

Çoruh Nehri Günlük Akımlarının Yapay Sinir Ağları ile Tahmin Edilmesi

Umut OKKAN^{1*}, Ayşe MOLLAMAHMUTOĞLU²

¹Balıkesir Üniversitesi Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü/ BALIKESİR

²Bayburt Üniversitesi Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü/ BAYBURT

Alınış tarihi:07.05.2010, Kabul tarihi:07.10.2010

Özet: Su kaynakları planlanması ve tasarımı aşamasında, güvenilir akım tahminlerinin ve akım modelleme çalışmalarının yapılması büyük önem taşımaktadır. Sunulan çalışmada, bir yapay sinir ağı modeli (YSA) geliştirilerek, bu model Çoruh havzasında yer alan Çoruh Nehrine ait günlük akımlara uygulanmıştır. Girdi olarak 1 ve 2 gün önceki akım değerlerine ihtiyaç duyan YSA modeli, 03.10.1991-01.04.1996 tarihleri arasındaki 1643 günlük akım verileri kullanılarak eğitilmiş; 02.04.1996-30.09.2000 tarihleri arasındaki 1643 günlük akım verileri kullanılarak sınanmıştır. Hazırlanan YSA modeli içsel bağımlı stokastik AR(2) model yapısıyla da karşılaştırılmıştır. Analiz sonucu, yöntemlerin yaklaşık sonuçlar verdiği görülmüş ancak YSA performansı içsel bağımlı modele göre daha başarılı bulunmuştur. Uzun dönemde gözlenmiş ve modellenmiş akımların istatistikleri karşılaştırıldığında; kurulan YSA modelinin Çoruh Nehri günlük akımlarını başarıyla temsil ettiği; böylece geliştirilen model yapısının diğer akarsu havzalarının günlük akımlarının tahmininde de başarıyla kullanılabilirdiği düşünülmektedir.

Anahtar Kelimeler: Günlük Akım tahmini, Yapay Sinir Ağları, İçsel Bağımlı Modeller, Çoruh Nehri

Daily Runoff Prediction of Coruh River by Artificial Neural Networks

Abstract: It is very important to make reliable runoff predictions and runoff modeling studies when planning and designing of water resources. In the study presented, an artificial neural network (ANN) model is improved and applied to the daily runoff values of Coruh River which is located in the Coruh basin. The ANN model which requires one day and two days ahead runoff values as the input data is trained by using the runoff data depending on the records that spreads to a time frame of 1643 days, made between 03.10.1991 and 01.04.1996, and then tested by the 1643 days of runoff data set which recorded between 02.04.1996 and 30.09.2000. The ANN model was also compared with autoregressive stochastic AR(2) model structure. After analysis, it was noticed that the results of each model are approximately similar but ANN is more successful than the autoregressive model. When the statistics of the long term recorded and modeled runoff values are compared, it can be seen that the ANN model structure that has been developed, successfully represents the daily runoff values of the Coruh River and can be also used to forecast the daily runoff values of the other river basin.

Keywords: Daily Runoff Prediction, Artificial Neural Networks, Autoregressive models, Coruh River

Giriş

Su kaynaklarının potansiyelinin ve yönetimindeki karar verme stratejilerinin belirlenmesinde büyük önem taşıyan akım tahmin modelleri hidrolojik model çalışmalarının genelini oluşturmaktadır (Andrews vd., 1978; Singh,1995; Bayazit, 1998). Gerek su kaynakları yönetimindeki kapsam ve ölçek değişiklikleri, gerek küresel iklim değişikliğinden kaynaklı sorunların varlığı, son dönemlerde akım tahmin modellerine ilginin daha da artmasına neden olmuştur.

Sözü edilen bu modeller en genel haliyle fiziksel tabanlı yayılı modeller (beyaz kutu modelleri), kavramsal modeller (gri kutu modelleri) ve kapalı (kara) kutu modelleri olmak üzere üç sınıfta değerlendirilebilmektedir (Abbott ve Refsgaard, 1996; Gül ve Harmancıoğlu, 2003).

Bunlardan beyaz kutu modellerinde, akımların diğer hidrolojik değişkenlerle olan ilişkileri fizik kanunlarına dayandırılmakta; ancak karmaşık yapıları ve veri ihtiyacının fazla olması nedeniyle kullanım alanları sınırlı olmaktadır. Beyaz kutu modellerinin yanı sıra, akımların fiziksel oluşum mekanizmalarını kavramsal olarak ele alan ve gri kutu modelleri olarak adlandırılan modeller de geliştirilmiştir. Bu modeller genellikle havzadaki sürekliliği esas alarak deterministik bir şekilde hazırlanmakta ancak parametre sayısı ve uygulanabilirliği

açısından belirsizlikler ve karmaşıklıklar içerebilmektedir (Abbott ve Refsgaard, 1996; Gül ve Harmancıoğlu, 2003).

Akım modelleme yöntemlerindeki bu karmaşıklıklardan ve belirsizliklerden ötürü, akım modelleme çalışmaları, olayın fiziksel yönünün dikkate alınmadığı kara kutu modelleriyle de gerçekleştirilebilmektedir. Bu kapsamda geliştirilmiş modellerde genel olarak, stokastik içsel bağımlı model yapıları, regresyon analizleri ve eğri uydurma yaklaşımları gibi klasik istatistiksel yöntemler (Karabörk ve Kahya, 1999; İcağa, 2003; Baran ve Bacanlı, 2006; Keskin ve Taylan, 2007) ve son zamanlarda önemini giderek arttıran yapay sinir ağları esas alınmaktadır (Raman ve Sunilkumar, 1995; Hsu vd., 1995; Minns ve Hall, 1996; Tokar ve Johnson, 1999; Cigizoglu, 2003; Alp ve Cigizoğlu, 2004; Kisi, 2005; Alp ve Cigizoğlu, 2005; Yurdusev vd., 2008).

Bu modeller incelendiğinde, yapay sinir ağı yaklaşımlarının klasik istatistiksel yöntemlere nazaran daha olumlu sonuçlar verdiği göze çarpmakta ve bu akım tahmin modellerinin genelinde ileri beslemeli geriye yayımlı yapay sinir ağı algoritmalarının kullanıldığı görülmektedir. Bu kapsamda yapılan çalışmaların bazıları şunlardır. Minns ve Hall (1996) ileri beslemeli ve geriye yayılım algoritması kullanarak sentetik olarak üretilmiş verilerden akım modelleme çalışmaları yapmışlardır.

Campolo vd. (1999) Pauloro, Ampezzo, Pesariis, Resia ve Moggio istasyonlarına ait yağış verilerini ve Venzone istasyonuna ait hidrometrik verileri kullanarak İtalya'nın Tagliamento nehri akımlarını modellemişlerdir. Alp ve Cıgızoğlu (2004, 2005) içinde ileri beslemeli geriye yayımlı algoritmaların da yer aldığı 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. Bu çalışmalara benzer bir şekilde, Méndez vd. (2004) ve Kisi (2005) YSA ve AR model yapılarını kullanarak günlük nehir akımı tahminleri yapmış; Cıgızoğlu (2003), stokastik ARMA model yapısını yapay sinir ağları ile entegre ederek Doğu Akdeniz havzasındaki Göksu Nehri-Karahacılı istasyonu aylık akımlarını modellemiştir.

Bunların yanı sıra ileri beslemeli geriye yayımlı algoritmalara alternatif olarak geliştirilmiş olan Genelleştirilmiş Regresyon Sinir Ağı, Probabilistik Sinir Ağı ve Radyal Tabanlı Sinir Ağı gibi algoritmaların da akım tahmin modeli uygulamalarına rastlanmaktadır (Fernando ve Jayawardena, 1998; Lin ve Chen, 2004; Lin vd., 2009).

Hazırlanan çalışmada, Çoruh havzasında yer alan Çoruh Nehri günlük akımları yukarıda sözü edilen içsel bağımlı (otoregresif) stokastik yöntemler (AR) ve yapay sinir ağları (YSA) ile ayrı ayrı modellenmiştir. Kurulan modellerin sonuçları istatistiksel açıdan değerlendirilerek modellerin performanslarının karşılaştırılması amaçlanmıştır.

Materyal ve Metot

Yapay Sinir Ağları (YSA)

Yapay sinir ağları, biyolojik sinir sistemini ve öğrenme sürecini esas alarak bilgi türetebilme, tanımlama ve tahmin etme gibi yetenekleri gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir (Haykin, 1994). Yapay sinir ağlarının tarihsel gelişimi incelendiğinde birçok farklı yapıda model ve algoritma örneği görmek mümkündür. Bu kapsamda geliştirilmiş tek katmanlı algılayıcılar ve perceptron adı verilen algılayıcı modelleri yapay sinir ağları için ilk çalışmalar niteliğinde olup halen uygulamalarına rastlanabilmektedir. Ancak uygulamaların genelinde çok katmanlı algılayıcı modelleri tercih edilmekte ve bu modellerin mimarisi giriş katmanı, gizli (ara) katman ve çıktı katmanı olmak üzere 3 katman halinde tanımlanmaktadır (Şekil 1). Burada giriş ve çıkış katmanlarına ait hücreler, modelleme aşamasında kullanılacak veriler esas alınarak belirlenmekte, ara (gizli) katmana ait hücreler ise probleme göre değişmesi sebebiyle deneme-yanılma yöntemiyle tasarlanmaktadır (Haykin, 1994, Ham ve Kostanic, 2001).

Çok katmanlı bir YSA modelinde katmanların yanı sıra; girdiler (x), ağırlıklar (w), net fonksiyonu (net), aktivasyon fonksiyonu (f) ve çıktılar (y) olmak üzere 5 temel elemanın varlığı söz konusudur (Şekil 1). Ağın girdi ve çıktıları problemin niteliğine göre değişmektedir.

Girdilerin yapay sinir ağı modelindeki etkinlikleri ve önemi ağırlıklarla sağlanmaktadır. Dolayısıyla modelin performansı ağırlık değerlerinin doğru belirlenmesine bağlı olmaktadır. Ağırlıklı girdilerin toplamı olarak bulunan *net* fonksiyonu ile ise girdilerin hücreler üzerindeki etkileri ifade edilmektedir. Hücrelere gelen bu net girdiler bir aktivasyon fonksiyonu yardımıyla çıktılara ya da ara katmandaki hücrelerin girdilerine dönüştürülmektedir (Haykin, 1994; Ham ve Kostanic, 2001; Öztemel, 2003). Aktivasyon fonksiyonu doğrusal (lineer) ve doğrusal olmayan (non-lineer) şekilde olabilmektedir. Birçok aktivasyon fonksiyonu bulunmasına rağmen, uygulamalarda genellikle *sigmoid* adı verilen aktivasyon fonksiyonu kullanılmaktadır (Hsu vd., 1995; Govindaraju ve Rao, 2000; Mandic ve Chambers, 2001; Öztemel, 2003).

Yapay sinir ağlarının mimarisi kadar ağın kurulumunda yani eğitiminde kullanılacak algoritma da çok önemli olmakta ve bu aşamada ağın girdilere karşılık beklenen çıktıları öğrenmesi amaçlanmaktadır (Mandic ve Chambers, 2001). Genel olarak çok katmanlı YSA algoritmalarının işleyişi ileriye doğru hesaplama ve geriye doğru hesaplama olmak üzere iki aşamada gerçekleşmektedir. Bundan dolayı bu tür algoritmalara *ileri beslemeli geri yayımlı* yapay sinir ağı algoritmaları da denmektedir.

İleri doğru hesaplama aşamasına, girdilerin ağa sunulması ile başlanmaktadır. Öncelikle gizli katmandaki her hücre girdi katmanından gelen bilgileri ağırlıklar yardımıyla almakta ve gizli katmandaki hücrelere gelen *net* girdiler hesaplanmaktadır.

$$net_j^a = \sum_{k=1}^n w_{kj} x_k^i \quad (1)$$

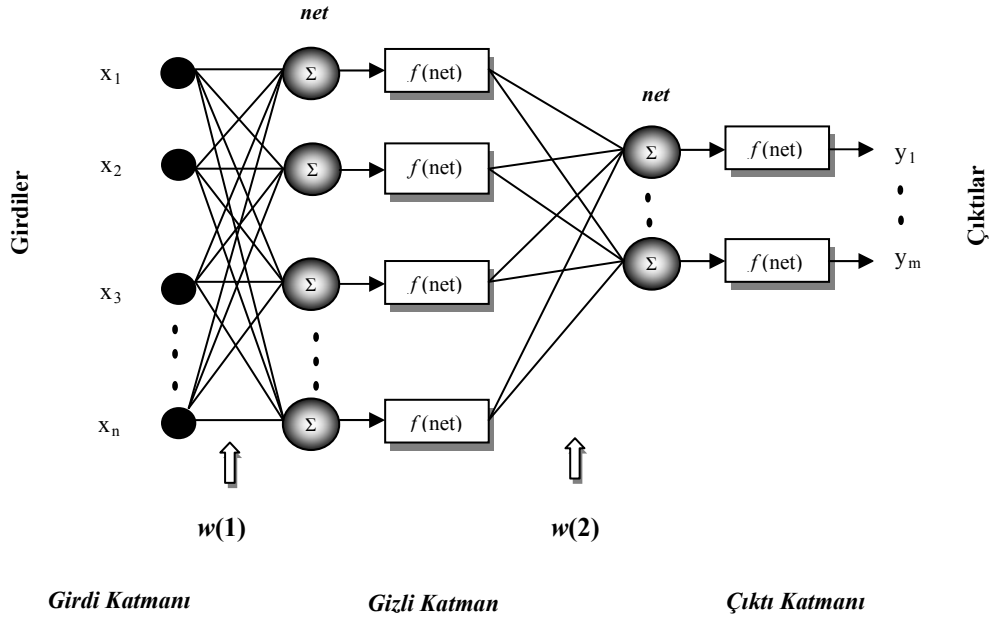
Burada w_{kj} k .girdi elemanını j . gizli katman elemanına bağlayan bağlantının ağırlık değeridir.

Bu *net* girdinin belirlenen bir aktivasyon fonksiyonundan geçirilmesiyle j . gizli katman elemanının çıktısı hesaplanabilmektedir. Sigmoid fonksiyonu kullanılması halinde çıktı,

$$y_j^a = \frac{1}{1 + \exp[-(net_j^a + b_j^a)]} \quad (2)$$

şeklinde hesaplanmaktadır. Burada b_j j . hücreye bağlanan eşik değer (bias) elemanının ağırlığını göstermektedir. Bu işlem tüm gizli katman ve çıktı katmanı hücreleri için tekrarlanmakta; çıktı katmanının çıktıları belirlendiğinde ileri hesaplama aşaması tamamlanmaktadır.

Geriye doğru hesaplama aşamasında ise ağın ürettiği çıktı (y_1, y_2, \dots) değerleri beklenen çıktı değerleri (b_1, b_2, \dots) ile karşılaştırılmaktadır. Bu çıktı değerleri arasındaki fark hata olarak tanımlanmakta ve geriye yayılım aşamasında bu hata miktarının ağırlık değerlerine paylaştırılarak her bir iterasyonda azaltılması hedeflenmektedir. Bu da başlangıçta rastgele değerler şeklinde atanan ağın ağırlıklarının güncellenmesi ile mümkün olmaktadır.



Şekil 1. Çok katmanlı bir yapay sinir ağı mimarisi

Bu YSA modellerinde hata kareler toplamı veya ortalaması hesabına dayalı performans (amaç) fonksiyonu ile gerçekleştirilebilmektedir (Rumelhart vd., 1986).

Ağda, ağırlıklarının değişimi de iki aşamada gerçekleşmektedir. Bunlar gizli katman ve çıktı katmanı arasındaki ağırlıkların ($w(2)$) değişimi ve gizli katman ve girdi katmanı arasındaki ağırlıkların ($w(1)$) değişimi şeklindedir.

Gizli katman ve çıktı katmanı arasındaki ağırlıkların ($w(2)$) değişimi şöyle gerçekleşmektedir. Gizli katmandaki j . hücreyi çıktı katmanındaki m . hücreye bağlayan bağlantının ağırlığındaki değişim miktarı Δw_{jm}^a ; m . hücre için oluşan hata E_m ; aktivasyon fonksiyonunun türevi $f'(net)$ ile gösterilirse, t . iterasyonda ağırlıkların değişimi aşağıdaki gibi hesaplanabilmektedir.

$$\Delta w_{jm}^a(t) = \eta [f'(net) E_m] y_j^a + \mu \Delta w_{jm}^a(t-1) \quad (3)$$

Burada η öğrenme oranını, μ ağırlık öğrenmesi esnasında yerel minimum probleminin çözülmesi için ağırlık değişim değerinin belirli bir oranda sonraki değişime eklenmesini sağlayan momentum oranını göstermektedir.

Yapılan çalışmalar, η öğrenme oranının 0.2-0.4, μ momentum oranının ise 0.6-0.9 değerleri arasında deneme-yanılma yöntemiyle bulunabileceğini göstermektedir (Öztemel, 2003).

Değişim miktarı hesaplandıktan sonra, ağırlıkların t . iterasyondaki yeni değerleri aşağıdaki gibi güncellenmektedir.

$$w_{jm}^a(t) = w_{jm}^a(t-1) + \Delta w_{jm}^a(t) \quad (4)$$

Benzer şekilde çıktı katmanında bulunan eşik değeri ($bias$) elemanlarının (b_m^c) da t . iterasyonda yeni değerleri aşağıdaki gibi hesaplanabilmektedir.

$$b_m^c(t) = b_m^c(t-1) + \Delta b_m^c(t) \quad (5)$$

Gizli katmanlar ile girdi katmanı arasındaki ağırlıkların ($w(1)$) değişimi ise

$$\Delta w_{kj}^i(t) = \eta \left[f'(net) \sum_m [f'(net) E_m] w_{jm}^a \right] y_k^i + \mu \Delta w_{kj}^i(t-1) \quad (6)$$

şeklinde hesaplanabilmektedir.

Gizli katmanlar ile girdi katmanı arasındaki ağırlıkların değişimi hesaplandıktan sonra ağırlıkların t . iterasyondaki yeni değerleri aşağıdaki gibi güncellenmektedir.

$$w_{kj}^i(t) = w_{kj}^i(t-1) + \Delta w_{kj}^i(t) \quad (7)$$

Benzer şekilde gizli katmanda bulunan eşik değeri ($bias$) elemanının (b_j^a) da t . iterasyonda yeni değerleri aşağıdaki gibi güncellenmektedir.

$$b_j^a(t) = b_j^a(t-1) + \Delta b_j^a(t) \quad (8)$$

Bu işlemler eğitim aşaması tamamlanana kadar sürmektedir. Ancak ağa çok fazla iterasyon yaptırılması da ağırlık performansını bozabilmektedir. Bu amaçla ağırlık her bir iterasyonda performans (amaç) fonksiyonundaki değişim grafiksel açıdan incelenerek eğitimin kaç iterasyon sonunda durdurulması gerektiği de belirlenebilmektedir. Bunlarla birlikte ağırlık genelleyebilme yeteneğinin de değerlendirilebilmesi

açısından ağır girdi ve çıktıları belirlenen bir oran dâhilinde eğitim ve test aşamalarında ayrı ayrı değerlendirilmektedir. Bu oranlar veri setinin uzunluğuna bağlı olarak değişmekle birlikte, verilerin %20-%50 oranında teste ayrılması önerilmektedir (Govindaraju ve Rao, 2000; Mandic ve Chambers, 2001; Ham ve Kostanic, 2001; Özetmel, 2003).

İçsel Bağımlı (Oto regresif) modeller (AR)

Akım modellemelerinde stokastik içsel bağımlılık için sıklıkla kullanılan yapılardan birisi de oto regresif model yapılarıdır (Yevjevich, 1972; Bayazıt, 1998; Box ve Jenkins, 1976; Salas vd., 1980; Box vd., 1994). Akımların ardışık doğrusal bağımlılığını esas alan bu modeller zaman ölçeği açısından yıllık, mevsimlik, aylık, haftalık veya günlük verilere uygulanabilmektedir (Keskin ve Taylan, 2007; İcağa, 2003; Cigizoglu, 2003; Méndez vd., 2004).

Markov modelleri olarak da adlandırılan bu modeller kullanılarak normalleştirilmiş seri aşağıdaki gibi ifade edilebilmektedir (Box ve Jenkins, 1976; Salas vd., 1980).

$$z_i = \sum_{j=1}^p \alpha_j z_{i-j} + \sigma_\varepsilon \xi_i \quad (9)$$

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

Akımların normalleştirilmesinin sebebi, akım serilerinin genellikle çarpık dağılması ve normal dağılım özelliği göstermemesidir. Dizinin normalite kontrolü Ki-Kare, Anderson-Darling gibi uygunluk sınamaları ile yapılabileceği gibi çarpıklık ve sivrilik katsayılarının irdelenmesi de yeterli görülmektedir (Yevjevich, 1972; Salas vd., 1980; Bayazıt, 1998). Normalite sınamasından geçemeyen akım verilerine uygun dönüşümler uygulayarak serinin çarpıklığı giderilebilmektedir. Box-Cox dönüşümü, logaritmik, üssel ve trigonometrik dönüşümler bunlardan bazıları olup çarpık dağılımlı mevsimsel akım verilerine sıklıkla Box-Cox dönüşümü uygulanarak akım serileri simetrikleştirilebilmektedir (Box ve Jenkins, 1976).

$$y_i = \frac{x_i^\lambda}{\lambda} \quad \lambda \neq 0 \quad (10)$$

Burada, y_i çarpıklığı giderilmiş yeni diziyi; x_i orijinal akım dizisini; λ Box-Cox dönüşüm parametresini simgelemektedir. Daha sonra dönüşüme uğramış verilerden seri ortalaması çıkarılıp, seri standart sapmasına bölünerek, ortalaması 0, standart sapması 1 olan boyutsuz z_i serisi elde edilmektedir.

Modele ait oto regresif parametrelerin moment tahminleri Yule-Walker eşitliklerinden (doğrusal denklem sisteminden) hesaplanabilmektedir (Box ve Jenkins, 1976; Salas vd., 1980).

$$\begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \cdot \\ \cdot \\ \cdot \\ \alpha_p \end{bmatrix} = \begin{bmatrix} 1 & r_1 & \cdot & r_{p-1} \\ r_1 & 1 & \cdot & r_{p-2} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ r_{p-1} & r_{p-2} & \cdot & 1 \end{bmatrix}^{-1} \begin{bmatrix} r_1 \\ r_2 \\ \cdot \\ \cdot \\ r_p \end{bmatrix} \quad (11)$$

Denklemden, p oto regresif modelin mertebesini; r_k aralarında k kadar zaman farkı (k) olan değerler arasındaki otokorelasyon katsayısını simgelemektedir.

N adet veriye sahip seriye ait belli bir k gecikme adımıdaki otokorelasyon değeri ise Denklem 12 yardımıyla hesaplanabilmektedir.

$$r_k = \frac{\text{cov}(z_i, z_{i+k})}{\text{var}(z_i)} \quad (12)$$

Normalize edilmiş zaman serisi gerçekten $AR(p)$ yapısında ise, p mertebesi aşağıda tanımlanan kısmi otokorelasyon katsayıları incelenerek kabaca saptanabilmektedir. Denklem 11'den sonuncu α katsayısı için hesaplanan $\hat{\phi}_{kk}$ katsayılarına kısmi otokorelasyon katsayıları denmektedir (Box ve Jenkins, 1976; Salas vd., 1980). Denklem 11'den veya aşağıdaki eşitliklerden bu katsayıların moment tahminleri rekürsif biçimde hesaplanabilmektedir (Durbin, 1960; Box ve Jenkins, 1976).

$$\hat{\phi}_{p+1,j} = \hat{\phi}_{pj} - \hat{\phi}_{p+1,p+1} \hat{\phi}_{p,p-j+1} ; j = 1, 2, \dots, p \quad (13)$$

$$\hat{\phi}_{p+1,p+1} = \frac{r_{p+1} - \sum_{j=1}^p \hat{\phi}_{pj} r_{p+1-j}}{1 - \sum_{j=1}^p \hat{\phi}_{pj} r_j} \quad (14)$$

Kısmi otokorelasyon katsayılarının örnekleme varyansı, $k \geq p+1$ için yaklaşık olarak şöyledir (Box ve Jenkins, 1976).

$$\sigma_{\hat{\phi}_{kk}}^2 = \text{var}(\hat{\phi}_{kk}) = 1/N ; k \geq p+1 \quad (15)$$

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

Modeller arasındaki en uygun model ise Düzeltilmiş Akaike Bilgi Kriteri (DABK) yardımıyla irdelenebilmekte ve en küçük DABK değeri ile uygun oto regresif model belirlenebilmektedir.

$$\text{DABK} = N \ln(\hat{\sigma}_\varepsilon^2) + 2N(p+1) / (N - p - 2) \quad (16)$$

Burada, N veri sayısını, p model mertebesini; $\hat{\sigma}_e^2$ kalıntı (*noise*) bileşeninin varyansını göstermektedir.

Model Performanslarının Kıyaslanması

Modeller hazırlandıktan sonra, performansları farklı istatistiksel kriterler yardımıyla karşılaştırılmıştır. Bunlar hata kareler ortalaması (*HKO*), hata kareler ortalamasının karekökü (*HKOK*) ve determinasyon katsayısı (R^2) değerleridir. Bunlardan *HKO* ve *HKOK* değerlerinin 0'a, R^2 değerinin 1'e yakın olması, tahmin edilen değerlerin kuvvetli biçimde doğruya yakınsadığını göstermektedir. Sözü edilen istatistiksel hesaplar sırasıyla Denklem 17, 18 ve 19 yardımıyla yapılabilmektedir.

$$HKO = \frac{1}{N} \sum_{i=1}^N (b_i - y_i)^2 \quad (17)$$

$$HKOK = \sqrt{HKO} \quad (18)$$

$$R^2 = \frac{\sum_{i=1}^N (b_i - b_{ort})^2 - \sum_{i=1}^N (b_i - y_i)^2}{\sum_{i=1}^N (b_i - b_{ort})^2} \quad (19)$$

Bu denklemlerde; b_i modellere ait beklenen (gözlenen) değerleri; y_i modellerin ürettiği çıktıları, N veri adedini simgelemektedir.

Uygulama Havzası

Çalışmada, Çoruh havzasında (23) Bayburt il merkezi içerisinde Elektrik İşleri Etüt İdaresi Genel Müdürlüğü tarafından işletilen ve 1734 km² yağış alanına sahip EIE 2304 numaralı Bayburt akım gözlem istasyonuna ait 01.10.1991 –30.09.2000 tarihleri arasında gözlenen 3288 adet günlük akım verisi kullanılmıştır. Şekil 2'de Çoruh Nehrinin ve EIE 2304-Bayburt akım gözlem istasyonunun havza üzerindeki konumu gösterilmektedir.

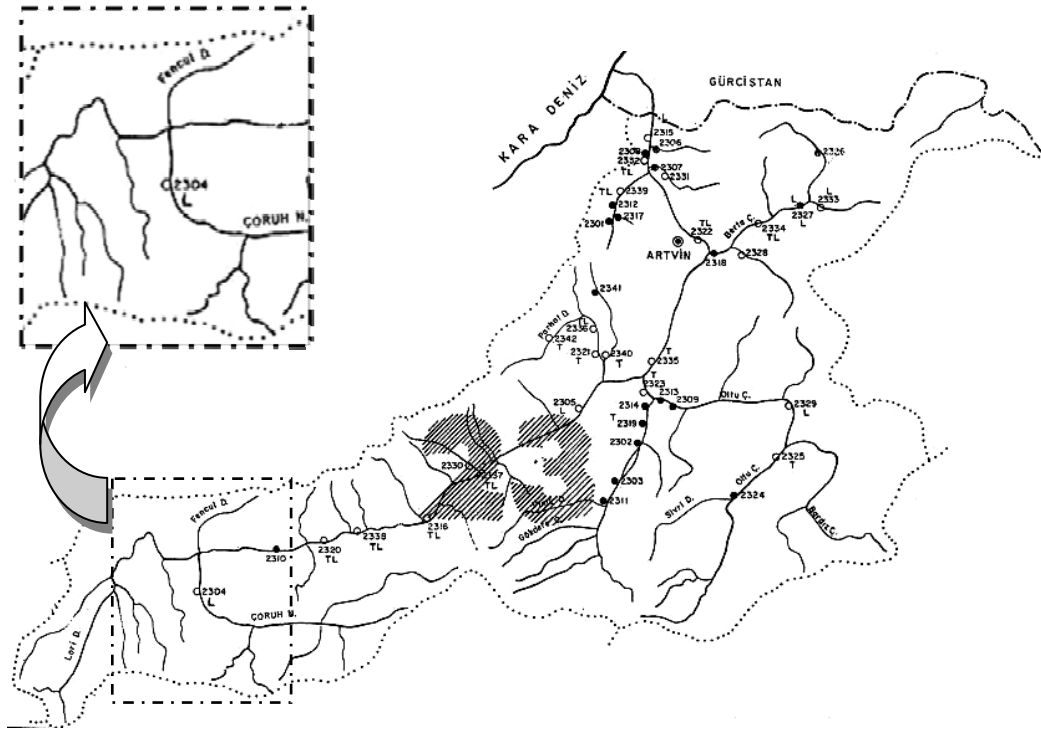
Bulgular

Otoregresif (AR) Modelin Hazırlanması

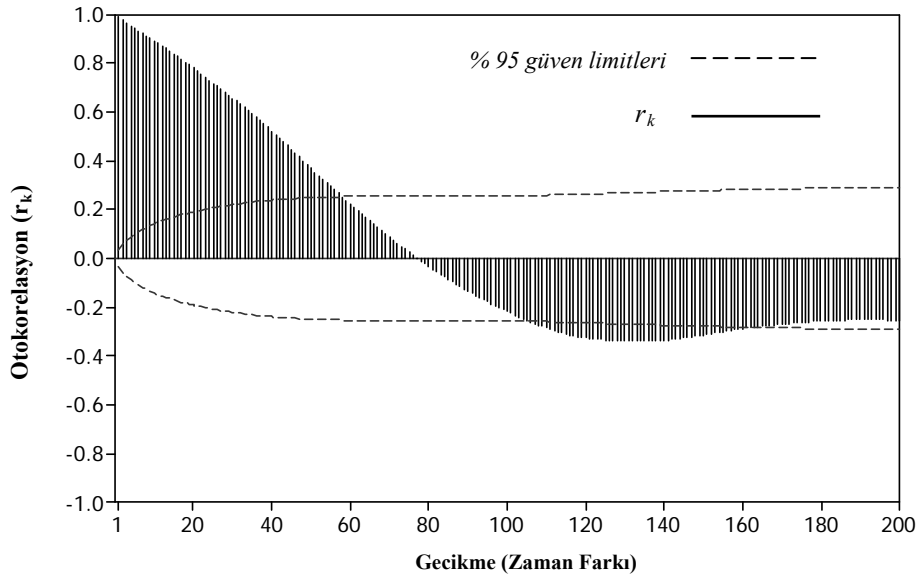
Yapılan inceleme sonucu, günlük akım verilerinin çarpık olduğu gözlenmiş ve bu sebepten ötürü verilere Box-Cox dönüşüm uygulanarak seri simetrik dağılımlı hale getirilmiştir. Çizelge 1'de orijinal diziye ve dönüştürülmüş diziye ait temel istatistikler özetlenmektedir.

Çizelge 1. Orijinal diziye (x_i) ve dönüştürülmüş diziye (y_i) ait temel istatistikler

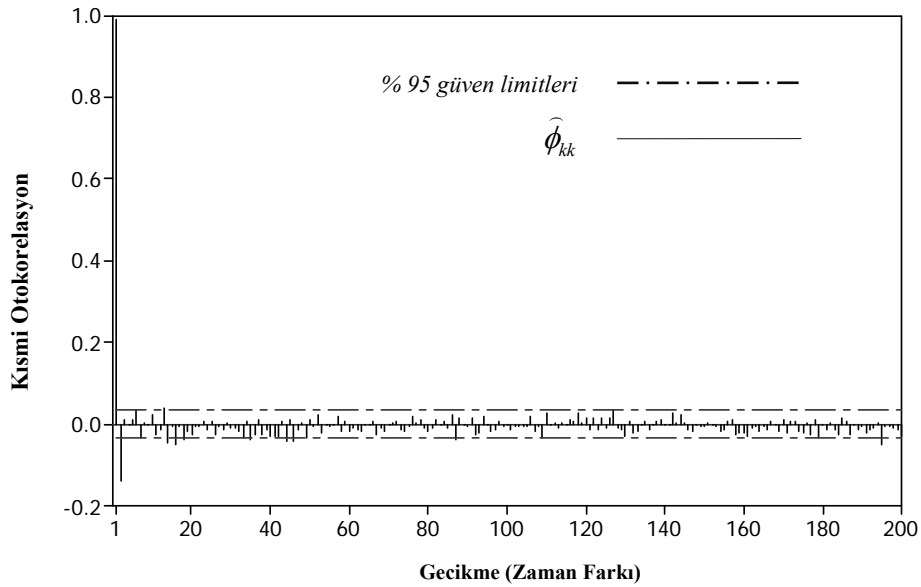
Temel İstatistikler	x_i	y_i
Ortalama (m ³ /sn)	15.317	-0.092
S.Sapma (m ³ /sn)	19.020	0.053
Çarpıklık	2.879	-0.001



Şekil 2. Çoruh Nehrinin ve EIE 2304 akım gözlem istasyonunun Çoruh Havzası (23) üzerindeki konumu



Şekil 3. Boyutsuz hale getirilmiş günlük akımların otokorelogramı



Şekil 4. Boyutsuz hale getirilmiş günlük akımların kısmi otokorelogramı

Dönüşüm uygulanmış ve ardından boyutsuz hale getirilmiş günlük verilere ait korelogramlar incelendiğinde (Şekil 3-4) AR(1) ve AR(2) modelleri potansiyel model olarak önerilebilir. Önerilen otoregresif modellere ait parametreler MATLAB ortamında hazırlanan kod vasıtasıyla belirlenmiştir. Önerilen modeller arasındaki en uygun model ise Düzeltilmiş Akaike Bilgi Kriteri (DABK) yardımıyla irdelenmiştir (Çizelge 2).

Çizelge 2. Otoregresif model parametreleri ve DABK sonuçları

AR(p)	α_1	α_2	σ_ε^2	DABK
AR(1)	0.9948	-	0.01829	-13151.96
AR(2)	1.1271	-0.1375	0.01795	-13212.72

Çizelge 2'de otoregresif modellere ait parametreler ve DABK sonuçları özetlenmiştir. Buna göre, önerilen modeller arasındaki en küçük DABK değerini AR(2) modeli vermiş ve en uygun model yapısının AR(2) modeline ait olduğu belirlenmiştir.

Yapay Sinir Ağı (YSA) Modelinin Hazırlanması

Yapay sinir ağı modelinde de, 2304 numaralı Bayburt akım gözlem istasyonuna ait 01.10.1991 –30.09.2000 tarihleri arasında gözlemlenmiş toplam 3288 adet günlük akım verisi değerlendirilmiştir. Ancak otoregresif modeller içinde en iyi model yapısının AR(2) olmasından ötürü, çalışmada iki gün önceki akım verileri (Q_{t-1} ve Q_{t-2}) yapay sinir ağı (YSA) modelinin girdileri olarak kullanılmıştır. Bu sebepten ötürü modeller 03.10.1991 – 30.09.2000 tarihleri arasındaki 3286 adet veri dikkate alınarak hazırlanmıştır. Böylece 03.10.1991 –30.09.2000

tarikhleri arasında çalıştırılan modelde, 1 ve 2 gün önceki veriler de sırasıyla 02.10.1991 ve 01.10.1991 tarihlerinden başlanarak derlenmiştir.


Yapay sinir ağı modelinin genelleme yeteneğinin sınanması açısından, model veri setinin yarısı ile eğitilmiş (03.10.1991-01.04.1996), geri kalan yarısı ile (02.04.1996-30.09.2000) test edilmiştir. Bu aşamada MATLAB ortamında hazırlanan kod kullanılmıştır. Çalışmada aktivasyon fonksiyonu olarak ise *sigmoid* fonksiyonu seçilmiştir.

Veriler *sigmoid* fonksiyonunun özelliğinden ötürü, $(x-x_{min})/(x_{max}-x_{min})$ bağıntısıyla 0 ile 1 arasında ölçeklendirilerek ağa sunulmuştur. Öğrenme işlemi tamamlandıktan sonra ağın çıktıları ters işlem ile gerçek ölçeğine dönüştürülmüştür.

Ağın eğitiminde, gizli katmandaki hücre sayısı 4, öğrenme oranı (η) 0.3 ve momentum oranı (μ) 0.7 olarak deneme yanılma yoluyla, hata kareler ortalaması (HKO) minimum olacak şekilde belirlenmiştir.

Ağın genelleme yeteneğini kaybetmemesi, dolayısıyla aşırı öğrenme durumundan performansının bozulmaması için eğitim aşamasında yaptırılan 100 adet iterasyon yeterli görülmüştür.

Şekil 5'te 2 ile 20 denenen gizli katmandaki hücre sayılarının (GKHS) test dönemindeki HKO performansları gösterilmektedir.



Şekil 5. Gizli katmandaki hücre sayılarının test dönemindeki hata kareler ortalaması performansları

Çizelge 3. Modellerin eğitim ve test dönemlerine ait uzun dönem temel istatistikleri (a)

		Ortalama m^3/sn	S. Sapma m^3/sn	Çarpıklık -	Basıklık -
Eğitim	Gözlenmiş	14.723	17.425	2.38	5.51
	YSA (2, 4, 1)	14.774	17.212	2.33	5.12
	AR(2)	14.142	15.870	2.23	4.57
Test	Gözlenmiş	15.922	20.488	3.13	12.90
	YSA (2, 4, 1)	15.800	19.378	2.66	7.79
	AR(2)	15.143	18.007	2.72	8.82

(b)

Modeller	R^2 -		HKO m^6/sn^2		HKOK m^3/sn	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
YSA (2, 4, 1)	0.9794	0.9756	6.2610	10.9899	2.5022	3.3151
AR(2)	0.9788	0.9727	8.6531	16.8853	2.9416	4.1092

Tartışma ve Sonuç

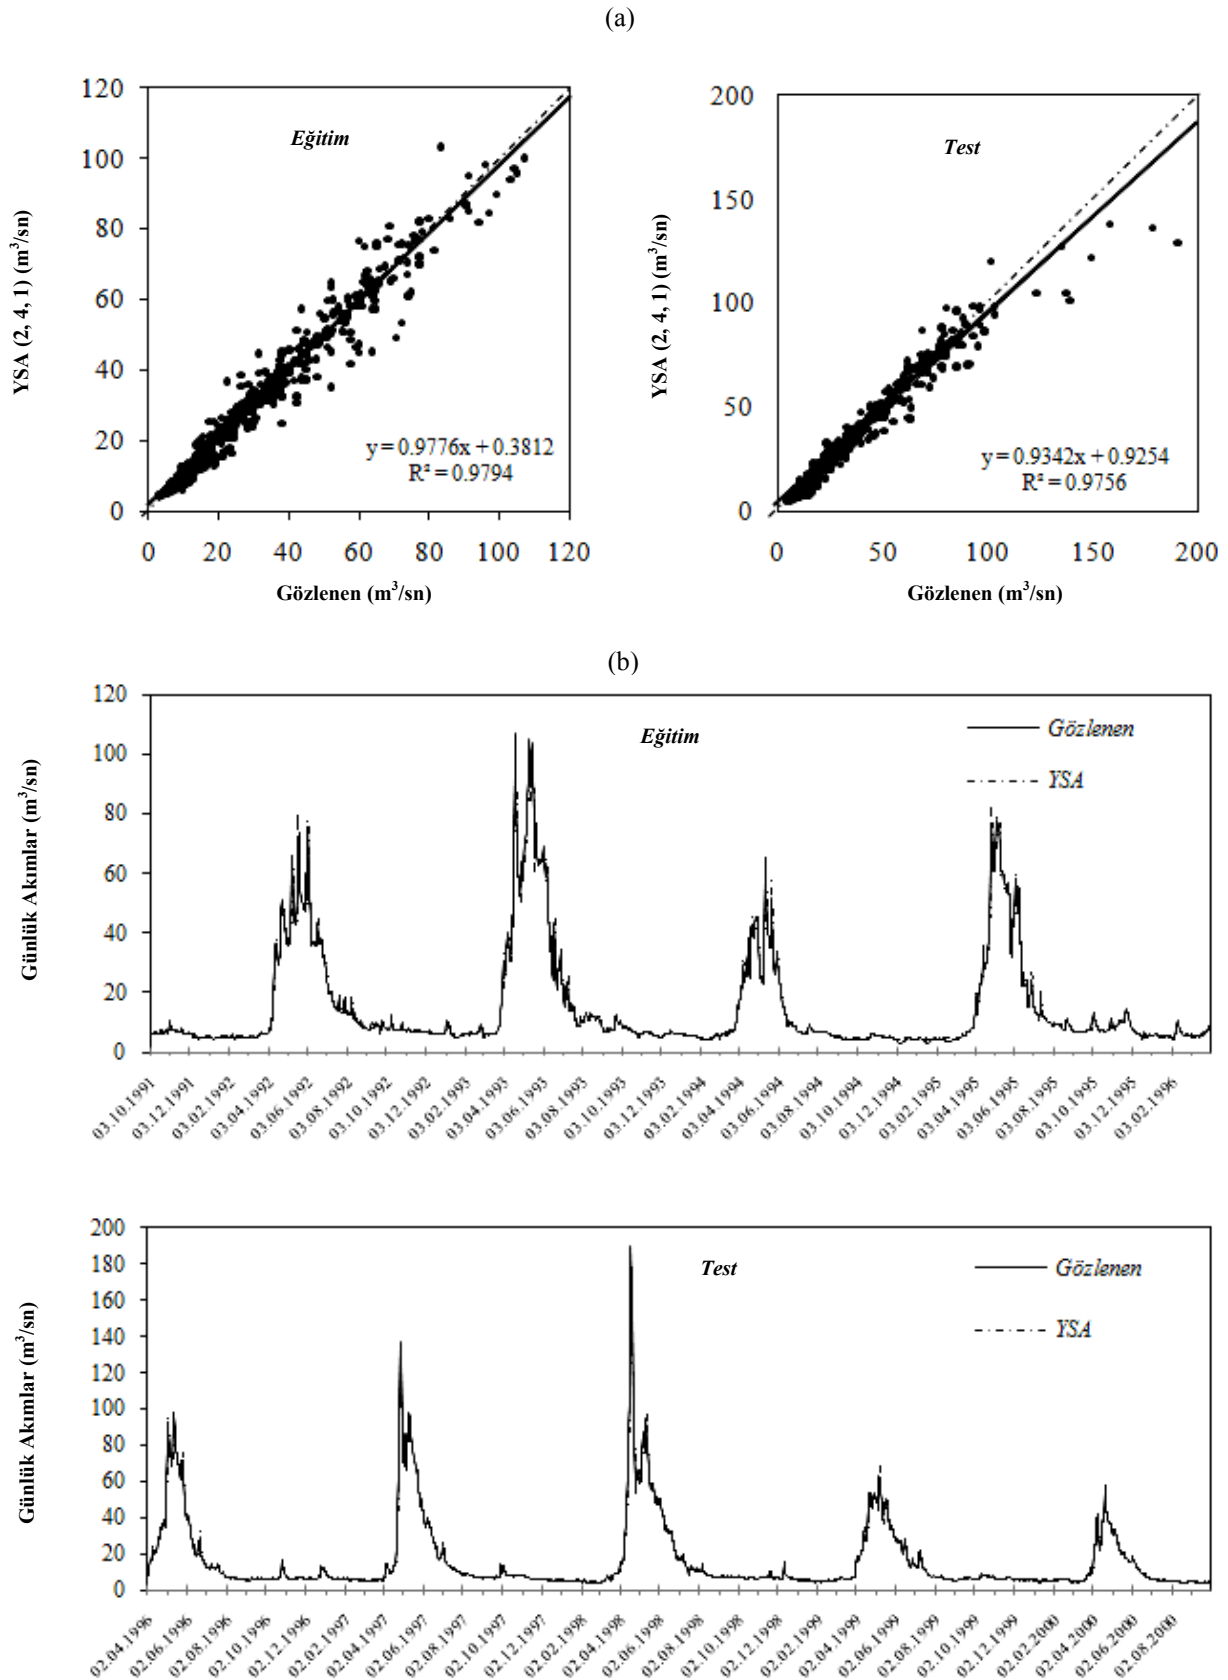
Modellerin kıyaslanması amacıyla öncelikle AR(2) modeline ait orijinal seri uzunluğunda ortalaması 0, standart sapması $\sigma_e = (0.01795)^{1/2} = 0.13397$ olan rastgele sayı setleri türetilmiş ve Denklem 20 yardımıyla yeni boyutsuz seri elde edilmiştir.

$$z_i = 1.1271z_{i-1} - 0.1375z_{i-2} + 0.13397\xi_i \quad (20)$$

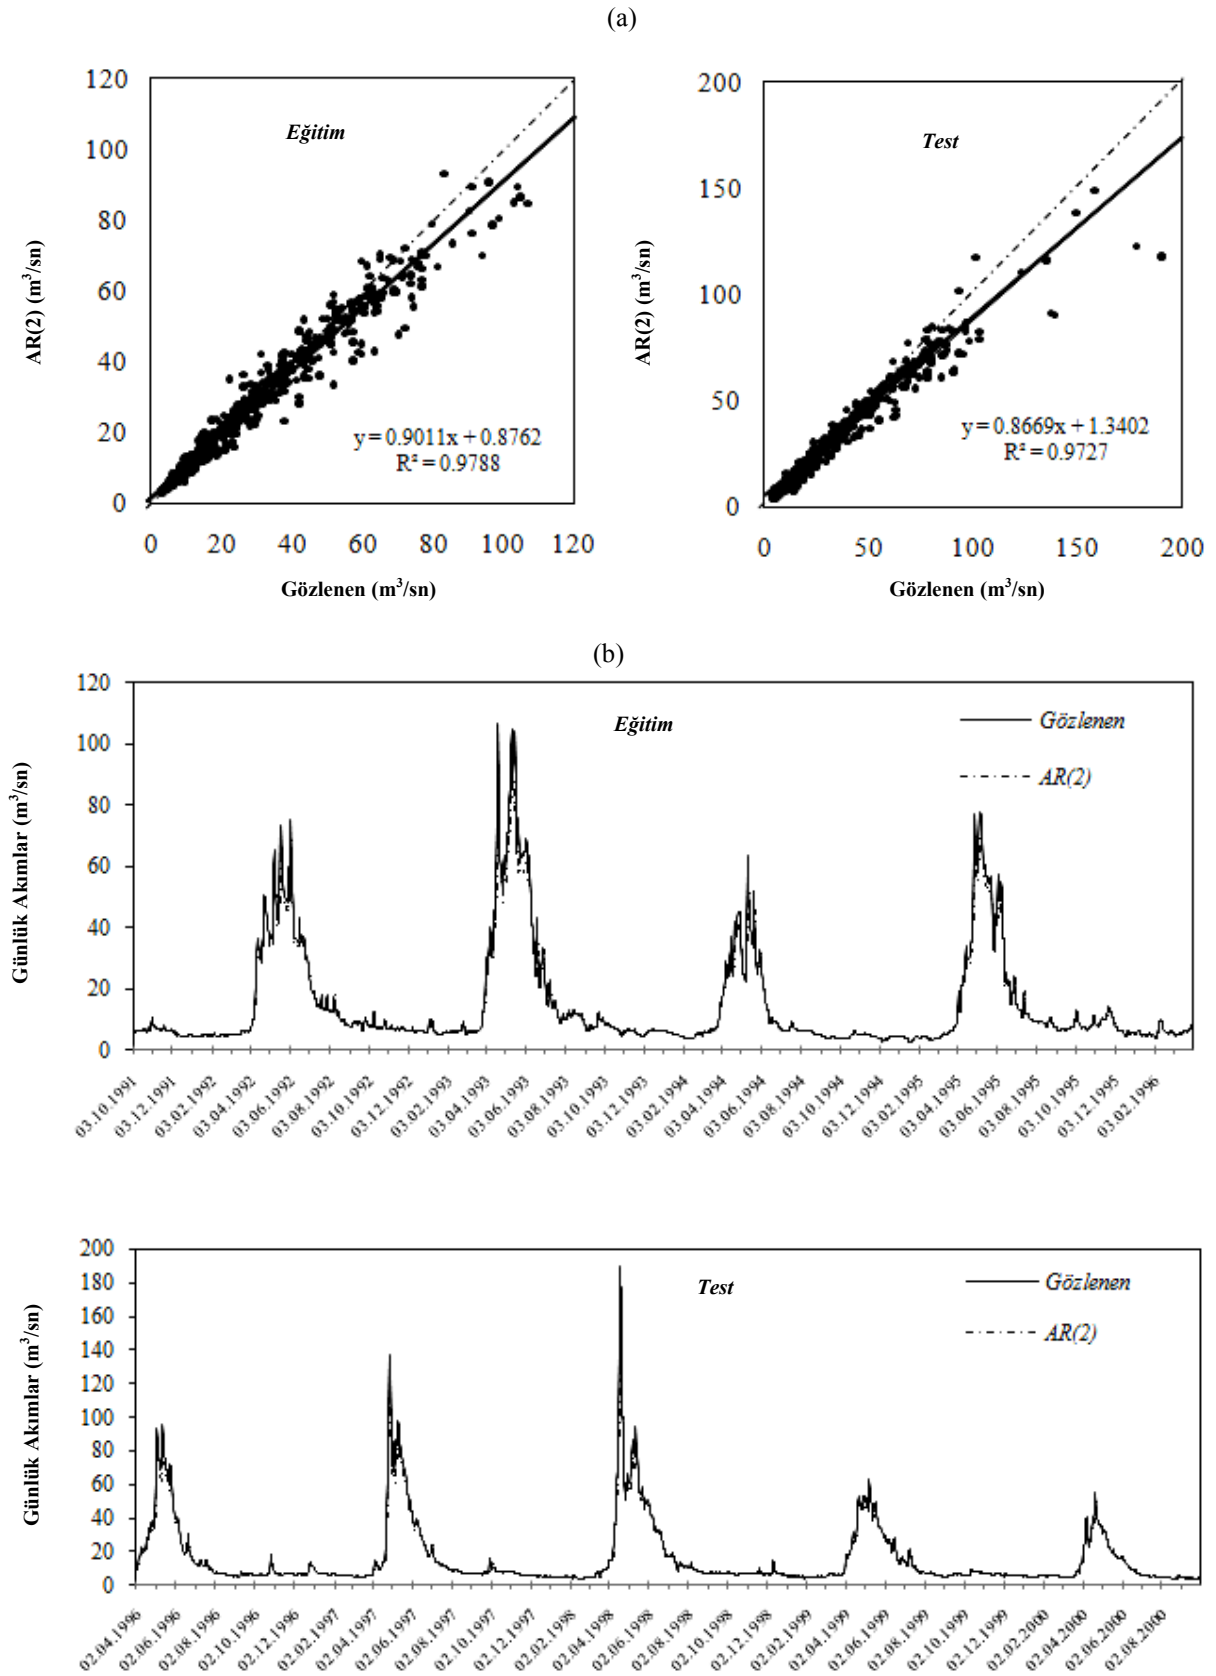
Elde edilen boyutsuz serilerin ortalaması kullanılarak, Box-Cox dönüşümünün tersi ile AR(2) modeline ait akım verileri hesaplanmıştır.

AR(2) modelinin YSA ile karşılaştırılabilmesi için AR(2) modeline ait türetilmiş serinin de 03.10.1991-01.04.1996 ve 02.04.1996-30.09.2000 kısımları ayrı ayrı değerlendirilmiştir. Modellerin eğitim ve test dönemlerine ait uzun dönem istatistikleri ise Çizelge 3(a) ve 3(b)'de gösterilmektedir.

YSA modelinin eğitim ve test dönemlerine ait saçılım diyagramları ve zamana bağlı gidişleri Şekil 6'da; AR(2) modelinin eğitim ve test dönemlerine ait saçılım diyagramları ve zamana bağlı gidişleri ise Şekil 7'de gösterilmektedir.



Şekil 6. Eğitim dönemi ve Test dönemi YSA sonuçları ile gözlenen akımlar (m^3/sn) arasındaki saçılım diyagramları (a) ve zamana bağlı gidışler (b)



Hazırlanan çalışmada, Çoruh havzasında yer alan Çoruh Nehri-Bayburt akım gözlem istasyonuna ait günlük akımlar içsel bağımlı yapı esas alınarak modellenmiştir. Bu amaçla öncelikle çarpık dağılımlı akım verilerine gerekli dönüşümler yapılarak seri boyutsuzlaştırılmış ve kısmi otokorelasyon katsayıları grafiksel açıdan incelenerek otoregresiflik mertebesine karar verilmiştir. Buna göre önerilen AR(1) ve AR(2) potansiyel modelleri arasından en uygun model ise Düzeltilmiş Akaike Bilgi Kriteri (DABK) yardımıyla belirlenmiştir. Sınama sonucu en küçük DABK değerini veren AR(2) modelinde karar kılınmış ve AR(2) modelinin genel yapısından ötürü, çalışmada iki gün önceki akım verileri (Q_{t-1} ve Q_{t-2}) yapay sinir ağı (YSA) modelinin de girdileri olarak kullanılmıştır

Modeller incelendiğinde, yöntemlerin yaklaşık sonuçlar verdiği görülmektedir. Ancak Şekil 6 ve Şekil 7 incelendiğinde hazırlanan YSA modeli için $y=x$ doğrusuna oldukça yakın bir saçılımın varlığı ve gidişlerdeki uyum göze çarpmaktadır. Çizelge 3(a)'da özetlenen uzun dönem istatistikleri ve Çizelge 3(b)'de sunulan performans sonuçları incelendiğinde de Çoruh Nehri günlük akımlarını temsil edebileceği düşünülen YSA modelinin klasik otoregresif modele göre üstünlüğü kanıtlanmıştır. Eğitim ve test dönemlerindeki hata büyüklükleri ve determinasyon katsayıları da ele alındığında YSA sonuçlarının oldukça başarılı olduğu görülmektedir.

Bunlara ilaveten, yapay sinir ağlarına sunulacak verilerin simetrik dağılımlı olma şartının olmaması ve teknik açıdan hızlı bir modelleme imkânı tanınması bakımından, YSA yaklaşımlarını akarsu havzalarının akım karakteristiklerini başarıyla modelleyebilecek bir araç olarak kullanmak mümkün gözükmemektedir. Ayrıca hazırlanan modelin iklim değişikliği öngörülerini doğrultusunda ve senaryo esaslı farklı çalışmalarda da rahatlıkla kullanılabilmesi düşünülmektedir.

Kaynaklar

Abbott, M.B. and Refsgaard, J.C. 1996. Distributed Hydrological Modelling. Kluwer Academic Publishers, Dordrecht. 17-39.

Alp, M. ve Cıgızoğlu, H. K., 2005. Yapay Sinir Ağı Metodları ve Regresyon Analizi ile Akım Tahmini, II. Ulusal Su Mühendisliği Sempozyumu, 589-598, İzmir.

Alp, M. ve Cıgızoğlu, H.K., 2004. Farklı yapay sinir ağı metodları ile yağış-akış ilişkisinin modellenmesi, İTÜ dergisi, 3(1), 80-88.

Andrews, W. H., Riley, J. P., and Masteller, M. B. 1978. Mathematical modeling of a sociological and hydrological system. ISSR Research Monograph, Utah Water Research Laboratory Utah State Univ., Logan, Utah.

Baran T. ve Bacanlı, Ü. 2006. Uygun stokastik model seçim ölçütlerinin değerlendirilmesi, İMO Teknik Dergi, 264, 3987-4002.

Bayazit, M., 1998. Hidrolojik Modeller. İTÜ, İnşaat Fakültesi Matbaası, İstanbul.

Box, G. E. P. and Jenkins, G. M., 1976. Time series analysis, forecasting and control. Holden Day Inc., San Francisco, California.

Box, G.E.P., Jenkins, G.M., and Reinsel G.C., 1994. Time series analysis forecasting and control, 3. Edition, Prentice Hall, New Jersey, USA.

Campolo, M., Andreussi, P. ve Soldati, A., 1999. River flood forecasting with a neural network model, Water Resources Research, 35, 1191-1197.

Cigizoglu, H.K., 2003. Incorporation of ARMA models into flow forecasting by artificial neural networks, Environmetrics, 14, 4, 417-427.

Durbin, J. 1960. The fitting of time series models. Rev. Inst. Int. Stat., 28, 233-243.

Fernando, D.A.K., and Jayawardena, A.W., 1998. Runoff forecasting using RBF networks with OLS algorithm, Journal of Hydrologic Engineering 3(3), 203-209.

Govindaraju, R.S. and Rao, A.R. 2000. Artificial Neural Networks in Hydrology. Kluwer: The Netherlands.

Gül, A. ve Harmancıoğlu, N. 2003. Su Kaynakları Yönetiminde Bilgisayar Modellerinin Kullanımı. I. Ulusal Su Mühendisliği Sempozyumu Bildiriler Kitabı, 735-745, İzmir.

Ham, F., and Kostanic, I., 2001. Principles of Neurocomputing for Science and Engineering. Macgraw-Hill. USA.

Haykin, S. 1994. Neural Networks: A Comprehensive Foundation. MacMillan. New York.

Hsu, K., Gupta, H.V. and Sorooshian, S., 1995. Artificial neural network modelling of the rainfall runoff process, Water Res. Research, 31, 2517-2530.

İçağa, Y. 2003. Akarçay Havzası Yağış-Akış İlişkilerinin Modellenmesi I. Ulusal Su Mühendisliği Sempozyumu, 203-214, İzmir.

Karabörk, M.Ç., ve Kahya, E., 1999, Sakarya havzasındaki aylık akımların çok değişkenli stokastik modellenmesi, Turkish J. Eng. Env. Sci., 23, 2, 133-147.

Keskin, E.M. ve Taylan D.E. 2007. Orta Akdeniz Havzasındaki Akımların Stokastik Modellenmesi, İMO Teknik Dergi, 282, 4271-4291.

- Kisi, O., 2005. Daily river flow forecasting using artificial neural networks and auto-regressive models. *Turkish Journal of Engineering and Environmental Sciences*, 29, 9–20.
- Lin, G., and Chen, L., 2004. A non-linear rainfall-runoff model using radial basis function network, *Journal of Hydrology*, 289, 1-8.
- Lin, G., Wu, M., Chen, G. and Tsai F., 2009. An RBF-based model with an information processor for forecasting hourly reservoir inflow during typhoons, *Hydrol. Process.* 23, 3598–3609.
- Mandic, D. P. and Chambers, J. A. 2001. *Recurrent Neural Networks for Prediction - Learning Algorithms, Architectures and Stability*, John Wiley & Sons Ltd.
- Méndez, M. C., Manteiga, W.G., Bande, M.F. Sánchez J.M.P. and Calderón R.L., 2004. Modelling of the monthly and daily behavior of the runoff of the Xallas river using Box–Jenkins and neural networks methods. *Journal of Hydrology*, 296, 38-58.
- Minns, A.W. and Hall, M.J., 1996. Artificial neural networks as rainfall runoff models *Hydrological Sciences Journal*, 41, 3, 399-417.
- Öztemel, E., 2003. *Yapay Sinir Ağları*. Papatya Yayıncılık. İstanbul.
- Raman, H. and Sunilkumar, N., 1995. Multivariate modelling of water resources time series using artificial neural networks, *Hydrological Sciences Journal*, 40(2), 145-163.
- Rumelhart D.E., Hinton G.E., Williams R.J. 1986. Learning representations by backpropagation errors, *Nature*, 323, 533-536.
- Salas, J.D., Delleur, J.W., Yevjevich, V., Lane, W.L., 1980. *Applied Modeling of Hydrologic Time Series*, Water Resources Publications, Colorado.
- Singh, V.P. 1995. *Watershed modeling. Computer models of watershed hydrology*. 1-22. Ed. By V.P. Singh. Water Resources Publication, USA.