



ISSN:1306-3111

e-Journal of New World Sciences Academy
2011, Volume: 6, Number: 4, Article Number: 1A0259

ENGINEERING SCIENCES

Received: May 2011

Accepted: October 2011

Series : 1A

ISSN : 1308-7231

© 2010 www.newwsa.com

Umut Okkan

Zafer Ali Serbeş

Balikesir University

Ege University

umutokkan@balikesir.edu.tr

Balikesir-Turkey

KEBAN BARAJI'NA GİREN GÜNLÜK AKIMLARIN YAPAY SİNİR AĞLARI VE STOKASTİK YÖNTEMLER KULLANILARAK MODELLENMESİ

ÖZET

Baraj haznelerinin tasarımı ve işletilmesi aşamalarında, güvenilir akım tahminlerinin ve akım modelleme çalışmalarının yapılması büyük önem taşımaktadır. Sunulan çalışmada, Levenberg-Marquardt optimizasyon algoritması tabanlı bir yapay sinir ağı (LM-YSA) modeli geliştirilerek, Keban Barajı'nı besleyen, Murat Nehri, Munzur Çayı ve Peri Suyu günlük akımlarına uygulanmıştır. Hazırlanan LM-YSA modelleri içsel bağımlı stokastik AR(p) model yapılarıyla da karşılaştırılmıştır. Uzun dönemde gözlenmiş ve modellenmiş akımların istatistikleri karşılaştırıldığında; kurulan tüm modellerin yaklaşık sonuçlar verdiği ancak LM-YSA modelinin Keban akımlarını istatistiksel açıdan daha iyi temsil ettiği görülmüştür.

Anahtar Kelimeler: Keban Barajı, Günlük Akımlar, Yapay Sinir Ağları, Levenberg-Marquardt Optimizasyon Algoritması, AR(p) Modelleri

MODELING OF DAILY INFLOWS OF KEBAN DAM USING ARTIFICIAL NEURAL NETWORKS AND STOCHASTIC METHODS

ABSTRACT

It is very important to make reliable runoff predictions and runoff modeling studies when planning and operating of dam reservoirs. In the study presented, the Levenberg-Marquardt optimization algorithm based artificial neural network (LM-ANN) model was improved and applied to the daily flow observations of Murat, Munzur and Peri Rivers which feed the Keban Dam. The LM-ANN models were also compared with autoregressive AR(p) model structures. When the statistics of the long term recorded and modeled flow values are compared, it can be seen that all model results are approximately similar but the LM-ANN that has been developed, is more successfully represents the daily flow values of the Keban Dam.

Keywords: Keban Dam, Daily Flows, Artificial Neural Networks, Levenberg-Marquardt Optimization Algorithm, AR(p) Models

1. GİRİŞ (INTRODUCTION)

Baraj haznelerinin kuraklık veya taşkın dönemlerindeki durumlarının tahmini ve geleceğe dönük senaryoların oluşturulması çalışmalarında barajı besleyen akarsu akımlarının modellenmesi büyük önem taşımaktadır.

Bu kapsamda, havzadaki süreklilik denklemlerini esas alarak geliştirilmiş kavramsal ve fiziksel tabanlı modeller bulunmaktadır. Ancak bu tür modeller parametre sayısı ve uygulanabilirliği açısından bazen belirsizlikler taşımaktadır [1].

Bu dezavantajlarından dolayı fiziksel tabanlı ve kavramsal modeller, yerini olayın fiziksel yönünün dikkate alınmadığı kara (kapalı) kutu modellerine bırakmıştır.

Kapalı kutu modelleri genel olarak, klasik stokastik içsel bağımlı model yapılarını, regresyon analizlerini, eğri uyurma yaklaşımlarını ve son zamanlarda önemini giderek arttıran yapay sinir ağlarını (YSA) esas almaktadır. Bu modeller incelendiğinde, YSA yaklaşımlarının klasik istatistiksel yöntemlere nazaran daha iyi sonuçlar verdiği göze çarpmaktadır.

Bu kapsamda yapılan bazı çalışmalar şunlardır. Campolo vd. [2] ile Hsu vd. [3] yağış-akış ilişkisini yapay sinir ağları ile modellemiştir. Minns ve Hall [4] ileri beslemeli geriye yayılım algoritması kullanarak sentetik olarak üretilmiş verilerden akım modelleme çalışmaları yapmıştır. Alp ve Cıgızoğlu farklı yapay sinir ağı algoritmalarını, regresyon analizlerini ve içsel bağımlı stokastik (AR) model yapılarını kullanarak akım modelleri hazırlamış ve yapay sinir ağı (YSA) model performanslarının regresyon ve AR sonuçlarına göre daha başarılı olduğunu göstermişlerdir [5].

Akım tahmin performansları farklı ileri beslemeli geriye yayılım algoritmaları için de yapılarak karşılaştırılmıştır. Kisi (2007) ve Okkan(2011)farklı algoritmalar içinde Levenberg-Marquardt algoritması tabanlı YSA'yı diğer algoritmalara kıyasla daha başarılı bulmuşlardır [6 ve 7]. Hızlı yakınsaması, hassas sonuçlar vermesi ve kalibre edilebilir tek bir parametre içermesi bakımından Levenberg-Marquardt algoritması oldukça başarılı bulunmuştur. Bunların yanı sıra ileri beslemeli geriye yayımlı algoritmalara alternatif olarak geliştirilmiş olan Genelleştirilmiş Regresyon Sinir Ağı [8 ve 9] ve Radyal Tabanlı Sinir Ağı gibi algoritmaların da akım tahmin modeli uygulamalarına rastlanmaktadır [10 ve 11].

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Sunulan çalışmada, Keban Baraj'ını besleyen akarsulara ait günlük akımların tahmin edilmesi için kullanılacak stokastik modeller ve YSA modelleri hazırlanmıştır. Stokastik model olarak otoregresif (AR(p)) içsel bağımlı modeller tercih edilmiştir. YSA modelleri için ise Levenberg-Marquardt optimizasyon algoritmasını kullanan ileri beslemeli bir YSA modeli (LMYSA) hazırlanmıştır. Önceki çalışmalar incelendiğinde, Keban Baraj'ını besleyen aylık bazda akımlar 1., 2. ve 3. mertebeden olmak üzere 3 farklı AR(p) yapısında modellenmiştir [12 ve 14]. Bu çalışmada ise önceki çalışmalardan farklı olarak günlük akım değerleri kullanılmış, otoregresiflik mertebesi en fazla 2 olmak üzere modeller kurulmuştur. Belirlenen otoregresiflik mertebesi esas alınarak aynı girdiler ile söz konusu akım gözlem istasyonlarına ait veriler ile YSA modelleri oluşturulmuş, model performansları istatistiksel kriterler kullanılarak karşılaştırılmıştır.

3. ANAKONU (SUBJECT)

3.1. İçsel Bağımlı Modeller (Autoregressive Models)

Çalışmada, 01.10.1991-30.09.2000 tarihleri arasında Elektrik İşleri Etüt İdaresi (E.İ.E) tarafından gözlenmiş, her bir akım gözlem istasyonuna ait 3289'ar adet günlük akım verisi kullanılmıştır. AR modellerinin hazırlanmasından önce çarpık dağılımlı olan serilere Box-Cox dönüşümü uygulanarak seriler simetrikleştirilmiştir.

$$Q_i^* = \frac{Q_i^\lambda}{\lambda} \quad \lambda \neq 0 \quad (1)$$

Burada, Q_i^* çarpıklığı giderilmiş yeni diziyi; Q_i gözlenen akım dizisini; λ Box-Cox dönüşüm parametresini simgelemektedir. Çalışmada Q_i^* serisine ait çarpıklık değerini 0 yapan Box-Cox dönüşüm parametreleri (λ), Murat (2102), Munzur (2133) ve Perisu (2166) için sırasıyla -0.25, -0.64 ve 0.03 olarak hesaplanmıştır. Daha sonra dönüşüme uğramış verilerden seri ortalamaları çıkarılıp, seri standart sapmalarına bölünerek, ortalaması 0, standart sapması 1 olan boyutsuz z_i serileri elde edilmiştir.

Boyutsuz z_i serileri elde edildikten sonra AR model yapısı aşağıdaki gibi ifade edilebilmektedir [15 ve 16].

$$z_i = \sum_{j=1}^p \alpha_j z_{i-j} + \sigma_\epsilon \xi_i \quad (2)$$

Denklemden p , modelin mertebesini; $\alpha_1, \dots, \alpha_p$ modele ait otoregresif parametreleri; z_{i-j} , j zaman önceki boyutsuz akımı; σ_ϵ kalıntı (noise) bileşeninin standart sapmasını ve ξ_i rastgele bağımsız standart normal sayıları simgelemektedir.

Modele ait otoregresif parametrelerin moment tahminleri Yule-Walker eşitliklerinden hesaplanabilmektedir [15 ve 16].

z_i serisini temsil eden AR(p) modelinin mertebesi (p) kısmi otokorelasyon katsayıları ($\hat{\phi}_{kk}$) incelenerek belirlenebilmektedir. Bu katsayıların moment tahminleri aşağıdaki gibi hesaplanabilmektedir [15 ve 17].

$$\hat{\phi}_{p+1,j} = \hat{\phi}_{pj} - \hat{\phi}_{p+1,p+1} \hat{\phi}_{p,p-j+1} ; j = 1, 2, \dots, p \quad (3)$$

$$\hat{\phi}_{p+1,p+1} = \frac{r_{p+1} - \sum_{j=1}^p \hat{\phi}_{pj} r_{p+1-j}}{1 - \sum_{j=1}^p \hat{\phi}_{pj} r_j} \quad (4)$$

Kısmi otokorelasyon katsayılarının örneklem varyansı, $k \geq p+1$ için yaklaşık olarak şöyledir [15]:

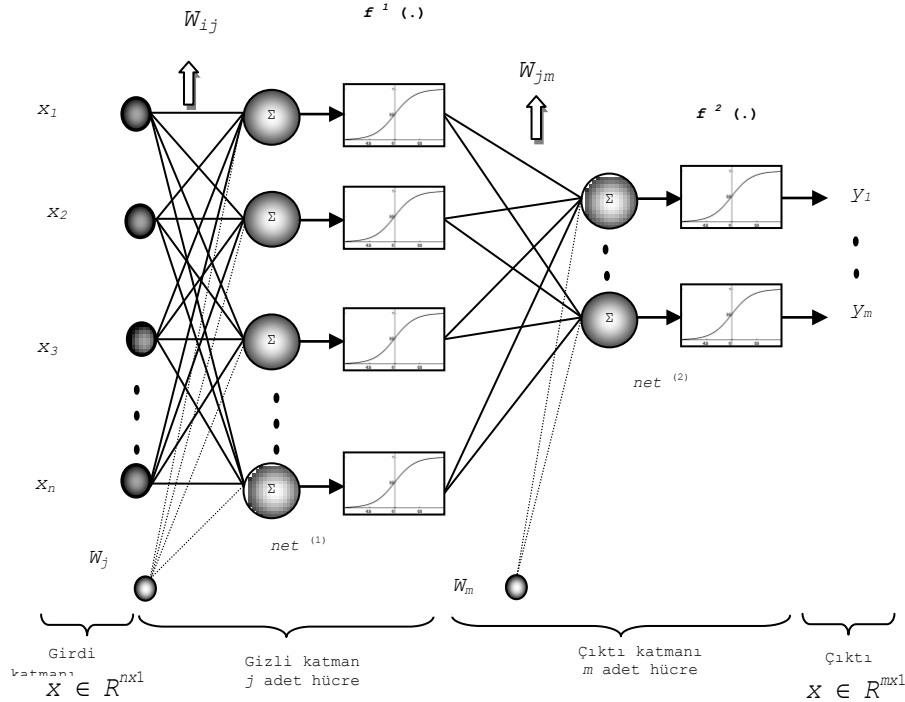
$$\sigma_{\hat{\phi}_{kk}}^2 = \text{var}(\hat{\phi}_{kk}) = 1/N ; k \geq p+1 \quad (5)$$

k zaman farkına göre $\hat{\phi}_{kk}$ değerlerinin grafiği çizilip, $\pm 2\sigma_{\hat{\phi}_{kk}}$ kaba güven limitlerini önemli ölçüde aşan $\hat{\phi}_{kk}$ değerleri p otoregresiflik düzeyini gösterir.

3.2. LM-YSA Modelleri (LM-ANN Models)

Sinir sisteminin çalışma prensibinden esinlenerek geliştirilen yapay sinir ağları günümüzden en çok kullanılan matematiksel araçlardan biridir [6 ve 11]. Yapay sinir ağları biyolojik sinir sistemlerinde olduğu gibi hücrelerin bir araya gelmesiyle oluşturulmakta ve katmanlar halinde tasarlanmaktadır. Söz konusu modellerin giriş katmanı, ara (gizli) çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Şekil 1'de görüldüğü üzere bir YSA modelinin yapısı, girdiler (x), ağırlıklar (W), net fonksiyonu (net), aktivasyon

fonksiyonu (f) ve çıktılar (y) olmak üzere 5 temel elemandan oluşmaktadır.



Şekil 1. Çok katmanlı bir YSA modelinin yapısı
(Figure 1. Multi-layer structure of an ANN model)

Modelde kullanılacak girdiler ve çıktılar problemin niteliğine göre değişkenlik göstermektedir. Girdilerin sistem içindeki etkinlikleri ise ağırlıklarla sağlanmakta, ağırlık değerlerinin doğru belirlenmesi modelin performansını etkilemektedir. Girdilerin bu hücre üzerindeki etkileri ise ağırlıklı girdilerin toplamı olarak bulunan net fonksiyonu şeklinde ifade edilmektedir. Hücrelere gelen bu net girdiler bir aktivasyon fonksiyonu (f) yardımıyla çıktılara dönüştürülür. Farklı türde aktivasyon fonksiyonları bulunmakla birlikte genellikle *sigmoid* fonksiyonu kullanılmaktadır [6, 7 ve 18].

Yapay sinir ağlarının yapısı kadar ağırlık kurulması, yani ağırlık eğitiminde kullanılacak yöntem de çok önemli olup, bu aşamada ağırlık girdilere karşılık üretilmesi gereken çıktıları öğrenmesi amaçlanmaktadır. Hazırlanan çalışmada ele alınan YSA modeli ileri beslemeli geri yayımlı türden olup işleyişi ileriye doğru ve geriye doğru hesaplama olmak üzere iki aşamada gerçekleştirilmektedir.

İleri hesaplama aşamasına, girdi katmanındaki girdilerin ağırlık ile başlanması ile başlanmaktadır. Gizli katmandaki her hücre girdi katmanından gelen girdileri ağırlıklar ile almakta ve gizli katmandaki hücrelere gelen net girdiler hesaplanmaktadır. Bu net girdi değerlerinin belirlenen bir aktivasyon fonksiyonundan geçirilmesiyle gizli katman elemanlarının çıktıları hesaplanmaktadır. Bu işlem tüm gizli katman ve çıktı katman elemanları için tekrarlanmakta, çıktı katmanının çıktıları ($y \in R^{m \times 1}$) belirlendiğinde ileri hesaplama aşaması tamamlanmaktadır (Denklem 6).

$$y_m = f^{(2)} \left\{ \sum_{j=1}^m \left[f^{(1)} \left(\sum_{i=1}^n x_i W_{ij} + W_j \right) \right] W_{jm} + W_m \right\} \quad (6)$$

Burada; x_i ağırlıklarını, W_{ij} girdi katmanı ile gizli katman arasındaki ağırlıkları, W_j girdi katmanı ile gizli katman arasındaki sabit (bias) terimleri, $f^{(1)}$ girdi katmanı ile gizli katman arasındaki aktivasyon fonksiyonunu, $f^{(2)}$ gizli katman ile çıktı katmanı arasındaki aktivasyon fonksiyonunu, j gizli katmana ait hücre sayısını, n girdi katmanındaki hücre sayısını, m çıktı katmanındaki hücre sayısını, W_{jm} çıktı katmanı ile gizli katman arasındaki ağırlıkları, W_m çıktı katmanı ile gizli katman arasındaki sabit (bias) terimleri göstermektedir. Çalışmada aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır.

Geriye doğru hesaplama aşamasında ise ağırlık çıktı değerleri beklenen çıktı değerleri ile karşılaştırılmaktadır. Çıktı (y_p) ile beklenen değerler (b_p) arasındaki fark hata (e_p) olup geriye yayılım aşamasında bu hatanın azaltılması amaçlanmaktadır. Böylece başlangıçta rastgele atanan ağırlıklar ve sabitleri, hata istenen sınırlara düşürülünceye kadar iteratif olarak güncellenmektedir. Bu işlem yapay sinir ağı modellerinde belli bir T eğitim seti için en küçük kareler yaklaşımına dayalı performans fonksiyonu ile gerçekleştirilebilmektedir (Denklem 7).

$$E = \frac{1}{2} \sum_{p=1}^P (e_p)^2, \quad (P = mT) \quad (7)$$

Burada, E performans fonksiyonunu, T eğitim aşamasında değerlendirilecek örnekleme, m çıktı katmanındaki hücre sayısını, e_p hataları ($b_p - y_p$) simgelemektedir. Çalışmada, daha önce de belirtildiği üzere E değerini minimize edecek algoritma olarak Levenberg-Marquardt algoritması kullanılmıştır.

Levenberg-Marquardt algoritması Newton algoritmasının bir versiyonu olarak geliştirilmiş ve YSA ile entegre edilerek ileri beslemeli geriye yayılım algoritmaları arasında kullanılmaya başlanmıştır [19].

Newton algoritmasında, performans fonksiyonunu minimize eden optimum ağırlıklar Denklem 8 yardımıyla bulunabilmektedir.

$$W(k+1) = W(k) - H_k^{-1} g_k \quad (8)$$

ikinci derece türevlerinden oluşan bir matrisi ($\nabla^2 E|_{W=W(k)}$); g_k , ise ağırlık gradyeni olup performans fonksiyonun ağırlıklara göre birinci derece türevlerinden oluşan bir matrisi ($\nabla E|_{W=W(k)}$) simgelemektedir. Ağırlık gradyeni $g = \partial E / \partial W$ Denklem 9'daki formuyla ifade edilebilmektedir.

$$g = J^T e \quad (9)$$

Burada J , Jakobien matrisi olarak adlandırılmakta ve ağırlıklarının ağırlıklara göre birinci türevlerinden oluşmaktadır. Jakobien ifadesi kullanılarak, Hessian matrisi Denklem 10'daki formuyla tekrar düzenlenebilmektedir.

$$\nabla^2 E = J^T J + S, \quad \left(S = \sum_{p=1}^P e_p \nabla^2 e_p \right) \quad (10)$$

Performans fonksiyonu minimize edildiğinde, Denklem 10'da S ifadesinin sayısal değeri giderek küçülmekte ve Hessian matrisinin yaklaşık değeri Denklem 11'deki gibi belirlenebilmektedir.

$$H \cong J^T J \quad (11)$$

Son olarak Newton ifadesi aşağıdaki gibi düzenlenebilmekte ve belli bir k iterasyon adımında ağırlıklar güncellenmektedir (Denklem 12).

$$W(k+1) = W(k) - [H_k]^{-1} J_k^T e_k, \quad (H_k = J_k^T J_k) \quad (12)$$

Ancak Denklem 12'de belirtilen iteratif çözüm Hessian matrisinin tersine ihtiyaç duymakta olup, Hessian matrisi ileri beslemeli yapay sinir ağı modelleri için hesaplanması oldukça zor bir matristir.

Bu problem, ikinci derece türev işlemlerinden oluşan Hessian matrisinin yaklaşık bir şeklini kullanan Levenberg-Marquardt algoritması ile çözülebilmektedir.

Levenberg - Marquardt algoritması ile Hessian matrisinin yaklaşık değeri Denklem 13 yardımıyla bulunabilmektedir.

$$H \cong J^T J + \mu I \quad (13)$$

Burada μ , Marquardt parametresini, I ise birim matrisi simgelemektedir.

Denklemler düzenlendiğinde, belli bir k iterasyon adımında ağırlıklarındaki değişim belirlenmekte (Denklem 14) ve güncellenmektedir (Denklem 15).

$$\Delta W(k) = -[J_k^T J_k + \mu_k I]^{-1} J_k^T e_k \quad (14)$$

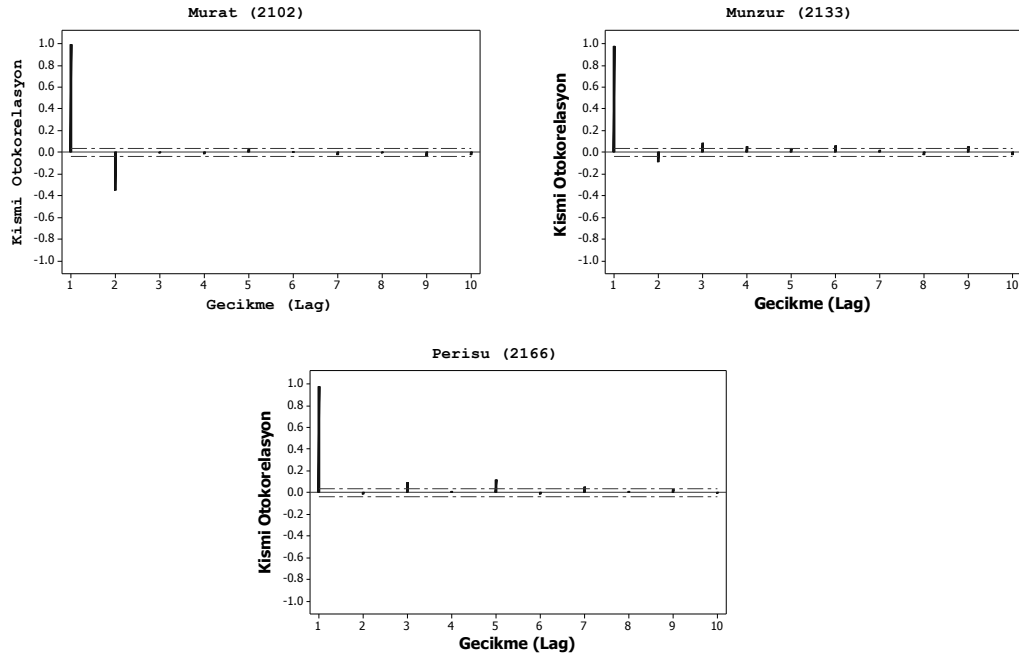
$$W(k+1) = W(k) + \Delta W(k) \quad (15)$$

Benzer bir şekilde, belli bir k iterasyon adımında Marquardt parametresi μ , E azaldığında belirli bir bozulma oranı (β ; $0 < \beta < 1$) ile çarpılmakta, E yeni bir adımda arttığında ise β değerine bölünmektedir. Böylece ağırlıkların performansı her adımda iyileştirilmektedir [20].

4. UYGULAMA (APPLICATION)

4.1. Otoregresif (AR) Modellerin Hazırlanması (Preparation of Autoregressive Models)

Dönüşüm uygulanmış ve ardından boyutsuz hale getirilmiş, sözkonusu istasyonlarda ölçümü yapılan günlük verilere ait kısmi otokorelasyon katsayıları incelenmiş (Şekil 2), potansiyel model yapıları belirlenmiştir. AR(p) modellerinin YSA modelleri ile karşılaştırılabilmesi için ilgili istasyona ait türetilmiş serilerin de eğitim ve test dönemlerine ait kısımları ayrı ayrı karşılaştırılmıştır. AR(p) modellerine ait parametreler doğrusal denklem takımı yardımıyla hesaplanmış olup Tablo 1'de verilmiştir.



Şekil 2. Boyutsuz hale getirilmiş günlük akımların kısmi otokorelogramları
(Figure 2. Partial autocorrelations of daily flows was made dimensionless)

Tablo 1. Otoregresif model parametreleri
(Table 1. Autoregressive model parameters)

İstasyon	AR(p)	α_1	α_2	σ_ε^2
Murat	AR(2)	1.3551	-0.3811	0.032
Munzur	AR(1)	0.9716	-	0.056
Perisu	AR(1)	0.9598	-	0.079

4.2. LM-YSA Modellerinin Hazırlanması (Preparation of LM-ANN Models)

Otoregresif model oluşturulma aşamasında Murat, Munzur ve Perisu istasyonları için en iyi model AR(p) yapılarının sırasıyla AR(2), AR(1) ve AR(1) olduğu belirlenmiş, ilgili istasyonlara ait AR(p) model girdileri YSA modelinin de girdileri olarak kullanılmıştır.

YSA modellerinin genelleme yeteneğinin sınanması açısından, modeller veri setinin %80'i ile eğitilmiş, geri kalan %20'si ile test edilmiştir. İlk olarak LM-YSA modeli MATLAB ortamında programlanmıştır. Modelde aktivasyon fonksiyonu olarak ($f^{(1)} - f^{(2)}$) sigmoid fonksiyonu seçilmiştir. Girdi ve çıktı değerleri, fonksiyonun özelliğinden dolayı $(x - x_{\min}) / (x_{\max} - x_{\min})$ bağıntısıyla 0-1 tanım aralığında ölçeklendirilerek ağa sunulmuştur. Eğitim tamamlandıktan sonra ölçeklendirilmiş çıktılar ters işlem ile model oluşturma aşamasındaki hallerine dönüştürülmüştür. Ağın eğitiminde, gizli katmanda kullanılacak hücre sayısı, başlangıç Marquardt parametresi (μ), bozulma oranı (β) deneme-yanılma yoluyla, Denklem 7'de belirtilen performans fonksiyonu E minimum olacak şekilde belirlenmiştir.

Çalışmada ayrıca, modellerin genelleme yeteneğini kaybetmemesi, dolayısıyla aşırı öğrenme durumundan test dönemi performanslarının bozulmaması için eğitim aşamasında optimum sayıda iterasyon

yaptırılması yoluna başvurulmuştur. Bu kapsamda üç istasyon için de 20 adet iterasyon yeterli görülmüştür.

Hazırlanan tüm modellerde E ölçütünün yanında, istatistiksel bir uyum iyiliği ölçütü olan determinasyon katsayıları (R^2) ile hata kareler ortalaması (HKO) ve hata kareler ortalamasının karekökü (HKOK) değerleri de incelenmiştir (Tablo 2). Modellerin eğitim ve test dönemlerine ait uzun dönem istatistikleri ise Tablo 3'te verilmiştir.

Tablo 2. Modellerin eğitim ve test dönemlerine ait performans kriterleri
(Table 2. Performance criteria of the models for the testing and training periods)

İstasyon	Model	R^2		HKO m^6/sn^2		HKOK m^3/sn	
		Eğitim	Test	Eğitim	Test	Eğitim	Test
Murat	AR(2)	0.9472	0.9734	7841.83	1513.23	88.55	38.90
	LM-YSA	0.9696	0.9765	4499.56	1333.32	67.08	36.52
Munzur	AR(1)	0.9459	0.9372	368.30	140.89	19.19	11.87
	LM-YSA	0.9485	0.9364	352.19	143.86	18.77	11.99
Perisu	AR(1)	0.9206	0.9323	1062.48	319.12	32.60	17.86
	LM-YSA	0.9289	0.9321	956.66	324.87	30.93	18.02

Modellerin performansları incelendiğinde AR(p) modelleri ile LM-YSA modellerinin birbirine yakın sonuçlar verdiği gözlenmiştir. Murat istasyonu için hazırlanan LM-YSA modelinin eğitim ve test dönemi istatistiklerinin AR(2) modelinkinden daha iyi olduğu görülmektedir. Munzur ve Perisu için ise AR(1) modellerinin performanslarının daha iyi olduğu gözlemlenmiştir.

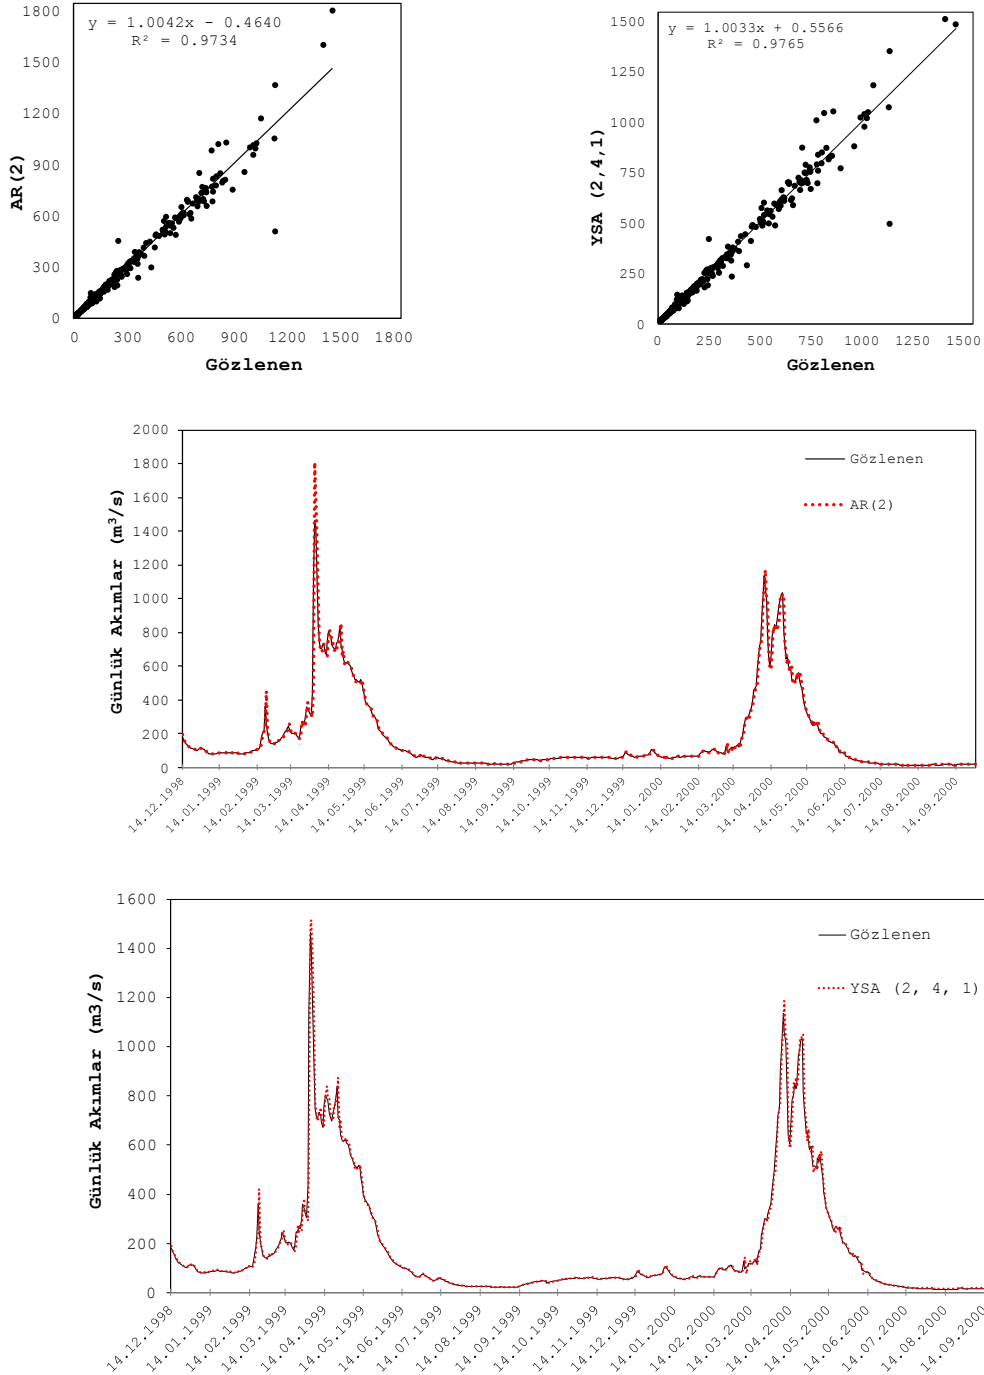
Ancak Murat, Munzur ve Perisu istasyonları için hazırlanan modellerin test dönemlerine ait saçılım grafikleri ve gidişleri (Şekil 3, 4 ve 5) incelendiğinde ve $y=a+bx$ doğru denklemlerine bakıldığında, LM-YSA modelleri için a değerinin istenildiği üzere 1'e, b değerinin de 0'a daha çok yakınsadığı göze çarpmaktadır. Bu durum dikkate alındığında YSA modellerinin söz konusu istasyonlara ait günlük akımları daha başarılı bir şekilde modellediği söylenebilir.

Tablo 3. Modellerin eğitim ve test dönemlerine ait uzun dönem temel istatistikleri
(Table 3. Basic statistics for the long-term of the models for the testing and training periods)

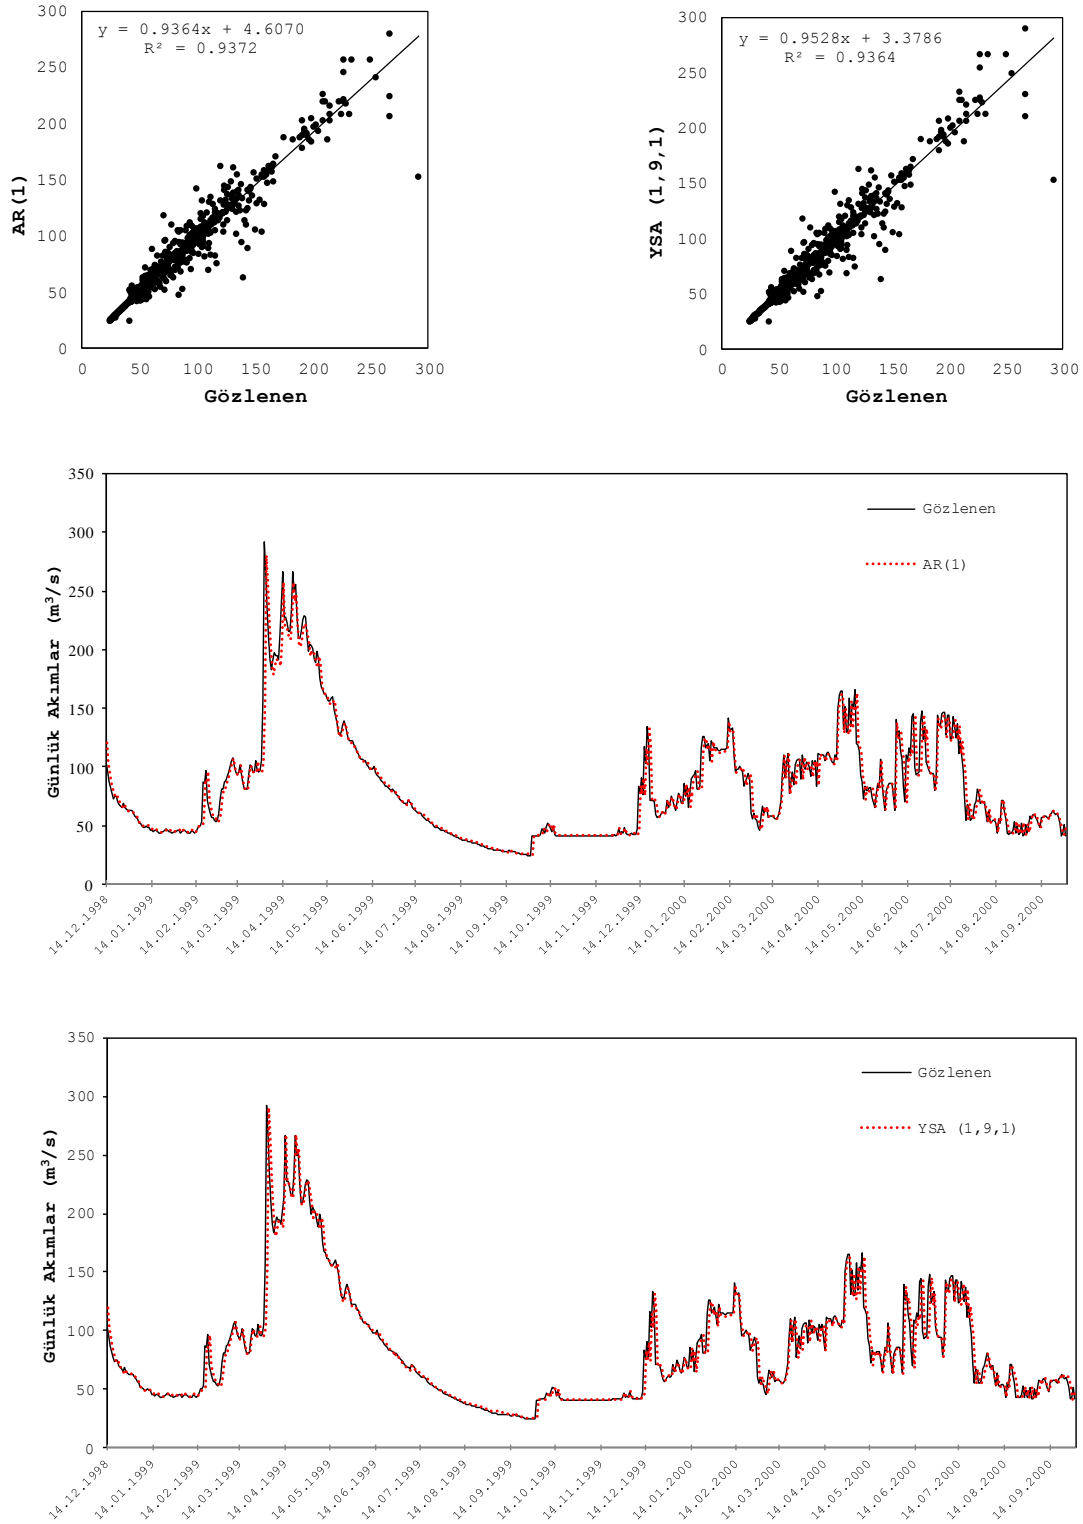
İstasyon	Model	Ortalama m^3/sn		S.Sapma m^3/sn		Çarpıklık -		Basıklık -	
		Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
Murat	Gözlem	262.03	169.73	376.65	234.30	2.67	2.35	7.77	5.57
	AR(2)	262.10	169.98	385.49	238.47	3.12	2.62	13.96	8.30
	LM-YSA	257.69	170.84	357.95	237.88	2.39	2.46	5.62	6.40
Munzur	Gözlem	91.79	83.04	81.95	47.42	2.07	1.47	4.42	2.31
	AR(1)	90.14	82.36	78.08	45.87	2.00	1.42	4.02	2.11
	LM-YSA	90.34	82.50	77.78	46.69	1.85	1.50	2.82	2.50
Perisu	Gözlem	81.87	58.72	115.55	68.71	2.76	1.48	9.63	1.83
	AR(1)	80.18	57.82	111.34	66.91	2.73	1.45	9.30	1.73
	LM-YSA	80.30	58.37	109.17	68.34	2.40	1.52	5.75	2.04

Uzun dönem temel istatistikleri incelendiğinde de AR(p) ve LM-YSA modellerinin gözlenmiş akım serilerinin temel istatistiklerine oldukça yakın olduğu gözlenmiştir. Ancak yine test dönemlerine

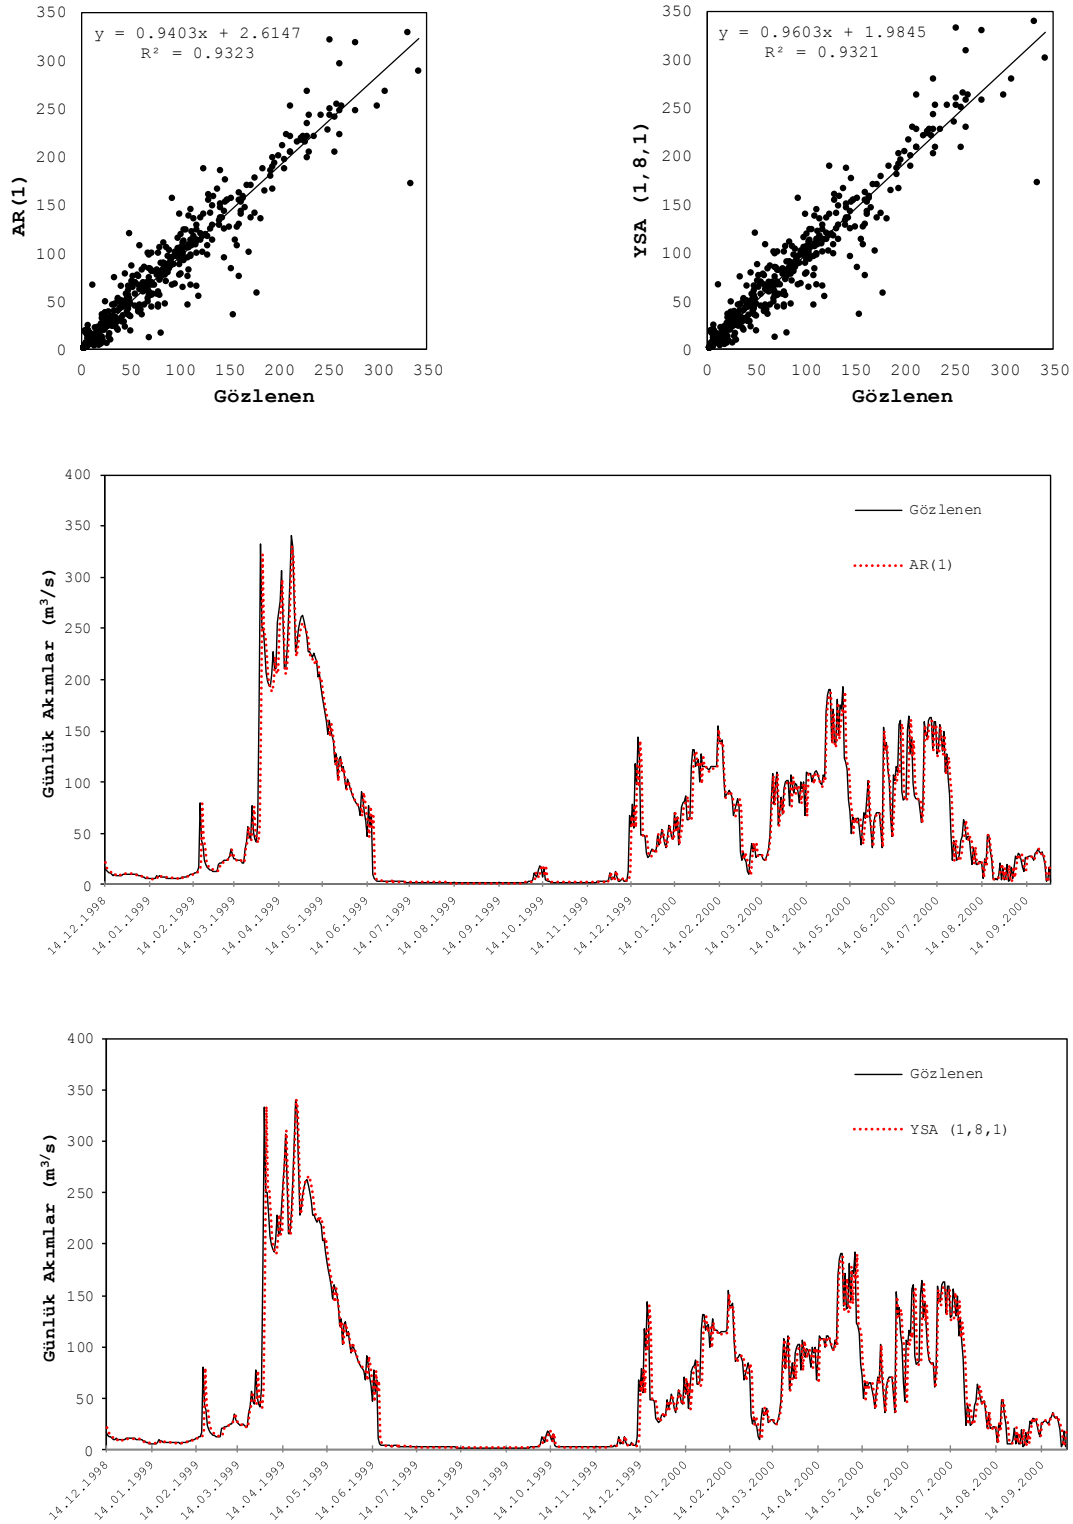
bakıldığında genel olarak LM-YSA modellerinin gözlenmiş akım serilerinin temel istatistiklerine daha yakın sonuçlar verdiği görülmüştür. Dolayısıyla LM-YSA modellerinin ilgili istasyonlara ait günlük akımların tahminlenmesinde daha başarılı olduğunu destekler niteliktedir.



Şekil 3. Murat 2102 AR(2) ve LM-YSA test dönemi saçılım grafikleri ve gidişleri
(Figure 3. Scatter plots and trend of the test period of Murat 2102 AR(2) and LM-ANN model)



Şekil 4. Munzur 2133 AR (1) ve YSA test dönemi saçılım grafiği ve gidişleri
(Figure 4. Scatter plots and trend of the test period of Munzur 2133 AR(1) and LM-ANN model)



Şekil 5. Perisu 2166 AR (1) ve LM-YSA test dönemi saçılım grafiği ve gidişleri
(Figure 5. Scatter plots and trend of the test period of Perisu 2166 AR(1) and LM-ANN model)

LM-YSA modelinde ağın eğitiminde, başlangıç Marquardt parametresi (μ) ve bozulma oranı (β) deneme yanılma yoluyla, hata kareler ortalaması (HKO) minimum olacak şekilde belirlenmiştir. Ağın genelleme yeteneğini kaybetmemesi, dolayısıyla aşırı öğrenme durumundan performansının bozulmaması için eğitim aşamasında belirli sayıdaki iterasyon yeterli görülmüştür. LM-YSA modellerine ait μ , β , HKO'nu minimum yapan gizli katmandaki hücre sayıları (GKHS) ve iterasyon adetleri Tablo 4'te verilmiştir.

Tablo 4. LM-YSA modellerine ait model parametreleri
(Table 4. Model parameters of LM-ANN models)

İstasyon	μ	β	GKHS	İterasyon
Murat	0.001	0.5	4	20
Munzur	0.5	0.1	9	20
Perisu	0.001	0.05	8	20

5. SONUÇLAR (CONCLUSIONS)

Çalışmada, Fırat Havzası'nda yer alan ve Keban Barajı'nı besleyen, Murat Nehri, Munzur Çayı ve Peri Suyu akım gözlem istasyonlarında 1991-2000 su yılları arasında ölçümü yapılan 3288 adet günlük akım verisi kullanılmış, akım serilerinin çarpıklıklarından dolayı Box-Cox dönüşümü uygulanarak seri boyutsuzlaştırılmış ve kısmi otokorelasyon katsayıları grafiksel açıdan incelenerek otoregresiflik mertebesine karar verilmiştir.

Buna göre Murat, Munzur ve Perisu istasyonları için en iyi model AR(p) yapılarının sırasıyla AR(2), AR(1) ve AR(1) olduğu belirlenmiştir. İlgili istasyonlara ait AR(p) model girdileri LM-YSA modelinin de girdileri olarak kullanılmıştır.

Modeller incelendiğinde, yöntemlerin yaklaşık sonuçlar verdiği görülmüştür. Ancak gerek saçılım grafiklerinin ve gidişlerin gerek performans kriterlerinin gerekse uzun dönem temel istatistiklerinin test dönemlerine ait sonuçlar incelendiğinde, hazırlanan LM-YSA daha başarılı olduğu, dolayısıyla ilgili istasyonlara ait günlük akımları daha iyi tahminlediği söylenebilir.

Hazırlanan çalışmada, YSA modellerinin içsel bağımlı AR(p) modellerinden her zaman daha iyi sonuçlar verdiği genellemesinin yapılamayacağı açıkça görülmüştür. İçsel bağımlı günlük akımların otoregresiflik mertebelerinin doğru tespit edilmesi ile bu modellerin de oldukça iyi sonuçlar verebildiği görülmektedir. Özellikle yüksek debili akımların gözlemlendiği havzalar için yapılacak akım modellerinin hassaslığı çok önemli olduğu düşünüldüğünde birçok model yapısının denenmesinden sonra en doğru ve hassas sonucu veren model veya modellerin kullanılması daha doğru olacaktır. Bunun yanı sıra içsel bağımlı ve YSA model yapılarının kombine edildiği modellerin oluşturulabilirliği de imkan dahilinde olduğundan sunulan çalışmanın bu türden çalışmalara ışık tutabilecek nitelikte olacağı düşünülmektedir.

İklim değişikliğinin etkileri de dikkate alındığında, günümüzde stratejik öneme sahip olan su kaynaklarının potansiyellerinin belirlenmesi, senaryo esaslı çalışmaların yapılması, gerekli kararların alınması ve planların oluşturulmasında hazırlanan modellerin bu konudaki ilgililere yararlı olacağı düşünülmektedir.

NOT (NOTICE)

Bu makale, 28-30 Eylül 2011 tarihleri arasında Elazığ Fırat Üniversitesinde "International Participated Construction Congress" IPCC11'de sözlü sunum olarak sunulmuştur.

KAYNAKLAR (REFERENCES)

1. Abbott, M.B. and Refsgaard, J.C., (1996). Distributed hydrological modeling. Kluwer Academic Publishers, Dordrecht.
2. Campolo, M., Andreussi, P., and Soldati, A., (1999). River flood forecasting with a neural network model. Water Resources Research, 35, pp:1191-1197
3. Hsu, K., Gupta, H.V., and Sorooshian, S., (1995). Artificial neural network modelling of the rainfall runoff process. Water Res. Research, 31, pp:2517-2530.
4. Minns, A.W. and Hall, M.J., (1996). Artificial neural networks as rainfall runoff models. Hydrological Sciences Journal, 41(3), pp:399-417.
5. Alp, M. ve Cıgızoğlu, H.K., (2004). Farklı yapay sinir ağı metodları ile yağış-akış ilişkisinin modellenmesi İTÜ dergisi, 3(1), ss: 80-88.
6. Kisi, O., (2007). Streamflow forecasting using different artificial neural network algorithms, ASCE J. of Hydrol. Eng., 12(5), pp: 532-539.
7. Okkan, U., (2011). Application of Levenberg-Marquardt Optimization Algorithm Based Multilayer Neural Networks for Hydrological Time Series Modeling, An International Journal of Optimization and Control: Theories & Applications, 1(1), pp:53-63.
8. Cigizoglu, H.K., (2005). Application of the generalized regression neural networks to intermittent flow forecasting and estimation. Journal of Hydrologic Engineering, 10(4), pp:336-341.
9. Okkan, U. and Dalkilic, H.Y., (2011) Reservoir Inflows Modeling with Artificial Neural Networks: The Case of Kemer Dam in Turkey, Fresenius Environmental Bulletin, 20 (11) (in press).
10. Lin, G. and Chen, L., (2004). A non-linear rainfall-runoff model using radial basis function network. Journal of Hydrology, 289, pp:1-8.
11. Okkan, U. ve Serbeş Z.A., (2010). Radyal tabanlı yapay sinir ağları yaklaşımı ile günlük akımların modellenmesi. İnşaat Mühendisleri Odası İzmir Şube Bülteni, 155, ss:26-29.
12. Aydın, M.C., (1988). Yukarı Fırat Havzası'nın DSİ IX. Bölge Dahilindeki Bölümünün Simülasyon Modeli İle İncelenmesi. Yüksek Lisans Tezi. Fırat Üniversitesi, Fen Bilimleri Enstitüsü.
13. Öztürk, M. ve Aydın, M.C., (2001). Yukarı Fırat Havzası'nın Simülasyon Modeli İle İncelenmesi, İstanbul, 1, ss:339-346.
14. Aydın, M.C., (2005). Keban Barajı'na Giren Akımların Modellenmesi. İMO Teknik Dergi. 326, ss:3561-3579.
15. Box, G.E.P. and Jenkins, G.M., (1976). Time series analysis, forecasting and control. Holden Day Inc., San Francisco, California.
16. Salas, J.D., Delleur, J.W., Yevjevich, V., and Lane, W.L., (1980). Applied Modeling of Hydrologic Time Series. Water Resources Publications, Colorado.
17. Durbin, J., (1960). The fitting of time series models. Rev. Inst. Int. Stat., 28, pp:233-243.

18. Ham, F. and Kostanic, I., (2001). Principles of Neurocomputing for Science and Engineering. Macgraw-Hill. USA.
19. Hagan, M.T. and Menhaj, M.B., (1994). Training feed forward techniques with the Marquardt Algorithm, IEEE Transactions on Neural Networks, 5(6), pp:989-993.
20. Cong Chen, T., Jian Han, D., Au, F.T.K., and Than, L.G., (2003). "Acceleration of Levenberg-Marquardt training of neural networks with variable decay rate" IEEE Trans. on Neural Net., 3(6), pp:1873-1878.