

## TAŞKIN DEBİLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ: BATI KARADENİZ HAVZASI ÖRNEĞİ

Neslihan SEÇKİN, Aytaç GÜVEN ve Recep YURTAL

Ç.Ü., İnşaat Mühendisliği Bölümü, Adana

**ÖZET:** Su yapılarının boyutlandırılması ve taşkınların zararlarının azaltılmasında en sık kullanılan yöntemlerden biri taşkın frekans analizidir. Taşkın frekans analizi ile elde edilen bilgiden yararlanarak tasarıma esas olan maksimum debi, güvenilir olarak hesaplanmakta ve ayrıca hidrolojik bilgi olmayan yerlerde dahi tasarım değerleri belirlenebilmektedir. Çalışmada Batı Karadeniz Havzası akım gözlem istasyonlarına ait taşkın değerlerine karşılık her istasyona ait kot, alan, enlem, boylam ve tekerrür periyotları kullanılarak modeller geliştirilmiştir. Çalışmanın amacı havzanın tamamı için tek bir model önerebilmektir. Çalışmada, Batı Karadeniz Havzasında yer alan akım kayıt uzunluklarının 14 ile 43 yıl arasında değişen 21 adet akım gözlem istasyonunun yıllık maksimum değerleri kullanılmıştır. Sonuçta, gelecekte gelebilecek maksimum debiyi tahmin etmede kullanılacak modeller arasında Çoklu Doğrusal Regresyon (ÇDR), Çoklu Doğrusal Olmayan Regresyon (ÇDOR), ve Yapay Sinir Ağları (YSA) incelenmiş ve eldeki mevcut veriyi en iyi tahmin eden model olarak YSA önerilmiştir.

**Anahtar kelimeler:** Taşkın Frekans Analizi, Çoklu Doğrusal Regresyon, Yapay Sinir Ağları

## MODELLING FLOOD DISCHARGE USING ARTIFICIAL NEURAL NETWORK: CASE STUDY-THE MIDDLE BLACK SEA WATERSHED

**ABSTRACT:** Flood frequency analysis is one of the most widely used methods in reduction of the flood damages and also in the design of hydraulic structures. By using the flood frequency analysis, maximum discharge used in projects are reliably calculated, and also it can be determined for ungaged stations. In this study, predictive models were developed based on elevation, area, altitude, longitude and return periods corresponding to the flood values of discharge gauges of Middle Black Sea Watershed. The main purpose is to propose a single model for the whole basin. The annual maximum discharge records of 21 gauging stations having 14 to 43 years record period, are used. Consequently, the methods to forecast the maximum possible discharge in the future as Multiple Linear Regression (MLR), Multiple Nonlinear Regression (MNLr) and Artificial Neural Network (ANN) were evaluated and ANN was proposed as the model that predicted the best the observed data in present study.

**Keywords:** Flood Frequency Analysis, Multiple Linear Regression, Neural Networks

## 1. GİRİŞ

Taşkın, bir akarsu yatağındaki debinin çeşitli nedenlerle hızla artarak yatağından çıkması suretiyle civardaki mal ve can kayıplarına, arazilere, yapılara zarar verecek hale gelmesidir. Yıllık maksimum debiler, maksimum yağışlar gibi hidrolojik olayların büyüklükleri ve oluş zamanları rastgele karakterli olaylar olduğundan kesin tahminde bulunmak mümkün olmamaktadır. Bu nedenle geçmiş tecrübelerle dayanarak belirli olasılıklarla gelecekte meydana gelecek olayların tahminine başvurulur. Bunun için istatistiksel yöntemlere ve frekans dağılımlarının hesabına gidilir. Oluşacak taşkın büyüklüğü ve frekansı su yapılarının boyutlandırılması, yerlerinin seçimi, planlama ve projelendirme amaçları için gereklidir ve ayrıca taşkın yatağının kullanımındaki riskin belirlenmesinde önemli bilgiler sağlar. Yapılacak tahminlerin güvenilir olması durumunda taşkın anında oluşabilecek zararlar minimuma indirilmiş olacaktır.

Bir yapay zeka metodu olan yapay sinir ağları (YSA) da son yıllarda sıkça kullanılan bir modeldir. 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 (1-5). Tokar ve Johnson (6) YSA teknolojisini günlük akımların; günlük yağış, sıcaklık, ve kar erimesi verilerinin fonksiyonu olarak kestiriminde kullanmışlardır. Campolo ve diğerleri (7, 8) YSA'nı yoğun yağış ve düşük akım süreçlerinde nehir akım kestiriminde kullanmışlardır. YSA aynı zamanda değişik yeraltı suyu problemlerinde kullanılmıştır (9, 10). Raman ve Sunilkumar (11) YSA'nın sentetik rezervuar akım serileri türetilmesinde kullanılabilirliğini incelemiştir. Boogaard ve diğerleri (12) otoregresif sinir ağlarını, geliştirerek zaman serilerinin lineer olmayan analizinde ve modellenmesine uygulamışlardır.

See ve Openshaw (13) sinir ağları ve bulanık mantığı kestirim konusunda birlikte kullanmışlardır. YSA ayrıca birim hidrograf elde edilmesinde (14), bölgesel taşkın frekans analizinde (15), kanalizasyon akımlarının tahmininde (16) olumlu sonuçlar vermiştir. Cıgızoğlu (17, 18) bu metodu sediment konsantrasyonu kestirimi ve tahmini problemlerine uygulamıştır. İleri beslemeli geriye yayılım algoritmasının akım serisi kestirimlerinde klasik istatistik ve stokastik modellere nazaran daha başarılı olduğu gösterilmiştir (19-21). Literatürdeki YSA çalışmalarında çoğunlukla ileri beslemeli geriye yayılım metodu (İBGY) kullanılmıştır.

Bu çalışmada, gelecekte gelebilecek maksimum debiyi tahmin etmek için kullanılacak modeller arasında ÇDR, ÇDOR, ve YSA incelenmiş ve eldeki mevcut veriyi en iyi tahmin eden model olarak YSA önerilmiştir.

## 2. MATERYAL VE YÖNTEM

### 2.1. MATERYAL

Filyos ve Bartın havzalarını kapsayan Batı Karadeniz bölgesinden seçilmiş uzun rasatlı akım gözlem istasyonlarının anlık maksimum akımları modelleme için kullanılmıştır. Bu bölgedeki rasat istasyonları 14 ile 43 yıl arasında değişen kayıt

*TAŞKIN DEBİLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ:  
ÖRNEKSEL BÖLGE ÇALIŞMASI-BATI KARADENİZ HAVZASI*

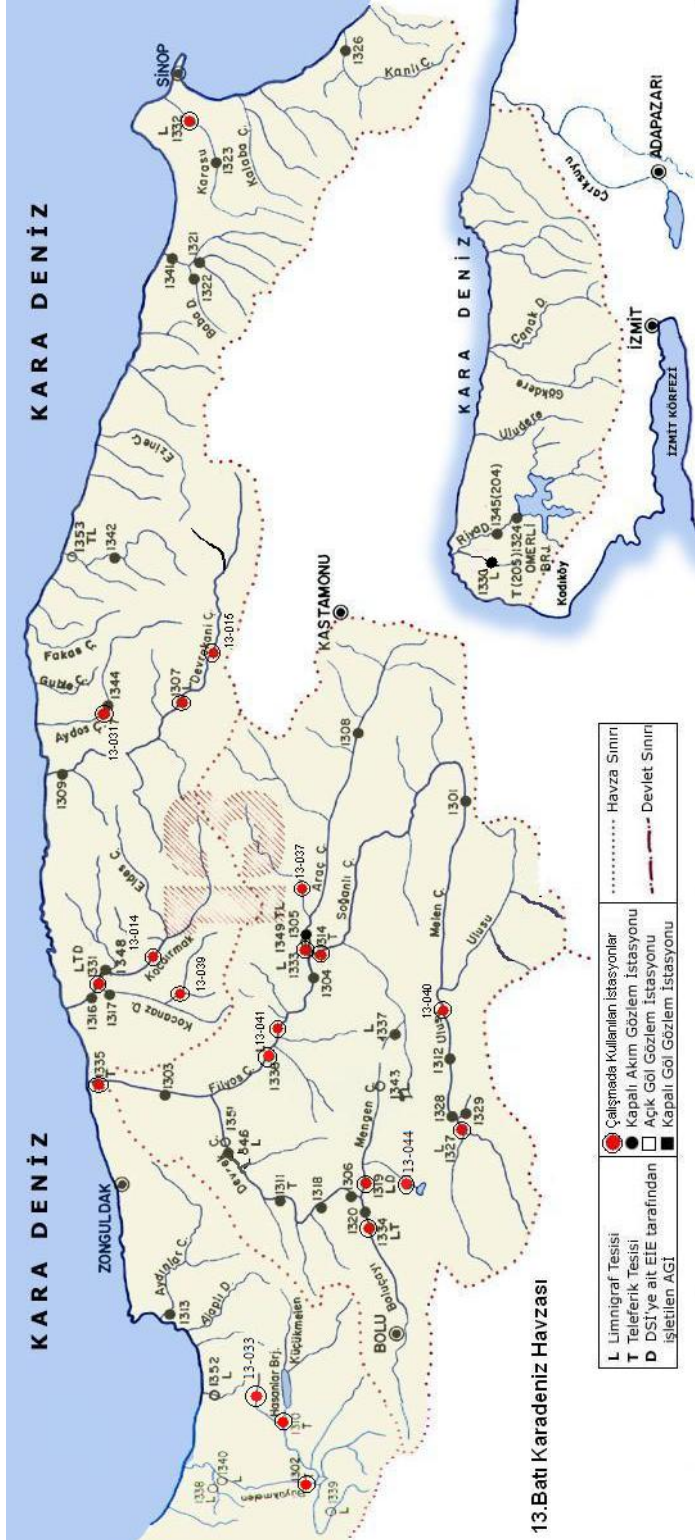
sürelerine sahiptir. Batı Karadeniz havzası ve kullanılan istasyonların yerleri Şekil 1 de görülmektedir.

## **2.2. YÖNTEM**

### **2.2.1. Yapay Sinir Ağları**


Yapay sinir ağları, farklı ağırlıklarla birbirine bağlı birçok işlem elemanlarından oluşmuş yoğun paralel sistemlerdir. YSA metotları içerisinde en çok kullanılanı hataların geriye yayılma (back-propagation) ilkesine göre çalışandır (22).

Şekil 2, 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, eğitime sürecinde tahmin edilen çıktılarla gerçek çıktı değerleri karşılaştırılarak devamlı değiştirilir ve hataları minimum yapan bağlantı ağırlık değerleri ayarlanıncaya kadar hatalar geriye doğru (Şekil 2'de sağdan sola) yayılır. Burada ağırlıkları ayarlamak için Levenberg-Marquardt metodu kullanılmıştır (23).



Şekil 1 Batı Karadeniz Havzasına ait DSİ ve EİE tarafından işletilen AGİ ler

*TAŞKIN DEBİLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ:  
ÖRNEKSEL BÖLGE ÇALIŞMASI-BATI KARADENİZ HAVZASI*



**Şekil 2.** Üç tabakalı bir yapay sinir ağı.

$j$  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,  $\theta_j$  taraflılık sabiti (bias),  $A_{ij}$   $i$  ve  $j$  tabakaları arasındaki ağırlıklar kümesi,  $C_{pi}$   $p$  örneği için  $i$  tabakasının çıktı kümesidir.  $j$  ve  $k$  tabakalarındaki her bir 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. Eğitim 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. Eğitim işleminin asıl amacı toplam hatayı,  $H$ , minimum yapan bir ağırlıklar kümesi üretmektir.

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

Her bir bağlantı ağırlığı,  $A_{ij}$ , (5) eşitliği ile yenilenir.

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

Burada  $\eta$  öğrenme oranı olarak adlandırılan orantılılık katsayısını,  $\partial H_p / \partial A_{ij}$  ise hata yüzeyinin eğimini göstermektedir (24).

### 2.2.2. Çoklu Doğrusal Regresyon

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  $\beta_j$  regresyon katsayısı, diğer değişkenler sabit tutulduğunda (diğer değişkenlerin etkisi ortadan kaldırıldığında)  $x_j$  değişkeninde ortaya çıkan bir birimlik değişmeye 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,  $\beta_j$  ( $j=1, 2, \dots, p$ ) parametreleri genellikle kısmi regresyon katsayıları olarak adlandırılmaktadır.  $\beta_0$ 'a ise kesim noktası veya sabit denir ve tüm  $x_j$  değişken değerleri sıfır olduğunda bağımlı değişkenin aldığı değeri gösterir.  $\varepsilon$  ise hata terimidir (25).

### 2.2.3 Çoklu Doğrusal Olmayan Regresyon (ÇDOR)

Temel fikri lineer regresyon ile aynı olan lineer olmayan regresyonda da amaç bağımlı ve bağımsız değişkenler arasında bir lineer olmayan bir ilişki kurmaktır. Lineer olmayan regresyonda farklı model denklemler kullanılabilir, en çok kullanılanları ise lojistik, üstel ve polinom denklemleridir. Bu model denklemlerde, üzerinde ilişki kurulan değişken ve bağımlı parametreler kullanılarak bulunması gereken, bir kaç bilinmeyen parametre mevcuttur. Bu çalışmada  $Q$  bağımlı değişkeni ile denklem (7)'de verilen bağımsız değişkenler arasında üstel (denklem 4) bağıntı düşünülerek lineer olmayan regresyon analizi gerçekleştirilmiştir.

$$Q = ax_1^{\theta_1} x_2^{\theta_2} x_3^{\theta_3} \dots x_n^{\theta_n} \quad (7)$$

*TAŞKIN DEBİLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ:  
ÖRNEKSEL BÖLGE ÇALIŞMASI-BATI KARADENİZ HAVZASI*

Burada  $\theta_i$  i'nci model parametresi,  $a$  çarpımsal hata terimi, ve  $n$  değişken sayısını belirtmektedir. Bu model parametreleri En Küçük Kareler tekniği ile optimize edilmiştir.

### 3. BULGULAR VE TARTIŞMA

Bu çalışmada, 21 istasyona ait veri, eğitime (413 data) ve test (158 data) olarak iki guruba ayrılmıştır. Bu veriye ait minimum ve maksimum değerler Çizelge 2 de görülmektedir.

**Çizelge 1** Batı Karadeniz Havzasına Ait Bilgiler

İstasyon No	Kayıt uzunluğu (yıl)	Drenaj Alanı (km <sup>2</sup> )	Kot (m)	Boylam (°)	Enlem (°)
13-014	25	890,0	125	34,5572	36,8722
1307	37	1097,6	817	32,3667	41,4667
1314	37	5086,8	271	33,1167	41,8667
1319	35	766,4	507	31,9500	41,2167
1335	35	13300,4	2	29,1897	41,1525
13-033	16	259,7	276	31,3833	40,9333
13-041	14	8310,0	150	32,6239	41,1958
13-044	16	2640,0	250	31,9417	40,8867
1336	20	8613,6	120	32,0792	41,5481
13-031	15	507,5	47	32,3239	41,2022
1327	32	953,6	1141	32,8000	40,7667
13-015	20	729,0	924	33,5022	41,5994
13-037	27	537,1	322	32,4000	41,2000
13-040	23	1262,0	1095	32,4667	41,5333
1334	30	1102,8	541	32,2508	40,7422
1332	31	340	20	35,0325	41,9992
1302	43	1988	115	30,9844	40,8578
1310	32	682	194	31,2594	40,9089
1331	30	1342,0	15	32,6431	41,1697
13-039	19	332,0	130	32,3558	41,6422
1333	34	2833,2	273	31,9672	40,8964

**Çizelge 2.** Girdi ve çıktı verilerinin minimum ve maksimum değerleri

Parametreler	Eğitme Dataları		Test Dataları	
	Min	Mak.	Min	Mak.
Drenaj alanı (DA), km <sup>2</sup>	259,7	13300,4	332,0	2833,2
Kot (K), m	2,0	1141,0	15,0	273,0
Boylam (B), °	29,2	35,0	31,0	32,6
Enlem (E), °	36,9	42,0	40,9	41,6
Dönüş Periyodu (T), yıl	1,0	105,7	1,0	97,1
ln(Debi) (ln(Q)), m <sup>3</sup> /s	2,5	7,9	3,3	7,3

Daha sonra, hem ÇDR hem de ÇDOR modelleri eğitme datalarına uygulandı. Aşağıda görülen formüller, sırasıyla ÇDR ve ÇDOR modelleri kullanılarak elde edildi.

$$\ln(Q) = 7,536 + 0,000103K + 0,000246DA - 0,184E + 0,124B + 0,0198T \quad (8)$$

$$\ln(Q) = 4,3733 \frac{DA^{0,129} B^{0,330} T^{0,1001}}{K^{0,0247} E^{1,308}} \quad (9)$$

Ortalama karesel hataları (OKH), Ortalama mutlak hata (OMH), ortalama mutlak göreceli hata (OMGH) ve regresyon katsayısı (R<sup>2</sup>) istatistikleri kullanılmıştır. OKH, OMH ve OMGH istatistikleri aşağıdaki formüller kullanılarak hesaplanmıştır.

$$OKH = \frac{1}{N} \sum_{i=1}^N (Y_i^{\text{gözlenen}} - Y_i^{\text{hesaplanan}})^2 \quad (10)$$

$$OMH = \frac{1}{N} \sum_{i=1}^N |Y_i^{\text{gözlenen}} - Y_i^{\text{hesaplanan}}| \quad (11)$$

$$OMGH = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i^{\text{gözlenen}} - Y_i^{\text{hesaplanan}}}{Y_i^{\text{gözlenen}}} \right| \times 100 \quad (12)$$

Burada,  $N$  data sayısı,  $Y_i$  maksimum debiyi göstermektedir.

Kullanılan modelleme tekniklerine ait OKH, OMH, OMGH ve R<sup>2</sup> değerleri eğitme ve test aşaması için Çizelge 3 de görülmektedir. Çizelge 3 den de görüldüğü gibi, YSA modeli hem eğitme hem de test aşamasında en düşük OKH, OMH, OMGH ve en yüksek R<sup>2</sup> değerine sahiptir. Bütün bu hesaplanan değerlere göre YSA modelleme tekniğinin ÇDR ve ÇDOR den daha iyi sonuç verdiği tespit edilmiştir. Hem eğitme hem de test aşamasında OÇDR modelleme tekniği OÇR modelleme tekniğinden çok daha iyi sonuçlar vermiştir.

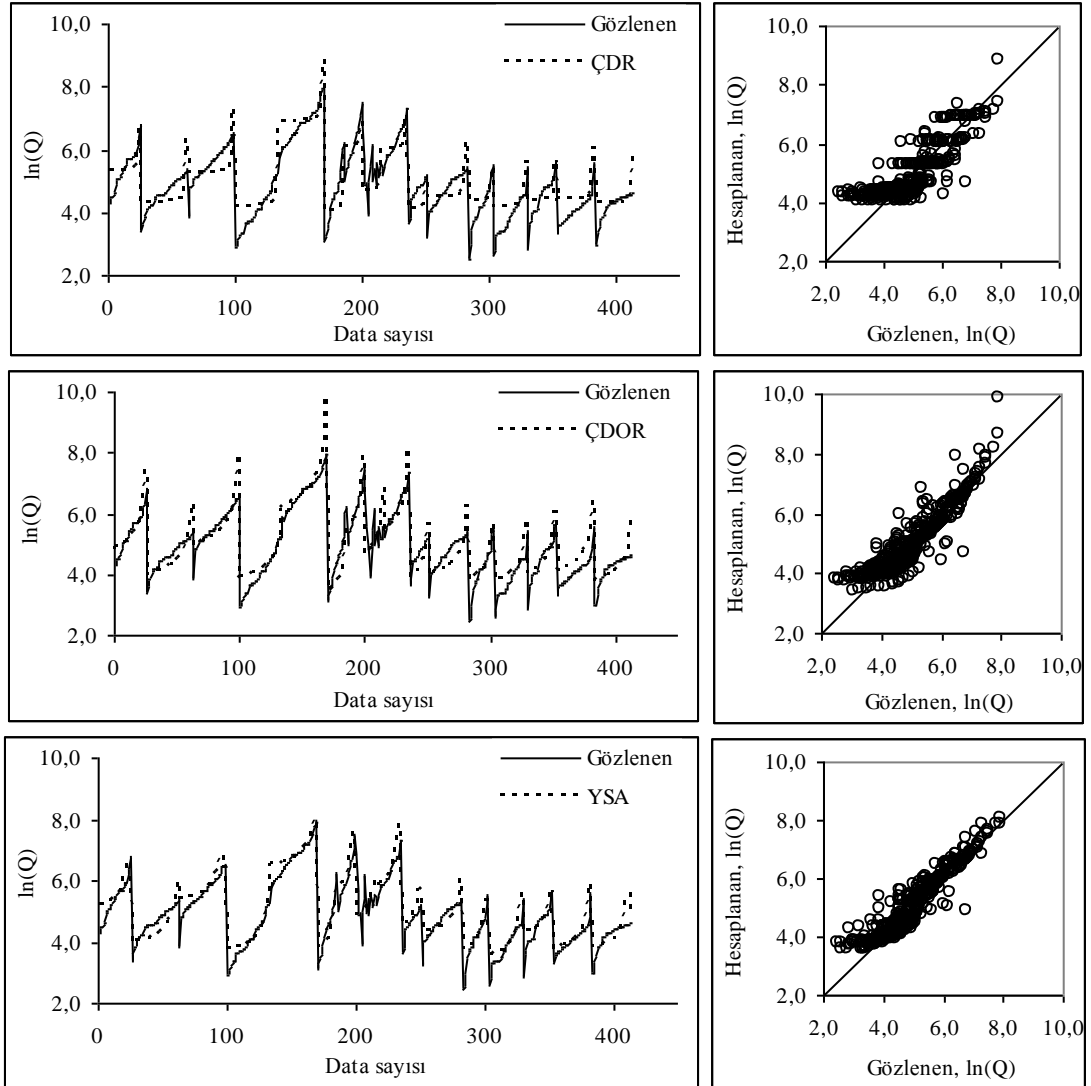


*TAŞKIN DEBİLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ:  
ÖRNEKSEL BÖLGE ÇALIŞMASI-BATI KARADENİZ HAVZASI*

**Çizelge 3.** Eğitim ve test aşamalarının ÇDR, ÇDOR ve YSA modelleme tekniklerine göre performansları

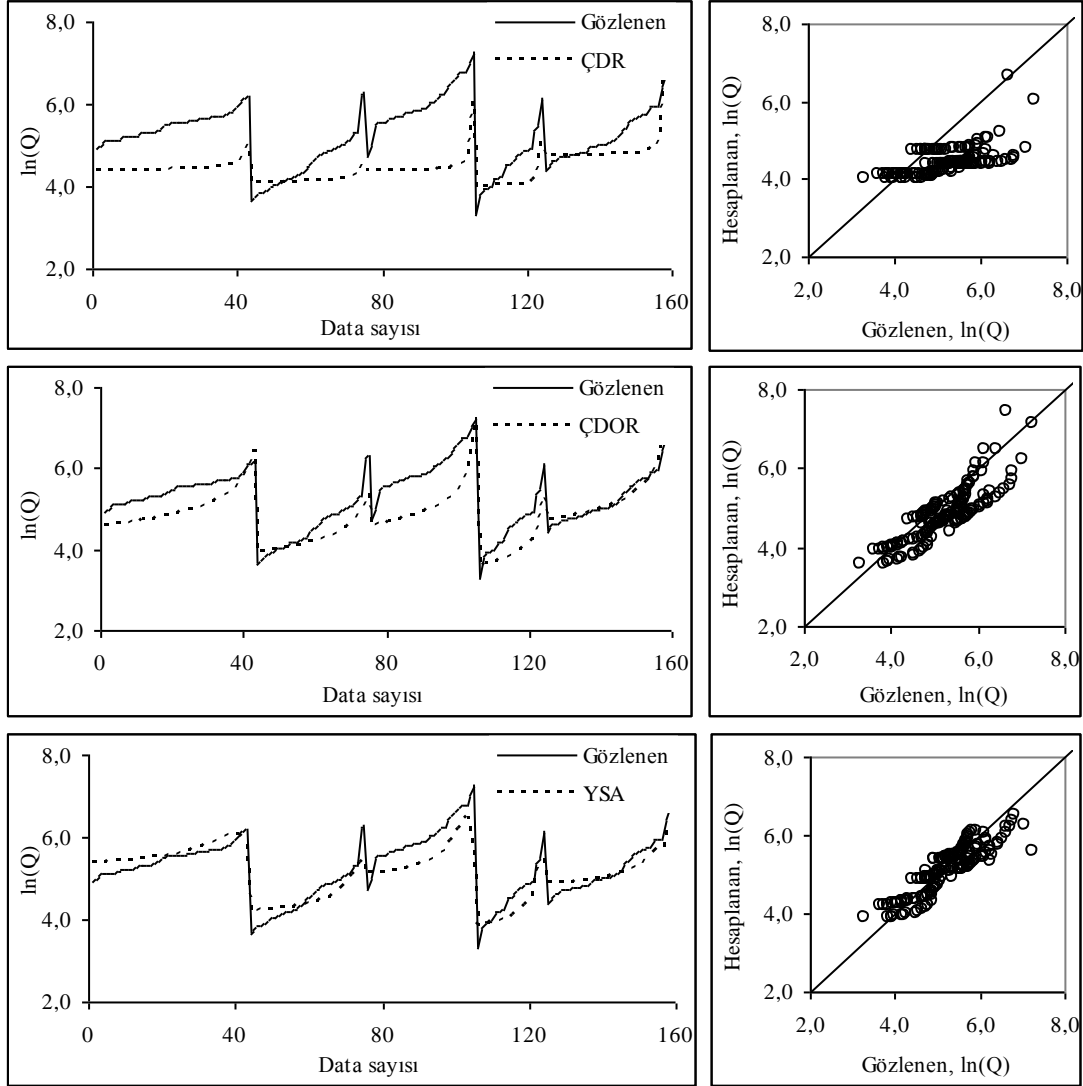
Metod	Eğitme Aşaması				Test Aşaması			
	OMGH (%)	OMH (m <sup>3</sup> /s)	OKH (m <sup>3</sup> /s) <sup>2</sup>	R <sup>2</sup>	OMGH (%)	OMH (m <sup>3</sup> /s)	OKH (m <sup>3</sup> /s) <sup>2</sup>	R <sup>2</sup>
ÇDR	10,082	0,454	0,325	0,710	186,131	0,839	1,018	0,320
ÇDOR	7,527	0,342	0,202	0,823	8,732	0,473	0,339	0,726
YSA	6,222	0,275	0,143	0,877	5,487	0,292	0,138	0,786

Şekil 3 ve 4, sırasıyla, YSA ve diğer metotların eğitim ve test aşamasındaki tahminlerinin gerçek verilerle karşılaştırmasını göstermektedir. Şekil 3'ten anlaşılacağı gibi, YSA tahminlerinin neredeyse tamamı en iyi uyum çizgisi üzerine düşmüştür, fakat ÇDR ve ÇDOR tahminleri en iyi uyumdan uzak ve oldukça dağınık bir görünüm göstermiştir. ÇDOR tahminlerini ÇDR'ye nisbeten daha iyi olduğu Şekil 3'te açıkça görülmektedir. Şekil 4 te Şekil 3'ten elde edilen bulgulara paralel bilgiler vermektedir. YSA tahminleri gerçek değerlere en yakın eğilimi göstermektedir. ÇDOR'nin ÇDR'ye olan üstünlüğü test aşamasında da açık olarak gözlemlenmektedir. Bu iki şekilden elde edilen bilgiler ışığında, YSA'nın genel performansının diğer metotlara göre çok daha iyi olduğu açıkça ifade edilebilir.



**Şekil 3.** Eğitime aşaması için regresyon analizleri ve YSA((4.6.1), Logsig-logsig) kullanılarak elde edilen tahmini maksimum debiler ile gözlenmiş debilerin karşılaştırılması.

*TAŞKIN DEBİLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ:  
ÖRNEKSEL BÖLGE ÇALIŞMASI-BATI KARADENİZ HAVZASI*



**Şekil 4.** Test aşaması için regresyon analizleri ve YSA((4.6.1), Logsig-logsig) kullanılarak elde edilen tahmini maksimum debiler ile gözlenmiş debilerin karşılaştırılması.

#### 4. SONUÇLAR

Bu çalışmada YSA modelinin Batı Karadeniz Havzası akım gözlem istasyonlarına ait yıllık maksimum akım değerleri ile her istasyona ait kot, alan, enlem, boylam ve tekrür periyotları arasındaki ilişkiyi modellemedeki kabiliyeti incelenmiştir. YSA modeli, gelebilecek taşkını tahmin etmede ÇDR ve ÇDOR'a göre daha iyi bir performans göstermiştir. ÇDR modelleme tekniği YSA'ya göre özellikle test aşamasında kötü tahminler vermiştir. YSA modellerin başka istasyonlara ve daha

uzun verilere uygulanması, ardından da regresyon teknikleri ile karşılaştırılması elde edilen sonuçların desteklenmesi açısından önemlidir. Bunun yanı sıra YSA'nın belirli bir problemi çözmek için fazla bir bilgiye ihtiyaç duymadan örnekleri kullanarak sonuca vardığı için su yapılarının tasarımında kullanılacak maksimum debinin tahmininde YSA modelleri rahatlıkla ve kolaylıkla kullanılabilir.

## 5. KAYNAKLAR

1. Hsu, K., Gupta, H.V. ve Sorooshian, S., "Artificial neural network modelling of the rainfall runoff process", *Water Resources Research*, 31, 2517-2530. 1995
2. 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.
3. Minns, A.W. ve Hall, M.J., (1996). "Artificial neural networks as rainfall runoff models" *Hydrological Sciences Journal*, 41, 3, 399-417.
4. 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.
5. Alp, M. Ve Cigizoglu, H. K. (2004). "Farklı yapay sinir ağı metodları ile yağış-akış ilişkisinin modellenmesi". *İtü mühendislik dergisi, Cilt:3, Sayı:1*, 80-88.
6. Tokar, A.S. ve Johnson, P.A., (1999). "Rainfallrunoff modelling using artificial neural Networks", *Journal of Hydrologic Engineering*, 4, 3, 232-239.
7. Campolo, M., Andreussi, P. ve Soldati, A., (1999a). "River flood forecasting with a neural network model", *Water Resources Research*, 35, 1191- 1197.
8. 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.
9. 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.
10. Rogers, L.L. ve Dowla, F.U., (1994). "Optimization of groundwater remediation using artificial neural networks with parallel solute transport modelling", *Water Resources Research*, 30, 2, 457-481.
11. Raman, H. ve Sunilkumar, N., (1995). "Multivariate modelling of water resources time series using artificial neural Networks", *Hydrological Sciences Journal*, 40, 2, 145-163.
12. Boogaard, H., Gautam, D.K. ve Mynett, A.E., (1998). "Auto-regressive neural networks for the modelling of time series", *Hydroinformatics Conference, Copenhagen*.
13. See, L. ve Openshaw, S., (1998). "Using soft computing techniques to enhance flood forecasting on the river Ouse", *Hydroinformatics Conference, Copenhagen*.

*TAŞKIN DEBİLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ:  
ÖRNEKSEL BÖLGE ÇALIŞMASI-BATI KARADENİZ HAVZASI*

14. Lange, N., (1998). “Advantages of unit hydrograph derivation by neural Networks”, *Hydroinformatics Conference, Copenhagen*.
15. Hall, M.J. ve Minns, A.W., (1998). “Regional flood frequency analysis using artificial neural Networks”, *Hydroinformatics Conference, Copenhagen*.
16. Djebbar, Y. ve Alila, Y., (1998). “Neural network estimation of sanitary flows”, *Hydroinformatics Conference, poster presentation, Copenhagen*.
17. Cıgızoğlu, H.K., (2002a). “Suspended sediment estimation and forecasting using artificial neural Networks”, *Turkish Journal of Engineering & Environmental Sciences*, 26, 15-25.
18. 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.
19. 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.
20. Cıgızoğlu, H.K., (2003a). “Incorporation of ARMA models into flow forecasting by artificial neural Networks”, *Environmetrics*, 14, 4, 417-427.
21. Cıgızoğlu, H.K., (2003b). “Estimation, forecasting and extrapolation of flow data by artificial neural networks”, *Hydrological Sciences Journal*, 48, 3, 349-361.
22. Lippman, R, (1987) “An Introduction to Computing With Neural Nets”, *IEEE ASSP Mag.*, 4, 4-22.
23. Marquardt, D., (1963) “An algorithm for least squares estimation of non-linear parameters”, *J.Soc.Ind.Appl.Math.*, pp.431-441, 1963
24. Kişi, Ö., (2004) “Yapay Sinir Ağları ve Regresyon Teknikleri ile Filyos Çayı Akımlarının Tahmini”, *IV.Hidroloji Kongresi*, 23-25 Haziran, 347-353, İstanbul, Türkiye
25. Alpar, R. (2003) “Uygulamalı Çok Değişkenli İstatistiksel Yöntemlere Giriş 1”, *Ankara, Türkiye*.