8’de gösterilen sonuçlara ait eğitim ve test verileri için tahmin edilen ve gözlenen akım değerlerinin zamana bağlı gidişleri ve saçılma diyagramları Şekil 3, 4, 5 ve 6’da gösterilmiştir. Burada Şekil 5’te RTYSA için elde edilen test grafikleri incelendiğinde bu modelde tahmin edilen akışın gözlenen akış ile diğer modellere göre daha uyumlu olduğu görülmektedir.

**Çizelge 8.** Tüm modellere ait en iyi sonucu veren durumlar için Eğitim ve Test sonuçlarının R<sup>2</sup> ve KOKH Değerleri

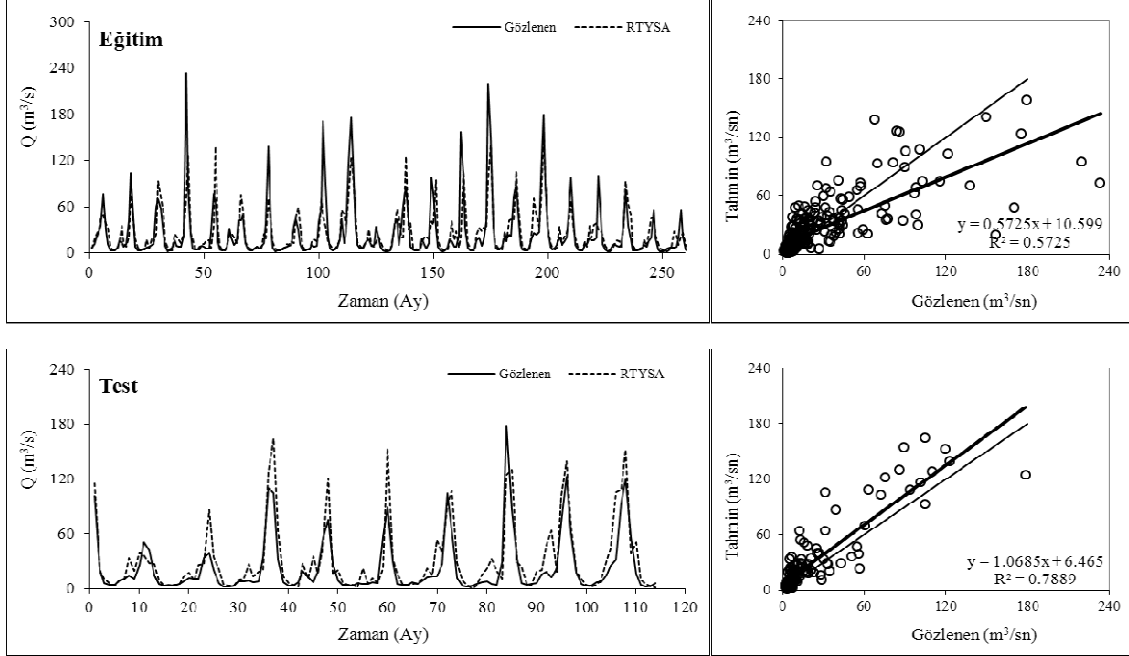
Model	Durum	Eğitim		Test	
		R <sup>2</sup>	KOKH	R <sup>2</sup>	KOKH
İBGYSA <sub>(2,2,1)</sub>	1	0.611	34.886	<b>0.768</b>	23.749
GRYSA <sub>(0,25)</sub>	5	0.644	48.713	<b>0.642</b>	29.343
RTYSA <sub>(1,8)</sub>	1	0.573	36.565	<b>0.789</b>	19.723
ÇDR	2	0.423	42.673	<b>0.578</b>	23.238



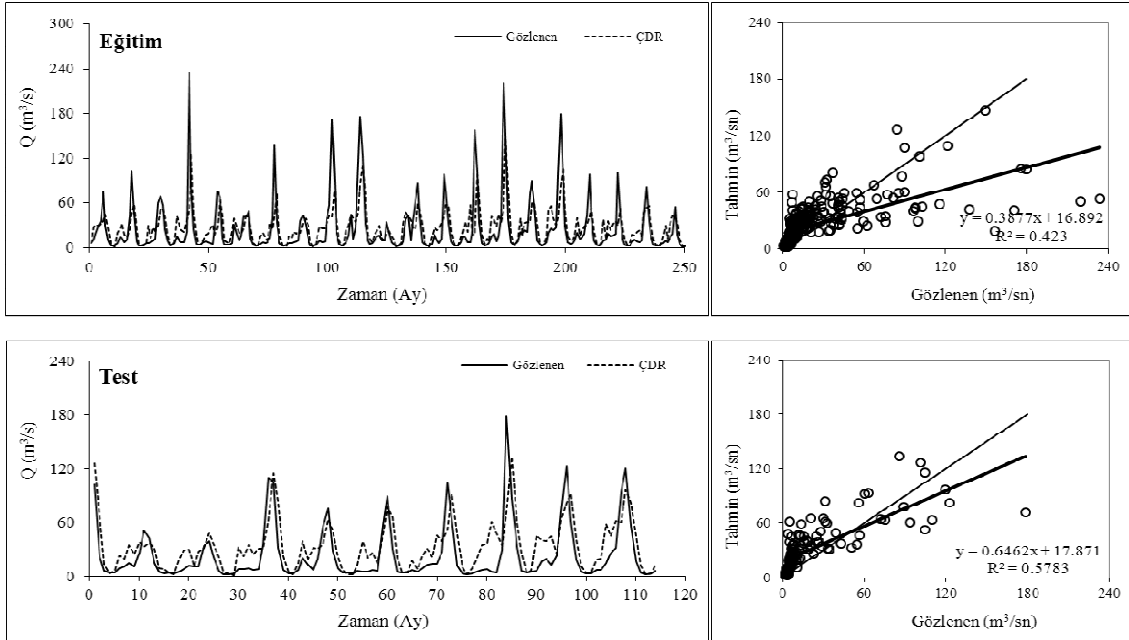
**Şekil 3.** Eğitim ve test dönemine ait Durum 1 için İBGYSA modeli ile tahmin edilen ve gözlenen akım değerleri



**Şekil 4.** Eğitim ve test dönemine ait Durum 5 için GRVSA modeli ile tahmin edilen ve gözlenen akım değerleri



Şekil 5. Eğitim ve test dönemine ait Durum 1 için RTYSA modeli ile tahmin edilen ve gözlenen akım değerleri



Şekil 6. Eğitim ve test dönemine ait Durum 2 için ÇDR modeli ile tahmin edilen ve gözlenen akım değerleri

#### 4. SONUÇLAR

Bu çalışmada, Orta Fırat Havzasında bulunan 2157 numaralı akım gözlem istasyonuna ait aylık ortalama akım verileri ile 17204 numaralı yağış gözlem istasyonuna ait aylık toplam yağış verileri arasındaki ilişki yapay sinir ağları metodlarından İleri Beslemeli Geri Yayınım Sinir Ağı (İBGYSA) metodu, Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA) ve Radyal Tabanlı Yapay Sinir Ağı (RTYSA) ile araştırılmış ve sonuçlar Çoklu Doğrusal Regresyon (ÇDR) yöntemi ile karşılaştırılmıştır. Çalışma kapsamında bu istasyonlara verinin %70'i eğitim sürecinde geri kalan %30'luk kısmı ise sadece test aşamasında kullanılmıştır. Beş farklı duruma göre yağış ve akım değerleri girdi verisi olarak ele alınmış bu durumlara göre akım değerleri tahmin edilmiştir. Kullanılan üç yapay sinir ağı yönteminin ÇDR yöntemine göre daha başarılı olduğu görülmüştür. Yapay sinir ağı yöntemleri arasında ise  $R^2$  ve KOKH bakımından en uygun ilişki yağış (P) ve akışın bir önceki değeri (Q-1)'in ele alındığı Durum 1 de RTYSA modelinden elde edilmiştir. İBGYSA, RTYSA ve ÇDR modellerinde yağış-akış korelasyonları sonucuna paralel olarak P, P-1 ve Q-1 girdileri dışında modellere eklenen iki, üç ve dört ay öncesindeki yağış girdileriyle anlamlı değişimler elde edilememiştir. Sonuç olarak, yapay sinir ağları ile hazırlanan akım modellerinin akarsu havzalarının doğrusal olmayan yağış-akış ilişkisini parametrik yöntemlere kıyasla yoğun verilere ihtiyaç duymadan başarıyla modellediği görülmüştür.

#### 5. KAYNAKLAR

1. Todini, E. (1988). "Rainfall-runoff modelling - past, present and future." J. Hydrology 100, 341-352.
2. Dragan, A., SAVIC, Godfrey, A. W., JAMES, W. D. (1999). "A Genetic Programming Approach to Rainfall-Runoff Modelling Water Resources Management." 13: 219-231, 1999.
3. Gümüş, V., Kavşut, M. E., Yenigün, K. (2011). "Yağış-Akış İlişkisinin Modellenmesinde YSA Kullanımının Değerlendirilmesi: Orta Fırat

- Havzası Uygulaması." New World Sciences Academy, 6(1), 1A0160.
4. Okkan, U., Mollamahmutoğlu, A. (2010). "Yiğitler Çayı Günlük Akımlarının Yapay Sinir Ağları ve Regresyon Analizi ile Modellenmesi." Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 1302-3055.
5. Tokar, A. S., Markus, M. (2000). "Precipitation-Runoff Modeling Using Artificial Neural Networks and Conceptual Models." J. Hydrol. Eng., 5:156-161.
6. Kişi, Ö., Shiri, J., Tombul, M. (2013). "Modeling Rainfall-Runoff Process Using Soft Computing Techniques." Computers & Geosciences, 51, 108-117.
7. Partal, T., Kahya, E., Cıgızoğlu, K. (2008). "Yağış Verilerinin Yapay Sinir Ağları ve Dalgacık Dönüşümü Yöntemleri ile Tahmini." İTÜ Dergisi/d mühendislik, cilt:7, sayı:3, 73-85.
8. Okkan, U., Dalkılıç, H. Y. (2012). "Radyal Tabanlı Yapay Sinir ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi." İMO Teknik Dergi, 5957-5966, Yazı:379, Teknik Not.
9. Çobaner, M., Ünal, B., Kişi, Ö. (2009). "Suspended Sediment Concentration Estimation by and Adaptive Neuro-Fuzzy." Journal of Hydrology, 367, 52-61.
10. Meteoroloji, (2012), Aylık Yağış Verileri, <http://www.tumas.dmi.gov.tr/wps/portal/>
11. EİEİ, (2000). Su Akımları Yıllığı, Elektrik İşleri Etüd İdaresi, Ankara.
12. Lippman, R. (1987). "An Introduction to Computing with Neural Nets." IEEE ASSP Mag., 4, 4-22.
13. Marquardt, D. (1963). "An Algorithm for Least Squares Estimation of Non-Linear Parameters." Journal of the Society for Industrial and Applied Mathematics, 11(2), 431-441.
14. Kişi, Ö. (2004). "Yapay Sinir Ağları ve Regresyon Teknikleri ile Filyos Çayı Akımlarının Tahmini." IV. Hidroloji Kongresi, 23-25 Haziran, 347-353, İstanbul, Türkiye.
15. Broomhead, D., Lowe, D. (1988). "Multivariable Functional Interpolation and Adaptive Networks." Complex Systems, 2, 6, 568-576.

16. Specht, D. F. (1991). "A General Regression Neural Networks." IEEE Transactions on Neural Networks, 2(6), 568-576.
17. Alpar, R. (2003). "Uygulamalı Çok Değişkenli İstatistiksel Yöntemlere Giriş 1." Ankara, Türkiye.
18. Van Ooyen, A. ve Nienhuis, B. (1992). "Improving the convergence of the back propagation algorithm". Neural Networks, 5, 465-471.
19. Cobaner, M., Seckin, G. ve Kisi, O. (2008) "Initial assessment of bridge backwater using an artificial neural network approach". Canadian Journal of Civil Engineering, 35, 500-510.

