

## Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi

Umut OKKAN\*  
H.Yıldırım DALKILIÇ\*\*

### ÖZ

Su kaynakları sistemlerinin planlanması ve tasarımı aşamasında, güvenilir akım tahminlerinin ve akım modelleme çalışmalarının yapılması büyük önem taşımaktadır. Sunulan çalışmada, bir Radyal Tabanlı Yapay Sinir Ağı modeli (RTYSA) geliştirilerek, Büyük Menderes Havzası'nda yer alan Kemer Barajı Havzası'na ait aylık akımlara uygulanmıştır. Girdi olarak yağış, sıcaklık ve 1 ay önceki yağış değerlerine ihtiyaç duyan RTYSA modeli, Mart 1979-Kasım 1997 tarihleri arasındaki 225 aylık akım verileri kullanılarak eğitilmiş; Aralık 1997-Aralık 2005 tarihleri arasındaki 97 aylık akım verileri ile sınanmıştır. Gözlenmiş ve modellenmiş akımların uzun dönem ve mevsimsel istatistikleri karşılaştırıldığında; kurulan modelin Kemer Barajı aylık akımlarını başarıyla temsil ettiği; böylece geliştirilen modelin, bir baraj havzasının aylık akımlarının tahmininde başarıyla kullanılabileceği gösterilmiştir.

**Anahtar Kelimeler:** aylık akım modeli, radyal tabanlı yapay sinir ağları, kemer barajı

### ABSTRACT

#### Monthly Runoff Model for Kemer Dam with Radial Based Artificial Neural Networks

It is very important to make reliable runoff estimations and runoff modeling studies when planning and designing water resources systems. In the study presented, a Radial Based Artificial Neural Network (RBANN) model is developed and applied to the monthly flows of Kemer Dam reservoir in the Büyük Menderes Basin. The best radial based neural network model which requires monthly areal precipitation, temperature and a month before areal precipitation as the input data, is trained by using 225 months of runoff data observed between March 1979 and October 1997. The model is then tested by 97 months of runoff data recorded between December 1997 and December 2005. When the statistics of the long term and seasonal term recorded and modeled runoff are compared, it can be seen that the developed model successfully represents the monthly runoff input to Kemer reservoir and can be used to forecast the monthly runoff in a watershed.

**Keywords:** monthly runoff model, radial based artificial neural networks, kemer dam

---

Not: Bu yazı

- Yayın Kurulu'na 13.07.2010 günü ulaşmıştır.
- 30 Haziran 2011 gününe kadar tartışmaya açıktır.

\* Balıkesir Üniversitesi, İnşaat Mühendisliği Bölümü, Balıkesir - umutokkan@balikesir.edu.tr

\*\* Dokuz Eylül Üniversitesi, İnşaat Mühendisliği Bölümü, İzmir - yildirim.dalkilic@deu.edu.tr

## 1. GİRİŞ

Su kaynakları mühendisliğinde, yağış ile akış arasındaki ilişkinin modellenmesi büyük önem taşımaktadır. Söz konusu yağış-akış modelleri su kaynakları ile ilgili birçok problemde kullanılmakta ve aynı zamanda hidrolojik olayların işleyiş mekanizmaları hakkında belirgin fikir vermektedirler. Modeller, bir akarsu havzasına düşen yağışı akarsu çıkışındaki akışa dönüştüren mekanizmayı esas almakta olup, fiziksel tabanlı yayılı modeller (beyaz kutu modelleri), kavramsal modeller (gri kutu modelleri) ve kapalı (kara) kutu modelleri olmak üzere üç sınıfta değerlendirilmektedirler. Bunlardan fiziksel tabanlı yayılı modeller ve kavramsal modeller gerek parametre gerekse algoritmanın karmaşıklığı ve fazla girdi içermeleri bakımından bazen belirsizlikler taşıyabilmekte ve uygulama havzasını temsil edemeyebilmektedirler [1].

Sözü edilen bu ilişkilerdeki karmaşıklık ve belirsizliklerden dolayı, yağış-akış ilişkilerinin modellenmesi fiziksel sürecinin ayrıntılarına girilmediği kapalı (kara) kutu modelleriyle de gerçekleştirilebilmekte olup, modeller havza girdileri ve çıktıları arasında kurulan matematiksel fonksiyonlar şeklinde ifade edilmektedir. Bu kapsamda geliştirilmiş modellerde, yağış olayının görülmesi ile akarsu çıkışında oluşacak akım arasındaki gecikmelerden ve akımlardaki içsel bağımlılık etkisinden yararlanılabilmekte ve modeller genel olarak klasik istatistiksel yöntemleri (AR, ARMA, Regresyon vb.) ve son zamanlarda önemini giderek arttıran yapay sinir ağlarını (YSA) esas almaktadırlar.


Bunlardan regresyon analizi en bilindik tekniklerden olup iki veya daha fazla değişken arasındaki ilişkinin matematiksel olarak ifadesini vermektedir. Son zamanlarda birçok alanda kullanılan YSA ise, verilen girdilere karşı çıktılar üreten akıllı bir kara kutu modeli veya doğrusal olmayan bir regresyon modeli gibi düşünülmekte olup birçok YSA uygulamasına rastlamak mümkündür. Uygulamalar incelendiğinde, YSA yaklaşımlarının klasik istatistik yöntemlere nazaran daha olumlu sonuçlar verdiği göze çarpmaktadır.

Bu kapsamda ele alınmış başlıca uygulamalar şunlardır: [2-6] 'da yağış-akış ilişkisi YSA kullanılarak başarıyla modellenmiştir. [5, 7-10] 'da akarsu akımları YSA ile tahmin edilerek klasik istatistiksel yöntemlerle kıyaslanmıştır. Akarsu akımlarının yanı sıra, baraj haznesine giren akımlar da YSA kullanılarak modellenmiştir [11-12]. Uygulamalar incelendiğinde, modellemelerde genellikle ileri beslemeli geriye yayımlı yapay sinir ağı algoritmalarının kullanıldığı göze çarpmaktadır. Ancak bu algoritmalara alternatif olarak geliştirilmiş olan Genelleştirilmiş Regresyon Sinir Ağı [13] ve Radyal Tabanlı Sinir Ağı [14-16] gibi algoritmaların da uygulamalarına rastlanmaktadır.

Hazırlanan çalışmada Kemer Baraj havzasına ait aylık yağış-akış ilişkisi Radyal tabanlı yapay sinir ağları (RTYSA) ile modellenmiştir. Bu kapsamda mevcut RTYSA uygulamalarında kullanılan Küçük Kareler (LMS) çözümü yerine [14, 15], Moore-Penrose Sözdere Ters (Pseudo-inverse) yaklaşımı tercih edilerek çok boyutlu interpolasyon probleminin çözüm performansı artırılmak istenmiştir. Ayrıca modellerde yağış olayının görülmesi ile akarsu çıkışında oluşacak akım arasındaki gecikmelerden de yararlanılmış ve farklı girdi setleri kullanılarak model performansları istatistiksel kriterler yardımıyla sınanmıştır.

## 2. RADYAL TABANLI YAPAY SİNİR AĞLARI (RTYSA)

Radyal Tabanlı Yapay Sinir Ağları (RTYSA), biyolojik sinir hücrelerinde görülen etki-tepki davranışlarından esinlenilerek 1988 yılında geliştirilmiş ve filtreleme problemine uygulanarak YSA tarihine girmiştir [17]. RTYSA modellerinin eğitimini çok boyutlu uzayda eğri uydurma yaklaşımı olarak görmek mümkündür [18]. Bu nedenle RTYSA modelinin eğitim performansı, çıktı vektör uzayındaki verilere en uygun yüzeyi bulma ve dolayısıyla bir interpolasyon problemine dönüşmektedir. RTYSA modelleri genel YSA mimarisine benzer şekilde giriş katman, gizli katmanı ve çıktı katmanı olmak üzere 3 katman halinde tanımlanmaktadır (Şekil 1). Ancak, klasik YSA yapılarından farklı olarak RTYSA'larda, girdi katmanından gizli katmanına geçişte radyal tabanlı aktivasyon fonksiyonları ve doğrusal olmayan bir kümeleme (cluster) analizi kullanılmaktadır. Gizli katman ile çıktı katmanı arasındaki yapı ise diğer YSA türlerinde olduğu gibi işleyişini sürdürmekte olup asıl eğitim burada gerçekleştirilmektedir.



Şekil 1. RTYSA'nın Yapısı

RTYSA modellerinde ağın ürettiği çıktı ( $y$ ) ise Denklem 1 yardımıyla hesaplanabilmektedir.

$$y_i = \sum_{k=1}^N w_{ik} \phi_k(x, c_k) = \sum_{k=1}^N w_{ik} \phi_k(\|x - c_k\|_2), \quad i = 1, 2, \dots, m \quad (1)$$

Burada  $x \in R^{n \times 1}$  ağın girdi vektörünü;  $\phi_k(\cdot) \in R^+$  radyal tabanlı aktivasyon fonksiyonunu;  $c_k \in R^{n \times 1}$  girdi vektör uzayının bir alt setinden seçilen radyal tabanlı merkezleri;  $\|\cdot\|_2$  girdi vektörünün merkezden ne kadar uzak olduğunun bir ölçütü olan Öklidyen normunu;  $w_{ik}$  çıktı katmanındaki ağırlıkları;  $N$  ise gizli katmanda bulunan hücre sayısını göstermektedir.

RTYSA modellerinde önem arz eden elemanlar; hücre merkezleri, çıktı katmanındaki ağırlıklar ve kullanılan aktivasyon fonksiyonunun yapısıdır. RTYSA modellerinde aktivasyon fonksiyonu olarak birçok fonksiyon tipi kullanılabilir. Doğrusal, Kübik,

Gauss, Multi-Kuadratik, Ters Multi-Kuadratik fonksiyonlar bunlardan bazıları olup bu çalışmada Gauss fonksiyonu tercih edilmiştir. Gauss fonksiyonunun matematiksel yapısı Denklem 2’de gösterilmektedir.

$$\phi_k(x) = \exp(-\|x - c_k\|_2^2 / 2\sigma^2) \quad (2)$$

Burada  $x$  girdi vektörünü,  $c_k$  merkezleri göstermektedir.  $\sigma$  ise standart sapma değerini simgelemekte olup; YSA terminolojisinde, RTYSA modelinin performansını önemli ölçüde etkileyen dağılma (spread) parametresi olarak da anılmaktadır [18].

RTYSA modellerinin eğitimi, hücre merkezlerinin bulunması ve çıktı katmanındaki ağırlıkların optimize edilmesi üzere iki aşamada gerçekleşmektedir. Literatürde hücre merkezlerini ( $c_k$ ) ve çıkış ağırlıklarını ( $w_{ik}$ ) bulabilmek için farklı yöntemler kullanılmaktadır. Hücre merkezlerini bulabilmek için en sık kullanılan yöntem  $K$ -ortalamalar ( $K$ -means) ve Kohonen kümeleme yöntemleridir. Çıkış ağırlıklarını bulmakta kullanılan yöntemler ise En Küçük Ortalamalı Kareler (LMS) ve Moore-Penrose Sözde Ters (Pseudo-inverse) yöntemleridir. Dağılma parametresi ise genellikle bütün hücreler için sabit alınmaktadır. RTYSA modellerinde dağılma parametresi için yaklaşık denklemler olmakla birlikte, bu parametre deneme-yanılma yöntemiyle de belirlenebilmektedir [18].

Çalışmada RTYSA modeline ait hücre merkezleri ( $c_k$ )  $K$ -ortalamalar yöntemi [19] ile belirlenmiştir. Hücre merkezlerinin belirlenmesinin ardından, belli bir  $Q$  eğitim seti için ağırlık çıkışı ( $y$ ) Denklem 1’dekine benzer biçimde hesaplanabilmektedir (Denklem 3).

$$y(q) = \sum_{k=1}^N w_{ik} \phi_k(x(q), c_k), \quad q = 1, 2, \dots, Q \quad (3)$$

Bu aşamadan sonra, ağırlık ürettiği çıktı değerleri ile beklenen çıktı değerleri arasındaki farklar karşılaştırılmakta ve Denklem 4’te verilen performans fonksiyonunun minimize edilmesi amaçlanmaktadır.

$$E(w) = \frac{1}{2} \sum_{q=1}^Q [b(q) - y(q)]^2 = \frac{1}{2} (b - \phi w)^T (b - \phi w) = \frac{1}{2} (b^T b - 2b^T \phi w + w^T \phi^T \phi w) \quad (4)$$

Burada,  $E(w)$  performans (amaç) fonksiyonunu,  $b$  ağırlık beklenen çıktıları (istenen veya ölçülmüş değerleri),  $y$  ağırlık ürettiği çıktıları,  $Q$  eğitim setini ve  $T$  ise serinin transpozunu simgelemektedir.

Çalışmada,  $E(w)$ ’nin ağırlıklara göre 1.dereceden türevi 0 değerine eşitlenerek ( $\partial E(w) / \partial w = 0 \rightarrow -\phi^T b + \phi^T \phi w = 0$ ) elde edilen denklem takımı Moore-Penrose Sözde Ters (Pseudo-inverse) yaklaşımı ile çözülmüş, ağırlık çıkış ağırlıkları belirlenmiştir (Denklem 5).  $\phi^+$  sözde ters çözümünün detayları [20]’de açıklanmaktadır.

$$w = (\phi^T \phi)^{-1} \phi^T b = \phi^+ b \quad (5)$$

### 3. RTYSA UYGULAMASI

Sunulan çalışmada, Ege Bölgesinin en uzun nehri olan Büyük Menderes'in Akçay kolu üzerinde, sulama, taşkın kontrolü ve enerji üretimi amacıyla inşa edilmiş olan Kemer Barajı'na ait aylık akımlar modellenmiştir. Barajın yer aldığı havza olan Büyük Menderes 9800 ha'lık sulak alanıyla bölgede büyük önem taşımakta ve bu anlamda Kemer Barajı havzanın önemli su kaynakları sistemlerinden birisi olarak görülmektedir. Çalışma bölgesinde barajı besleyen 4 adet akarsu kolu ve mevcut akarsu kollarında EIE tarafından ölçülen 4 adet akım gözlem istasyonu bulunmaktadır (EIE-730, EIE-731, EIE-732 ve EIE-733). İstasyonlara ait Ocak 1979-Aralık 2005 takvim yıllarını kapsayan rasat kayıtları DSİ XXI. Bölge Müdürlüğü ve Kemer Barajı HES İşletme Müdürlüğünden aylık hacimler ( $10^6$  m<sup>3</sup>) şeklinde temin edilmiş ve dört koldan gelen debi ortalamaları derlenmiştir. Bunların yanı sıra, bölgede baraj havzasını temsil edebilecek bölgeye en yakın ve yeterli gözleme sahip 2 adet meteoroloji istasyonu tespit edilmiştir. Bu istasyonlar DMI tarafından işletilen Denizli (17237) ve Muğla (17292) istasyonları olup, modelleme çalışmasında bu istasyonlara ait Thiessen poligonları kurularak alansal ortalama yağış değerleri elde edilmiştir. Sıcaklıklar için ise iki istasyona ait verilerin aritmetik ortalaması kullanılmıştır.

Çalışmada, hazırlanan RTYSA modeli birçok farklı girdi kombinasyonu ile ayrı ayrı çalıştırılmıştır. Çalışmada öncelikle yağış ( $Y_t$ ) ve sıcaklık ( $S_t$ ) girdileri ile model kurulmuştur. Ancak yağış olayının görülmesi ile akarsu çıkışında oluşacak akım arasındaki gecikmeler de düşünülerek modele sırasıyla 1 ay önceki yağış ( $Y_{t-1}$ ) ve 2 ay önceki yağış ( $Y_{t-2}$ ) girdileri de eklenmiştir. En son olarak modele 1 ay ( $A_{t-1}$ ) ve 2 ay ( $A_{t-2}$ ) önceki akım değerleri de ilave edilmiş ve akımlardaki içsel bağımlılık etkisi de dikkate alınarak modeller irdelenmiştir. Modelleme çalışmalarında farklı girdi kombinasyonlarının uygulanmasından ötürü modeller Mart 1979-Aralık 2005 takvim yılları arasındaki veriler dikkate alınarak hazırlanmıştır. Böylece Mart 1979-Aralık 2005 tarihleri arasında çalıştırılan modelde, 1 ve 2 ay önceki veriler de sırasıyla 1979 yılının Şubat ve Ocak aylarından başlanarak derlenmiştir. Modelin genelleme yeteneğinin sınanması açısından, model 322 adet veri içeren veri setinin %70'i (Mart 1979- Kasım 1997) ile kurulmuş (eğitilmiş), geri kalan % 30'u (Aralık 1997- Aralık 2005) ile test edilmiştir. Bu aşamada MATLAB ortamında kodlanan Radyal Tabanlı Yapay Sinir Ağı (RTYSA) modeli ve Gauss aktivasyon fonksiyonu kullanılmıştır. Modelin eğitim aşamasında hızlı yakınsayabilmesi ve performansının artırılması açısından, tüm veriler  $(x-x_{min})/(x_{max}-x_{min})$  bağıntısıyla 0 ile 1 arasında ölçeklendirilerek ağa sunulmuştur. Öğrenme işlemi tamamlandıktan sonra ölçeklendirilen veriler ters işlem ile orijinal ölçeğine dönüştürülmüştür. Ağın eğitiminde, RTYSA modeline ait dağılım parametresi ise deneme yanılma yoluyla, Denklem 4'te belirtilen  $E(w)$  değeri minimum olacak şekilde belirlenmiştir. Modelde  $E(w)$  ölçütünün yanında, istatistiksel uyum iyiliği ölçütlerinden olan determinasyon katsayıları ( $R^2$ ) ve maksimum rölatif hata yüzdeleri de incelenmiştir.

### 4. BULGULAR

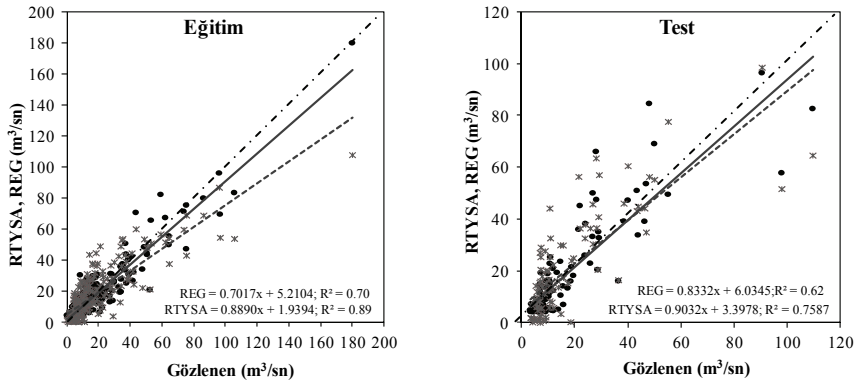
Yöntem bölümünde detayları anlatılan RTYSA modeli birçok farklı girdi kombinasyonu ile MATLAB ortamında kodlanan program vasıtasıyla çalıştırılmış ve her bir kombinasyon için en uygun yapıya, test dönemindeki ortalama karesel hata performansları irdelenerek karar verilmiştir. Bu amaçla modelin performansını önemli ölçüde değiştiren gizli

katmandaki hücre sayısı (GKHS) 5 ile Q (eğitim seti) arasında 5'er artımlarla ve dağılma parametresi ( $\sigma$ ) 0.1 ile 5.0 değerleri arasında 0.1 artımlarla deneyerek belirlenmiştir. Modellerin eğitim ve test dönemi performansları Çizelge 1'de gösterilmektedir.


Farklı girdiler kullanılarak çalıştırılan RTYSA modeline ait sonuçlar incelendiğinde, akımlardaki içsel bağımlılık etkisinin hesaba katıldığı model yapılarının performansları diğer 3 kombinasyona göre daha olumlu sonuçlar vermiştir. Ancak olayın içselligi ihmal edildiğinde ve yağışın akıma dönüşmesindeki gecikmelerden de faydalanılarak hazırlanan 2. ve 3. model yapılarının da oldukça başarılı olduğu düşünülmektedir. Bu modeller içinde de en az girdi kullanılarak hazırlanan 2. model yapısının 3. model yapısına oldukça yakın sonuçlar verdiği, hatta 2. modelin test dönemi HKO performansının 3. model yapısına göre daha başarılı olduğu göze çarpmaktadır. Bu sebeplerden ötürü yağış ( $Y_t$ ), sıcaklık ( $S_t$ ) ve 1 ay önceki yağış ( $Y_{t-1}$ ) girdilerini kullanan 2. model yapısının (\*), gerek girdi sayısının daha az olması, gerek genelleme yeteneğindeki başarısından ötürü havzanın yağış-akış ilişkisini başarıyla temsil edebildiği düşünülmektedir. Çalışmada en uygun (\*) RTYSA modelinin klasik yöntemlere karşı performansı ise yine verilerin %70'lik kısmı ile hazırlanan çoklu doğrusal regresyon (REG) modeli ile karşılaştırılmıştır. Eğitim dönemi ve test dönemi olmak üzere iki aşamada değerlendirilen modellerin saçılım diyagramları (Şekil 2) ve test dönemine ait aylık hidrografları (Şekil 3) verilmiştir.

Çizelge 1. RTYSA modeline ait eğitim ve test dönemi performanslarının karşılaştırılması (\* : önerilen model)

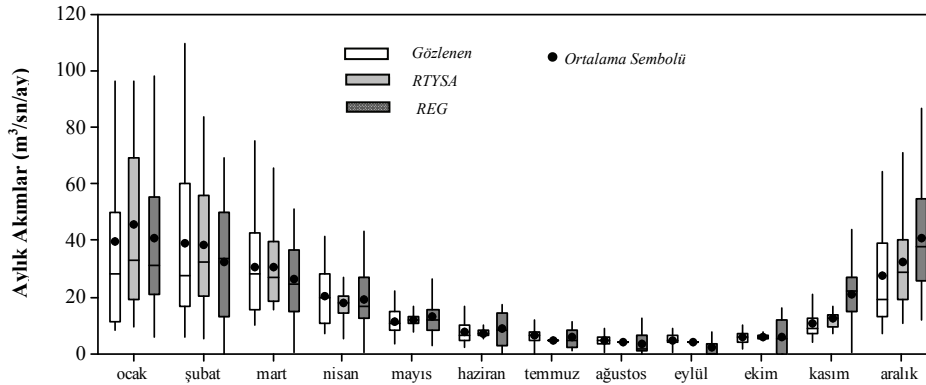
Girdiler	GKHS	$\sigma$	$R^2$		HKO $m^6/sn^2/ay$		M.Hata %	
			Eğitim	Test	Eğitim	Test	Eğitim	Test
$Y_t, S_t$	50	0.3	0.80	0.70	89.35	113.84	5.26	10.03
$Y_t, S_t, Y_{t-1}$ (*)	30	0.3	0.89	0.76	50.36	101.91	3.95	9.49
$Y_t, S_t, Y_{t-1}, Y_{t-2}$	15	0.3	0.91	0.82	37.09	112.08	3.39	9.96
$Y_t, S_t, Y_{t-1}, Y_{t-2}, A_{t-1}$	5	2.2	0.93	0.83	31.25	80.67	3.11	8.45
$Y_t, S_t, Y_{t-1}, Y_{t-2}, A_{t-1}, A_{t-2}$	5	0.9	0.93	0.85	32.21	79.73	3.06	8.40
$Y_t, S_t, Y_{t-1}$ (REG)	-	-	0.70	0.62	135.30	171.41	6.47	12.31



Şekil 2. Eğitim-test dönemi RTYSA ve REG sonuçları ile gözlenen akımlar ( $m^3/sn/ay$ ) arasındaki saçılım diyagramları (\* REG --- ; • RTYSA — ;  $y=x$  - - - -)



Şekil 3. Test dönemi RTYSA(\*), REG modeli akımlarına ve gözlenen akımlara ait hidrograflar ( $m^3/sn/ay$ )



Şekil 4. RTYSA(\*), REG modeli akımlarına ve gözlenen akımlara ait aylık kutu diyagramı ( $m^3/sn/ay$ )

Çizelge 2. RTYSA ve REG sonuçları ile gözlenen aylık akımların M-W test istatistikleri ( $z_{kr}=1.96$ ; Altu çizili aylar homojendir)

$Z_{hesap}$	ocak	şubat	mart	nisan	mayıs	haziran	temmuz	ağustos	eylül	ekim	kasım	aralık	yıllık
$Z_{RTYSA}$	<u>1.17</u>	<u>0.38</u>	<u>0.27</u>	<u>0.70</u>	<u>0.82</u>	1.06	2.93	1.54	2.20	<u>0.37</u>	2.20	<u>1.37</u>	<u>0.95</u>
$Z_{REG}$	<u>1.35</u>	<u>0.29</u>	<u>0.70</u>	<u>0.35</u>	<u>0.53</u>	<u>0.53</u>	1.46	2.01	3.74	<u>0.72</u>	3.86	2.58	<u>1.67</u>

Uzun dönem temel istatistiklerin yanı sıra modellerin eğitim ve test dönemini birlikte içeren (1979-2005) aylık kutu diyagramları (Şekil 4) ve mevsimsel homojenlikleri (Çizelge 2) de incelenmiştir. Mevsimsel homojenlikler Mann-Whitney U testi (M-W) ile sınanmıştır. Bu test iki karşılaştırma grubunun aynı dağılımdan gelip gelmediğini incelemek için kullanılan non-parametrik bir istatistik testidir [21]. Yöntem sonucu hesaplanan  $z_{hesap}$  değeri, % 5 önem düzeyindeki tablo değeri ( $z_{kr} = 1.96$ ) ile karşılaştırılmıştır.  $z_{hesap} < 1.96$  durumunu sağlayan aylar homojenlik sınavından geçmiş ve Çizelge 2’de vurgulanmıştır.

## 5. SONUÇLAR

Sunulan çalışmada Kemer Baraj havzasına ait aylık yağış-akış ilişkisi Moore-Penrose Sözde Ters algoritması alt yapılı RTYSA ile modellenmiş ve standart en küçük kareler (LMS) algoritmasına alternatif bir çözüm yönteminin uygulanabilirliği araştırılmıştır. Farklı girdi setleri denenerek hazırlanan modeller içinde, yağış ( $Y_t$ ), sıcaklık ( $S_t$ ) ve 1 ay önceki yağış ( $Y_{t-1}$ ) girdilerini kullanan 2. model yapısının (\*), gerek girdi sayısının daha az olması, gerek istatistiksel performansı açısından uygulama havzasını temsil edebildiği düşünülmektedir. YSA kullanılarak geliştirilen yağış-akış modelleri incelendiğinde genellikle modellerde girdi olarak önceki akım verileri de kullanılmaktadır. Bu yaklaşımla içsel bağımlı yapı esas alınarak model performansları artırılabilir de yağış, sıcaklık, buharlaşma gibi girdiler ile akımı modellemek daha istenen bir durumdur. Çalışmada önerilen model yapısının bu bakımdan da tutarlı ve anlamlı olduğu düşünülmektedir.

RTYSA modeli aynı girdiler altında hazırlanan basit doğrusal regresyon (REG) modeliyle de karşılaştırılmıştır. Eğitim-test dönemi olmak üzere iki aşamada değerlendirilen modellerin  $y=x$  doğrusu etrafındaki saçılımları incelendiğinde RTYSA modelinin gerek regresyon doğrusu ( $y = ax+b$ ) gerekse determinasyon katsayısı açısından REG modelinden daha üstün olduğu göze çarpmaktadır. Bunların yanı sıra karesel hata ortalamaları (HKO) ve mutlak hata yüzdeleri açısından da RTYSA modeli REG modeline göre oldukça başarılı bulunmuştur. Bu uzun dönem istatistiklere ilaveten tahminlenen akımlar mevsimsel olarak da incelenmiştir. Bu maksatla 12 ay için minimum, maksimum, kartiller, medyan ve ortalamalar açısından da modeller kutu grafiği (box-plot) yardımıyla incelenmiştir. Buna göre Ocak ayı dışındaki tüm aylarda medyan ve ortalama değerler açısından RTYSA modeli sonuçlarının REG modeline göre gerçeğe daha yakın olduğu göze çarpmaktadır. Minimum ve maksimum akımlar açısından irdelendiğinde de RTYSA modeli sonuçları çoğu ay için daha başarılı görülmüştür.

Her ne kadar model sonuçlarının tatmin edici olduğu düşünülse de tahmin edilen akımların gözlenmiş dönem akımlarını temsil edip etmediği dolayısıyla istatistiksel olarak aynı toplumdaki veya dağılımdan gelip gelmediği non-parametrik Mann-Whitney  $U$  testi ile sınanmıştır. Sınama sonucu RTYSA modeli sonuçlarının Temmuz, Eylül ve Kasım ayları dışındaki tüm aylar ve yıllık ortalamalar açısından homojen olduğu tespit edilmiştir.

Bunlara ilaveten, diğer YSA algoritmalarında rastlanan yerel minimuma takılma probleminden kurtulmak ve başarılı bir sonuç elde edebilmek için çok fazla sayıda simülasyon yapma gerekliliğinden kaynaklı sorunların Radyal Tabanlı Yapay Sinir Ağı (RTYSA) modelleri ile aşılabileceği düşünülmektedir. Sonuç itibarıyla, uygun merkezlerin ve dağılıma parametresinin belirlenmesiyle tek bir simülasyonda değişmeyen sonuç veren bu algoritmanın aylık baraj akımlarına uygulanabilirliği sınanmış ve RTYSA yaklaşımı oldukça başarılı bulunmuştur.

### Semboller

- $\| \cdot \|_2$  Öklidyen normu,  
 $w$  ağırlıklar,  
 $x$  ağırlık girdi vektörü,



$\phi_k(\cdot)$	radyal tabanlı aktivasyon fonksiyonu,
$c_k$	radyal tabanlı merkezler,
$A_t$	aylık akımlar ( $m^3/sn/ay$ ),
$b$	ağın beklenen çıktıları,
$E(w)$	ağın performans (amaç) fonksiyonu,
$HKO$	hata kareler ortalaması ( $m^6/sn^2/ay$ ),
$N$	gizli katmanda bulunan hücre sayısı,
$Q$	ağın eğitim seti,
$R^2$	determinasyon katsayısı,
$S_t$	aylık alansal ortalama sıcaklıklar ( $^{\circ}C/ay$ ),
$y$	ağın ürettiği çıktılar,
$Y_t$	aylık alansal ortalama yağışlar ( $mm/ay$ ),
$\sigma$	dağılım parametresi.

#### Kaynaklar

- [1] Abbott, M.B., Refsgaard, J.C., Distributed Hydrological Modelling, Kluwer Academic Publishers, Dordrecht. 17-39, 1996.
- [2] Hsu, K. L., Gupta, H. V., Sorooshian, S., Artificial Neural Network Modeling of Rainfall-Runoff Process, Water Resources Research, 31, 10, 2517–2530, 1995.
- [3] Minns, A. W., Hall, M. J., Artificial Neural Networks as Rainfall-Runoff Models, Hydrological Sciences Journal, 41, 3, 399–417, 1996.
- [4] Dawson C.W., Wilby R., An Artificial Neural Network Approach to Rainfall-Runoff Modelling, Hydrological Sciences Journal, 43, 47-66, 1998.
- [5] Alp, M., Cıgızoğlu, H. K., Farklı Yapay Sinir Ağı Metotları ile Yağış-Akış İlişkisinin Modellenmesi, İstanbul Teknik Üniversitesi Dergisi/d, 3, 1, 80-88, 2004.
- [6] Okkan, U., Mollamahmutoğlu, A., Yiğitler Çayı Günlük Akımlarının Yapay Sinir Ağları ve Regresyon Analizi ile Modellenmesi, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 23, 33-48, 2010.
- [7] Alp, M., Cıgızoğlu, H. K. , Yapay Sinir Ağı Metodları ve Regresyon Analizi ile Akım Tahmini, II. Ulusal Su Mühendisliği Sempozyumu, 589-598, Gümüşdör, İzmir, 2005.
- [8] Kişi, O., Daily River Flow Forecasting Using Artificial Neural Networks and Auto-Regressive Models, Turkish Journal of Engineering and Environmental Sciences, 29, 9–20, 2005.

- [9] Mendez, M. C., Manteiga, W. G., Bande, M. F., Sanchez, J. M. P., Calderon, R. L., Modelling of Monthly and Daily Behaviour of the Runoff of the Xallas River Using Box-Jenkins and Neural Networks Methods, *Journal of Hydrology*, 296, 38–58, 2004.
- [10] Okkan, U., Mollamahmutoğlu, A., Çoruh Nehri Günlük Akımlarının Yapay Sinir Ağları ile Tahmin Edilmesi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14, 3, 251-261, 2010.
- [11] Coulibaly, P., Anctil, F., Bobee, B., Daily Reservoir Inflow Forecasting Artificial Neural Networks with Stopped Training Approach, *Journal of Hydrology*, 230, 244–257, 2000.
- [12] Razavi, S., Araghinejad, S., Reservoir Inflow Modeling Using Temporal Neural Networks with Forgetting Factor Approach, *Water Resources Management*, 23, 39–55, 2009.
- [13] Cigizoglu, H., K., Application of the Generalized Regression Neural Networks to Intermittent Flow Forecasting and Estimation, *Journal of Hydrologic Engineering*, 10,4, 336-341, 2005.
- [14] Fernando, D.A.K., Jayawardena, A.W., Use of Radial Basis Function Type Artificial Neural Networks for Runoff Simulation, *Computer-Aided Civil and Infrastructure Engineering*, 13, 91-99, 1998.
- [15] Lin, G., Chen, L., A Non-Linear Rainfall-Runoff Model Using Radial Basis Function Network, *Journal of Hydrology*, 289, 1-8, 2004.
- [16] Moradkhani, H., Hsu, K., Gupta, H. V., Sorooshain, S., Improved Streamflow Forecasting Using Self-Organizing Radial Basis Function Artificial Neural Networks, *Journal of Hydrology* 295, 246–262, 2004.
- [17] Broomhead, D., Lowe, D., Multivariable Functional Interpolation and Adaptive Networks, *Complex Systems*, 2, 6, 568-576, 1988.
- [18] Ham, F., Kostanic, I., *Principles of Neurocomputing for Science and Engineering*. Macgraw-Hill. USA, 2001.
- [19] MacQueen, J. B., Some Methods for Classification and Analysis of Multivariate Observations, *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability*, Berkeley, University of California Press, 1, 281-297, 1967.
- [20] Penrose, R., A Generalized Inverse for Matrices. *Proceedings of the Cambridge Philosophical Society*, 51, 406-413, 1955.
- [21] Mann, H.B., Whitney, D.R., On a Test of Whether One of Two Random Variables is Stochastically Larger Than the Other. *Annals of Mathematical Statistics*, 18, 50-60, 1947.