

Zamanti Nehri-Ergenuşağı İstasyonu Eksik Aylık Akım Verilerinin Tahmini

Veysel GÜMÜŞ, M. Eyyüp KAVŞUT*

Çukurova Üniversitesi Müh. Mim. Fakültesi, İnşaat Mühendisliği Bölümü, Balcalı/ADANA

Başvuru: 11.04.2013 Düzeltme: 08.04.2013 Kabul:08.04.2013

ÖZET

Akarsu yapılarının tasarımında, akım verilerinin sürekliliği büyük önem taşımaktadır. Ancak bazı istasyonlara ait ölçümler belli zaman aralıklarında eksik olabilmektedir. Geçmişe yönelik yeterli ölçümü bulunmayan istasyonların verileri aynı havza içerisinde bulunan ve hidrometeorolojik olarak benzer diğer istasyonların verileri ile farklı yöntemler kullanılarak tahmin edilebilmektedir. Bu çalışmada, yapay sinir ağı yöntemlerinden, İleri Beslemeli Geri Yayınimli Yapay Sinir Ağı (İBGYSA), Radyal Tabanlı Yapay Sinir Ağı (RTYSA) ve Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA) kullanılarak, Seyhan Havzasında bulunan 1806 numaralı Zamanti Nehri-Ergenuşağı akım gözlem istasyonuna ait eksik aylık akım verileri tahmin edilmiştir. Çalışma sonucunda İBGYSA yönteminin eksik veri tahmininde diğer yöntemlerden az da olsa daha iyi sonuç verdiği görülmüştür.

Anahtar kelimeler: Yapay sinir ağları, eksik veri, Seyhan Havzası, Zamanti Nehri.

ABSTRACT

The continuity of the streamflow data is of great importance to design practices on rivers. The missing measured data from the gaging stations can normally be estimated using those of collected from the hydrometeorologically similar stations in the same river basin. In this study, the missing monthly streamflow data of Gaging Station Nr: 1806 (Zamanti River-Ergenuşağı) in the Seyhan Basin is estimated using different artificial neural network methods, namely, feed-forward back-propagation neural network (FFBPNN), radial based artificial neural network (RBANN) and generalized regression neural network (GRNN). It is found that the FFBPNN method provides slightly better results compared to those from the other two.

Key words: Missing data, Artificial neural network, Seyhan River Basin, Zamanti River .

1. GİRİŞ

Su yapılarının etkili ve doğru planlaması ve su yönetimi için kesintisiz, sağlıklı ve uzun akım verilerine ihtiyaç duyulmaktadır. Doğada olayların rastgele ve belirsiz karakterlere sahip olmasının yanı sıra, olayda etkili olan parametreler arasındaki ilişkinin doğrusal olmaktan çok doğrusal olmayan bir ilişkiye sahip olması modelleme ve kontrol için zorluklar çıkarmaktadır. Başka bir deyişle, doğrusal ilişkilere dayalı olarak kurulan modeller, olaylardaki parametreler arasındaki ilişkileri yansıtmakta yetersiz kalabilmektedir. Dolayısıyla teknolojinin gelişimi ve bununla birlikte yeni yöntemlerin ortaya çıkması, doğası tam olarak ortaya çıkarılamamış olayların bu yeni yöntemlerle yeniden ele alınmasını zorunlu kılmaktadır. Yapay sinir ağları (YSA) gibi lineer olmayan modellerin gözlenen zaman verilerinin analizinde kullanılmaları uygun gözükmektedir. YSA modelleri sınırlı sayıda verinin bulunması halinde dahi, lineer olmayan modellemelerde başarı gösterebilirler. Lineer olmayan sistem davranışının modellenmesindeki başarısından dolayı en etkin tahmin yöntemlerinden biri olan YSA, hidroloji ve hidrolik konularındaki çalışmalarda daha sık kullanılmaya başlanmıştır.


Yapay sinir ağlarının su kaynaklarında, değişik meteorolojik olayların tanımlanması, sınıflanması ve tahmininde sıkça karşılaşılan değişik problemlere uygulanması ile ilgili çok sayıda çalışma bulunmaktadır. Zealand ve ark. [1], kısa süreli eksik akım verilerini YSA kullanarak tahmin etmeye çalışmışlardır. Mevcut verilerin bir kısmını eğitim bir kısmını test sürecinde kullanarak kurmuş oldukları modelde YSA'nın nehir akım tahmini gibi karmaşık bir problemde başarılı bir şekilde kullanılabileceği sonucuna varmışlardır. Kişi [2] çalışmasında Göksudere nehri üzerinde bulunan İsaköy akım gözlem istasyonu aylık akımlarını YSA ve farklı istatistik yöntemler kullanarak tahmin etmeye çalışmış ve çalışma sonucunda YSA yönteminin akım tahmininde başarılı

bir şekilde kullanılabileceği sonucuna varmıştır. Coulibaly ve Evora [3], çalışmalarında günlük eksik meteorolojik verilerin tahmini için altı farklı yapay sinir ağı yöntemi kullanmışlar ve bunları karşılaştırmışlardır. Çalışma sonucunda İBGYSA yönteminin günlük meteorolojik eksik veri tahmininde ele aldıkları diğer yapay zeka yöntemlerine göre daha başarılı olduğunu belirlemişlerdir. Rajurkar ve ark. [4] yağış akış ilişkisinin belirlenmesinde yapay sinir ağı yöntemlerinin başarısını ortaya koymuşlardır. Yurdusev ve ark. [5], çalışmalarında Akarçay havzasındaki aylık akımları, yağış ve akım verilerini kullanarak yapay sinir ağı yöntemleriyle tahmin etmişlerdir. Uygulama sonucunda yeterli miktarda verinin var olması durumunda yapay sinir ağlarının yağış-akış modellemesine başarılı bir şekilde uygulanabileceği ortaya koymuşlardır. Ayrıca hidrolojik modelleme ve tahmin işlemlerinde yapay sinir ağları sıklıkla kullanılmaktadır [6-11].


Bu çalışmada, Seyhan Havzasında bulunan 1806 numaralı akım gözlem istasyonuna (AGİ) ait eksik aylık akım verileri, bu istasyona yakın olan 1805 numaralı akım gözlem istasyonu aylık akım verileri kullanılarak farklı yapay sinir ağı yöntemleri ile tahmin edilmiştir. Eksik akım verilerinin belirlenmesinde, yapay sinir ağı yöntemlerinden İleri Beslemeli Geri Yayınimli Yapay Sinir Ağı (İBGYSA), Radyal Tabanlı Yapay Sinir Ağı (RTYSA) ve Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA) ile birlikte daha klasik olan Çoklu Doğrusal Regresyon (ÇDR) yöntemi kullanılmıştır.

2. ÇALIŞMA ALANI

Çalışma kapsamında, Seyhan Havzasındaki Çatalan barajının kuzeyinde bulunan 1805 ve 1806 numaralı Akım Gözlem İstasyonları (AGİ) kullanılmıştır (Şekil 1). Göksu Nehri üzerindeki 1805 numaralı 1805-Göksu-Gökdere AGİ'si ile Zamanti Nehri üzerindeki 1806-Zamanti Nehri-Ergenuşağı AGİ'si arasındaki mesafe 5.2 km olup, debi ölçümü yapılan nehirler Seyhan nehrini beslemektedir.



Şekil 1. Çalışma Alanı



Şekil 1. (Devamı) Çalışma Alanı

Çalışmada, 1805 numaralı AGİ'nin aylık ortalama akımları kullanılarak 1806 numaralı AGİ'ye ait eksik olan 1957-1960 yılları arasındaki akımların tahmin edilmesi için yapay sinir ağı yöntemleri ile çoklu

doğrusal regresyon yöntemi kullanılmıştır. Ele alınan istasyonların genel özellikleri Tablo 1'de, istatistikleri ise Tablo 2'de verilmiştir.

Tablo 1. Akım gözlem istasyonlarına ait bilgiler [12] (Information on gaging stations).

İstasyon No	Adı	Yağış alanı (km ²)	Enlem	Boylam	Rasat
1805	Göksu-Gökdere	4242,8	35° 36' 52''	37° 37' 07''	1939-2012
1806	Zamanti Nehri-Ergenusağı	8698,3	35° 34' 36''	37° 39' 17''	1938-1981

Tablo 2. Kullanılan verilerin istatistiksel özellikleri (Statistical properties of used data).

Parametre	1805	1806
x_{ort}	61.98 (m ³ /s)	67.27 (m ³ /s)
s_x	58.71 (m ³ /s)	38.63 (m ³ /s)
c_{sx}	2	1.76
x_{min}	17.4 (m ³ /s)	31.9 (m ³ /s)
x_{max}	372 (m ³ /s)	239 (m ³ /s)

Tablo 2'de x_{ort} , s_x , c_{sx} , x_{min} ve x_{max} parametreleri sırasıyla, aylık akımların ortalamasını, standart sapmasını, çarpıklığını, en küçük ve en büyük değerini ifade etmektedir. Burada, iki istasyona ait akımların çarpık bir dağılıma sahip olduğu görülmektedir.


3. YÖNTEM

3.1. Yapay Sinir Ağları

İleri Beslemeli Geri Yayınimli Yapay Sinir Ağı (İBGYSA)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 çalışır [13].

Şekil 2, İBGYSA mimarisini şematik olarak göstermektedir. Burada i girdi tabakasını, j gizli tabakayı ve k çıktı tabakasını, W_{ij} ve W_{jk} ise hücre tabakaları arasındaki bağlantı ağırlıklarını temsil etmektedir. Başlangıçta rastgele atanan ağırlık değerleri, eğitime sürecinde tahmin edilen çıktılarla gerçek çıktı değerleri karşılaştırılarak devamlı değiştirilir ve hataları minimum yapan bağlantı ağırlık değerleri ayarlanıncaya kadar hatalar geriye doğru (Şekil 2'de sağdan sola) yayılır. Burada ağırlıkları ayarlamak için Levenberg-Marquardt metodu kullanılmıştır [14].



Şekil 2. İBGYSA mimarisinin şematik gösterimi

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

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

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

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

şeklinde ifade edilir. Eğitime 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. Eğitime işleminin asıl amacı toplam hatayı (H) minimum yapan bir ağırlıklar kümesi üretmektir.

$$y_i = \sum_{k=1}^N w_{ik} \phi_k(x, c_k) = \sum_{k=1}^N w_{ik} \phi_k(\|x - c_k\|_2), i = 1, 2, \dots, m \quad (6)$$

Burada $x \in R^{n \times 1}$ ağırlık 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; $\|x - c_k\|_2$ 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.

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

Herbir bağlantı ağırlığı, W_{ij} , (5) eşitliği ile yenilenir.

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

Burada η öğrenme oranı olarak adlandırılan orantılılık katsayısını, $\partial H_p / \partial W_{ij}$ ise hata yüzeyinin eğimini göstermektedir [15].

Radyal Tabanlı Yapay Sinir Ağı (RTYSA)

Radyal Tabanlı Fonksiyonlar kavramı 1988 yılında Broomhead ve Lowe [16] 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 katmanı, gizli katman ve çıktı katmanı 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 ağırlık ürettiği çıktı (y), Denklem 6 yardımıyla hesaplanabilmektedir.

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, σ ise standart sapma değerini simgelemektedir. σ değeri ayrıca RTYSA modelinin performansını önemli ölçüde etkileyen dağılım (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 arasında lineer bir bağıntı veya kombinasyon bulunmaya çalışılır.

Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA)

Specht [17] 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 tahmin fonksiyonunu, direk olarak eğitim verilerinden oluşturur. Ayrıca, GRYSA modelinde tahmini hata, eğitim verilerinin boyutunun büyük olduğu durumlarda fonksiyonda hafif bir kısıtlamayla sifıra yaklaşır.

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

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

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

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

3.2. Çoklu Doğrusal Regresyon

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;

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_j x_j + \dots + \beta_p x_p + \varepsilon \quad (12)$$

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 denebilir.

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

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

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 σ düzeltme parametresidir.

olarak yazılabilir.

Denklem 12'deki $\beta_0, \beta_1, \beta_2, \dots, \beta_j, \dots, \beta_p$ bilinmeyenlerine regresyon katsayıları denir. Herhangi bir β_j regresyon katsayısı, diğer değişkenler sabit tutulduğunda (diğer değişkenlerin etkisi ortadan kaldırıldığında) x_j değişkeninde ortaya çıkan bir birimlik değişime 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, β_j ($j=1, 2, \dots, p$) parametreleri genellikle kısmi regresyon katsayıları olarak adlandırılmaktadır. β_0 'a ise kesim noktası veya sabit denir ve tüm x_j değişken değerleri sıfır olduğunda bağımlı değişkenin aldığı değeri gösterir, ε ise hata terimidir [18].

4. UYGULAMA

Eksik verilerin tamamlanması amacıyla 1805 numaralı AGİ ile 1806 numaralı AGİ arasındaki ilişki dört farklı durum için kurulmuş ve buna bağlı olarak akım tahmini yapılmaya çalışılmıştır (Tablo 3). Çalışma kapsamında kullanılan tüm yöntemlerde bu istasyonlara ait 1940-1956 yılları arasındaki toplam 204 verinin 142'si eğitim sürecinde geri kalan 62 veri ise sadece test aşamasında kullanılmıştır. Test aşamasında kullanılan veriler eğitim sürecine dâhil edilmemiştir.

Tablo 3. İki istasyon arasındaki ilişkisinin belirlenmesinde kullanılan model girdileri ve çıktıları
(The model inputs and outputs used to determine the relationship between of the two stations).

Durum	Girdi	Çıktı
1	Q_{1805}	Q_{1806}
2	Q_{1805}, Q_{1806-1}	Q_{1806}
3	$Q_{1805}, Q_{1805-1}, Q_{1806-1}$	Q_{1806}
4	$Q_{1805}, Q_{1805-1}, Q_{1806-1}, Q_{1806-2}$	Q_{1806}

Tablo 3'te Q_{1805} , 1805 numaralı istasyonunun o aya, Q_{1805-1} , 1805 numaralı istasyonunun bir önceki aya, Q_{1806} , 1806 numaralı istasyonunun o aya, Q_{1806-1} , 1806 numaralı istasyonunun bir önceki aya, Q_{1806-2} ise 1806 numaralı istasyonunun iki öncesindeki aya ait akım değerlerini temsil etmektedir.

YSA modeli geliştirilirken sigmoid transfer fonksiyonu kullanıldığından, verilerin ağa girilmeden önce normalize edilmesi gereklidir [19, 20]. Bunun için her bir değişken, Denklem 13 kullanılarak normalize edilmiştir.

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

Denklemdaki Q_{\min} ve Q_{\max} sırası ile her bir istasyonun minimum ve maksimum debisini, Q_i ölçülmüş, Q_{ni} ise normalize edilmiş debi değerlerini ifade etmektedir. Denklemdaki a ve b değerleri sırasıyla 0.6 ve 0.2 alınmıştır. Dört model için de normalizasyon işlemi yapılmış, elde edilen çıktılar, Denklem 13'ün tersi kullanılarak normalizasyon işlemi tersine çevrilmiştir.

Modellerin tahmin sonuçları ortalama karesel hata (OKH) ve belirlilik katsayısı (R^2) kriterlerine göre karşılaştırılmıştır. Bunlardan OKH değerlerinin sıfıra, R^2 değerinin ise bire yakın olması, tahmin edilen değerlerin kuvvetli biçimde doğruya yakınsadığını göstermektedir. Buna göre N toplam veri sayısı olmak üzere,

$$OKH = \frac{1}{N} \sum_{n=1}^N (Q_{\text{ölçüm}} - Q_{\text{tahmin}})^2 \quad (14)$$

$$R^2 = \frac{\sum_{i=1}^N (Q_{\text{ölçüm}} - Q_{\text{ort.}})^2 - \sum_{i=1}^N (Q_{\text{ölçüm}} - Q_{\text{tahmin.}})^2}{\sum_{i=1}^N (Q_{\text{ölçüm}} - Q_{\text{ort.}})^2} \quad (15)$$

şeklinde tanımlanırlar. Burada $Q_{\text{ölçüm}}$, gözlenen akım değerini, Q_{tahmin} ise model sonucunda elde edilen akım değerini ifade etmektedir. Dört farklı duruma ait hazırlanan modellerin eğitim ve test sonuçları için hesaplanan R^2 ve OKH değerleri Tablo 4 ve 5'te verilmiştir.

Tablo 4. İBGYSA ve GRYSA modelleri için eğitim ve test sonuçlarının R^2 ve OKH değerleri

Durum	Girdiler	İBGYSA				GRYSA			
		Eğitim		Test		Eğitim		Test	
		R^2	OKH	R^2	OKH	R^2	OKH	R^2	OKH
1	Q_{1805}	0.8015	659.78	0.8267	443.81	0.8093	636.60	0.8388	434.25
2	Q_{1805}, Q_{1806-1}	0.9193	268.33	0.9504	286.54	0.9313	231.34	0.9391	303.40
3	$Q_{1805}, Q_{1805-1}, Q_{1806-1}$	0.9170	275.81	0.9507	276.97	0.9565	147.31	0.9274	326.85
4	$Q_{1805}, Q_{1805-1}, Q_{1806-1}, Q_{1806-2}$	0.9226	257.59	0.9324	341.03	0.9738	88.55	0.9055	365.80

Tablo 5. RTYSA ve ÇDR modelleri için eğitim ve test sonuçlarının R² ve OKH değerleri

Durum	Girdiler	RTYSA				ÇDR			
		Eğitim		Test		Eğitim		Test	
		R ²	OKH	R ²	OKH	R ²	OKH	R ²	OKH
1	Q ₁₈₀₅ ,	0.8046	649.65	0.8318	435.99	0.7930	813.95	0.8434	424.87
2	Q ₁₈₀₅ , Q ₁₈₀₆ ⁻¹	0.8994	334.35	0.9392	301.88	0.8974	343.37	0.9391	303.59
3	Q ₁₈₀₅ , Q ₁₈₀₅ ⁻¹ , Q ₁₈₀₆ ⁻¹	0.9029	322.66	0.9482	292.19	0.8990	340.08	0.9428	300.41
4	Q ₁₈₀₅ , Q ₁₈₀₅ ⁻¹ , Q ₁₈₀₆ ⁻¹ , Q ₁₈₀₆ ⁻²	0.9035	320.86	0.9474	286.68	0.9013	328.65	0.9395	289.64

Tüm modellere ait en başarılı sonuçlar Tablo 6'da verilmiştir. Tabloda, Durum 3 için İBGYSA yöntemine ait OKH ve R² değerlerinin diğer tüm modellere göre daha iyi sonuç verdiği, İBGYSA, RTYSA ve ÇDR yöntemlerinin en iyi sonuçları Durum 3'te verdikleri, sadece GRYSA yönteminin en başarılı sonucu Durum 2'de verdiği görülmektedir. Böylece Durum 2'de model girdisi olarak ele alınmayan Q₁₈₀₅⁻¹' in akım

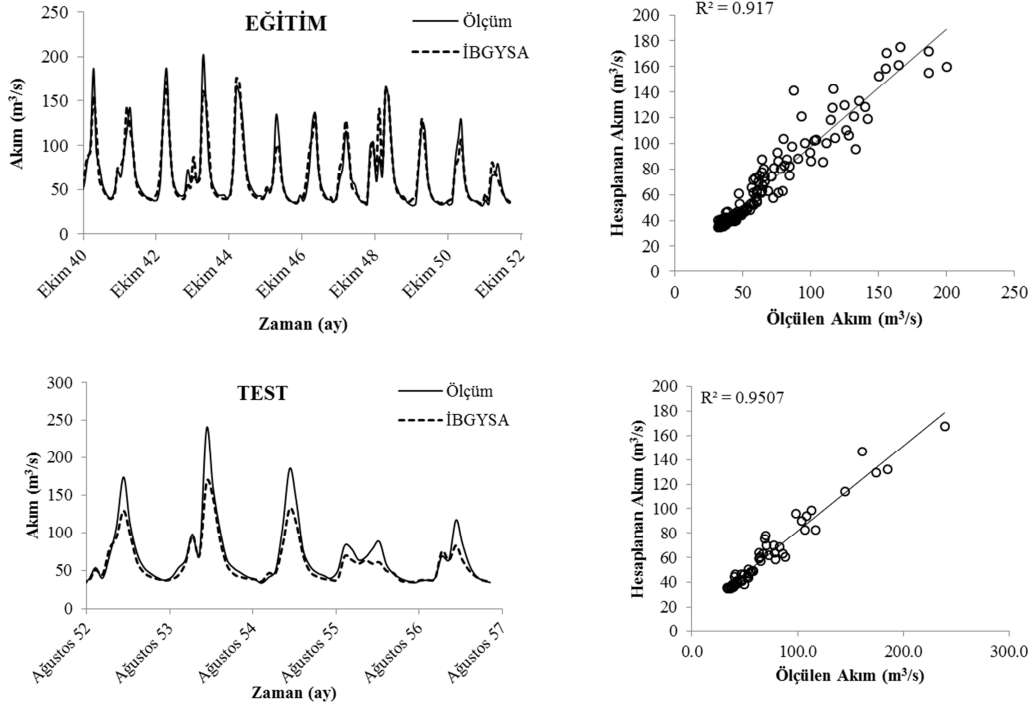
tahmininde önemli rol oynadığı görülmektedir. Tablo 6'da İBGYSA yanında verilen (3,3,1) sırasıyla girdi sayısını, ara katman sayısını ve çıktı sayısını, RTYSA yanında bulunan (2,4) sırasıyla, dağılım (spread) parametresi ile nöron sayısını, GRYSA modelinin yanındaki (0.044) ise düzeltme parametresini temsil etmektedir. Bu ifadeler test süreci için en düşük OKH değerinin elde edilmesi amacıyla deneme yanılma yoluyla belirlenmiştir.

Tablo 6. Tüm modellere ait test sonuçlarının R² ve OKH değerleri

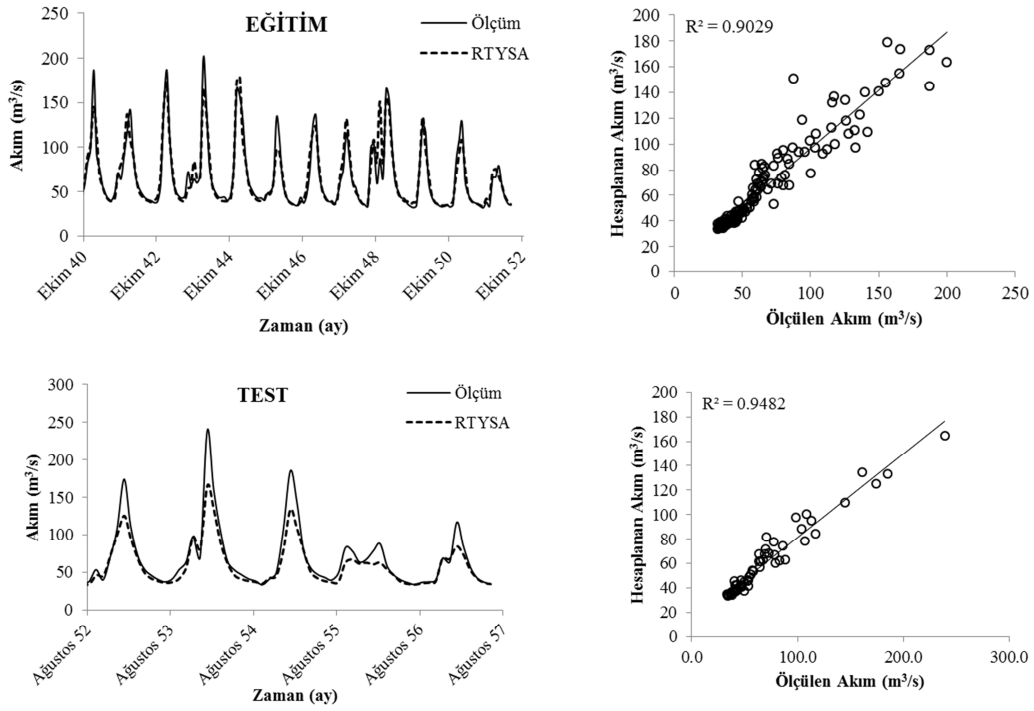
Model	Durum	R ²	OKH
İBGYSA(3,3,1)	3	0.9507	276.97
RTYSA(2,4)	3	0.9482	292.19
ÇDR	3	0.9428	300.41
GRYSA(0.044)	2	0.9391	303.40

Tablo 6'da verilen sonuçlara ait eğitim ve test süreçlerinde tahmin edilen akımlar ile gözlenen akımların zamana bağlı değişimleri ve saçılma

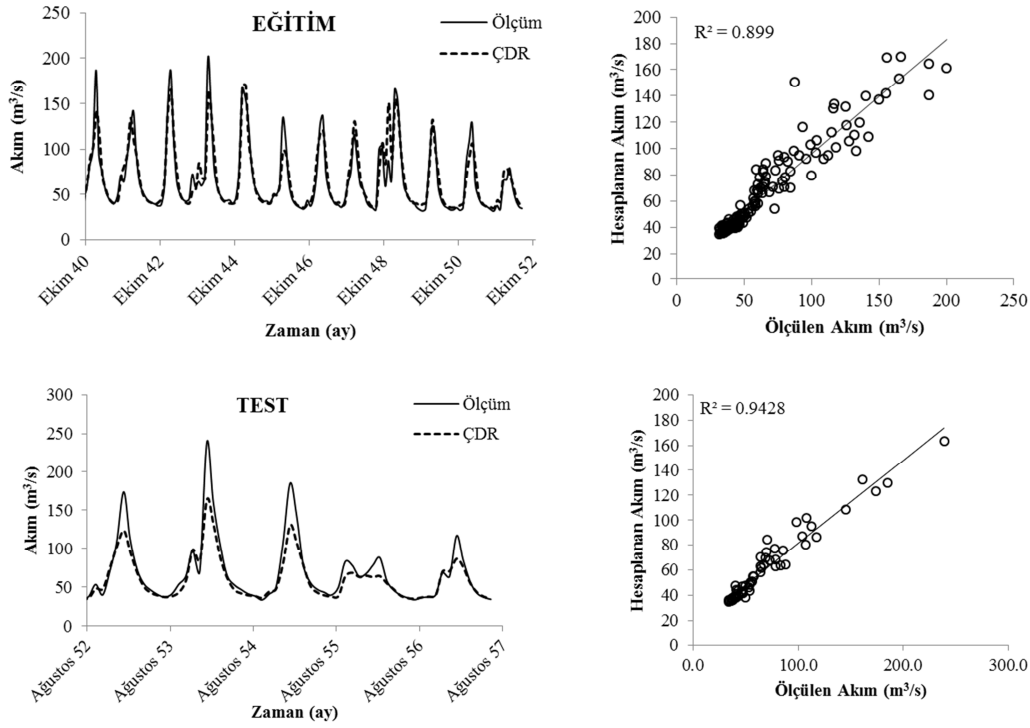
diyagramları Şekil 3, 4, 5 ve 6'da gösterilmiştir. Şekiller incelendiğinde GRYSA yönteminin eğitim sürecinde en yüksek belirlilik katsayısını verdiği görülse de, kriter olarak ele alınan test sürecinde İBGYSA'nın en iyi sonucu verdiği görülmektedir.



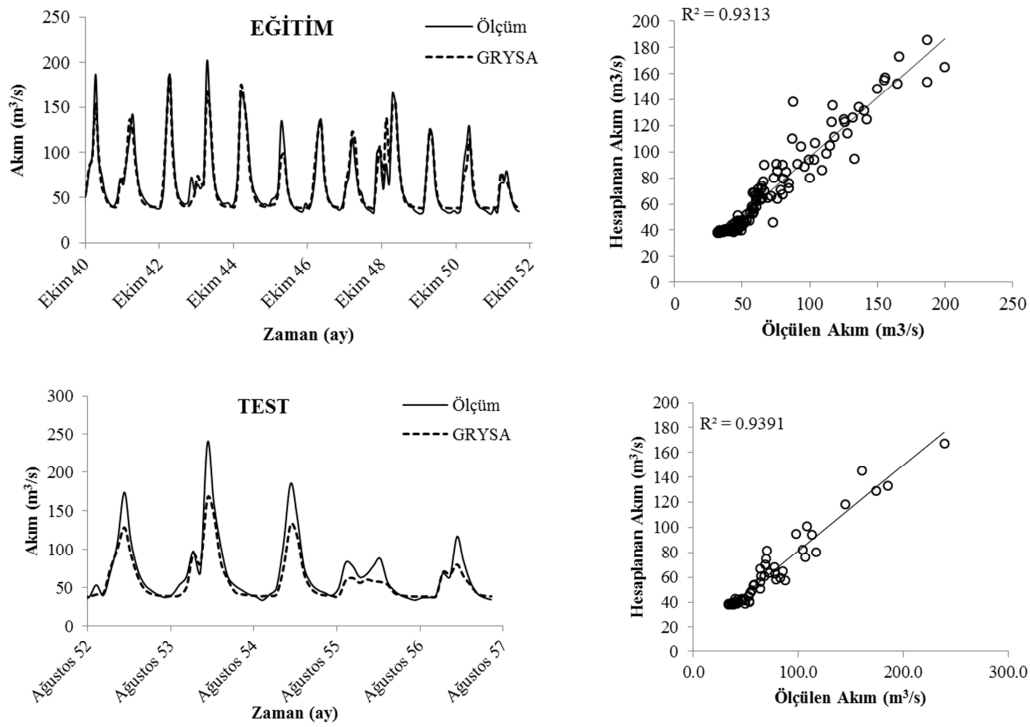
Şekil 3. Eğitim ve test dönemine ait Durum 3 için İBGYSYA modeli ile tahmin edilen ve gözlenen akım değerleri



Şekil 4. Eğitim ve test dönemine ait Durum 3 için RTYSA modeli ile tahmin edilen ve gözlenen akım değerleri

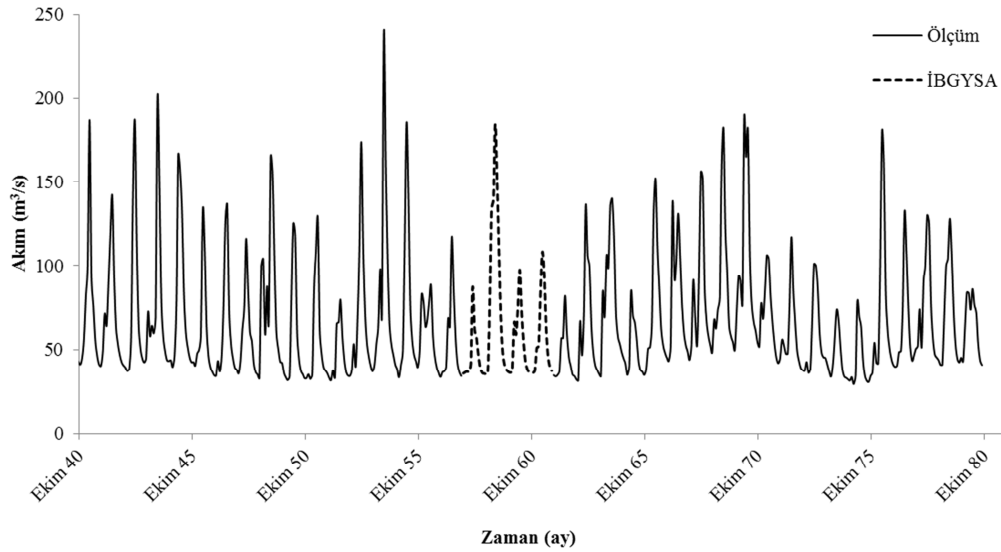


Şekil 5. Eğitim ve test dönemine ait Durum 3 için ÇDR modeli ile tahmin edilen ve gözlenen akım değerleri



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

İBGYSYA ile tahmin edilen akımlar, öncesi ve sonrasında ölçülmüş aylık ortalama akımlar ile birlikte Şekil 7’de görülmektedir.



Şekil 7. 1806 istasyonuna ait tamamlanmış akım değerleri

4. SONUÇLAR VE ÖNERİLER

Seyhan Havzasında bulunan 1806 numaralı AGİ'ye ait eksik aylık ortalama akım verileri, 1805 numaralı AGİ'nin aylık ortalama akım verileri kullanılarak, İleri Beslemeli Geri Yayınımlı Sinir Ağı (İBGYSA), Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA), Radyal Tabanlı Yapay Sinir Ağı (RTYSA) ve Çoklu Doğrusal Regresyon (ÇDR) yöntemleri kullanılarak tahmin edilmiştir. 1805 ve 1806 numaralı AGİ verileri kullanılarak dört farklı giriş şartı oluşturulmuş ve 1957-1960 yılları arasındaki 48 akım verisi tahmin edilmiştir. 1940-1956 yılları arasındaki akım verilerinin %70'i eğitim %30'u ise test sürecinde kullanılmıştır. Karşılaştırma kriteri olarak ortalama karesel hata (OKH) ve belirlilik katsayıları (R^2) göz önünde bulundurulduğunda test sürecinde başarı sıralaması İBGYSA, RTYSA, ÇDR ve GRYSA şeklindedir. Kullanılan modellerin R^2 ve OKH değerleri incelendiğinde ise modeller arasındaki farkın az olduğu anlaşılmıştır. Ayrıca İBGYSA, RTYSA ve ÇDR yöntemleri en uygun sonucu Q_{1805} , Q_{1805-1} ve Q_{1806-1} girdi değerleri kullanarak oluşturulan Durum 3'te verdiği görülmüştür. Bundan dolayı akım verilerinin bir önceki ayın akım verileri ile de ilişkili olduğu anlaşılmıştır. Çalışma sonunda, uygun ve yeterli girdi parametreleri ile yapay sinir ağı yöntemlerinin eksik akım verilerinin tahmin edilmesi amacıyla kurulacak modellemelerde kullanılabileceği sonucuna varılmıştır.

KAYNAKLAR

[1] Zealand, C. M., Burn, D. H. ve Simonovic, S. P. "Short term streamflow forecasting using artificial neural networks", *Journal of Hydrology*, 214: 32-48, (1999).

[2] Kişi, Ö. "River Flow Modeling Using Artificial Neural Networks". *J Hydrol Eng*, 9: 60-63, (2004).

[3] Coulibaly, P. ve Evora, N. D. "Comparison of neural network methods for infilling missing daily weather records". *Journal of Hydrology*, 341: 27-41, (2007).

[4] Rajurkar, M. P., Kothiyari, U. C. ve Chaube, U. C. "Modeling of the daily rainfall-runoff relationship with artificial neural network". *Journal of Hydrology*, 285, 1-4, 96-113, (2004).

[5] Yurdusev, M. A., Acı, M., Turan, M. E. ve İçağa, Y. "Akarçay Nehri Aylık Akımlarının Yapay Sinir Ağları ile Tahmini". *C.B.Ü. Fen Bilimleri Dergisi*, 4.1, 2008, 73-88, (2008).

[6] Cigizoglu, H. K. "Estimation and forecasting of daily suspended sediment data by multi-layer perceptrons". *Advances in Water Resources*, 27: 185-195, (2004).

[7] Kişi, Ö. "Daily River Flow Forecasting Using Artificial Neural Networks and Auto-Regressive Models". *Turkish J. Eng. Env. Sci.*, 29: 9-20, (2005).

[8] Küçük, M. ve Ağirialioğlu, N. "Wavelet Regression Technique for Streamflow Prediction". *Journal of Applied Statistics*, 33: 943-960, (2006).

[9] Shiri, J. ve Kişi, Ö. "Comparison of genetic programming with neuro-fuzzy systems for predicting short-term water table depth fluctuations". *Computers & Geosciences*, 37: 1692-1701, (2011).

[10] Kisi, O., Shiri, J. ve Tombul, M. "Modeling rainfall-runoff process using soft computing techniques". *Computers & Geosciences*, 51: 108-117, (2013).

- [11] Gümüş, V., Kavşut, M. E. ve Yenigün, K. "Yağış-Akış İlişkisinin Modellenmesinde YSA Kullanımının Değerlendirilmesi: Orta Fırat Havzası Uygulaması". **Bilimde Modern Yöntemler Sempozyumu**, Diyarbakır, 14-16 Ekim, (2010).
- [12] EİEİ "Su Akımları Yıllığı", (2005).
- [13] Lippmann, R. P. "An introduction to computing with neural nets". **ACM SIGARCH Computer Architecture News**, 16, 7-25, (1988).
- [14] Marquardt, D. W. "An Algorithm for Least-Squares Estimation of Nonlinear Parameters". **Journal of the Society for Industrial and Applied Mathematics**, 11: 431-441, (1963).
- [15] Kişi, Ö. "Yapay Sinir Ağları ve Regresyon Teknikleri ile Filyos Çayı Akımlarının Tahmini". **IV.Hidroloji Kongresi**, İstanbul, (2004).
- [16] Broomhead, D. S. ve Lowe, D. "Multivariable Functional Interpolation and Adaptive Networks". **Complex Systems**, 2: 321-355, (1988).
- [17] Specht, D. F. "A general regression neural network.". **IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council**, 2: 568-576, (1991).
- [18] Partal, R. "Uygulamalı Çok Değişkenli İstatistiksel Yöntemlere Giriş - 1", 404, (2003).
- [19] Van Ooyen, A. ve Nienhuis, B. "Improving the convergence of the back-propagation algorithm". **Neural Networks**, 5: 465-471, (1992).
- [20] Cobaner, M., Seckin, G. ve Kisi, O. "Initial assessment of bridge backwater using an artificial neural network approach". **Canadian Journal of Civil Engineering**, 35: 500-510, (2008).