

YİĞİTLER ÇAYI GÜNLÜK AKIMLARININ YAPAY SINIR AĞLARI VE REGRESYON ANALİZİ İLE MODELLENMESİ

Umut OKKAN¹, Ayşe MOLLAMAHMUTOĞLU²

¹Balıkesir Üniversitesi Mühendislik-Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Balıkesir,
umutokkan@balikesir.edu.tr

²Bayburt Üniversitesi Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Bayburt, amollamahmutoglu@bayburt.edu.tr

Geliş Tarihi: 12.05.2010

Kabul Tarihi:22.10.2010

ÖZET

Su kaynaklarının planlanması ve projelendirilmesi aşamasında, güvenilir akım tahminlerinin ve akım modelleme çalışmalarının yapılması büyük önem taşımaktadır. Sunulan çalışmada, Gediz havzasında yer alan Yiğitler Çayına ait günlük akımların modellenmesi için kullanılabilir bir yapay sinir ağı modeli (YSA) hazırlanmıştır. Hazırlanan YSA modeli çoklu doğrusal regresyon modeli ile karşılaştırılmış, model performansları, Yiğitler Çayına ait ölçülmüş günlük akım değerleri ile sınanmıştır. Analiz sonucu, yapay sinir ağı algoritması performansı regresyon modeline göre daha başarılı bulunmuştur.

Anahtar Kelimeler: *Günlük akım tahmini, yapay sinir ağları, regresyon analizi, Yiğitler Çayı*

DAILY RUNOFF MODELLING OF YIGITLER STREAM BY USING ARTIFICIAL NEURAL NETWORKS AND REGRESSION ANALYSIS

ABSTRACT

It is very important to make reliable runoff estimations and runoff modeling studies when planning and designing of water resources. In the study presented, an artificial neural network (ANN) model was established to estimate daily runoff of Yigitler Stream in Gediz basin. The ANN model was also compared with multi-linear regression model structures. Performances of each model were examined with observed daily runoff values of Yigitler Stream. After analysis, it was noticed that the artificial neural network algorithm is more successful than the regression model

Key Words: *Daily Runoff estimation, Artificial Neural Networks, Regression Analysis, Yigitler River*

1. GİRİŞ

Su kaynakları potansiyelinin belirlenmesinde, taşkın veya kuraklık durumlarında baraj haznelerinin davranışlarının kestirilmesinde ve buna bağlı gelecek dönem senaryolarının oluşturulmasında büyük önem taşıyan akım tahmin modelleri hidrolojik model çalışmalarının temelini oluşturmaktadır. Son dönemlerde gerek su kaynakları yönetimindeki stratejik çalışmalar gerekse küresel iklim değişikliğinin varlığı, sözü edilen bu akım tahmin modellerine ilginin daha da artmasına neden olmuştur.

Sözü edilen bu modeller, bir akarsu havzasına düşen yağışı akarsu çıkışındaki akışa dönüştüren mekanizmanın tanımlanmasını esas almakta olup, fiziksel tabanlı yayılı modeller (beyaz kutu modelleri), kavramsal modeller (gri kutu modelleri) ve kapalı (kara) kutu modelleri olmak üzere üç sınıfta değerlendirilebilmektedir [1, 2].

Bunlardan fiziksel tabanlı yayılı modellerde ve kavramsal modellerde, yağış ile akış ilişkilerindeki fiziksel süreç dikkate alınmakta ancak bu modeller gerek parametre gerekse algoritmanın derecesi açısından bazen karmaşık olabilmekte ve belirsiz öğeler taşıyabilmektedirler [3].

Sözü edilen bu ilişkilerdeki karmaşıklık ve belirsizliklerden dolayı, son dönemlerde yağış-akış ilişkilerinin modellenmesi genellikle olayın fiziksel yönünün dikkate alınmadığı ve sürecin ayrıntılarına girilmediği kapalı (kara) kutu modelleri ile hazırlanmakta olup modeller girdi ve çıktı değişkenleri arasında kurulan matematiksel fonksiyonlar şeklinde ifade edilmektedir.

Bu kapsamda geliştirilmiş modellerde, yağış olayının görülmesi ile akarsu çıkışında oluşacak akım arasındaki gecikmelerden yararlanılmakta ve bu kapsamda hazırlanan modeller genel olarak klasik stokastik zaman serilerini [4, 5 6], klasik regresyon analizlerini [7, 8] ve son zamanlarda önemini giderek arttıran yapay sinir ağlarını esas almaktadırlar [9, 10, 11, 12].

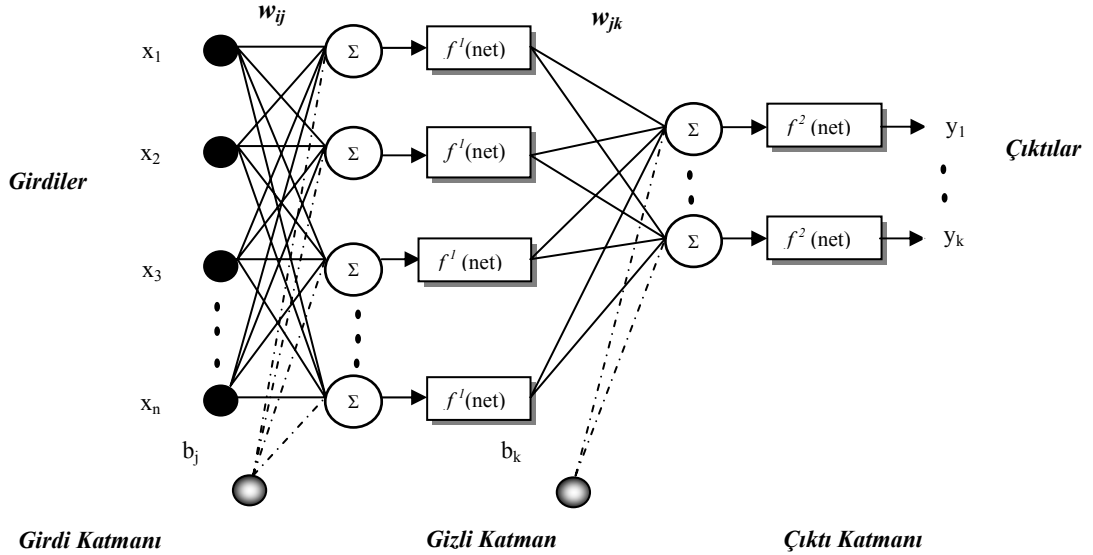
Bunlardan çoklu regresyon teknikleri en bilindik tekniklerden olup iki veya daha fazla değişken arasındaki ilişkinin matematiksel olarak ifadesini vermektedirler. Son zamanlarda birçok alanda kullanılan yapay sinir ağları ise, verilen girdilere karşı çıktılar üreten akıllı bir kara kutu modeli veya doğrusal olmayan bir regresyon modeli gibi düşünülmekte olup akım tahmin modelleri arasında sıklıkla kullanılmaktadırlar. Bu modeller incelendiğinde, yapay sinir ağı yaklaşımlarının klasik istatistiksel yöntemlere nazaran daha olumlu sonuçlar verdiği göze çarpmakta ve modellemelerde genellikle ileri beslemeli geriye yayımlı yapay sinir ağı algoritmalarının kullanıldığı görülmektedir. Bu kapsamda yapılan bazı çalışmalar şunlardır. Campolo vd. [11] ile Hsu vd. [12] yağış-akış ilişkisini yapay sinir ağları ile modellemiştir. Minns ve Hall [13] ileri beslemeli ve 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 [7, 14]. Bunların yanı sıra ileri beslemeli geriye yayımlı algoritmalara alternatif olarak geliştirilmiş olan Genelleştirilmiş Regresyon Sinir Ağı [15, 16] ve Radyal Tabanlı Sinir Ağı gibi algoritmaların da akım tahmin modeli uygulamalarına rastlanmaktadır [17, 18].

Hazırlanan çalışmada, Yiğitler Çayı günlük akımları, yağış olayının görülmesi ile akarsu çıkışında oluşacak akım arasındaki gecikmelerden yararlanılarak klasik çoklu regresyon analizi ve yapay sinir ağları ile ayrı ayrı modellenmiştir. Bu amaçla bir, iki ve üç gün önceki yağış ve akım verileri kullanılarak model performansları sınanmıştır. Çalışma kapsamında ele alınan yöntemlere ait detaylara Yöntem bölümünde değinilmiştir.

2.YÖNTEM

2.1.Yapay Sinir Ağları

Yapay sinir ağları, sinir sisteminin özelliklerinden (bilgi türetebilme, tanımlama, tahmin etme vb.) esinlenerek geliştirilen bilgisayar sistemleridir [19]. Yapay sinir ağları biyolojik sinir sistemlerinde olduğu gibi hücrelerin bir araya gelmesiyle oluşturulmakta ve genel olarak yapay sinir ağı mimarisi 3 katman halinde tanımlanmaktadır (Şekil 1).




Şekil 1. Çok tabakalı yapay sinir ağının mimarisi

İlk katman giriş katmanı; son katman ise çıkış katmanıdır. Aradaki diğer katmanlar ise gizli katman ya da ara katman olarak adlandırılmaktadır. Bir ağda birden fazla ara katman olabilmektedir. Bir yapay sinir ağında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç sinir hücresi olacağı ise bugüne kadar belirlenememiş; probleme göre değişen bu duruma deneme - yanılma yoluyla çözüm getirilebilmiştir [20, 21].

Şekil 1 incelendiğinde bir yapay sinir ağı modelinde katmanların yanı sıra; girdiler, ağırlıklar, net fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere 5 temel elemanın varlığı göze çarpmaktadır. Ağın girdi ve çıktı tabakasında probleme ait veriler bulunmaktadır. Girdi ve çıktı tabakalarındaki hücre sayıları problemde tanımlanan bilgilere bağlı değişkenlik göstermektedir. Girdi tabakasındaki bilgilerin sistem içindeki etkinlikleri ve önemi ise ağırlıklarla sağlanmaktadır. Bilgi, bu ağırlıklarda saklanmakta olup; ağın zekâsı ve öğrenme performansı ağırlık değerlerinin doğru belirlenmesine bağlı olmaktadır. Ağırlıklı girdilerin toplamı olarak bulunan *net* fonksiyonu ile ise girdilerin bu hücre üzerindeki etkileri ifade edilmektedir.

Hürelere gelen bu *net* girdiler ise bir *aktivasyon fonksiyonu* yardımıyla çıktı şeklinde çıktılara dönüştürülür ya da diğer ara hürelere bağlanır. Aktivasyon fonksiyonu doğrusal (lineer) ve doğrusal olmayan (non-lineer) özellikte olabilmektedir. Uygulamalarda genellikle tanım aralığı yaklaşık 0-1 arasında olan *sigmoid* adı verilen aktivasyon fonksiyonu kullanılmasıyla beraber (Şekil 2), hiperbolik tanjant, lineer, step gibi farklı fonksiyonlar da kullanılabilir [21].



Şekil 2. Sigmoid aktivasyon tonksiyonu

Sigmoid fonksiyonunun kullanılması halinde hücre çıktısı Denklem 1’de gösterildiği şekilde hesaplanmaktadır.

$$f(net) = \frac{1}{1 + \exp[-(net)]} \quad (1)$$

Yapay sinir ağlarının mimarisi kadar ağın eğitilmesinde, yani ağın öğrenmesinde kullanılacak yöntem de çok önemli olmakta ve bu aşamada ağın girdilere karşılık üretilmesi gereken çıktıları öğrenmesi amaçlanmaktadır. Bu kapsamda birçok yapay sinir ağı algoritması geliştirilmesine karşın uygulamalarda sıklıkla kullanılan algoritmalar **ileri beslemeli geri yayımlı** yapay sinir ağı algoritmalarıdır. Algoritmanın bu ismi almasının temel sebebi ise algoritmanın işleyişinin ileriye doğru hesaplama ve geriye doğru hesaplama olmak üzere iki aşamada gerçekleşmesidir.

İleri doğru hesaplama aşamasına, yukarıda özetlendiği gibi girdi katmanındaki girdilerin ağa sunulması ile başlanmaktadır. Gizli katmandaki her hücre girdi katmanından gelen girdileri bağlantı ağırlıkları ile almakta ve gizli katmandaki hücelere gelen net girdiler hesaplanmaktadır. Bu net girdi değerlerinin belirlenen bir aktivasyon fonksiyonundan geçirilmesiyle gizli katman elemanlarının çıktıları hesaplanabilmektedir. Bu işlem tüm gizli katman ve çıktı katman elemanları için tekrarlanmakta; çıktı katmanının tüm çıktıları belirlendiğinde ileri hesaplama aşaması tamamlanmaktadır.

İleri doğru hesaplama aşamasında, bir yapay sinir ağının girdileri, çıktıları dönüştüren mekanizması Denklem 2’de gösterilmektedir.

$$y_k = f_2 \left\{ \sum_{j=1}^k [f_1 \left(\sum_{i=1}^n x_i w_{ij} + b_j \right)] w_{jk} + b_k \right\} \quad (2)$$

Burada;

- x_i : ağın girdilerini ($i=1,2, \dots, n$)
- w_{ij} : girdi katmanı ile gizli katman arasındaki ağırlıkları,
- b_j : girdi katmanı ile gizli katman arasındaki eşik (bias) terimlerini,
- f_1 : girdi katmanı ile gizli katman arasındaki aktivasyon (transfer) fonksiyonunu,
- f_2 : çıktı katmanı ile gizli katman arasındaki aktivasyon (transfer) fonksiyonunu,
- j : gizli katmana ait hücre sayısını,
- n : girdi katmanındaki hücre sayısını,
- k : çıkış katmanındaki hücre sayısını,
- w_{jk} : çıktı katmanı ile gizli katman arasındaki ağırlıkları,
- b_k : çıktı katmanı ile gizli katman arasındaki eşik (bias) terimlerini göstermektedir.

Bununla birlikte yapay sinir ağı modellerinde ağın genelleme yeteneğinin değerlendirilebilmesi açısından ağın girdi ve çıktı değerlerinin hepsi kullanılmamakta, belli bir kısmı eğitim, belli bir kısmı ise test safhalarında değerlendirilmektedir [20, 21].

Geriye doğru hesaplama aşamasında ise ağın ürettiği çıktı değerleri beklenen çıktı değerleri ile karşılaştırılmaktadır. Çıktı ile beklenen değerler arasındaki fark yapay sinir ağı modellerinde hata olarak adlandırılmakta ve geriye yayılım aşamasında bu hatanın kabul edilebilir düzeye indirilebilmesi ağın ağırlık ve eşik (bias) değerlerinin iteratif olarak değiştirilmesi ile mümkün olmaktadır. Böylece başlangıçta rastgele atanan ağın ağırlıkları hata istenen sınırlara ulaşıncaya kadar güncellenmektedir. Bu yapay sinir ağı modellerinde hata kareler toplamı veya ortalaması hesabına dayalı performans (amaç) fonksiyonu ile [22] gerçekleştirilebilmektedir (Denklem 3).

$$E(w) = \frac{1}{2} \sum_{i=1}^n e_i^2(w) \quad (3)$$

Burada; $E(w)$ performans fonksiyonunu, w ağırlıklarının, $e(w)$ ise çıktı ile beklenen değerler arasındaki farkı göstermektedir.

Bu kapsamda, belirlenen performans fonksiyonunu en küçükleyecek ileri beslemeli geri yayımlı yapay sinir ağı algoritmaları geliştirilmiş ve uygulamalarda kullanılmıştır. Klasik geriye yayılım algoritması, Momentum terimli geriye yayılım algoritması gibi deneme yanılma yöntemini kullanan ağlar bunlardan sadece bazılarıdır. Bu klasik algoritmaların yanı sıra sayısal optimizasyon yöntemlerini kullanan ve çözümlenmelerde hızlı yakınsama sağlayan Newton ve Levenberg-Marquardt algoritmaları da sıklıkla tercih edilir hale gelmiştir [23, 24, 25].

Hazırlanan çalışmada, yukarıda sözü edilen ileri beslemeli geri yayımlı ağ algoritmalarının gelişmiş bir türü olan **Levenberg-Marquardt** algoritmasından yararlanılmıştır.

Levenberg – Marquardt algoritmasında Newton algoritmasından farklı olarak, Hessian matrisi ($H(w)$) adı verilen çözümlenmesi karışık bir matrisin yaklaşık değeri kullanılmaktadır [26]. Bu çözüm Denklem 4 yardımıyla yapılabilmektedir [27].

$$H(w) \cong J^T(w)J(w) + \mu I \quad (4)$$

Denklem 4'te; μ , Marquardt parametresini, I ise birim matrisi simgelemektedir. Buradaki J matrisi ise, Jakobien matris olarak adlandırılmakta ve ağ hatalarının ağırlıklara göre birinci türevlerinden elde edilmektedir.

Ağın hatasının geri yayılması aşamasında, öncelikle Jakobien matrisin transpozunu ve ağ hataları kullanılarak ağın gradyeni hesaplanmaktadır (Denklem 5).

$$\nabla E(w) = J^T(w)e(w) \quad (5)$$

Ağın gradyeni hesaplandıktan sonra, ağın ağırlıklarındaki vektörel değişim Hessian matrisinin tersi ile ağın gradyeninin çarpılmasıyla belirlenmekte (Denklem 6) ve ağın ağırlıkları Denklem 7'de gösterildiği gibi güncellenmektedir.

$$\Delta w = -[H(w)]^{-1} \nabla E(w) \quad (6)$$

$$w_{yeni} = w_{eski} + \Delta w \quad (7)$$

Levenberg-Marquardt algoritmasında en önemli parametre, μ olup skaler bir sayı olarak tanımlanmaktadır. Eğer μ sıfıra yakınsarsa, yöntem Newton algoritması gibi işleyişini sürdürmekte; μ büyük bir sayıyı temsil ettiğinde ise yöntem küçük adımlı gradyen azalması yöntemi haline gelmektedir [27, 28].

2.2. Çoklu Doğrusal Regresyon Analizi

İki değişken arasındaki doğrusal bağıntı en basit matematiksel ifadesi: $Y = a + bx + \varepsilon$ olarak gösterilir. Bu denkleme dayanarak, bağımlı değişken y 'nin, bağımsız değişken varsayılan x 'in belli bir düzeyi için alabileceği ölçümsel sonuç $\pm \varepsilon$ kadar bir hata yapmak göze alınarak modellenebilir [29].

Bağımsız değişken sayısının birden fazla olduğu durumlarda (x_1, x_2, x_3, \dots gibi) denklemin genel yapısı da;

$$Y = a + b_1x_1 + b_2x_2 + b_3x_3 + \dots + b_nx_n \pm \varepsilon \quad (8)$$


şeklini almakta ve böyle denklemler çoklu regresyon denklemleri olarak adlandırılmaktadır [29, 30]. Denklemlerdeki a (bias), b_1, b_2, \dots, b_n parametreleri ise en küçük kareler yaklaşımı ile hesaplanabilmektedir.

Bu denklemlerde, hazırlanan modelin gerçeğe uygunluğunu yansıtan gösterge ise, tanım aralığı 0-1 arasında olan determinasyon katsayısı (R^2) olarak adlandırılan ölçüttür. Bu katsayı bağımlı değişkenin gözlenen değeri ile modelde tahminlenen değeri arasındaki korelasyon katsayısının karesidir. Değer, bağımlı değişkendeki oynamaların yüzde kaçının bağımsız değişkendeki farklılaşmalardan kaynaklandığını yansıtmakta ve nedensellik hakkında belirgin fikir vermektedir [29, 30].

3. UYGULAMA

3.1. Uygulama Havzası ve Verilerin Derlenmesi


Gediz Havzası'nda, Yiğitler kasabasının yakınlarında yer alan Yiğitler çayı Gediz nehrinin en büyük kolu olan Nif çayının bir parçası olup *Yiğitler Barajı'nı* beslemektedir. Çalışmada Elektrik İşleri Etüt İdaresi (EIE) tarafından işletilen ve 64 km² yağış alanına sahip 525 numaralı Yiğitler akım gözlem istasyonuna ait 01.10.2002 – 30.09.2006 tarihleri arasında gözlemlenmiş toplam 1461 adet günlük akım verisi (Şekil 3) kullanılmıştır.



Şekil 3. EIE-525 günlük akımlarının gidişleri

Havzayı temsil edeceği düşünülen yağış istasyonları incelendiğinde, bölgede Devlet Meteoroloji İşleri (DMI) tarafından işletilen Turgutlu (5615) ve Kemalpaşa (5785) meteoroloji istasyonları tespit edilmiştir. Ancak Kemalpaşa (5785) istasyonuna ait verilerin eksikli olması nedeniyle, çalışmada Turgutlu (5615) istasyonuna ait yağış verilerinin kullanılmasına karar verilmiştir.

Şekil 4'te Yiğitler havzasının Gediz havzası üzerindeki konumu ve kullanılan EIE-525 akım gözlem istasyonu ile DMI-5615 yağış gözlem istasyonu gösterilmiştir. Kullanılan yağış ve akım verilerine ait temel istatistikler ise Çizelge 1'de özetlenmiştir. İstatistikler incelendiğinde verilerin normal dağılım göstermediği gerek çarpıklık gerekse değişkenliklere bakılarak anlaşılabilmektedir.



Şekil 4. Nif çayının ve kullanılan akım - yağış gözlem istasyonlarının Gediz Havzası üzerindeki konumu

Çizelge 1. Akım (Q_t) ve yağış (P_t) verilerine ait temel istatistikler

(a)								
	Ortalama	Std. Sapma	Değişkenlik	Minimum	Maksimum	Çarpıklık	Basıklık	Otokorelasyon
	m^3/sn	m^3/sn	-	m^3/sn	m^3/sn	-	-	-
Q_t	0.664	1.221	1.839	0.002	14.700	4.670	32.720	0.832

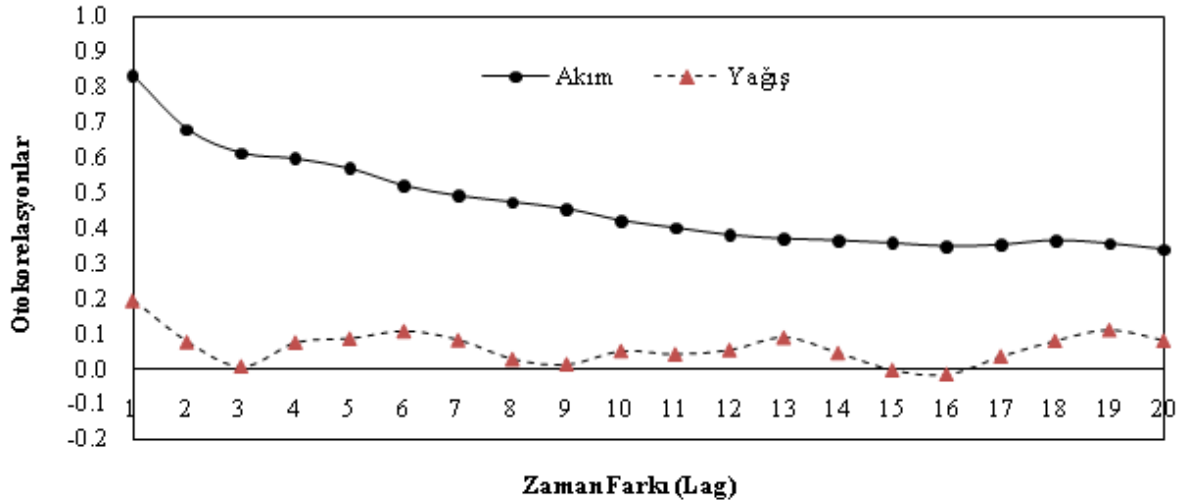
(b)								
	Ortalama	Std. Sapma	Değişkenlik	Minimum	Maksimum	Çarpıklık	Basıklık	Otokorelasyon
	mm	mm	-	mm	mm	-	-	-
P_t	1.446	5.285	3.655	0.000	56.200	5.580	37.630	0.194

3.2. Modellere Ait Girdilerin Belirlenmesi

Kurulan modellerin girdilerinin belirlenmesi aşamasında, günlük yağış ve günlük akım değerlerinin arasındaki korelasyonlar (Çizelge 2) ile günlük akım ve yağış verilerine ait otokorelasyonlardan (Şekil 5) yararlanılmıştır.

Çizelge 2. Günlük yağış ve akım verileri arasındaki korelasyonlar

	Q_t	P_t	P_{t-1}	P_{t-2}	P_{t-3}	Q_{t-1}	Q_{t-2}	Q_{t-3}
Q_t	1.000	0.447	0.292*	0.200	0.181	0.832*	0.680	0.613
P_t	0.447	1.000	0.194	0.076	0.007	0.308	0.134	0.091
P_{t-1}	0.292*	0.194	1.000	0.195	0.076	0.447	0.308	0.134
P_{t-2}	0.200	0.076	0.195	1.000	0.196	0.293	0.449	0.310
P_{t-3}	0.181	0.007	0.076	0.196	1.000	0.200	0.293	0.449
Q_{t-1}	0.832*	0.308	0.447	0.293	0.200	1.000	0.832	0.680
Q_{t-2}	0.680	0.134	0.308	0.449	0.293	0.832	1.000	0.832
Q_{t-3}	0.613	0.091	0.134	0.310	0.449	0.680	0.832	1.000



Şekil 5. Günlük yağış ve günlük akımların otokorelasyon değerleri

Günlük yağış ve günlük akım verilerinin Şekil 5'te gösterilen otokorelasyon sonuçlarına göre t günündeki akım değerlerinin bir, iki ve üç gün önceki değerler ile yüksek korelasyon gösterdiği; fakat t günündeki yağış değerlerinin bir, iki ve üç gün önceki değerler ile düşük korelasyon gösterdiği görülmektedir.

Bununla birlikte Çizelge 2' de verilen günlük yağış ve günlük akımlar arasında oluşturulan korelasyon matrisi incelendiğinde günlük akım değerleri ile o günkü yağış ve bir önceki günkü akım değerlerinin daha yüksek korelasyonlar gösterdiği göze çarpmaktadır. Günlük yağış ve günlük akım değerleri arasındaki ilişkinin ise düşük olduğu görülmüş, bu nedenle modellerde önceki yağış girdilerinin kullanılmasının performansı ne ölçüde etkileyeceği de araştırılmıştır.

Bu sebeplerden ötürü, çalışmada öncelikle yağış (P_t) girdisi ile modeller kurulmuştur. Ancak yağış olayının görülmesi ile akarsu çıkışında oluşacak akım arasındaki gecikmeler de düşünülerek modele sırasıyla 1 gün önceki yağış (P_{t-1}), 2 gün önceki yağış (P_{t-2}) ve 3 gün önceki yağış (P_{t-3}) girdileri de eklenmiştir. En son olarak modele 1 gün (Q_{t-1}), 2 gün (Q_{t-2}) ve 3 gün (Q_{t-3}) önceki akım değerleri de ilave edilmiş, akımlardaki içsel bağımlılık etkisi de dikkate alınarak modeller irdelenmiştir. Çalışmada son olarak, optimum sayıda girdi kullanan model yapısı da aranmaya çalışılmıştır. Çünkü uygun sayıda tahminleyicinin yani girdinin kullanımıyla, akımı yüksek bir doğrulukla kestirebilme olanağı varsa, modellerin fazla sayıda girdi içermesi gereksiz görülmektedir.

3.3. YSA ve Çoklu Doğrusal Regresyon Modellerinin Hazırlanması

Modelleme çalışmalarında farklı girdi kombinasyonlarının uygulanmasından ötürü modeller 04.10.2002-30.09.2006 takvim yılları arasındaki veriler dikkate alınarak hazırlanmıştır. Böylece 04.10.2002-30.09.2006 tarihleri arasında çalıştırılan modelde, 1, 2 ve 3 gün önceki veriler de sırasıyla 03.10.2002, 02.10.2002 ve 01.10.2002 tarihlerinden başlanarak derlenmiştir.

Modellerin genelleme yeteneğinin sınanması açısından, modeller 1458 adet veri içeren veri setinin %80'i (04.10.2002- 12.12.2005) ile kurulmuş (eğitilmiş), geri kalan % 20'si (13.12.2005-30.09.2006) ile test edilmiştir. Bu aşamada MATLAB ortamında programlanan Levenberg-Marquardt Yapay Sinir Ağı algoritması ve sigmoid aktivasyon fonksiyonu kullanılmıştır.

Veriler sigmoid fonksiyonunun özelliğinden ötürü, $(x-x_{\min})/(x_{\max}-x_{\min})$ bağıntısıyla 0 ile 1 arasında ölçeklendirilerek ağa sunulmuştur. Böylece veriler arasındaki uzaklıklar ortadan kaldırılarak ağın eğitim aşamasında daha hızlı yakınsaması sağlanmıştır. Eğitim işlemi tamamlandıktan sonra ölçeklendirilmiş çıktılar ters işlem ile orijinal ölçeğine dönüştürülmüştür.

Ağın eğitiminde, gizli katmandaki hücre sayısı, başlangıç Marquardt (μ_0) parametresi ve ağın iterasyon sayısı deneme yanılma yoluyla, Denklem 3'te belirtilen toplam karesel hata değeri $E(w)$ 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.

YSA modelleri hazırlandıktan sonra çoklu doğrusal regresyon (ÇDR) modeli ile kıyaslanmıştır. ÇDR modeli uygulamasında da YSA modelinde kurulan girdiler kullanılmıştır. Çoklu regresyon modeli ile YSA modelinin kıyaslanması amacıyla çoklu regresyon modeli de 1458 adet veri içeren veri setinin %80'i (04.10.2002-12.12.2005) ile kurulmuş (eğitilmiş), geri kalan % 20'si (13.12.2005-30.09.2006) ile test edilmiştir.

3.4. Modellerin Değerlendirilmesi

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 9, 10 ve 11 yardımıyla yapılabilmektedir.

$$HKO = \frac{1}{N} \sum_{i=1}^N (b_i - y_i)^2 \quad (9)$$

$$HKOK = \sqrt{\frac{1}{N} \sum_{i=1}^N (b_i - y_i)^2} \quad (10)$$

$$R^2 = \frac{\sum_{i=1}^N (b_i - b_{ort})^2 - \sum_{i=1}^N (b_i - y_i)^2}{\sum_{i=1}^N (b_i - b_{ort})^2} \quad (11)$$

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

Farklı girdi kombinasyonları ile hazırlanan modellere ait sonuçlar Çizelge 3(a) ve 3(b)'de verilmiştir.

Çizelge 3. Çoklu doğrusal regresyon ve yapay sinir ağı modellerine ait uzun dönem temel istatistikler

(a)


Girdiler	R^2		HKO m^6/sn^2		HKOK m^3/sn	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
P_t	0.25	0.09	0.96	2.17	0.98	1.47
P_t, P_{t-1}	0.31	0.11	0.88	2.13	0.94	1.46
P_t, P_{t-1}, P_{t-2}	0.32	0.13	0.86	2.09	0.93	1.45
$P_t, P_{t-1}, P_{t-2}, P_{t-3}$	0.34	0.15	0.84	2.04	0.92	1.43
$P_t, P_{t-1}, P_{t-2}, P_{t-3}, Q_{t-1}$	0.77	0.68	0.29	0.76	0.54	0.87
$P_t, P_{t-1}, P_{t-2}, P_{t-3}, Q_{t-1}, Q_{t-2}$	0.78	0.67	0.28	0.78	0.53	0.88
$P_t, P_{t-1}, P_{t-2}, P_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3}$	0.78	0.68	0.28	0.76	0.53	0.87

(b)

Girdiler	GKHS	R^2		HKO m^6/sn^2		HKOK m^3/sn	
		Eğitim	Test	Eğitim	Test	Eğitim	Test
P_t	6	0.33	0.12	0.85	2.15	0.92	1.47
P_t, P_{t-1}	19	0.36	0.16	0.83	2.08	0.91	1.44
P_t, P_{t-1}, P_{t-2}	4	0.38	0.17	0.80	2.01	0.89	1.42
$P_t, P_{t-1}, P_{t-2}, P_{t-3}$	7	0.47	0.18	0.67	1.97	0.82	1.40
$P_t, P_{t-1}, P_{t-2}, P_{t-3}, Q_{t-1}$	3	0.85	0.74	0.19	0.64	0.44	0.80
$P_t, P_{t-1}, P_{t-2}, P_{t-3}, Q_{t-1}, Q_{t-2}$	6	0.85	0.76	0.19	0.65	0.44	0.80
$P_t, P_{t-1}, P_{t-2}, P_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3}$	17	0.88	0.76	0.16	0.56	0.40	0.75

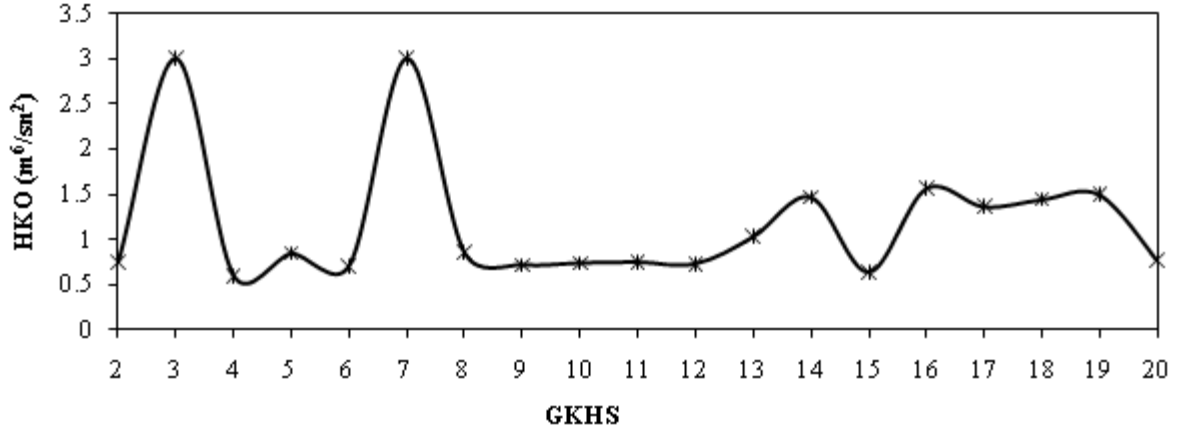
Sonuçlar incelendiğinde YSA sonuçlarının ÇDR sonuçlarına göre daha başarılı olduğu göze çarpmaktadır. Her iki yöntemde de sadece yağış girdilerinin kullanılması tatmin edici sonuçlar vermemiştir. Ayrıca t günündeki yağış girdisi dışında modellere eklenen bir, iki ve üç gün önceki yağış girdileriyle de anlamlı değişimler elde edilememiştir. Bu sebepten ötürü modellere bir, iki ve üç gün önceki akım değerleri de eklenmiş ve içsel bağımlılık etkisinin de dâhil edildiği bu yaklaşımlarla daha anlamlı sonuçlar gözlemlenmiştir. Ancak iki ve üç gün önceki akım değerlerinin eklendiği içsel bağımlı model yapılarının da bir gün önceki akım girdisi ile çalıştırılan modelden çok büyük farklılıklar taşımadığı görülmüştür.

Bu sebeplerden ötürü çalışmada optimum sayıda girdi ile anlamlı sonuçlar veren bir başka YSA modeli daha denenmiştir. Bu model yapısı, t günündeki yağış (P_t) ve bir gün önceki akım verileri (Q_{t-1}) ile hazırlanmış olup; ağırlık genelleme yeteneğini kaybetmemesi, dolayısıyla aşırı öğrenme durumundan performansının bozulmaması için eğitim aşamasında yaptırılan 50 adet iterasyon yeterli görülmüştür. Bu durum Levenberg-Marquardt algoritmasının diğer YSA algoritmalarına kıyasla daha hızlı yakınsama özelliğine sahip olduğunu da destekler niteliktedir [23, 24, 26]. Yaptırılan bu 50 iterasyon boyunca Marquardt (μ) parametresindeki ve ağırlık gradyanındaki değişim Şekil 6(a) ve 6(b)'de gösterilmektedir. Modelin ürettiği çıktılar ise istatistiksel (Çizelge 4) ve grafiksel (Şekil 8) olarak vurgulanmıştır.

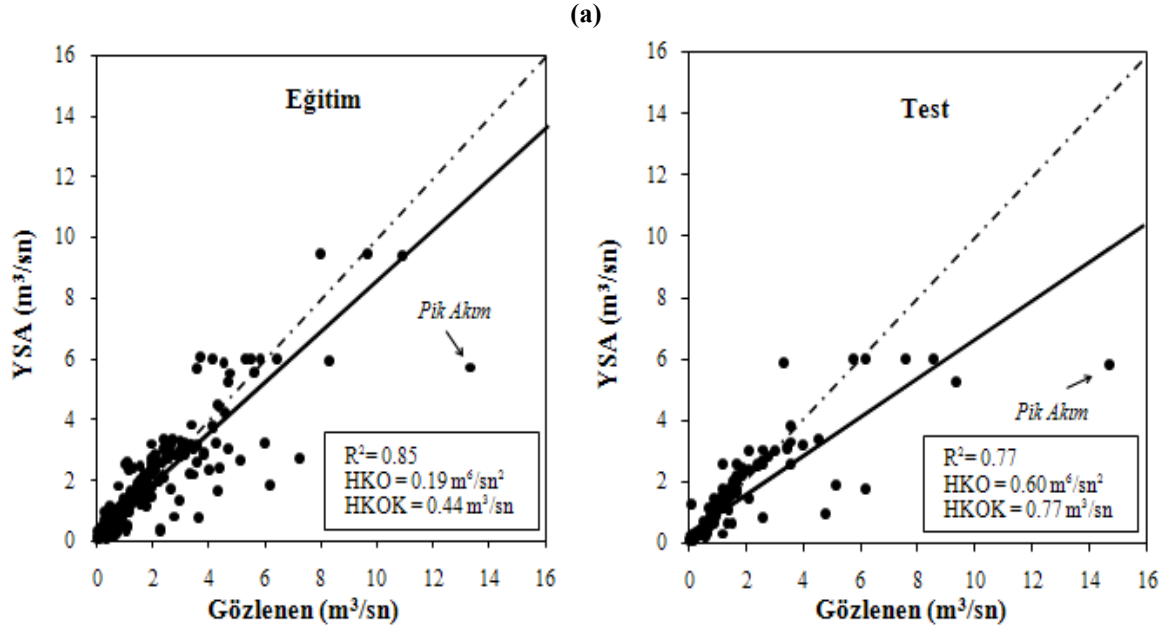


Şekil 6. Marquardt (μ) parametresindeki ve ağırlık gradyanındaki değişim


Şekil 7’de ise 2 ile 20 denenen gizli katmandaki hücre sayılarının (GKHS) test dönemindeki HKO performansları gösterilmektedir. Buna göre ağa, gizli katmanda kullanılan 4 adet hücrenin en iyi performansı verdiği görülmektedir.



Şekil 7. Gizli katmandaki hücre sayılarının test dönemindeki hata kareler ortalaması performansları



(b)



Şekil 8. Eğitim dönemi ve Test dönemi YSA sonuçları ile gözlenen akımlar (m^3/sn) arasındaki saçılım diyagramları (a) ve zamana bağlı gidişler (b)

Çizelge 4. Optimum girdi içeren YSA modelinin eğitim ve test dönemlerine ait istatistikler
(a)

		Ortalama m ³ /sn	S. Sapma m ³ /sn	Çarpıklık -	Maksimum m ³ /sn	Minimum m ³ /sn
Eğitim	Gözlenmiş	0.63	1.13	4.44	13.30	0.00
	YSA	0.64	1.03	3.71	9.45	0.10
Test	Gözlenmiş	0.82	1.54	4.62	14.70	0.00
	YSA	0.76	1.12	2.81	6.05	0.10

(b)

R ² -		HKO m ⁶ /sn ²		HKOK m ³ /sn	
Eğitim	Test	Eğitim	Test	Eğitim	Test
0.85	0.77	0.19	0.60	0.44	0.77

4. SONUÇLAR

Sunulan çalışmada, Yiğitler çayı günlük yağış-akış ilişkisi, yağış olayının görülmesi ile akarsu çıkışında oluşacak akım arasındaki gecikmelerden yararlanılarak regresyon analizi ve yapay sinir ağları ile ayrı ayrı modellenmiştir. Yapay sinir ağı uygulamasında ise ileri beslemeli geri yayımlı ağ algoritmalarının gelişmiş bir türü olan Levenberg-Marquardt algoritması kullanılmıştır. Levenberg-Marquardt algoritması, diğer ileri beslemeli geri yayımlı ağ algoritmalarında olduğu gibi öğrenme oranı, momentum oranı gibi deneme-yanılma yöntemiyle belirlenebilecek birden çok parametre içermemesi, diğer algoritmalara kıyasla daha hızlı yakınsaması ve daha güvenilir sonuçlar vermesi sebebiyle tercih edilmiştir.

Regresyon ve yapay sinir ağı modellerine ait girdilerin belirlenmesi aşamasında günlük yağış ve günlük akım değerlerinin arasındaki korelasyon matrisinden ve günlük yağış-akış verilerine ait otokorelasyonlardan yararlanılmıştır. Üç gün önceki yağış ve akım gecikmelerinin dâhil edildiği analizlerde, günlük akım değerleri ile o günkü yağış ve bir önceki günlük akım değerlerinin daha yüksek korelasyonlar gösterdiği göze çarpmaktadır. Günlük yağış ve günlük akım değerleri arasındaki ilişkinin ise düşük olduğu görülmüştür. Bu sebepten ötürü, modellere önceki yağış girdileri de eklenerek performansın ne ölçüde değişeceği de araştırılmıştır. Böylece bağımlı değişken olarak tanımlanan akımların, bağımsız değişken olarak tanımlanan üç gün önceki yağış-akım verileri ile ilişkisinin yanı sıra, bağımsız değişkenler arasındaki iç ilişkiler de irdelenmiştir.

Veri setinin %80'i ile kurulan (eğitilen) modellerde, öncelikle yağış (P_t) girdisi kullanılmıştır. Daha sonra modellere sırasıyla bir gün önceki yağış (P_{t-1}), iki gün önceki yağış (P_{t-2}) ve üç gün önceki yağış (P_{t-3}) girdileri de eklenmiştir. En son olarak modele 1 gün (Q_{t-1}), 2 gün (Q_{t-2}) ve 3 gün (Q_{t-3}) önceki akım değerleri de ilave edilerek akımlardaki içsel bağımlılık etkisi de modellerde dikkate alınmıştır. Çalışmada son olarak, optimum sayıda girdi kullanan model yapısı da aranmaya çalışılmıştır. Tüm modeller veri setinin geri kalan % 20'si ile test edilmiştir.

Sonuçlar incelendiğinde yapay sinir ağı sonuçlarının regresyon sonuçlarına göre daha başarılı olduğu göze çarpmaktadır. Her iki yöntemde de sadece yağış girdilerinin kullanılması anlamlı sonuçlar vermemiştir. Ayrıca t günündeki yağış girdisi dışında modellere eklenen bir, iki ve üç gün önceki yağış girdileriyle de anlamlı değişimler gözlenmemiştir. Bu sebepten ötürü modellere bir, iki ve üç gün önceki akım değerleri de eklenmiş ve bu yaklaşımlarla daha anlamlı sonuçlar elde edilmiştir. Ancak iki ve üç gün önceki akım değerlerinin eklendiği

içsel bağımlı model yapılarının da bir gün önceki akım girdisi ile çalıştırılan modelden çok büyük farklılıklar taşımadığı görülmüştür.

Bu sebeplerden ötürü çalışmada optimum sayıda girdi ile anlamlı sonuçlar veren bir başka YSA modeli daha denenmiştir. Bu model yapısı, t günündeki yağış (P_t) ve bir gün önceki akım verileri (Q_{t-1}) ile hazırlanmıştır. Hazırlanan modele ait istatistikler incelendiğinde modelin başarılı olduğu düşünülmektedir. Saçılım diyagramları, determinasyon katsayıları ve ortalama karesel hata değerleri dikkate alındığında da sonuçların tatmin edici olduğu düşünülmektedir. Ancak eğitim dönemine rastlayan $13.3 \text{ m}^3/\text{sn}$ ve test dönemine rastlayan $14.7 \text{ m}^3/\text{sn}$ değerindeki gözlenen pik akımlar doğru tahmin edilememiştir. Bu durumun yapay sinir ağı modelinin test dönemine göre daha düşük akım istatistikleri ile eğitilmiş olmasından kaynaklandığı düşünülmektedir. Çizelge 4'te gerek ortalama akımlar gerekse pik akımlar açısından test döneminin daha sulak olduğu görülmektedir. Ancak uzun dönem ortalama, standart sapma istatistikleri ve düşük akım tahminleri açısından model, eğitim ve test dönemlerinde başarılı bulunmuştur.

Bu girdi değişkenlerine ilave olarak iki veya daha fazla gün önceki akım ve yağış girdileri ile akımların içsel bağımlılık etkisi de artırılabilen ve böylece modellerin performanslarının daha da iyileşebileceği düşünülmektedir. Ancak, az sayıda girdi değişkeni kullanımıyla akım değerini yüksek bir doğrulukla kestirebilme olanağı varsa, anlamlı bile olsalar diğer değişkenleri kullanmaya kalkışmak gereksiz görülmüştür. Bu sebepten ötürü çalışma kapsamında ele alınan YSA girdilerinin Yiğitler baraj akımlarını modellemede yeterli olduğu düşünülmüştür.

Sonuç olarak, yapay sinir ağları ile hazırlanan akım modellerinin akarsu havzalarının doğrusal olmayan yağış-akış ilişkilerini başarıyla modelleyebildiği, kavramsal ve fiziksel tabanlı modellere kıyasla yoğun verilere ve kalibrasyon işlemlerine gerek kalmaksızın hızlı bir modelleme imkanı tanıdığı görülmektedir.

TEŞEKKÜR

Yazarlar bu çalışmanın hazırlanması aşamasında gerek veri temini gerekse fikir aşamasında yardımlarını esirgemeyen DSİ II. Bölge Müdürlüğü Planlama Şube Müdürü Aslı SİLAY'a ve diğer tüm çalışanlarına teşekkürü bir borç bilirler.

KAYNAKÇA

- [1] Abbott, M.B. and Refsgaard, J.C. "Distributed Hydrological Modelling" Kluwer Academic Publishers, Dordrecht. 17-39 (1996).
- [2] Gül, A. ve Harmancıoğlu, N. "Su Kaynakları Yönetiminde Bilgisayar Modellerinin Kullanımı" I. Ulusal Su Mühendisliği Sempozyumu Bildiriler Kitabı, 735-745 (2003).
- [3] Perrin, C., Michel, C. and Andreassian, V. "Does a large number of parameters enhance model performance?. Comparative assessment of common catchment model structures on 429 catchments". Journal of Hydrology. 242, 275-301 (2001).
- [4] İcağa, Y. "Akarçay Havzası Yağış-Akış İlişkilerinin Modellenmesi" I. Ulusal Su Mühendisliği Sempozyumu, 22-26 Eylül, İzmir, Türkiye, 203-214 (2003).
- [5] Karabörk, M.Ç., ve Kahya, E. "Sakarya havzasındaki aylık akımların çok değişkenli stokastik modellenmesi" Turkish J. Eng. Env. Sci., 23(2), 133-147 (1999).
- [6] Keskin, E.M. ve Taylan D.E. "Orta Akdeniz Havzasındaki Akımların Stokastik Modellemesi" İMO Teknik Dergi, 282, 4271-4291 (2007).
- [7] Alp, M. ve Cıgızoğlu, K. "Yapay Sinir Ağı Metodları ve Regresyon Analizi ile Akım Tahmini" II. Ulusal Su Mühendisliği Sempozyumu Bildiriler Kitabı, 589-598 (2005).
- [8] Raman, H. and Sunilkumar, N. "Multivariate modelling of water resources time series using artificial neural networks" Hydrological Sciences Journal, 40(2), 145-163 (1995).

- [9] Cıgızoğlu, H.K. "Incorporation of ARMA models into flow forecasting by artificial neural networks" *Environmetrics*, 14(4), 417-427 (2003).
- [10] Tokar, A.S. and Johnson, P.A., "Rainfall runoff modelling using artificial neural networks" *Journal of Hydrologic Engineering*, 4(3), 232-239 (1999).
- [11] Campolo, M., Andreussi, P. and Soldati, A., "River flood forecasting with a neural network model" *Water Resources Research*, 35, 1191-1197 (1999).
- [12] Hsu, K., Gupta, H.V. and Sorooshian, S., "Artificial neural network modelling of the rainfall runoff process" *Water Res. Research*, 31, 2517-2530 (1995).
- [13] Minns, A.W. and Hall, M.J., "Artificial neural networks as rainfall runoff models" *Hydrological Sciences Journal*, 41(3), 399-417 (1996).
- [14] Alp, M. ve Cıgızoğlu, H.K., "Farklı yapay sinir ağı metodları ile yağış-akış ilişkisinin modellenmesi" *İTU dergisi*, 3(1), 80-88 (2004).
- [15] Cigizoglu H.K. "Application of the Generalized Regression Neural Networks to Intermittent Flow Forecasting and Estimation", *Journal of Hydrologic Engineering*, 10(4), 336-341 (2005a).
- [16] Cigizoglu H.K. "Generalized regression neural networks in monthly flow forecasting" *Civil Engineering and Environmental Systems*. 22 (2), 71-84 (2005b).
- [17] Fernando, D.A.K., and Jayawardena, A.W., "Runoff forecasting using RBF networks with OLS algorithm" *Journal of Hydrologic Engineering* 3(3), 203-209 (1998).
- [18] Lin, G., and Chen, L., "A non-linear rainfall-runoff model using radial basis function network", *Journal of Hydrology*, 289, 1-8 (2004).
- [19] Skapura, D. M. "Building Neural Networks" Addison-Wesley, New York (1996).
- [20] Haykin, S. "Neural Networks: A Comprehensive Foundation" MacMillan. New York (1994)
- [21] Öztemel, E., "Yapay Sinir Ağları" Papatya Yayıncılık. İstanbul (2003).
- [22] Rumelhart D.E., Hinton G.E., Williams R.J. "Learning representations by backpropagation errors" *Nature*, 323, 533-536 (1986).
- [23] Kisi, O., "Multi-layer perceptrons with Levenberg-Marquardt training algorithm for suspended sediment concentration prediction and estimation" *Hydrological Sciences Journal* 49 (6), 1025-1040 (2004).
- [24] Cigizoglu, H.K., and Kisi, O., "Flow prediction by three back propagation techniques using k-fold partitioning of neural network training data" *Nordic Hydrology* 36 (1), 49-64, (2005).
- [25] Okkan, U. ve Dalkılıç, H. Y." Demirköprü barajı aylık buharlaşma yüksekliklerinin yapay sinir ağları ile tahmin edilmesi" *DSİ Teknik Bülten*. 108, 30-36 (2010).
- [26] Marquardt, D., "An algorithm for least squares estimation of non-linear parameters" *Journal of the Society for Industrial and Applied Mathematics* 11 (2), 431-441 (1963).
- [27] Hagan M. T. and Menhaj M. B. "Training feed forward network with the Marquardt algorithm" *IEEE Trans. on Neural Net.*, 5(6), 989-993 (1994).
- [28] Cong Chen T., D. Jian Han, F. T. K. Au, L. G. Than. "Acceleration of Levenberg-Marquardt training of neural networks with variable decay rate," *IEEE Trans. on Neural Net.*, 3(6), 1873-1878 (2003).
- [29] Lindley, D.V. "Regression and correlation analysis". New Palgrave: A Dictionary of Economics, 4, 120-23 (1987).
- [30] Hocking, R. R. "The Analysis and Selection of Variables in Linear Regression" *Biometrics*, (1976).