

Farklı yapay sinir ağı metodları ile yağış-akış ilişkisinin modellenmesi

Murat ALP*, H. Kerem CIĞIZOĞLU

İTÜ İnşaat Fakültesi, İnşaat Mühendisliği Bölümü, 34469, Ayazağa, İstanbul

Özet

Eldeki hidrometeorolojik verilerin yardımı ile nehir akımı tahmininin yapılması su kaynakları projelendirme çalışmaları açısından önem taşımaktadır. Bu çalışmada, su kaynakları uygulamalarında sıkça kullanılan ileri beslemeli geriye yayılım metodu (İBGY) ile son zamanlarda uygulanmaya başlanan genelleştirilmiş regresyon sinir ağı (GRSA) yöntemi bu problem için uygulanmış ve sonuçlar seçilen performans kriterleri cinsinden karşılaştırılmıştır. GRSA metodu ile İBGY'nin yerel minimum sorunu çözülmekte ve tek simülasyonla değişmeyen bir sonuç elde edilmektedir. İBGY ile ise her farklı yapay sinir ağı mimarisi için en iyi sonucu elde edene kadar çok sayıda simülasyon yapılmaktadır. En iyi İBGY simülasyonu gerek GRSA gerekse klasik istatistik ve stokastik model tahminlerinden daha iyi sonuçlar vermiştir.

Anahtar Kelimeler: Akım tahmini, genelleştirilmiş regresyon sinir ağı, ileri beslemeli geriye yayılım metodu.

Modelling rainfall-runoff relation using different artificial neural network methods

Abstract

In this study daily mean river flow estimations based on the antecedent rainfall and/or river flow values are carried out using two different ANN algorithms. Estimations obtained by the conventional feed forward back propagation (FFBP) and the new generalized regression neural network (GRNN) methods using different network architectures are compared with conventional statistical and stochastic model results. GRNN is used for estimation of continuous variables, as in standard regression techniques. Generalized regression neural network does not require an iterative training procedure as in back propagation method. In the applications presented in this study the daily hydro meteorologic data belonging to Juniata River Basin in Pennsylvania state of USA are employed. The FFBP results are found to be superior to GRNN and conventional methods. However it was shown that FFBP method performances are very sensitive to the randomly assigned initial weight values. This problem, however, was not faced in GRNN simulations. The local minima problem in feed forward back propagation algorithm applications was not faced in GRNN simulations. In the study it was also seen that the analysis of the cross-correlations and autocorrelations provide useful information about the input node number of the ANN network.

Keywords: Flow estimation, generalized regression neural network, feed forward back propagation method.

*Yazışmaların yapılacağı yazar: Murat ALP. alpmurat@hotmail.com; Tel: (216) 325 63 20.

Bu makale, birinci yazar tarafından İTÜ İnşaat Fakültesi'nde tamamlanmış "Akarsulardaki askı maddesi miktarının kara kutu modeliyle belirlenmesi" adlı doktora tezinden hazırlanmıştır. Makale metni 01.08.2003 tarihinde dergiye ulaşmış, 17.09.2003 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 30.06.2004 tarihine kadar dergiye gönderilmelidir.

Giriş

Gelecekteki belli bir tarihte görülecek akımın (debi, seviye, akış hacmi) tahmini, taşkın uyarılarının yapılması, taşkın kontrolü maksatlı haznelerin işletilmesi, akarsuyun su potansiyelinin belirlenmesi, kurak dönemlerde hidroelektrik üretiminin, şehir suyu ve sulama suyunun dağıtımı ve akarsularda ulaşımın planlanması açısından önem taşımaktadır. Bir akarsudaki akım havzaya düşen yağışa bağlı olmakla birlikte yağış olayının görülmesi ile akımın oluşması arasında belli bir gecikme vardır. Akım tahminlerini yaparken bu gecikmeden yararlanılır. Ancak tahmin edilmek istenen akım tahminin yapıldığı andan sonra meydana gelecek meteorolojik olaylara da bağlı ise bu olayların da tahmin edilmesi gerekir.

Havzanın yağışı akışa dönüştürmesi sürecinin fiziksel yönleriyle daha iyi bir şekilde benzeştirilebilmesi için parametrik (çok bileşenli, kavramsal) modeller geliştirilmiş ve bilgisayar programları hazırlanmıştır. Bu modellerde akarsu havzası, biriktirme sistemleri ve bunların arasındaki ilişkilerle temsil edilir. Biriktirme sistemlerine süreklilik denkleminin uygulanması ile model çalıştırılır. Havzaya düşen yağış, kayıplar çıkarıldıktan sonra, yüzeysel biriktirme sistemine girer. Bu sistem, yağışı akarsu ağına ulaştırır havzadaki su yollarından ve akarsu ağından oluşur. Yüzealtındaki gecikmesiz biriktirme sistemi de bunlara katılır. Bazı modellerde havzadaki kar örtüsünün erimesiyle oluşan akış da gözönüne alınır.

Parametrik modeller özellikle kapalı kutu modellerinin kullanılmadığı, havzanın özelliklerinin değiştirilmesinin etkilerini incelemek istenen durumlarda yararlı olur. Ancak bunun için de modelin parametrelerinin havza üzerinde değişimini hesaba katmak gerekebilir (yayımlı model). Modelde havza sistemi ne kadar çok sayıda elemana ayrılırsa o ölçüde ayrıntılı bir model geliştirilmiş olur. Ancak böyle bir modelde kalibrasyon için gerekli veri miktarı artacaktır. Kullanılacak modelin ölçeği eldeki verilere bağlı olarak seçilmelidir. Pratikte çoğu zaman parametrelerin havza üzerinde sabit kaldığı

kabul edilen toplu modeller kullanmak gerekir (Bayazit, 1998).

Akım tahmini konusunda stokastik modellerin kullanımı da oldukça yaygındır. ARMA(p,q) modelleri zaman serileri için genel bir matematik modeldir (Box ve Jenkins, 1976). Kara kutu modelleri ise havzanın bir alt sistemi veya bütünü için davranışının havza özellikleri ile havza işleyişine hemen hemen hiç bakılmaksızın matematiksel olarak bir davranış fonksiyonları takımı ile temsili esasına dayanır. Kara kutu sistem deyimini ile yapısal özellikleri ve çalışma tarzları ayrıntılı şekilde ve tam olarak ölçülüp değerlendirilemeyen ve dolayısıyla modellendirilmeleri oldukça güç veya imkansız olabilen sistemler kastedilir. Kara kutu sistemlerin modellenmesi sistem davranışı kavramına dayanmaktadır. Davranış fonksiyonları havzanın girdi ve çıktı dataları üzerinde belirlenir (Müftüoğlu, 1991). Birim hidrograf metodu yağış-akış ilişkisinin modellenmesinde sıkça kullanılan bir kara kutu modelidir.

Bir yapay zeka metodu olan yapay sinir ağları (YSA) da son yıllarda sıkça kullanılan bir kara kutu modelidir. YSA'nın su kaynaklarında sıkça karşılaşılan değişik problemlere uygulanması ile ilgili çok sayıda çalışma bulunmaktadır. Lineer olmayan YSA yaklaşımının yağış-akış ilişkisini iyi temsil ettiği gösterilmiştir (Hsu vd., 1995; Mason vd., 1996; Minns ve Hall, 1996; Fernando ve Jayawardena, 1998). Tokar ve Johnson (1999) YSA teknolojisini günlük akımların; günlük yağış, sıcaklık, ve kar erimesi verilerinin fonksiyonu olarak kestiriminde kullanmışlardır. Campolo ve diğerleri (1999a, b) YSA'nı yoğun yağış ve düşük akım süreçlerinde nehir akım kestiriminde kullanmışlardır. YSA aynı zamanda değişik yeraltı suyu problemlerinde kullanılmıştır (Ranjithan vd., 1993; Rogers ve Dowla, 1994). Raman ve Sunilkumar (1995) YSA'nın sentetik rezervuar akım serileri türetilmesinde kullanılabilirliğini incelemiştir. Boogaard ve diğerleri (1998) otoregresif sinir ağlarını geliştirerek zaman serilerinin lineer olmayan analizinde ve modellenmesine uygulamışlardır. See ve Openshaw (1998) sinir ağları ve bulanık mantığı kestirim konusunda birlikte kullanmışlardır. YSA ayrıca birim hidrograf elde edilme-

sinde (Lange, 1998), bölgesel taşkın frekans analizinde (Hall ve Minns, 1998), kanalizasyon akımlarının tahmininde (Djebbar ve Alila, 1998) olumlu sonuçlar vermiştir. Cıgızoğlu (2002a, 2002b) bu metodu sediment konsantrasyonu kestirimi ve tahmini problemine uygulamıştır. İleri beslemeli geriye yayılım algoritmasının akım serisi kestirimlerinde klasik istatistik ve stokastik modellere nazaran daha başarılı olduğu gösterilmiştir (Brikundavyi vd., 2002; Cıgızoğlu 2003a, 2003b).

Literatürdeki YSA çalışmalarında çoğunlukla ileri beslemeli geriye yayılım metodu (İBGY) kullanılmıştır. Bu metodun hızlı bir şekilde programlanabilmesi gibi bir faydası bulunmakla birlikte, algoritmanın yerel minimuma takılması ve negatif tahminler üretilebilmesi gibi istenmeyen yönleri de bulunmaktadır (Cıgızoğlu 2003c, 2003d). Bu nedenle son zamanlarda alternatif YSA metodlarının da su kaynakları mühendisliğinde uygulamalarına başlanmıştır. Genelleştirilmiş regresyon sinir ağı (GRSA) yöntemi ile yapılan çalışmalar oldukça iyi sonuçlar vermiş ve İBGY'nin kullanımı sırasında gözlenen sorunların yaşanmadığı tespit edilmiştir (Cıgızoğlu 2003c, 2003d).

Bu çalışmada her iki YSA metodu kullanılarak iki tip çalışma yapılmıştır. İlk olarak geçmiş nehir akım değerleri kullanılarak bir sonraki akımın tahmini çalışması gerçekleştirilmiştir. İkinci olarak da yağış ve geçmiş akım verileri kullanılarak akım tahmini yapılmıştır. Her iki çalışmadan elde edilen sonuçlar klasik istatistiksel ve stokastik model uygulamaları ile karşılaştırılmıştır.

Çalışmada kullanılan YSA metodları

İleri beslemeli geriye yayılım metodu

İleri beslemeli geriye yayılım sinir ağına girdi, gizli ve çıktı birimleri olmak üzere üç farklı birim bulunmaktadır. Her birim bir çok hücreden oluşmakta olup birimler aralarında ağırlık

kümeleri ile bağlanmaktadır. Bağlanma şekli ve her kısımdaki hücre sayısı değişebilmektedir. Aynı kısımdaki hücreler arasında iletişim olmasına izin verilmemektedir. Hücreler girdiyi ya başlangıç girdilerinden ya da ara bağlantılardan alırlar. Geriye doğru hata yayılması iki etaptan oluşmaktadır: çıktı birimindeki çıktı bilgi sinyali hesaplamak için girdi hücrelerindeki dış girdi bilgisini ileriye doğru ileten bir ileriye doğru besleme etabı ile çıktı birimindeki hesaplanan ve gözlenen bilgi sinyalleri arasındaki farklara dayanarak bağlantı kuvvetleri üzerinde değişikliklerin yapıldığı bir geriye doğru ilerleme etabı (Eberhart ve Dobbins, 1990).

Bir eğitim sürecinin başında, bağlantı kuvvetleri rastgele değerler olarak atanmaktadır. Öğrenme algoritması her iterasyonda eğitim başarı ile tamamlanana kadar kuvveti değiştirmektedir. İterasyon süreci bir sonuca vardığında bağlantı kuvvetleri, eğitim sürecinde kullanılan örneklerdeki mevcut bilgiyi elde eder ve saklar.

Genelleştirilmiş regresyon sinir ağı

Specht (1991) tarafından önerilen genelleştirilmiş regresyon sinir ağı, geriye yayılım metodunda olduğu gibi bir iteratif eğitim prosedürü gerektirmemektedir.

$f(x,y)$ ortak olasılık yoğunluk fonksiyonunun bilinmesi durumunda, bağımsız x değişkenine göre bağımlı y değişkeninin regresyonu:

$$E[y|X] = \frac{\int_{-\infty}^{\infty} y f(X, y) dy}{\int_{-\infty}^{\infty} f(X, y) dy} \quad (1)$$

şeklinde ifade edilir. Eğer olasılık yoğunluk fonksiyonu bilinmiyorsa gözlenen X^i ve Y^i değerlerinden bu fonksiyon tahmin edilir.

$$\hat{f}(X, Y) = \frac{1}{(2\pi)^{(p+1)/2} s^{(p+1)}} \frac{1}{n} \sum_{i=1}^n \exp \left[-\frac{(X - X^i)^T (X - X^i)}{2s^2} \right] \exp \left[-\frac{(Y - Y^i)^2}{2s^2} \right] \quad (2)$$

Bu denklemde p , x vektörünün boyutu, n , gözlenen veri sayısı, s ise düzeltme parametresidir. D_i^2 bir skaler fonksiyon olmak üzere,

$$D_i^2 = (X - X^i)^T (X - X^i) \quad (3)$$

olarak tanımlanırsa, bağımsız x değişkenine göre bağımlı y değişkeninin regresyonu,

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp\left(-\frac{D_i^2}{2s^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2s^2}\right)} \quad (4)$$

şeklinde bulunur.

Veri analizi

Bu çalışmada, Amerika Birleşik Devletleri Jeolojik Araştırma Kurumu'nun internet sitesinde yayınlamış olduğu Pennsylvania eyaletindeki Juniata Nehri'ne ait günlük akım değerleri kullanılmıştır (USGS İstasyon No: 01567000). Kara kutu modellerinin istediği havza davranışını en iyi yansıtabilme şartını, herhangi bir baraj olmaması nedeniyle sağlayan 8687 km² drenaj alanına sahip Juniata Nehri çalışmamız için uygun bulunmuştur. Yağış ile akış arasındaki ilişkiyi de araştırabilmek için Juniata Nehir Havzası'ndaki meteoroloji istasyonlarının verileri elde edilmeye çalışılmış; Amerika'daki Ulusal İklim Veri Merkezi'nden (National Climatic Data Center, NCDC) bu istasyonlara ait yağış verileri temin edilmiştir. Juniata Havzası'ndaki 3 meteoroloji istasyonunun (Lewistown, İstasyon No: 364992, Mapleton Depot, İstasyon No: 365381, Newport River, İstasyon No: 366297) günlük toplam yağış verilerinin ortak ölçüm süreleri açısından çalışmamız için uygun olduğu tespit edilmiştir. Modelde bu 3 istasyonun yağış verilerinin ortalaması kullanılmıştır. Bölgesel ortalama yağış yüksekliği bulunurken havza haritası temin edilerek Thiessen Metodu kullanılmıştır. Havzadaki meteoroloji istasyonlarına ait günlük toplam yağış değerleri ile günlük akım değerlerinin en uzun süreli ortak ölçüm zamanı olan 01.01.1983 ile 23.09.1989 tarihleri arasındaki

2458 veri, yapay sinir ağları uygulamasında kullanılmıştır. Bu verilere ait ortalama, \bar{x} , standart sapma, s_x , çarpıklık katsayısı, c_{sx} , minimum ve maksimum değerleri Tablo 1'de verilmiştir.

Tablo 1. Juniata Havzası yağış ve akım verisine ait istatistik parametre değerleri

	Yağış	Akım
\bar{x}	2.73 (mm)	117.86 (m ³ /s)
s_x	5.15 (mm)	149.65 (m ³ /s)
c_{sx}	3.69	4.53
x_{\min}	0 (mm)	13.7 (m ³ /s)
x_{\max}	72.33 (mm)	2470 (m ³ /s)

Yapay sinir ağları ile önceki nehir akımları kullanılarak gelecekteki akım değerinin kestirimi

Yapay sinir ağlarının lineer olmayan sistemlerin modellenmesindeki başarısı hidroloji ve hidrolik konularındaki uygulamalarını artırmıştır. Bu çalışmada ilk aşamada yapay sinir ağlarının ileri beslemeli geriye yayılımı metodu, ikinci aşamada da genelleştirilmiş regresyon sinir ağları kullanılarak akım değerlerinin kestirilmesine çalışılmıştır.

Yapay sinir ağlarının girdi tabakasındaki hücre sayısı belirlenirken genelde deneyerek en iyi sonuçlar bulunmaya çalışılır. Son zamanlarda bir ilk yaklaşım olması bakımından girdi tabakasındaki hücre sayısı tespit edilirken yağış ve akım veri çiftlerinin çapraz korelasyon katsayıları dikkate alınmaktadır (Cığızoğlu, 2003c). Tablo 2'de yağış-akış veri çiftlerinin çapraz korelasyon ve akım serisinin otokorelasyon değerleri verilmiştir. Buna göre en yüksek çapraz korelasyon katsayısı t anındaki akım ile $t-2$ anındaki yağış arasında çıkmıştır. Bu havzanın geçiş süresinin yaklaşık iki gün olduğu söylenebilir. Akım oto-korelasyonlarında ise ilk 5 değerden sonra ardışık otokorelasyon değerleri arasındaki değişim miktarı düşmektedir.

Tablo 2. Yağış-akım çapraz korelasyon katsayıları ile akım otokorelasyon değerleri

Yağış-Akım çapraz korelasyon		Akım otokorelasyon	
$r_{x,y,0}$	0.215	r_1	0.886
$r_{x,y,1}$	0.414	r_2	0.724
$r_{x,y,2}$	0.432	r_3	0.614
$r_{x,y,3}$	0.351	r_4	0.536
$r_{x,y,4}$	0.276	r_5	0.473
$r_{x,y,5}$	0.218	r_6	0.423
$r_{x,y,6}$	0.175	r_7	0.374

Bütün akım değerleri 0.1 ile 0.9 arasında ölçeklendirilerek 01.01.1983 ile 22.06.1988 tarihleri arasındaki 2000 değer eğitim, 23.06.1988-23.09.1989 tarihleri arasındaki 458 değer de test aşamasında kullanılmıştır. Tablo 3 ve Tablo 4'te girdi ve gizli tabakasındaki farklı hücre sayıları için test bölümüne ait sonuçlar özetlenmiştir.

Tablo 3. İleri beslemeli geriye yayılım metodu ile test süresi için akım kestirimi sonuçları

Girdi tabakasındaki hücreler	Gizli hücre sayısı	OKH (m^6/s^2)	R^2
Q_{t-1}	1	3551	0.833
Q_{t-1}, Q_{t-2}	2	3568	0.835
$Q_{t-1}, Q_{t-2}, Q_{t-3}$	2	3537	0.839
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	3	2800	0.871
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	3	2779	0.872
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	4	3087	0.864

Tablo 4. Genelleştirilmiş regresyon sinir ağı yöntemiyle akım kestirim sonuçları

Girdi tabakasındaki hücreler	s	OKH (m^6/s^2)	R^2
Q_{t-1}	0.01	3901	0.818
Q_{t-1}, Q_{t-2}	0.02	4128	0.809
$Q_{t-1}, Q_{t-2}, Q_{t-3}$	0.01	4476	0.790
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	0.03	5028	0.765
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	0.03	4992	0.767
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	0.04	5131	0.762



Tablo 3'te ileri beslemeli geriye yayılım (İBGY) sinir ağı metoduyla farklı girdi ve gizli tabaka hücre sayıları kullanılarak elde edilen ortalama kare hatası ve belirlilik katsayıları

sonuçları verilmiştir. En iyi ortalama kare hatası ($OKH=2779 m^6/s^2$) ve belirlilik katsayısı ($R^2=0.872$) değerleri (t-5), (t-4), (t-3), (t-2) ve (t-1) anındaki akım değerlerinin girdi olarak alınıp t anındaki akımın kestirildiği alternatifte elde edilmiştir. Bu alternatifte girdi tabakasındaki hücre sayısı 5, gizli tabakadaki hücre sayısı 3 ve çıktı tabakasındaki hücre sayısı 1'dir. Bu sonuç daha önce yapılan otokorelasyon analizi ile uyumaktadır. Daha önce de açıklandığı gibi 5'inci otokorelasyondan (r_5) sonra ardışık değerler arasındaki fark azalmaktadır.

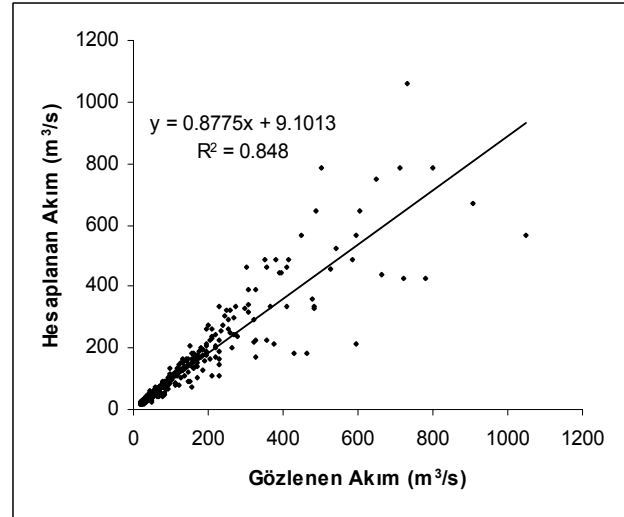

Tablo 4'te genelleştirilmiş regresyon sinir ağı (GRSA) algoritmasıyla farklı girdi hücre sayıları ve düzeltme parametresi (s) değerleri kullanılarak bulunan sonuçlar özetlenmiştir. Burada en iyi sonuç (t-1) anındaki akım değerinin girdi olarak alındığı $s=0.01$ değeri ile elde edilmiştir ($OKH=3901 m^6/s^2$ ve $R^2=0.818$). Her bir alternatif için s değerleri belirlenirken farklı düzeltme parametreleri için denemeler yapılmış ve en iyi sonucu verenler tabloya alınmıştır. Her iki tablo da göz önüne alındığında en iyi sonucu veren kombinasyona (İBGY(5,3,1)) ait grafikler Şekil 1'de verilmiştir.

Akımdan akım tahmini simülasyonlarında genelde İBGY metodunun GRSA'na göre daha iyi sonuç verdiği görülmüştür. Ancak belli bir YSA mimarisi için İBGY metodu ile en iyi sonucu elde etmek için çok sayıda simülasyon yapılması gerekmektedir. Bunun nedeni, eğitim başlangıcında her seferinde rastgele dağılmış farklı başlangıç ağırlık değerlerinin atanması ve eğitim sırasında yerel minimumlara takılıp global minimuma ulaşamamasıdır (Cıgızoğlu 2003c, 2003d). GRSA ile ise bir seferde değişmeyen tek bir sonuca ulaşılmaktadır.

YSA sonuçları ile karşılaştırma amacı ile aynı veriye klasik ARMA modeli uygulanmıştır. En iyi YSA sonucu (İBGY(5,3,1)) için 5 geçmiş akım değeri kullanıldığından AR(5) modeli uygun görülmüştür. AR(5) modeli sonuçları değerlendirme kriterleri ($OKH=3277 m^6/s^2$, $R^2=0.848$) açısından İBGY'e göre daha zayıf, GRSA'ya göre ise daha iyi sonuç vermiştir (Şekil 2).



Şekil 1. İleri beslemeli geriye yayılım metodu ile akım kestirimi (5,3,1) ve saçılma diyagramı



Şekil 2. Otoregresif model (AR5) ile akım kestirimi ve saçılma diyagramı

Yapay sinir ağları ile yağış ve önceki akım verileri kullanılarak gelecekteki akım değerinin tahmini

Yapay sinir ağları gibi kara kutu modellerinde havzanın yağışı akışa dönüştürmesi sürecinin ayrıntılarına girilmemektedir. Bu tip modellerde havzaya yağışı akışa çeviren kapalı bir kutu gözüyle bakılır. Sistemin dönüşüm fonksiyonunun o havzada gözlenmiş olan yağış ve akış kayıtlarına dayanarak belirlenmesine çalışılır.

Bu bölümde Juniata Nehir Havzası'na ait yağış değerleri kullanılarak nehir akımları tahmin

edilmiştir. Oluşturulan yapay sinir ağları mimarisinde 3 gün önceye kadar olan yağış verileri girdi olarak alınmış, ileri beslemeli geriye yayılım metodunda farklı gizli tabaka hücre sayıları, genelleştirilmiş regresyon sinir ağlarında ise en iyi çözümü veren düzeltme parametreleri ile çıktı tabakasındaki akım değerleri hesaplanmıştır. Girdi tabakasındaki hücre sayısı belirlenirken bir ilk yaklaşım olması bakımından yağış ile akım arasındaki korelasyon katsayılarına bakılmıştır.

İBGY ve GRSA metodlarının değişik YSA mimarileri için uygulama sonuçları Tablo 3 ve

Tablo 4'te verilmiştir. Sadece yağış verilerinin girdi olarak kullanıldığı farklı kombinasyonlardan en iyi sonucu girdi tabakası (t-2), (t-1), t anlarındaki yağış değerlerinden oluşan seçenek vermiştir (İBGY(3,2,1); OKH=14009 m⁶/s², R²=0.343). Girdi tabakasına daha önceki yağışlar eklendiğinde tahmin performansı artmamaktadır. Bu da daha önce yapılan çapraz korelasyon analizinde elde edilen iki günlük geçiş süresi sonucu ile uyum içindedir. Bu sonuç regresyon analizi sonrasında elde edilen ortalama kare hatası ve belirlilik katsayısı ile kıyaslandığında (OKH=14219 m⁶/s², R²=0.332) daha iyi netice verse de düşük belirlilik katsayısından da anlaşılacağı üzere yeterince tatmin edici değildir. Bunun en önemli nedenlerinden biri havza fiziksel özelliklerinin yeterince bilinmemesinden dolayı yağış verilerinin artık (etkin) yağış, akım verilerinin de dolaysız akış olarak hesaplanamamasıdır.

Tablo 5. İleri beslemeli geriye yayılım metodu ile akım tahmini



Girdi tabakasındaki hücreler	Gizli hücre sayısı	OKH (m ⁶ /s ²)	R ²
P _t	1	20622	0.028
P _t , P _{t-1}	2	16238	0.252
P _t , P _{t-1} , P _{t-2}	2	14009	0.343
P _t , P _{t-1} , P _{t-2} , P _{t-3}	3	18510	0.271
P _t , P _{t-1} , P _{t-2} , Q _{t-1}	3	2800	0.900
P _t , P _{t-1} , P _{t-2} , Q _{t-1} , Q _{t-2}	3	3834	0.869

Tablo 6. Genelleştirilmiş regresyon sinir ağı yöntemiyle akım tahmini



Girdi tabakasındaki hücreler	s	OKH (m ⁶ /s ²)	R ²
P _t	0.02	19923	0.080
P _t , P _{t-1}	0.03	16081	0.247
P _t , P _{t-1} , P _{t-2}	0.02	15217	0.285
P _t , P _{t-1} , P _{t-2} , P _{t-3}	0.04	15122	0.302
P _t , P _{t-1} , P _{t-2} , Q _{t-1}	0.03	4742	0.784
P _t , P _{t-1} , P _{t-2} , Q _{t-1} , Q _{t-2}	0.03	4549	0.802

Tablo 6'da görüldüğü gibi, genelleştirilmiş regresyon sinir ağı algoritması kullanılarak farklı s değerleri ile test süresi için elde edilen tahmin sonuçları genel olarak İBGY'ye oranla daha zayıf bulunmuştur. Ancak daha önce de belirtildiği gibi en iyi İBGY sonuçlarını elde etmek için çok sayıda simülasyon yapmak gerekmektedir.

Girdi tabakasında yağış değerlerine ek olarak önceki akım verisi de alındığında sonuçlarda olumlu gelişmeler olmuştur. En iyi sonuç (t-2), (t-1), t anlarındaki yağış ve (t-1) anındaki akım değerinin girdi olarak alınmasıyla İBGY(4,3,1) için elde edilmiştir (Tablo 5). Bu YSA mimarisi kullanıldığında OKH değeri 2800 m⁶/s²'ye düşerken R² değeri 0.900 değerine yükselmiştir. YSA sonucuna ait hidrograf ve saçılma diyagramı Şekil 3'te verilirken regresyon analizi neticeleri de Şekil 4'te gösterilmiştir.



Şekil 3. İleri beslemeli geriye yayılım metodu ile girdi tabakasında yağış ve akım verisi kullanılarak akım tahmini (4,3,1) ve saçılma diyagramı



Şekil 4. Regresyon analizi ile yağış ve akım verisi kullanılarak akım tahmini ve saçılma diyagramı

Bu grafikler incelendiğinde özellikle küçük akış değerlerinin tahmininde yapay sinir ağlarının regresyona nazaran daha başarılı olduğu görülmektedir. Geçmiş akım değerleri girdi tabakasına katıldığında GRSA sonuçlarında da net bir iyileşme görülmektedir. Ancak yine sonuçlar İBGY'e göre daha zayıftır.

Sonuçlar

Bu çalışmada iki farklı YSA metodu ile akımdan akım kestirimi ve yağış-akış modellenmesi yapılmıştır. Bu modellerden ileri beslemeli geriye yayılım metodu (İBGY), genelleştirilmiş regresyon sinir ağı (GRSA) yöntemine oranla daha iyi sonuçlar vermiştir. Ancak belli bir YSA mimarisi ile en iyi İBGY sonuçlarını elde etmek için çok sayıda simülasyon yapmak gerekmektedir. Her İBGY simülasyonundan önce başlangıç ağırlık değerleri olarak farklı rastgele dağılmış değerler atanmakta ve yerel minimumlara takılma sorunu yaşanmaktadır. GRSA yönteminde ise uygun düzeltme parametresi (s) seçildikten sonra, bir simülasyon değişmeyen tek bir sonuç vermektedir. İBGY sonuçları klasik regresyon ve AR modeli sonuçlarına oranla daha başarılı bulunmuştur. Çalışmadan elde edilen diğer önemli sonuç da YSA uygulaması öncesi yapılan oto-korelasyon ve çapraz-korelasyon analizinin YSA mimarisindeki girdi sayısı hakkında önemli bir ipucu verdiğidir. YSA uygulaması öncesi yapılacak bir istatistik analiz farklı YSA mimarileri denenmesi için gerekli

süreyi azaltacaktır. Çalışma sonuçları GRSA algoritmasının da gerek akımdan akım gerekse yağıştan akış tahmini çalışmalarında rahatça kullanılabileceğini göstermiştir. Bu algoritmanın diğer su kaynakları problemlerinde de İBGY ile birlikte kullanılması ve performanslarının karşılaştırılması faydalı olacaktır.

Kaynaklar

- Bayazit, M., (1998). *Hidrolojik Modeller*, İTÜ İnşaat Fakültesi Matbaası, İstanbul.
- Boogaard, H., Gautam, D.K. ve Mynett, A.E., (1998). Auto-regressive neural networks for the modelling of time series, *Hydroinformatics Conference*, Copenhagen.
- Box, G. E. P. ve Jenkins, G. M., (1976). Time series analysis, forecasting and control. *Holden Day Inc.*, San Francisco, California.
- Brikundavyi, S., Labib, R., Trung, H.T. ve Rousselle, J., (2002). Performance of neural networks in daily streamflow forecasting, *Journal of Hydrologic Engineering*, **7**, 5, 392-398.
- Campolo, M., Andreussi, P. ve Soldati, A., (1999a). River flood forecasting with a neural network model, *Water Resources Research*, **35**, 1191-1197.
- Campolo, M., Soldati, A. ve Andreussi, P., (1999b). Forecasting river flow rate during low flow periods using neural networks, *Water Resources Research*, **35**, 11, 3547-3552.
- Cığızoğlu, H.K., (2002a). Suspended sediment estimation and forecasting using artificial neural

- networks, *Turkish Journal of Engineering & Environmental Sciences*, **26**, 15-25.
- Cıgızoğlu, H.K., (2002b). Suspended sediment estimation for rivers using artificial neural networks and sediment rating curves, *Turkish Journal of Engineering & Environmental Sciences*, **26**, 27-36.
- Cıgızoğlu, H.K., (2003a). Incorporation of ARMA models into flow forecasting by artificial neural networks, *Environmetrics*, **14**, 4, 417-427.
- Cıgızoğlu, H.K., (2003b). Estimation, forecasting and extrapolation of flow data by artificial neural networks, *Hydrological Sciences Journal*, **48**, 3, 349-361.
- Cıgızoğlu, H.K., (2003c). Generalized regression neural networks in intermittent flow forecasting and estimation (makale hakemlerin incelemesinde).
- Cıgızoğlu, H.K., (2003d). Generalized regression neural networks in monthly flow forecasting (makale hakemlerin incelemesinde).
- Djebbar, Y. ve Alila, Y., (1998). Neural network estimation of sanitary flows, *Hydroinformatics Conference*, poster presentation, Copenhagen.
- Eberhart, R.C. ve Dobbins, R.W., (1990). Neural Network PC Tools: A Practical Guide, Academic Press, San Diego.
- Fernando, D.A.K. ve Jayawardena, A.W., (1998). Runoff forecasting using RBF networks with OLS algorithm, *Journal of Hydrologic Engineering* **3**, 3, 203-209.
- Hall, M.J. ve Minns, A.W., (1998). Regional flood frequency analysis using artificial neural networks, *Hydroinformatics Conference*, Copenhagen.
- Hsu, K., Gupta, H.V. ve Sorooshian, S., (1995). Artificial neural network modelling of the rainfall runoff process, *Water Resources Research*, **31**, 2517-2530.
- Lange, N., (1998). Advantages of unit hydrograph derivation by neural networks, *Hydroinformatics Conference*, Copenhagen.
- Mason, J.C., Price, R.K. ve Tem'ne, A., (1996). A neural network model of rainfall runoff using radial basis functions, *Journal of Hydraulic Research*, **34**, 4, 537-548.
- Minns, A.W. ve Hall, M.J., (1996). Artificial neural networks as rainfall runoff models *Hydrological Sciences Journal*, **41**, 3, 399-417.
- Müftüoğlu, R.F., (1991). Yağış-akış modelleri, *Hidrolojik Analiz ve Tasarım*, İTÜ İnşaat Fakültesi Hidrolik Anabilim Dalı.
- Raman, H. ve Sunilkumar, N., (1995). Multivariate modelling of water resources time series using artificial neural networks, *Hydrological Sciences Journal*, **40**, 2, 145-163.
- Ranjithan, S., Eheart, J.W. ve Garrett, J.H., (1993). Neural network-based screening for groundwater reclamation under uncertainty, *Water Resources Research*, **29**, 3, 563-574.
- Rogers, L.L. ve Dowl, F.U., (1994). Optimization of groundwater remediation using artificial neural networks with parallel solute transport modelling, *Water Resources Research*, **30**, 2, 457-481.
- See, L. ve Openshaw, S., (1998). Using soft computing techniques to enhance flood forecasting on the river Ouse, *Hydroinformatics Conference*, Copenhagen.
- Specht, D.F., (1991). A general regression neural network, *IEEE Transactions on Neural Networks*, **2**, 6, 568-576.
- Tokar, A.S. ve Johnson, P.A., (1999). Rainfall-runoff modelling using artificial neural networks, *Journal of Hydrologic Engineering*, **4**, 3, 232-239.
- USGS İstasyon No: 01567000
<http://co.water.usgs.gov/sediment>