



**Makale
(Article)**

Yapay Sinir Ağları ile Akarçay Akımının Modellemesi

Hüseyin USLU, Yılmaz İÇAĞA

Afyon Kocetepe Üniversitesi, Teknik Eğitim Fakültesi, 03200 Afyonkarahisar/TÜRKİYE
yicaga@hotmail.com

Özet

Bu çalışmada, Yapay Sinir Ağı (YSA) modeliyle DSİ'nin akım ve DMI'nin meteoroloji verileri kullanılarak Akarçay akımının tahmin edilmesi ve YSA özelliklerinin incelenmesi amaçlanmıştır. Modelleme için 6 akım gözlem verisi ile ay ve yıl sıra sayıları kullanılmıştır. Tüm veriler 0-1 arasında üniformize edilmiş, ayrıca gözlem değerleri normalize edilmiştir. 3 katmanlı YSA modelinde nöron adedi, öğrenme ve momentum oranları geniş bir yelpaze içinde sınanmıştır. Model çalışmaları sonucunda ay sıra sayılarının eğitime verisi olarak kullanıldığı modeller, bir gözlem yeri hariç, gözlem verilerinin eğitime verisi olarak kullanıldığı modellere göre daha başarılı sonuçlar vermiştir. YSA araştırmalarında belirsiz parametrelerden olan nöron adedi ve öğrenme oranı seçilen modellerde farklı değerler almışlardır. Fakat diğer belirsiz parametre olan momentum oranı değeri modellerin çoğunluğunda 0,90 çıkmıştır. Genel olarak YSA akım modellemesi için iyi sonuçlar vermekle beraber, ağ yapısındaki etkileşim tam olarak bilinemediğinden koşullar sağlandığı takdirde kavramsal ve/veya istatistiksel yöntemlerin modelleme çalışmalarında tercih edilmesi uygun seçenek olacaktır.

Anahtar Kelimeler: Yapay Sinir Ağları, Akarçay, Akım, Modelleme

Stream Flow Modeling Using Artificial Neural Networks

Abstract

In this study, estimation of Akarçay flow using data of DSİ (State Hydraulic Works) flow and of DMI (State Meteorology Works) meteorologic in Artificial Neural Network model, and investigation properties of ANN was purposed. In modeling, 6 flow observation stations' data with month and year order numbers were used. All data uniformised between 0-1, and moreover the observed data were normalised. Neuron number, learning and momentum rates in large range were examined in a ANN model with three layer. At the end of modeling studies, the models which month order numbers were used as training data, were successful than the other models which used observation as trainings data. Neuron numbers and learning rates, which are two of the undetermined parameters in YSA studies, in selected models have different values in optimum models. But, momentum rate which the other undefined parameter was 0,9 in most model. Though, ANN usually has good results in flow modeling, but, because of interaction in network structure is unknown exactly, preferring the conceptual and/or statistical methods should be reasonable alternative in case the conditions were provided.

Keywords: Artificial Neural Networks, Akarçay, Flow, Modeling

1. GİRİŐ

Yüzeysel suların miktarındaki yetersizlik, kaynakların olabildiđince etkin, verimli kullanılmasını zorunlu hale getirmiŐtir. Bu zorunluluk su miktarındaki deđişikliklerin önceden bilinmesini gerektirmektedir. Ancak su miktarındaki deđişiklik birkaç sebepten yeterli derecede bilinmemektedir. Bu sebeplerin en önemlilerinden birincisi, suyun asıl kaynađı olan yađışın bir zaman periyodunda tam olarak miktarının önceden belirlenmesinin mümkün olmamasıdır. İkincisi yađış ve akış gibi hidrolojik işlemlerin topografya, jeoloji, iklim ve zaman gibi birçok etkenden dolayı karmaşık olması ve bu etkenler arası ilişkiyi açıklayacak bir teori olmayışıdır. Bu sebepler suyun konum ve zaman içinde dağılımındaki deđişimlerinin belirlenmesini oldukça zorlaştırmaktadır [1]. Teori yoksunluğu ve su miktarını belirleme gerekliliđinden dolayı deđişik model çalışmaları ile problem çözülmeye çalışılmaktadır. Bu model çalışmaları, genelde, havzada bulunan ve su miktarını etkileyen etkenler arasındaki ilişkiyi tanımlayan kavramsal (fiziksel) modeller, istatistiksel modeller ve yapay sinir ađları gibi sayısal modeller çerçevesindedir.

İnsanın düşünme yapısını anlamak ve bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışmak olarak tanımlanan yapay zekâ, aslında programlanmış bilgisayarlara düşünme yeteneđi sağlama girişimidir. İnsan gibi düşünen ve davranan sistemlerin geliştirilmesine yönelik yapay zekâ çalışmaları, bir noktada insanı taklit etmeye yönelik olduğundan çok çeşitli alanlarda ilgi görmüŐtür [2]. Yapay zekâ çalışmalarından bir tanesi, yapay sinir ađları (YSA) teknolojisidir. YSA, basit biyolojik sinir sisteminin çalışma şekli taklit edilerek tasarlanan programlama yaklaşımıdır. Bu ađlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler [3].

Yapay sinir ađları hidrolojik süreçlerde ve akım modelleme çalışmalarında yaygın olarak kullanılan yöntemlerden biridir. Aqıl vd. YSA yaklaşımı ile taşkın risk yönetimi stratejisi geliştirmek amacıyla havza akım tahmin etmişlerdir. Çalışmada ileri beslemeli ve tekrarlanan ađ mimarisi, deđişken momentum ve öğrenme oranı kullanan geri yayılmalı algoritma kullanılarak uygulama gerçekleştirilmiştir. Model başarısını ölçmek için kullanılan korelasyonun 0,91 olduğunu belirtmiştir [4]. Ahmad ve Simonovic, havzadaki akım sürecini tanımlamada en iyi seçimin kavramsal model olduğunu fakat topografik, hidrolojik ve meteorolojik verilerin kalibrasyonunun engelleyici faktör olduğunu ifade etmektedir. Bu sebeple YSA'nın hidrolojik süreç hakkında açık ve kesin bilgiler olmadıkça akım modellemesinde daha etkili yol olduğunu ve esnek matematiksel yapısı nedeniyle nonlinear sistemlerde girdi ile çıktı arasındaki ilişkiyi tanımlayabileceđini bildirmektedir. Ahmad ve Simonovic yaptığı arařtırmada akım hidrografi geliştirmek için Kanada Manitoba'daki Red nehrinde kar erime indeksi, yađış indeksi, kış yađışı, bahar yađışı ve zaman deđişkenlerini girdi deđeri olarak kullanarak ileri beslemeli, geri yayılmalı YSA modelleri eğitmişlerdir. Modellerin tahmin başarıları 0,99 ile 0,88 deđerler arasında olduğunu belirtmişlerdir [5]. Jain ve Srinivasulu, kavramsal ve YSA modellerini birlikte kullanarak akım hidrografi geliştirmişlerdir. Çalışma Kentucky nehri havzası verileri ile taban akımı, evapotranspirasyon, zemin nemi için kavramsal model, yađış akış prosesi için ise YSA modeli kullanılmıştır [6]. Lallahem ve Mania akifer akımını simüle etmek için akımı etkileyen parametreleri belirlemek amacıyla uzman sistem, matematiksel model ve YSA'dan oluşan bir yöntem önermişlerdir. Önerilen yöntemin büyük ölçekli ve uzun dönem simülasyonlar için uygun olduğunu ifade etmişleridir [7]. Kentel, su kaynakları planlama ve yönetimi çalışmalarında kavramsal modellerin doğal süreci anlamadaki zorluklar sebebiyle yetersiz olduğunu, YSA'nın ise başarılı sonuçlar verdiđini belirtmektedir [8]. Singh ve Deo, günlük akım tahmini için YSA modeli kullanmışlar, YSA'nın günlük nehir akımları için kullanılmasının gerekliliđini ifade etmişlerdir [9]. Baratti vd. ileri beslemeli, çok tabakalı algılamalı YSA ile Tirso havzasında (İtalya) havza yönetimi açısından yađış-akış sürecini modellemiş, fiziksel tabanlı yaklaşımların yetersiz olması halinde YSA ile modelleme yapmayı önermişlerdir [10].

Bu çalışmada, Akarçay havzasında bulunan 6 gözlem istasyonunun akım verilerini modellemek ve YSA mimarisi ile parametrelerinin hangi deđerleri alabileceđi arařtırmak amacıyla deđişik nöron adedi ve parametre kullanılarak YSA modellerindeki parametrelerin dağılımını incelemektir. Modellemelerde

Akaray akım gzlemleri ile yıl ve ay sıra sayıları kullanılmıřtır. alıřmada YSA modellemesi VM 2.0 programı ile yapılmıřtır [11].

2. YAPAY SİNİR AĞI (YSA)

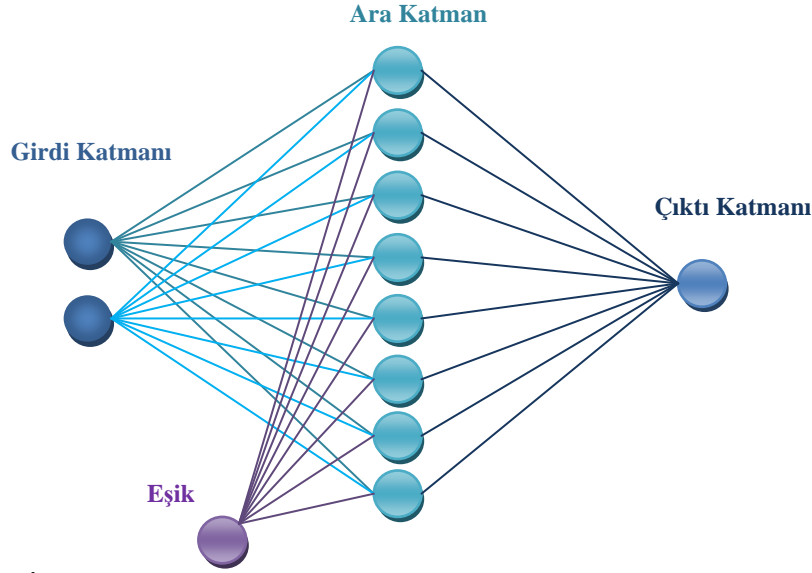
Biyolojik sistemlerde ğrenme, nöronlar arasındaki baėlantıların sisteme uyarlanması ile olur. Yařayıp tecrbe ettike bu baėlantılar ayarlanır ve gerekli ise yeni baėlantılar oluřur ve bu sayede ğrenme gerekleřir. Bu durum YSA iin de geerlidir. ğrenme, eėitme yoluyla rnekler kullanarak olur; bařka bir deyiřle, gerekleřme girdi/ıktı verilerinin iřlenmesiyle, yani eėitme algoritmasının bu verileri kullanarak baėlantı aėırlıklarını bir yakınsama saėlanana kadar, tekrar tekrar deėiřtirerek ayarlamasıyla olur [12]. YSA'nın ana ėesi olan matematiksel fonksiyon, aėın mimarisi tarafından řekillendirilir. YSA'ların davranıřları, girdi ile ıktı verisi arasındaki iliřki, nöronların transfer fonksiyonları, baėlantılar ve bu baėlantıların aėırlıklarından etkilenir. YSA'ların uygulama alanları iin bir sınır yoktur fakat ngr, modelleme ve sınıflandırma gibi bazı alanlarda aėırlıklı olarak kullanılmaktadır. Verideki trend veya yapıyı en iyi tanımlayan yntem olmaları dolayısıyla tahmin iřlemleri iin ok uygundur [13]. YSA'lar doėrusal olmama, ğrenme, genelleme yapma, adaptasyon, veri iřleme, hata ve grntye karřı duyarlılık ve tolerans, donanım, hazır paket program avantajlarına; donanıma baėımlı olmaması, aė mimarisinin ve parametre deėerlerinin belirlenmesi iin belli bir kural olmaması, ğrenilecek problemin aė olarak ifade edilmesi problemi, aėın eėitiminin ne zaman bitirilmesi gerektiėine iliřkin belli bir yntem olmaması, aėın davranıřları aıklanamaması dezavantajlarına sahiptir [14-15].

YSA'da, kullanılan mimarinin yanı sıra, aėırlık deėerlerinin belirleme eėitim metodu da nemli bir ayırt edici bir karakteristiktir. Gruplama aısından bakıldıėında, ğrenme modları YSA eėitimi iin eėitici verilerin kullanıldıėı ‘‘Eėitici ğrenme’’; eėitim seti kullanılmadan veriler arasındaki matematiksel iliřkinin baėlantı aėırlıklarının ayarlandıėı, kendi kendine ğrenilebilen mod da denilen ‘‘Eėitici olmayan ğrenme’’; elde edilen ıkıřın verilen giriře karřılık iliřkisini deėerlendiren bir lt kullanılan ve eėitici ğrenmeye yakın bir metot olan ‘‘Takviyeli ğrenme’’ olmak zere e ayrılmaktadır [15-16].

Eėitici ğrenmede girdi ve ıktı verileri arasındaki iliřkiler Őekil 1'deki gibi aė ile tanımlanır. Bu aėda nöron dizilerinden oluřan ara katmanların adedi problem eřidine gre deėiřik olmaktadır. Modelleme aė baėlantılarının her birine atanan aėırlık oranlarının, girdi ile ıktı arasındaki farkı azaltacak řekilde ğrenme oranı denilen belirli oranda deėiřtirilmesi ve iřlemin istenen hassasiyet saėlanıncaya kadar tekrarı ile yapılır. Modelleme ařamasında yakınsama yapılabilmesi diėer ifade ile hesaplamayı takılmaması iin momentum oranı denilen bir sabit sayı ve aė ıktısının sıfır olmasını engellemek iin girdisi daima 1 olan eřik deėeri de hesaplamaya katılır. Hesaplama, dnřm iin deėiřik fonksiyonlar kullanılabilmeyle beraber oėunlukla sigmoid fonksiyonu kullanılır. Sigmoid fonksiyonu

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

Burada x niformize edilmiř gzlem deėeridir [3-13].

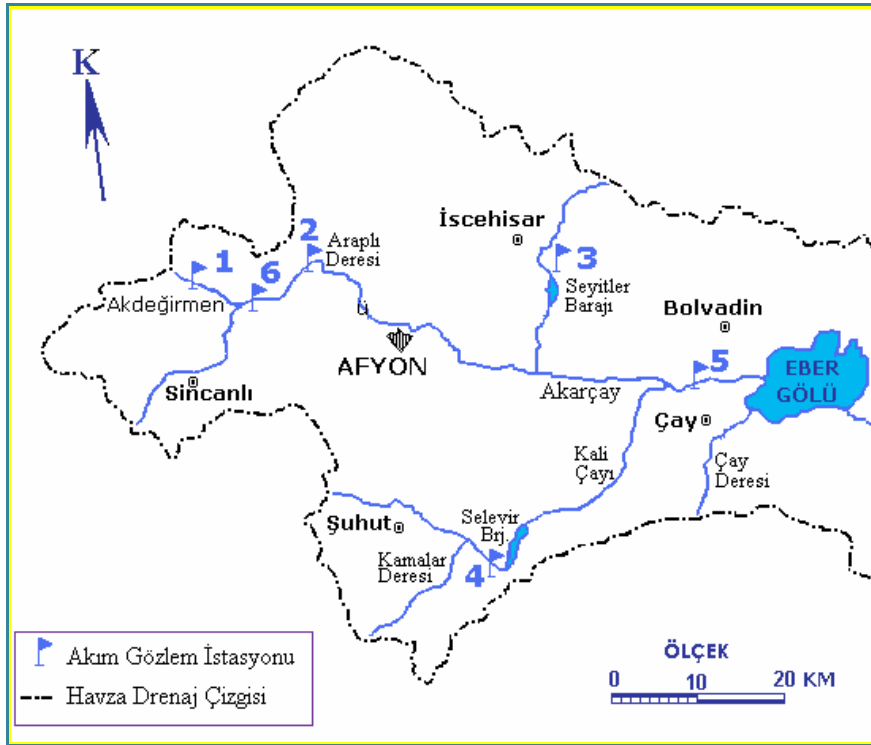


Şekil 1. İki girdili, bir çıktılı, bir ara katmanlı nöron sayısı 7 olan YSA yapısı.

3. MATERYAL METOT

3.1 Akarçay Havzası

Akarçay havzası coğrafi konum olarak Ege, İç Anadolu ve Akdeniz bölgelerinin kesişim noktalarında yer almaktadır. Havzanın geniş bir bölümü Ege bölgesinin İç Batı Anadolu bölümündedir. Doğu ve kuzey doğuda yer alan arazinin bir bölümü İç Anadolu Bölgesine uzanır. Havzanın önemli bir kesimi Afyonkarahisar il sınırları içerisinde olup, doğudan Konya sınırlarına girer (Şekil 2) [17-18].



Şekil 2. Akarçay gözlem istasyonları [22].

3.2 Veriler

Havzanın yaėıř alanında Afyonkarahisar, Seyitler, Selevir, Nacak, ay, Bolvadin, řuhut, Akdeėirmen, Akören, Serban, Köprölü, İhsaniye ve Cankurtaran meteoroloji ve hidrometeoroloji istasyonları bulunmaktadır. Afyonkarahisar ve Bolvadin baz istasyonlardır. Adı geen istasyonlardan Afyonkarahisar, ay, ve Bolvadin DMİ istasyonlarıdır. alıřmada kullanılan deėerler 1993 ile 1996 tarihleri de dâhil olmak üzere bu zaman dilimine aittir. DMİ istasyonları yanı sıra DSİ istasyonlarından yararlanılmıřtır [19-20-21].

3.3 Yapay Sinir Aėları

YSA da arařtırılan modeller Tablo 1’de verilmiřtir. Tabloda birinci grupta baėımlı (tahmin edilen) deėiřken aylık ortalama (AO), ikinci grupta ise aylık normalize ortalamadır (ANO). Deėiřkenlerin, gözlem deėerlerine ek olarak yıllık ortalama, ay sıra sayısı (her bir ayın yıl içindeki sıra numarası), yıl sıra sayısı (bařlangıtan itibaren yıllara verilen sıra numarası) ve aylık ortalamaların normalize deėerleri kullanılmıřtır. Aylık normalize ortalama deėerleri, aylık ortalama gözlem deėerlerinin Box-Cox dönüřümü ile normal daėılımlı hale dönüřtürülmüř deėerleridir [23]. Kullanılan bütün veriler 0 – 1 arasında olacak řekilde;

$$X_{\ddot{u}} = \frac{|X - X_{\min}|}{|X_{\max} - X_{\min}|} \quad (2)$$

dönüřümü ile üniformize edilmiřtir. Eřitlikte $X_{\ddot{u}}$: Üniformize veri, X : Gözlem (gerek) verisi, X_{\min} : Gözlem dizideki en küük deėer, X_{\max} : Gözlem dizide ki en büyük deėerdir. Uygulamada eėitici ili öėrenen YSA modeli kullanılmıřtır. Arařtırılan her bir model için bir ara katmanlı, nöron adedi 1’den 24’e kadar arttırılan YSA mimarileri kullanılmıřtır (řekil 1).

Tablo 1. Akım tahmini için arařtırılan modeller.

1.GRUP			2.GRUP		
Baėımlı Deėiřken	Baėımsız Deėiřken	Baėımsız Deėiřken	Baėımlı Deėiřken	Baėımsız Deėiřken	Baėımsız Deėiřken
AO	AO		ANO	AO	
	YO			YO	
	YS			YS	
	AS			AS	
	ANO			ANO	
	YO	AO		YO	AO
	YO	YS		YO	YS
	YO	AS		YO	AS
	YO	ANO		YO	ANO
	AO	YS		AO	YS
	AO	AS		AO	AS
	AO	ANO		AO	ANO
	YS	AS		YS	AS
	YS	ANO		YS	ANO
AS	ANO	AS	ANO		

AO: Aylık ortalama, YO: Yıllık ortalama, YS: Yıl sıra sayısı, AS: Ay sıra sayısı, ANO: Aylık normalize ortalama.

Programda katman adedi 3 olup, çekirdek fonksiyonu olarak sigmoid fonksiyonu kullanılmıřtır. Hesaplamalar için en fazla döngü sayısı 25000 olarak belirlenmiř, durdurma ölçütü olarak MAE (ortalama mutlak hata) kullanılmıřtır:

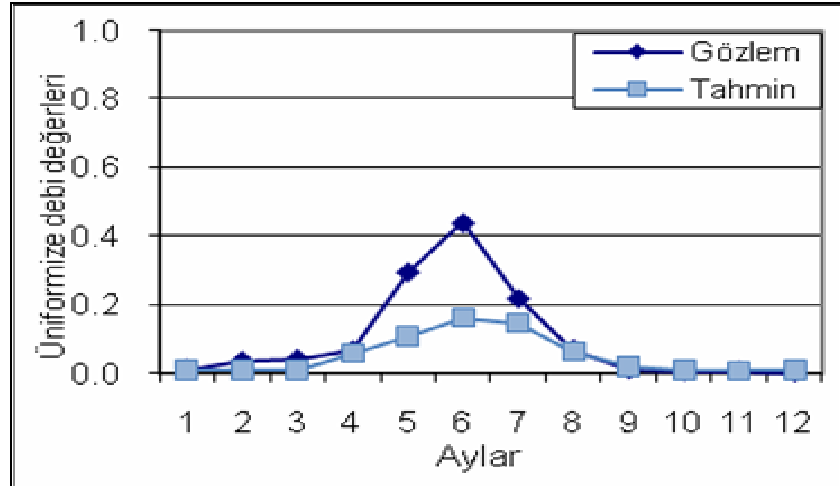
$$MAE = \frac{1}{n} \sum_{i=1}^n |g_i - t_i| \quad (3)$$

Burada n, veri adedi; g_i : i. gözlem değeri, t_i : i. tahmin değeridir. Program MAE'nin azalma göstermediği 5 işlem adımı sonunda durdurulmuştur.

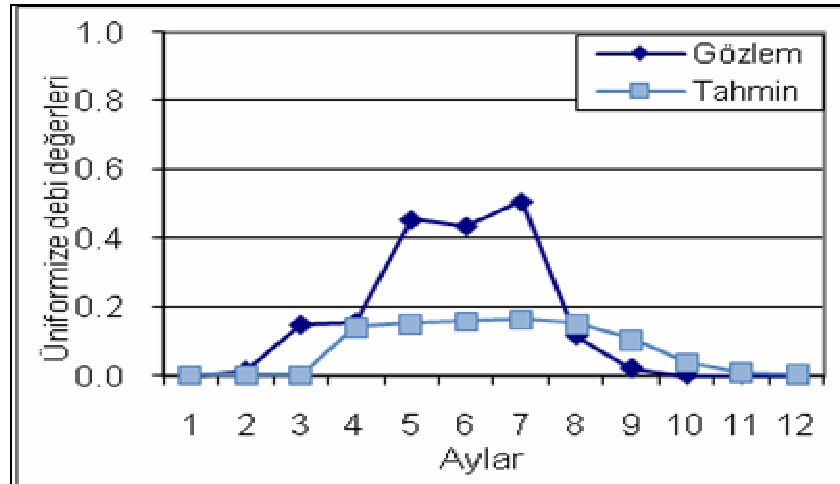
Program her yaklaşımda her ay için birer tahmin olmak üzere toplam 12 sonuç vermektedir. YSA modellerine ulaşmak için kullanılan eğitime adedi 1993-1994 yıllarına ait 24 aylık veridir. Tahmin edilen değerler ise 1995 yılına ait 12 aylık veridir. Hesaplamalar için VM 2.0 ticari olmayan paket programından yararlanılmıştır [11].

4. BULGULAR


Havzada hepsi üniformize olmak üzere 6 akım gözlem istasyonunun her birinde *aylık ortalama (AO)*, *yıllık ortalamalar (YO)*, *yıl sıra sayısı (YS)*, *aylık normalize ortalama (ANO)*, *ay sıra sayısı (AS)* şeklinde 5 farklı veri türünün kombinasyonu ve çıktısı olarak AO ile ANO kullanılmak üzere her bir gözlem istasyonunda 30'ar tane farklı model araştırılmıştır (Tablo 1). 30 modelin her biri için 3 katmanlı, nöron adedi 1'den 24'e kadar 1'er artırılarak, öğrenme ve momentum oranlarının her biri 0,1'den 0,9'a kadar 0,1'er artırılarak düzenlenen hesaplama yapılmıştır. Bu kombinasyonlara göre bir gözlem istasyonunda 30 modelin her biri için 1944 (24x9x9) alternatif araştırılmıştır. Araştırılan modeller içinde MAE ölçütüne göre en uygun sonuçları verenler aylar su yılından (Ekim ayı) başlamak üzere Şekil 3-8'de verilmiştir.




Şekil 3. 1 nolu gözlem istasyonu için YSASAO ve YOASAO verilerine göre model çıktıları.



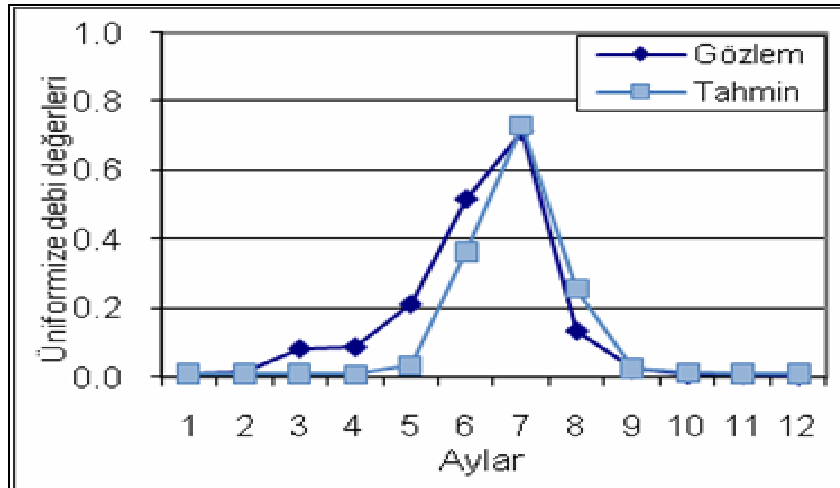
Şekil 4. 2 nolu gözlem istasyonu için YSASAO verilerine göre model çıktıları




Şekil 5. 3 nolu gözlem istasyonu için YOASAO verilerine göre model çıktıları



Şekil 6. 4 nolu gözlem istasyonu için ANOANO verilerine göre model çıktıları

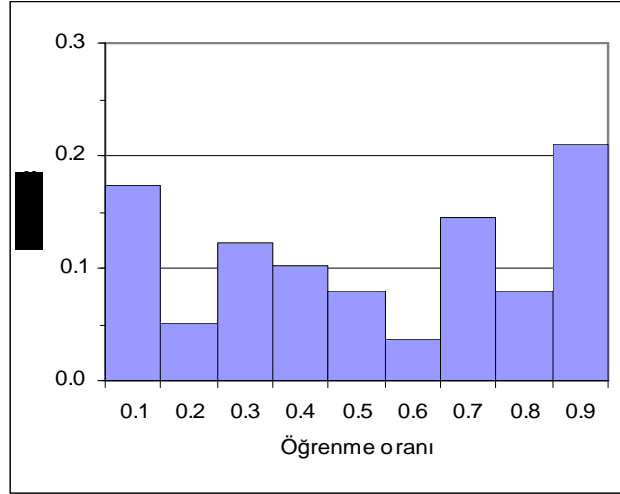


Şekil 7. 5 nolu gözlem istasyonu için YOASAO ve YSASAO verilerine göre model çıktıları

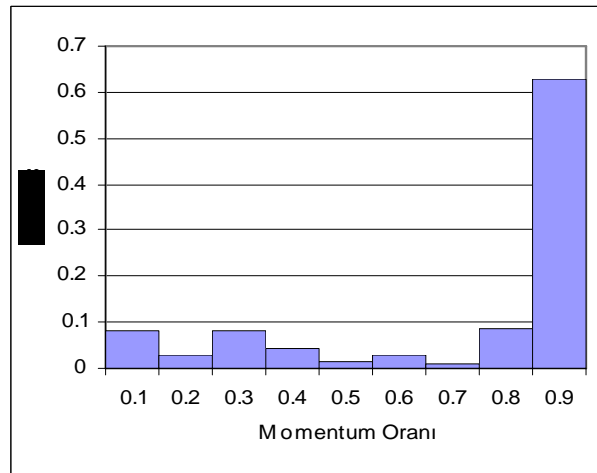


Şekil 8. 6 nolu gözlem istasyonu için YSASAO verilerine göre model çıktıları.

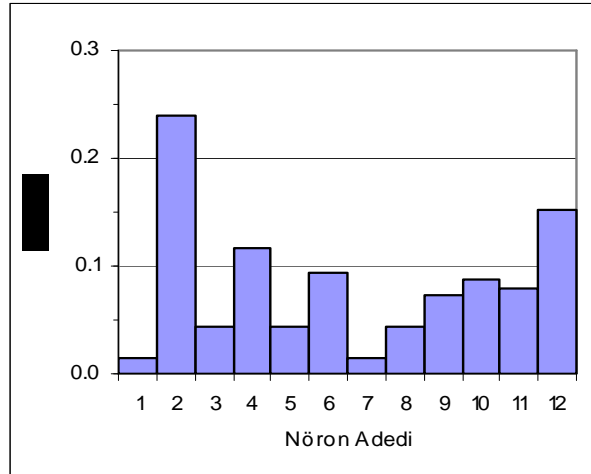
MAE kriterine göre seçilen modellerdeki öğrenme, momentum oranlarının ve nöron adetlerinin frekans dağılımları Şekil 9-11'de verilmiştir.



Şekil 9. Optimum sonuca ulařılan modellerdeki öğrenme oranlarının frekans dağılımı.



Şekil 10. Optimum sonuca ulařılan modellerdeki momentum oranlarının frekans dağılımı.



Şekil 11. Modellerde belirlenen nöron adetlerinin frekansları.

5. SONUÇ VE ÖNERİLER

Bu alıřmada Akaray akım verilerinin davranıřının modellenmesi amacıyla önceki iki yıllık akım verileri, ay ve yıl sıra sayıları kullanılarak YSA modeli tanımlanmıř, son yıla ait veriler ile model davranıřı ölçölmüřtür. Modeller 5 farklı veri türü ile nöron adedi, öęrenme oranı ve momentum oranlarının deęiřik deęerleri kullanılarak arařtırılmıřtır. Hesaplama durdurma ölçütü olarak MAE kullanılmıřtır.

1 nolu gözlem istasyonu verileri için yapılan modelleme alıřmasında Şubat, Mart, Nisan ayları, 2 nolu modellemede Aralık, Şubat, Mart, Nisan ayları, 3 nolu modellemede Ocak, Şubat, Mart ayları, 4 nolu modellemede Nisan, Mayıs ayları, 5 nolu modellemede Şubat, Mart ayları, 6 nolu modellemede Şubat, Mayıs, Haziran ayları hari dięer aylar için gözlem verileri ile tahmin verilerin uyum saęladığı görölmektedir (Şekil 3-8). Tüm modelleme sonuçlarından genel olarak anlařıldığına göre tahmin edilen veriler ile gerek verilerin grafiklerinden durdurma kriteri olarak kullanılan küçük MAE deęerleri tahmin ile gözlem deęerlerinin tam örtüşmesini gerektirmemektedir. Yüksek (ekstrem) deęerlerin olduęu verilerde YSA tahminlerinin başarısını arttırmak için verilerin iki paraya ayrılarak iki ayrı model kurulması daha başarılı modeller için uygun çözüm olacaktır. Bu sebeple gözlem ve tahmin verilerinin uyum saęladığı aylar için YSA modelleri gelecek yıllarda olası akımları tahmin etmek için kullanılabilir.

6 modellemenin yalnızca birinde sadece verilerin kullanıldığı model dięer veri kombinasyonlarından daha iyi sonuç vermiřtir. Dięer ifade ile 4 nolu model hari dięerlerinde ay sıra sayısının girdi olarak kullanıldığı görölmektedir. Bu durumun eęitme verilerindeki deęiřiklięin model performansını etkilemesinden kaynaklandığı düşünölmektedir. 24 aylık eęitme için kullanılan gözlem verilerinden birinci yılın bir ayındaki veri ikinci yılın aynı ayındaki veriden farklı deęerde olabildięinden bu deęiřiklik YSA performansını etkilemektedir. Ay sıra sayısının kullanıldığı modellerde ise bu deęiřiklik olmamaktadır. Bu sonuç bir yıllık gözlem verisinin kullanılması ile daha başarılı modellere ulařılabileceęine iřaret etmektedir. Ancak, özellikle hidrolojik olaylarda kısa süreli veri yerine veri karakterini iyi yansıtacağından uzun süreli gözlem verileri tercih edilmektedir.

Ađ mimarilerini ele aldığımızda öğrenme oranlarının 0,1 ve 0,9 değerlerinde modellerin daha iyi sonuç verdiği fakat hesaplamalarda kullanılması için net olarak önerilecek bir öğrenme oranının olmadığı görülmektedir (Şekil 9). Hesaplamalar için momentum oranının 0,9 kullanılabileceđi anlaşılmaktadır (Şekil 10). Diđer deđişle, hesaplamaya momentum oranı olarak 0,9 ile bařlandığında tatmin edici sonuca daha kolay ulařabileceđi anlaşılmaktadır. Şekil 11'den modelleme çalıřmalarının sonucunda, modellerin %24'ünde nöron adetlerinin 2, %15'ine ise 12 olduđu görülmektedir. 8 adet nöron içeren modeller hariç diđer modellerde çift rakamlı nöron adedinin tek rakamlı bitişik değerlerinden daha iyi performans gösterdikleri anlaşılmaktadır.

Genel olarak YSA, regresyon analizi gibi parametrik modellerdeki kabullere ihtiyaç göstermediğinden bu tür modelleme çalıřmalarında dikkate alınmalı, uygun sonuca ulařıldığında tercih edilmelidir. Bununla beraber, YSA'ların içyapıları bilinmediğinden kavramsal ve istatistiksel modeller verilerin model için uygun olması (yöntemin gerektirdiđi kabulleri karřılama) halinde tercih edilmelidir.

6. KAYNAKLAR

1. İçađa, Y., 2001, "Akarçay Aylık Akımlarının Modellenmesi", III. Ulusal Hidroloji Kongresi, Ed: Özkul, S., Baran, T. ve Harmancıođlu, N., 630-640, İzmir
2. Yurtođlu, H. 2005,. "Yapay Sinir Ađları metodolojisi İle Öngörü Modellemesi: Bazı Makro Ekonomik Deđişkenler İçin Türkiye Örneđi", Uzmanlık Tezi, Selçuk Üniversitesi, Ankara
3. Öztemel , E., 2003, "Yapay Sinir Ađları. Papatya Yayıncılık", 1. Basım, İstanbul
4. Aqil, M., Kita, I., Yano, A. and Nishiyama, S., 2007, "Neural Networks for Real Time Catchment Flow Modeling and Prediction", *Water Resources Management*, 21(10), 1781-1796
5. Ahmad, S., Simonovic, S.P., 2005, "An artificial neural network model for generating hydrograph from hydro-meteorological parameters", *Journal of Hydrology*, 315 (1-4), 236-251
6. Jain, A. and Srinivasulu, S., 2006, "Integrated approach to model decomposed flow hydrograph using artificial neural network and conceptual techniques", *Journal of Hydrology*, 317(3-4), 291-306
7. Lallahem,S. ve Mania J., 2003, "A nonlinear rainfall-runoff model using neural network technique: example in fractured porous media", *Mathematical and Computer Modelling*, 37(9-10), 1047-1061
8. Kentel, E., 2009, "Estimation of river flow by artificial neural networks and identification of input vectors susceptible to producing unreliable flow estimates", *Journal of Hydrology*, 375(3-4), 15 481-488
9. Singh,P., Deo., M.C., 2007, "Suitability of different neural networks in daily flow forecasting", *Applied Soft Computing*, 7(3), 968-978

10. Baratti, R. Cannas, B. Fanni, A. Pintus, M. Sechi, G. M. Toreno N., 2003, "River flow forecast for reservoir management through neural networks", *Neurocomputing*, 55(3-4), 421-437
11. VM 2.0, 2006, Veri Modelleme, http://www2.aku.edu.tr/~icaga/programlar/ysa_pg3_1_3kasim2006.zip
12. <http://www.herseykitap.googlepages.com> ; Eriřim tarihi: 29.04.2008
13. Elmas, ., 2003, "Yapay Sinir Aęları", Seękin Yayıncılık, 1. Basım, Ankara
14. <http://www.yapay-sinir-aglari.uzerine.com> ; Eriřim tarihi: 01.05.2008
15. Saęıroęlu, ř., Beřdok, E. ve Erler, M., 2003, "Mühendislikte Yapay Zeka Uygulamaları 1:Yapay Sinir Aęları", Ufuk Kitap Kırtasiye-Yayıncılık Tic. Ltd. ř., Ankara
16. <http://www.backpropagation.com> ; Eriřim tarihi: 02.24.2007
17. Tezcan, L., 1999, "Akaręay Havzası Hidroloji ve Yeraltı Suyu Akım Modeli", 2. Ara Rapor. Hacettepe Üniversitesi, Ankara
18. Yurtcu, ř., 2001, "Kil Zeminlerde Yer altı Suyu Davranışının Modellenmesi", Yüksek lisans tezi, Afyon Kocatepe Üniversitesi, Afyonkarahisar
19. Uslu, H., 2008, "Yapay Sinir Aęları İle Yeraltı Su Seviyesi Modellenmesi", Yüksek lisans tezi, Afyon Kocatepe Üniversitesi, Afyonkarahisar
20. DMİ, 2007, "Meteoroloji Deęerleri", Devlet Meteoroloji İşleri Genel Müdürlüęü, Afyonkarahisar
21. DSİ, 1998, "Eber-Akşehir Projesi Hidroloji Revize Rapor", Devlet Su İşleri Genel Müdürlüęü, Isparta
22. İaęa, Y., 2004. "Akaręay Havzasında Aylık Akışların Yaęış, Sıcaklık ve Buharlaşma Gözlemlerinden Tahmini İin Regresyon Modelleri", IV. Ulusal Hidroloji Kongresi & Hidrolojide Yeni Yöntemler Semineri, Ed.: Avcı, İ., Önöz, B. ve Aksoy, H., İstanbul Teknik Üniversitesi İnřaat Fakültesi, İstanbul
23. McMahon, T.A. & Mein, R.G., 1986, "River and Reservoir Yield", University of Melbourne & Monash University, Victoria, Australia