



ISSN:1306-3111

e-Journal of New World Sciences Academy
2011, Volume: 6, Number: 1, Article Number: 1A0160

ENGINEERING SCIENCES

Received: October 2010

Accepted: January 2011

Series : 1A

ISSN : 1308-7231

© 2010 www.newwsa.com

Veysel Gümüş¹

Mehmet Eyyup Kavsut²

Kasım Yenigün³

Cukurova University¹⁻²

Harran University³

vgumus@harran.edu.tr

Adana-Turkey

**YAĞIŞ-AKIŞ İLİŞKİSİNİN MODELLENMESİNDE YSA KULLANIMININ DEĞERLENDİRİLMESİ:
ORTA FIRAT HAVZASI UYGULAMASI**

ÖZET

Son yıllarda Yağış-Akış ilişkisinin modellenmesinde, giderek daha farklı alanlarda kullanılmaya başlayan ve oldukça başarılı sonuçlar veren, ancak su mühendisliği alanında henüz yeni yeni ivmelenen Yapay Sinir Ağları, Genetik Algoritma ve Bulanık Mantık gibi Yapay Zeka Yöntemlerinin kullanımı gündeme gelmiştir. Bu çalışmada, Orta Fırat Havzasında bulunan 2122 numaralı akım gözlem istasyonuna ait aylık ortalama akım verileri ile 17099 numaralı yağış gözlem istasyonuna ait aylık toplam yağış verileri arasındaki ilişki yapay sinir ağları metotlarından İleri Beslemeli Geri Yayılım Sinir Ağı (İBGYSA) metodu ile araştırılmış ve ardından bu sonuçlar daha klasik bir yöntem olan Çoklu Doğrusal Regresyon (ÇDR) yöntemi ile karşılaştırılmıştır. Akım ve yağış verilerinin girdi olarak kullanıldığı bu işlemde yeni akım değerleri tahmin edilmiştir. Çalışma sonunda İBGYSA yönteminin ÇDR yöntemine göre daha iyi sonuç verdiği görülmüştür.

Anahtar Kelimeler: Yapay Sinir Ağları, Yağış-Akış, Orta Fırat Havzası, Çoklu Doğrusal Regresyon

**ASSESSMENT OF USING ANN FOR MODELLING THE RAINFALL-RUNOFF RELATION: AN
APPLICATION FOR MIDDLE PART OF EUPHRATES BASIN**

ABSTRACT

Artificial intelligence methods such as Artificial Neural Network (ANN), Genetic Algorithm (GA) and Fuzzy Logic (FL) provide prosperous results have recently been used in the modelling of rainfall-flow relations and they are becoming more popular in hydraulic engineering practices. In this paper the relations between the average monthly flow data from the flow observation station numbered as 2122 and the monthly total rainfall data from the rainfall observation station numbered as 17099 located in the central Euphrates river basin are investigated by using the feed-forward back-propagation neural network (FFBPNN) method from ANN solutions and afterwards the results are compared using Multi linear Regression (MLR) method. New flow values are estimated by this procedure that uses the flow and rainfall data as input. This paper concludes that FFBPNN method provides better results compared to the results from MLR method.

Keywords: Artificial Neural Network, Rainfall-Runoff, Middle Part of Euphrates Basin, Multi Linear Regression

1. GİRİŞ (INTRODUCTION)

Bir akarsu havzası üzerine düşen yağışın akış haline dönüşmesi olayını benzeştiren yağış-akış modelleri özellikle taşkın hidrolojisinde önem taşır. Çeşitli kayıplar çıktıktan sonra yağışın geriye kalan kısmı farklı yolları izleyerek havzada ötelenmekte, biriktirmeler yoluyla sönümlendirilmekte ve sonuçta çıkış noktasındaki akış haline dönüştürülmektedir. Çok karmaşık bir sistem olan akarsu havzası için dönüşüm fonksiyonu bir matematik modelle ifade edilebilir. Matematik modeller parametrik (çok bileşenli, kavramsal) modeller ve kapalı kutu (kara kutu) modelleri olmak üzere genellikle iki türlü değerlendirilmektedir.

Parametrik (çok bileşenli, kavramsal) modeller dönüşüm işlemini sızma, yeraltı akışı, yüzeysel akış gibi bileşenlerine ayırarak analiz ederken bu bileşenlerin aralarındaki ilişkileri fiziksel açıdan oldukça ayrıntılı bir şekilde ifade ederler. Hidrodinamik yasalarının uygulanması güç olduğundan bu modellerde de genellikle basitleştirmeler yapılır. Modeller bir takım biriktirme elemanlarından kurulur, suyun izlediği yola bağlı olarak bu elemanların arasındaki ilişkiler (giren ve çıkan su miktarları) fiziksel özellikleriyle belirlenir. Bu gibi modellerin çok sayıda parametreleri vardır. Belli bir havza için model parametrelerinin değerleri, havzada gözlenmiş olan hidrograflar yeterli bir yaklaşımla modelden elde edilinceye kadar deneme yaparak belirlenir.

Kapalı kutu (kara kutu) modellerinde havzada yer alan olaylar ayrıntılı olarak incelenmeyip havzaya yağışı akışa çeviren kapalı bir kutu gözüyle bakılır. Sistemin dönüşüm fonksiyonunun o havzada gözlenmiş olan yağış ve akış kayıtlarına dayanarak belirlenmesine çalışılır. Bu tip modeller gerçek durumu tam olarak yansıtmaları da uygulaması oldukça basittir, ancak daha önceden denenmemiş koşullar için kullanılmalarda hatalara yol açabilir. Kapalı kutu modelleri dönüşüm fonksiyonunun doğrusal olduğunun kabul edilip edilmemesine göre de sınıflara ayrılırlar.

Geleneksel yağış-akış modelleme teorisi doğal olarak sistemi indirgemek, zaman zaman doğrusallaştırmak zorunda kalmaktadır. Buda modellerin güvenilirliğini ve modellerin sonuçlarını kuşkulu yapmaktadır. Halbu ki sistemin içinde ne olup bittiğine bakmadan sadece sistemin girdi-çıkış mekanizmasının öğrenilmesi ile sistem sağlıklı bir şekilde modellenilebilmektedir. Bu konuda insan beyninin çalışma sisteminin taklidi ile geliştirilmiş olan Yapay Sinir Ağları(YSA) uygun bir alternatif sağlamaktadır.

Yapay sinir ağlarının su kaynaklarında ve değişik meteorolojik olayların tanımlanması, sınıflanması ve tahmininde sıkça karşılaşılan değişik problemlere uygulanması ile ilgili çok sayıda çalışma bulunmaktadır. Aci (2006), YSA kullanarak Akarçay Havzasının yağış-akış ilişkisini incelemiştir, Partal (2008) YSA ve dalgacık dönüşümü yöntemlerini kullanarak yağış tahmininde bulunmuştur. Ayrıca hidroloji alanında YSA sıklıkla kullanılmaktadır. (Kişi, 2003), (Kişi, 2005), (Küçük ve Ağırlioğlu, 2006).

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)


Bu çalışmada, Orta Fırat Havzasında bulunan 2122 numaralı akım gözlem istasyonuna ait aylık ortalama akım verileri ile 17099 numaralı yağış gözlem istasyonuna ait aylık toplam yağış verileri arasındaki ilişki yapay sinir ağları metotlarından İleri Beslemeli Geri Yayınım Sinir Ağı (İBGYSA) metodu ile araştırılmış ve ardından bu sonuçlar daha klasik bir yöntem olan Çoklu Doğrusal Regresyon (ÇDR) yöntemi ile karşılaştırılmıştır.

3. YÖNTEM (THE METHOD)

3.1. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları, farklı ağlarla birbirine bağlı birçok işlem elemanlarından oluşmuş yoğun paralel sistemlerdir. YSA metotları içerisinde en çok kullanılanı hataların geriye yayılma (back-propagation) ilkesine göre çalışandır (Lippman, 1987).

Şekil 1, üç tabakalı bir yapay sinir ağını göstermektedir. Burada i girdi tabakası, j gizli tabaka ve k çıktı tabakası, A_{ij} ve A_{jk} ise hücre tabakaları arasındaki bağlantı ağırlıklarıdır. Başlangıçta rastgele atanan ağırlık değerleri, eğitme sürecinde tahmin edilen çıktılarla gerçek çıktı değerleri karşılaştırılarak devamlı değiştirilir ve hataları minimum yapan bağlantı ağırlık değerleri ayarlanıncaya kadar hatalar geriye doğru (Şekil 1'de sağdan sola) yayılır. Burada ağırlıkları ayarlamak için Levenberg-Marquardt metodu kullanılmıştır (Marquardt, 1963).



Şekil 1. Üç tabakalı bir yapay sinir ağı.

(Figure 1. An artificial neural network with three layers)

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

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

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

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

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

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

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

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

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

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

Burada η öğrenme oranı olarak adlandırılan orantılılık katsayısını, $\partial H_p / \partial A_{ij}$ ise hata yüzeyinin eğimini göstermektedir (Kişi, 2004).

3.2. Çoklu Doğrusal Regresyon (Multi Linear Regression)

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

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

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_j x_j + \dots + \beta_p x_p + \varepsilon \quad (6)$$

olarak yazılabilir.

Burada $\beta_0, \beta_1, \beta_2, \dots, \beta_j, \dots, \beta_p$ bilinmeyenlerine regresyon katsayıları denir. Herhangi bir β_j regresyon katsayısı, diğer değişkenler sabit tutulduğunda (diğer değişkenlerin etkisi ortadan kaldırıldığında) x_j değişkeninde ortaya çıkan bir birimlik değişmeğe karşılık y değişkenindeki beklenen değişiklik miktarını vermektedir. Diğer bir ifadeyle; $\beta_1, \beta_2, \dots, \beta_j, \dots, \beta_p$; bağımsız değişkenlerin y 'nin saptanmasına yaptıkları göreceli katkıya ilişkin ağırlıklardır. Bu nedenle, β_j ($j=1, 2, \dots, p$) parametreleri genellikle kısmi regresyon katsayıları olarak adlandırılmaktadır. β_0 'a ise kesim noktası veya sabit denir ve tüm x_j değişken değerleri sıfır olduğunda bağımlı değişkenin aldığı değeri gösterir. ε ise hata terimidir (Alpar, 2003).

4. UYGULAMA (THE APPLICATION)

Çalışma kapsamında Orta Fırat Havzasında bulunan 17099 numaralı Yağış Gözlem İstasyonu (YAGİ) ile 2122 numaralı Akım Gözlem İstasyonu'na (AGİ) ait veriler kullanılmıştır (Şekil 2, Tablo 1, Tablo 2). Bu verilere ait istatistik özellikler Tablo 3 te verilmiştir.

Tablo 1. 17099 nolu yağış gözlem istasyonuna ait bilgiler
(Table 1. Informations about rainfall observation station number 17099)
(Meteoroloji, 2010)

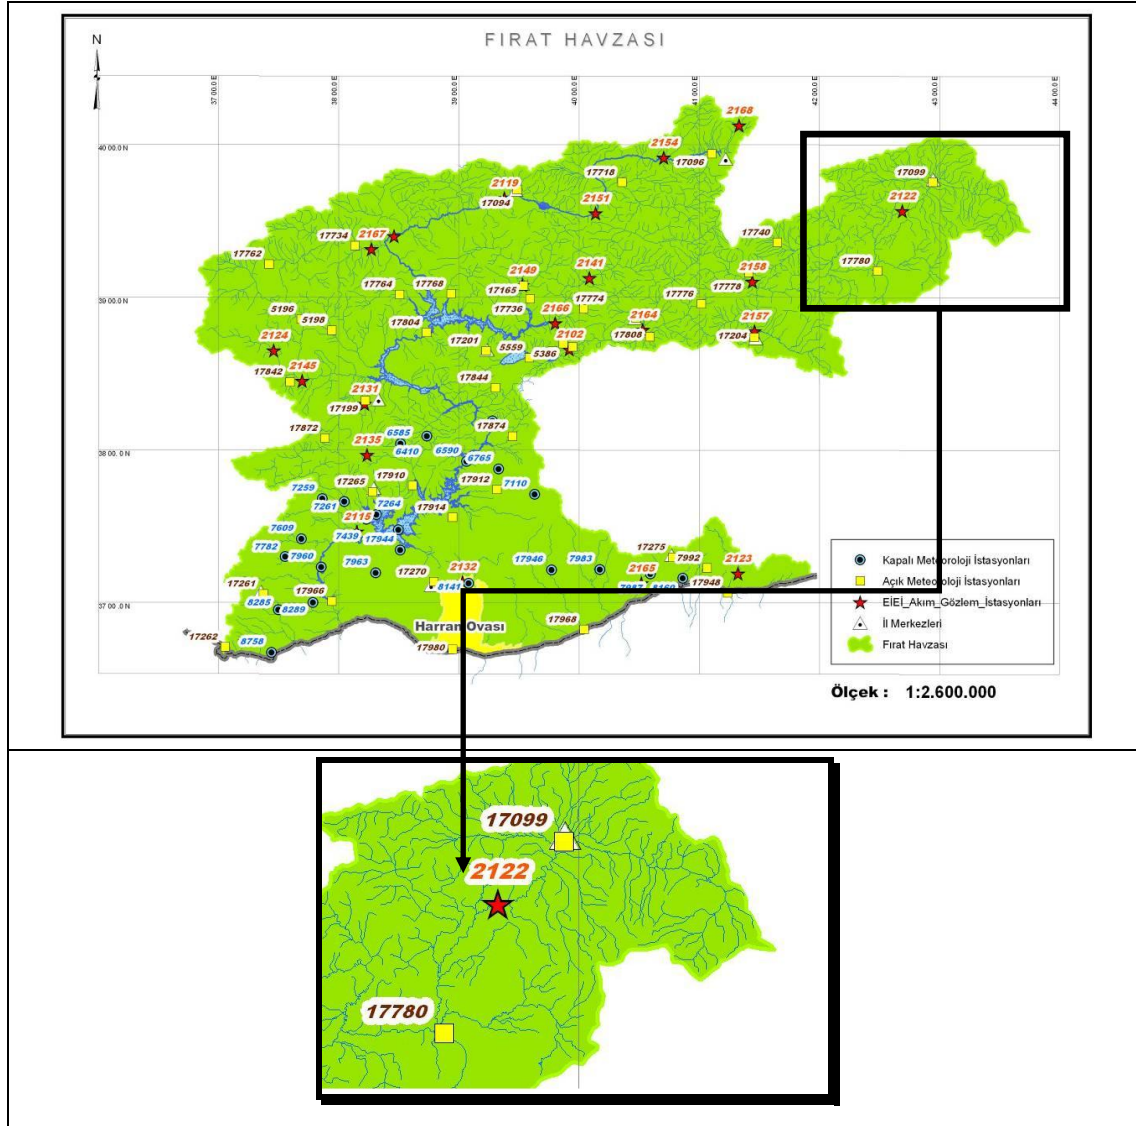
İstasyon No	Adı	Bölge	Yük (m)	Enlem	Boylam	Rasat
17099	AGRI	KARS	1632	36,43 K	43,03 D	1939-2010

Tablo 2. 2122 nolu akım gözlem istasyonuna ait bilgiler (EİEİ,2000)
(Table 2. Informations about flow observation station number 2122)

İstasyon No	Adı	Yağış alanı (km ²)	Enlem	Boylam	Rasat
2122	Murat Nehri-Tutak	5852	39,54 K	42,78 D	1969-2000

Tablo 3. Kullanılan verilerin istatistiksel özellikleri
(Table 3. Statistical parameters of studied data)

Parametre	Yağış	Akış
X_{ort}	43.25 (mm)	45.56 (m ³ /s)
S_x	33.65 (mm)	61.53 (m ³ /s)
C_{sx}	1.25	2.08
X_{min}	0 (mm)	2.54 (m ³ /s)
X_{max}	254.50 (mm)	329 (m ³ /s)



Şekil 2. Çalışma alanı
(Figure 2. Study area)

4.1. Yağış-Akış İlişkisi (Rainfall-Runoff Relation)

Yağış-Akış ilişkisi için 17099 numaralı YAGİ ile 2122 numaralı AGİ arasındaki ilişki için 5 farklı durum için girdi verileri verilmiş (Tablo 4) ve buna bağlı olarak akım tahmini yapılmaya çalışılmıştır. Çalışma kapsamında bu istasyonlara ait toplam 464 verinin 325 i eğitim sürecinde geri kalan 139 veri ise sadece test aşamasında kullanılmıştır. Test aşamasında kullanılan veriler eğitim sürecine dahil edilmemiştir.

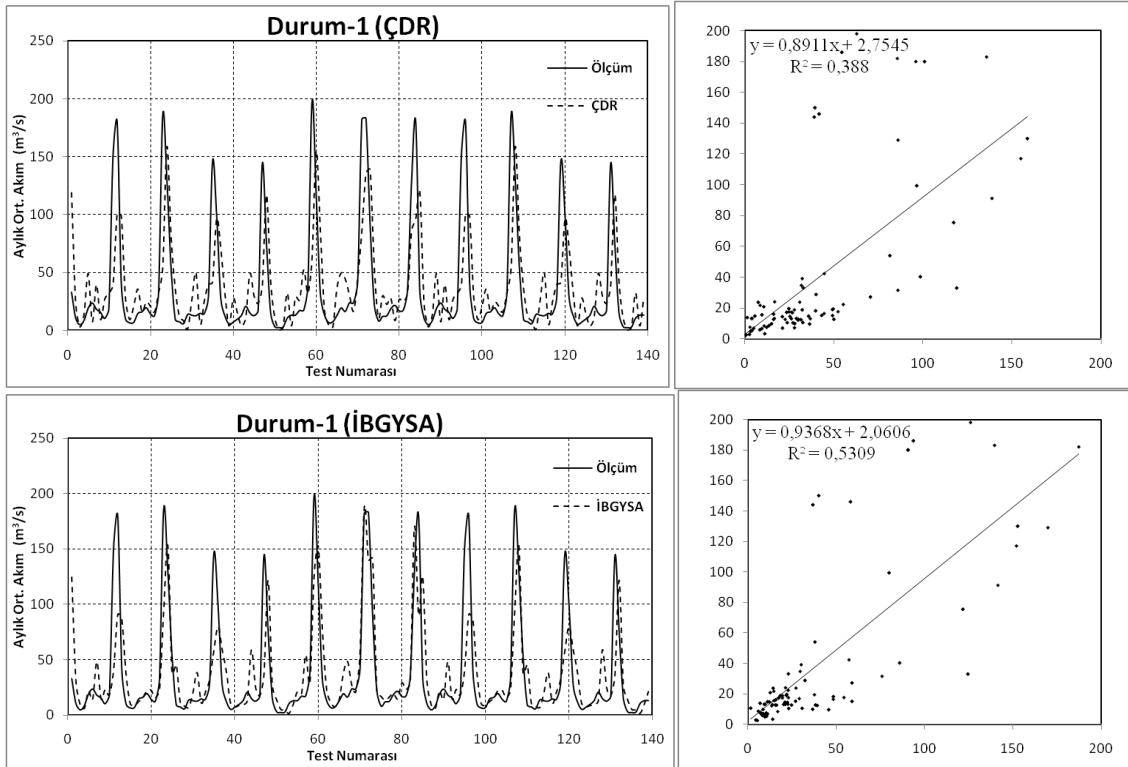
Tablo 4. Yağış-Akış ilişkisindeki kullanılan model girdi ve çıktıları
(Table 4. Input and output data for rainfall-runoff modelling)

DURUM	Girdi	Çıktı
1	p, q-1	q
2	p, p-1, q-1	q
3	p, p-1, p-2, q-1	q
4	p, p-1, p-2, p-3, q-1	q
5	p, p-1, p-2, p-3, p-4, q-1	q

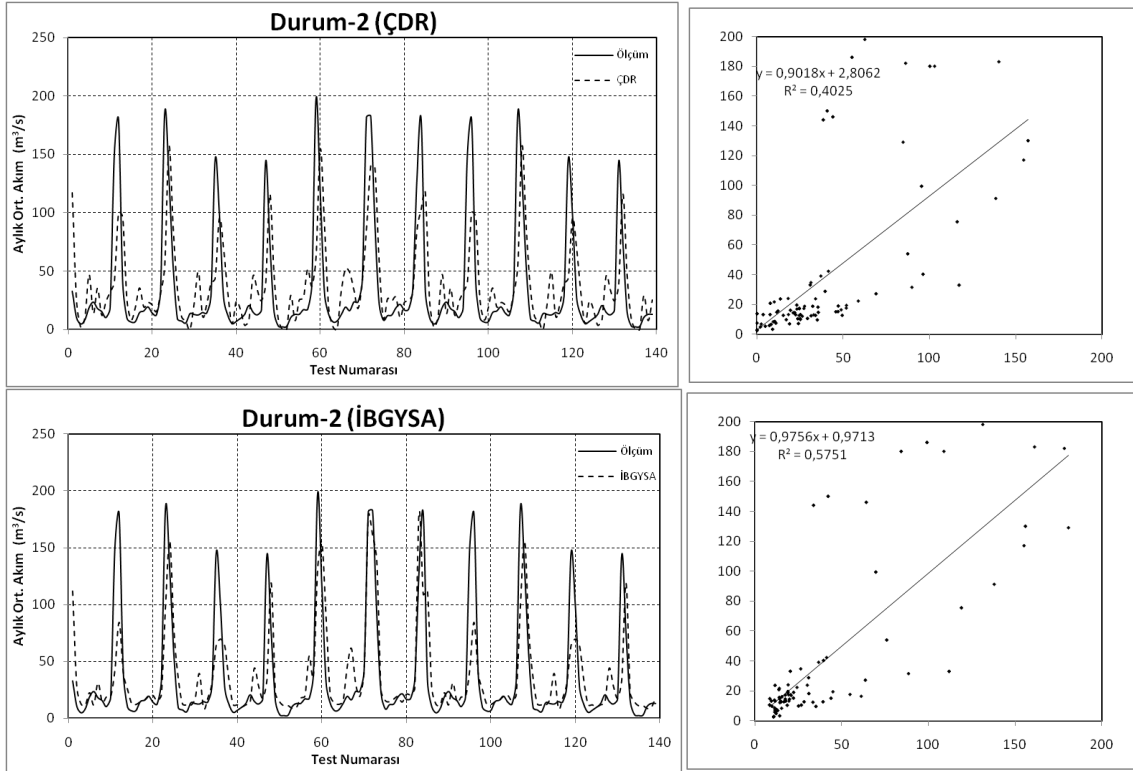
Beş farklı durum için eğitim ve test sonuçlarına ait R^2 değerleri Tablo 5 te verilmiştir. bu durumlar için tahmin ve saçılma grafikleri verilmiştir (Şekil 3, Şekil 4, Şekil 5, Şekil 6, Şekil 7)

Tablo 5. Modellere göre eğitim ve test sonuçlarının R^2 değerleri
(Table 5. R^2 values of training and test results by models)


DURUM	Eğitim	Test
1	ÇDR	0.432
	YSA	0.388
2	ÇDR	0.434
	YSA	0.579
3	ÇDR	0.437
	YSA	0.670
4	ÇDR	0.438
	YSA	0.751
5	ÇDR	0.441
	YSA	0.768



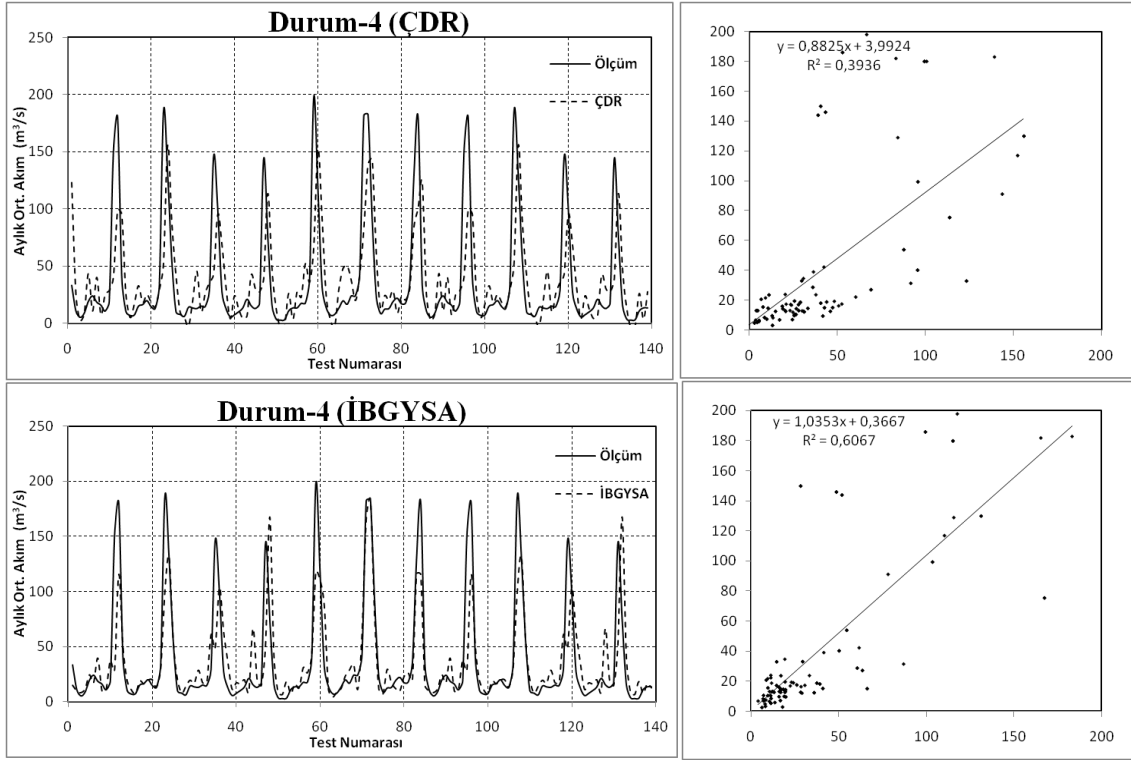
Şekil 3. Ölçülmüş ve tahmin edilen akım değerleri (Durum 1)
(Figure 3. Observed and predicted flows (Case 1))



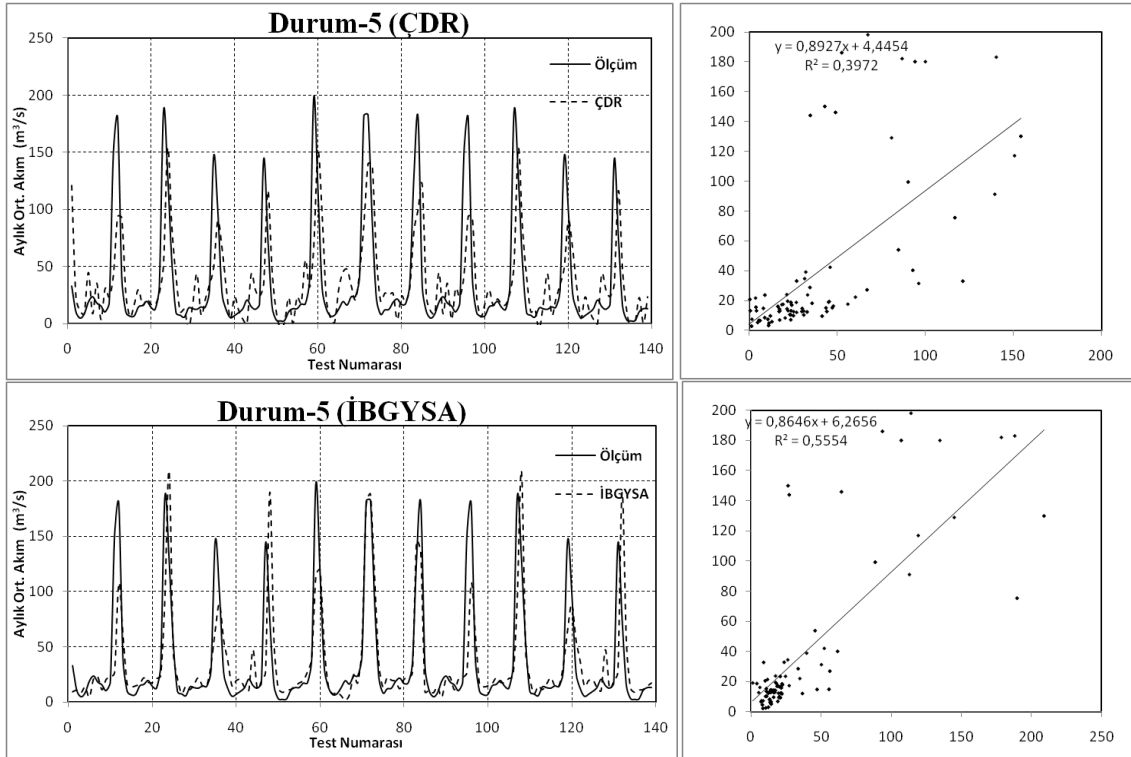
Şekil 4. Ölçülmüş ve tahmin edilen akım değerleri (Durum 2)
(Figure 4. Observed and predicted flows (Case 2))



Şekil 5. Ölçülmüş ve tahmin edilen akım değerleri (Durum 3)
(Figure 5. Observed and predicted flows (Case 3))



Şekil 6. Ölçülmüş ve tahmin edilen akım değerleri (Durum 4)
(Figure 6. Observed and predicted flows (Case 4))



Şekil 7. Ölçülmüş ve tahmin edilen akım değerleri (Durum 5)
(Figure 7. Observed and predicted flows (Case 5))

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, Orta Fırat Havzasında bulunan 2122 numaralı akım gözlem istasyonuna ait aylık ortalama akım verileri ile 17099 numaralı yağış gözlem istasyonuna ait aylık toplam yağış verileri arasındaki ilişki yapay sinir ağları metotlarından İleri Beslemeli Geri Yayınım Sinir Ağı (İBGYSA) metodu ile araştırılmış ve elde edilen bu sonuçlar daha klasik bir yöntem olan Çoklu Doğrusal Regresyon (ÇDR) yöntemi ile karşılaştırılmıştır. 5 farklı duruma göre yağış ve akım değerleri girdi verisi olarak ele alınmış bu durumlara göre akım değerleri tahmin edilmiştir.

Çalışma sonunda, ÇDR yönteminde en iyi sonuç **Durum 2** de, İBGYSA yönteminde ise en iyi sonuç **Durum 4**'te gözlenmiştir, tüm durumlarda ise İBGYSA yönteminin ÇDR yöntemine göre daha iyi sonuç verdiği görülmüştür. Buna göre bir kara kutu modeli olan Yapay Sinir Ağları yöntemi yağış-akış modellemesinde rahatlıkla ve kolaylıkla kullanılabilmesi sonucuna varılmıştır.

NOT (NOTICE)

Bu çalışma, 14-16 Ekim 2010 tarihinde Dicle Üniversitesinde tamamlanan Bilimde Modern Yöntemler Sempozyumunda (BUMAT2010) sözlü sunumu yapılmış ve NWSA yazım esaslarına göre yeniden düzenlenmiştir.

KAYNAKLAR (REFERENCES)

1. Aci, M., (2006) Yapay Sinir Ağları ile Hidrolojik Modelleme, Yüksek Lisans Tezi, CBÜ, Fen Bilimleri Enstitüsü.
2. Partal, Ö., Kahya, E. ve Cıgızoğlu, K., (2008). "Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini", İTÜ Dergisi, 7(3) 73-85.
3. Kisi, Ö., (2003). River flow modeling using artificial neural networks. J. Hydrol. Eng. 9(1), 60-63.
4. Kisi, Ö., (2005). Daily river flow forecasting using artificial neural networks and auto-regressive models. Turkish J. Eng. Environ. Sci. 29, 9-20.
5. Küçük, M., Agiralıoğlu, N., (2006). Regression technique for stream flow prediction. J. Appl. Stat. 33 (9), 943-960.
6. Lippman, R., (1987). "An Introduction to Computing With Neural Nets", IEEE ASSP Mag., 4, 4-22.
7. Marquardt, D., (1963). An algorithm for least squares estimation of non-linear parameters", J. Soc. Ind. Appl. Math., pp.431-441.
8. Kişi, Ö., (2004). "Yapay Sinir Ağları ve Regresyon Teknikleri ile Filyos Çayı Akımlarının Tahmini", IV. Hidroloji Kongresi, 23-25 Haziran, 347-353, İstanbul, Türkiye.
9. Alpar, R., (2003). "Uygulamalı Çok Değişkenli İstatistiksel Yöntemlere Giriş 1", Ankara, Türkiye.
10. EİEİ, (2000). Su Akımları Yıllığı, Elektrik İşleri Etüd İdaresi, Ankara.
11. Meteoroloji, 2010, Aylık Yağış Verileri, <http://www.tumas.dmi.gov.tr/wps/portal/>