

# Yağış-Akış Modellemesinde Optimum Yapay Sinir Ağı Yapısının Araştırılması

Ömer YÜKSEK<sup>1,\*</sup>, Hasan Törehan BABACAN<sup>2</sup>, Fatih SAKA<sup>3</sup>

<sup>1</sup>Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Trabzon, Türkiye, yuksek@ktu.edu.tr

<sup>2</sup>Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Trabzon, Türkiye, htabacan@ktu.edu.tr

<sup>3</sup>Karabük Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Karabük, Türkiye, sakafatih@karabuk.edu.tr

Received: D 12.04.2018; Accepted: 29.05.2018; Published: D 05.06.2018

Tur. J. Hyd. Vol: 2 No: 1 Page: 31-37 (2018) ISSN: XXXX-YYYY

SLOI: <http://www.dergipark.gov.tr>

\*Correspondence E-mail: htabacan@ktu.edu.tr

**ÖZET:** Bu çalışmada, Giresun ili Aksu deresi üzerinde bulunan D22A116 numaralı Akım Gözlem İstasyonu'nda ölçülmüş günlük ortalama akış ve 17034 numaralı Giresun Meteoroloji İstasyonu'nda ölçülmüş günlük toplam yağış verileri kullanılarak tasarlanmış 5 girdi modeli kullanılmış, farklı Yapay Sinir Ağı (YSA) yapıları ile noktasal yağış-akış modeli oluşturulmuştur. Oluşturulan yağış-akış modelinde; YSA'da eğitim algoritması olarak Levenberg-Marquardt (LM), Quasi-Newton (QN) ve Conjugate-Gradient (CG) kullanılmıştır. Her farklı YSA yapısında, Hiperbolik Tanjant Sigmoid (HTS), Logaritmik Sigmoid (LS) transfer fonksiyonları ve gizli katmanda farklı nöron sayıları denenmiştir. YSA yapılarının performansları Ortalama Hata Kareleri Karekökü (RMSE), Korelasyon Katsayısı (R) ve Nash-Sutcliffe Katsayısı (E) hesaplanarak belirlenmiştir. Oluşturulan yağış-akış modelinde tüm YSA yapıları iyi sonuçlar üretilmiş, ancak en iyi yapı olarak YSA-QN belirlenmiştir (RMSE=12.090, R=0.806, E=0.649).

**Anahtar Kelimeler:** Yapay Sinir Ağları; Yağış-Akış Modeli; Yüzeysel Akış Tahmini.

**ABSTRACT:** In this study, by using 5 different input models, point rainfall-runoff model has been generated by means of different Artificial Neural Network (ANN) structures. The daily average discharge data of D22A116 Flow Gauging Station, located in Giresun Province Aksu Stream, together with daily average rainfall data measured at Giresun Meteorology Station 17034 were used in the study. In the generated rainfall-runoff model; Levenberg-Marquardt (LM), Quasi-Newton (QN) and Conjugate-Gradient (CG) were used as training algorithms in ANN. Hyperbolic tangent sigmoid (HTS) and logarithmic sigmoid (LS) transfer functions and different neuron numbers in hidden layer were tested in each different ANN structure. The performances of ANN constructions were determined by calculating Root Mean Squares Error (RMSE), Correlation Coefficient (R) and Nash-Sutcliffe Coefficient (E). In the generated rainfall-runoff model, all ANN structures have yielded satisfactory results, however ANN-QN has been determined as the best structure (RMSE = 12.090, R = 0.806, E = 0.649).

**Keywords:** Artificial Neural Network; Rainfall-Runoff Modelling; Streamflow Forecasting.

## 1. GİRİŞ

Karmaşık yapıda gerçekleşen hidrolojik süreçlerin incelenmesinde, deneysel yöntemlerin modellemesinin zor olması ve modellerin küçük değişikliklerden fazla etkilenmesi nedeniyle alternatif yöntemler araştırılmıştır. Deneysel yöntemlere alternatif olarak, hidrolojik ve hidrolik eşitliklerden yararlanarak geliştirilen ampirik yöntemler geliştirilmiş ve uygulanmıştır. Bu yöntemlerin uygulanması için uzun süreli düzenli şekilde ölçülmüş veriye ihtiyaç duyulması ve ölçümlerin ekonomik olmaması nedeniyle hidrolojik süreçleri açıklamak konusunda yapay zekâ modelleri tercih edilmiştir [6]. Yapay zekâ modelleri, iç dinamiklerinin bilinmesi çok önemsenmeyen, girdilere karşılık çıktılar üreten ve paralel işlemler gerçekleştiren sayısal modellerdir. Yapay zekâ modellerine örnek olarak Yapay Sinir Ağları (YSA) ve Bulanık Mantık (BM) verilebilmektedir.

Paralel olarak çalışan katmanlar ve verilerin bu katmanlar arasında hareketini gerçekleştiren transfer fonksiyonları ile hesaplamalar gerçekleştiren bir yapay zekâ modeli örneği olan YSA, geçmiş veriler yardımıyla gerçekleştirdiği makine öğrenmesi ile geleceğe dair tahminler üretebilmektedir [8].

Hidroloji alanında yapılan araştırmalarda, doğrusal olmayan ilişkilere sahip olan hidrolojik süreçlerin modellenmesi konusunda ve hidrolojik olayları direkt olarak etkileyen parametrelerin hesaplanmasında YSA yönteminin geniş kullanım alanı olduğu görülmektedir. YSA, su kalitesi [23], taşınan sediment miktarının belirlenmesi [6, 24], kuraklık [12], yeraltı suyu seviyesinin tahmin edilmesi [11, 15] ve meteorolojik verilerin tahmin edilmesi [9] gibi önemli hidrolojik konularda başarılı bir şekilde uygulanmıştır.

Çalışmanın konusu olan yağış-akış modellemeleri konusunda; Machado vd. (2011), tarafından yapılan çalışmada, yağış-akış arasındaki ilişkiyi bulmak için YSA metodu kullanılmıştır. YSA yönteminde aylık ortalama akış, aylık ortalama buharlaşma ve aylık ortalama yağış verileri gün gecikmeli şekilde girdi verisi olarak kullanılmış ve bir sonraki aylık ortalama akış değerleri tahmin edilmeye çalışılmıştır. YSA yöntemi ile elde edilen sonuçlar, ampirik bir yöntem olan IPHMEN ile kıyaslanmış YSA yönteminin başarısı belirlenmiştir [10]. Antar vd. (2006), çalışmalarında akış verileri ile yağış verilerini kullanarak geleceğe dair akış tahmini yapmış, YSA yönteminde farklı nöron sayıları ve transfer fonksiyonları deneyerek en iyi yöntemi bulmayı amaçlamıştır. YSA yönteminden elde edilen sonuçlar ampirik yöntemler ile kıyaslanmış ve YSA yöntemlerinin başarılı olduğu belirlenmiştir [3]. Shoaib vd. (2018) çalışmalarında, günlük ortalama akış ve günlük toplam yağış verilerini kullanarak oluşturdukları yağış-akış modeli ile Çok Katmanlı Algılayıcı, Genelleştirilmiş İleri Beslemeli YSA, Radyal Tabanlı YSA, Modüler YSA yöntemleri ile Dalgacık dönüşümlü YSA yöntemlerinin performanslarını karşılaştırmış, YSA yöntemlerinin yağış-akış modellemesinde etkin olduğunu ifade etmiştir. [19]. Motahari vd. (2017) YSA yapısının otomatik olarak belirlediği ve optimize ettiği ağırlık değerlerinin kullanıldığı ve Parçacık Sürü Optimizasyonu (PSO)

kullanılarak optimize edilmiş ağırlık değerlerinin atandığı yöntem olmak üzere iki modeli yağış-akış sürecini açıklayabilme konusunda kıyaslamıştır. Performans değerlendirmesi sonucunda PSO-YSA yönteminin klasik YSA yöntemine göre daha iyi sonuç verdiği görülmüştür [14].

Bu çalışmada, YSA yönteminde eğitim algoritması olarak Levenberg-Marquardt (LM), Quasi-Newton (QN) ve Conjugate-Gradient (CG) algoritmaları kullanılarak geliştirilen üç farklı YSA modelinin, farklı nöron sayıları, Hiperbolik Tanjant Sigmoid (HTS) ve Logaritmik Sigmoid (LS) transfer fonksiyonları ile yağış-akış modeli oluşturma konusundaki performansları değerlendirilmiştir. Yağış-akış modelinde günlük ortalama akış (Q) değerleri ve günlük toplam yağış (P) değerleri kullanılarak gün gecikmeli girdi setleri oluşturulmuş ve bir sonraki gün için Q değerleri tahmin edilmeye çalışılmıştır.

## 2. YÖNTEM

### 2.1. Yapay Sinir Ağları

YSA, paralel şekilde işlem gerçekleştirebilen katman ve düğüm noktalarından oluşan, insandaki biyolojik sinir sistemine benzeyen yapıda çalışan ve makine öğrenmesi gerçekleştirebilen sayısal bir yöntemdir. Genel olarak YSA yapısında, girdi katmanı, ara katman ve çıktı katmanı şeklinde üç farklı katman bulunmaktadır: Girdi katmanı, dış dünyadan bilgilerin ağa alındığı kısımdır. Dışarıdan alınan bilgiler bu katmanda bulunan düğüm noktalarına (nöronlara) aktarılmaktadır. Girdi katmanından ağa alınmış bilgiler ara (gizli) katmana aktarılmaktadır. Bilgilerin bu geçişi sırasında ağın başlangıçta rastgele olarak atadığı bir katsayı olan ağırlık (w) ve sabit hata (ε) değerleri, bilginin geçtiği bağlantı yoluna atanır. Ara katmandan geçen bilgiler tekrar bir transfer fonksiyonu kullanılarak çıktı katmanına aktarılır ve bir önceki gibi bu geçiş bağlantısına da w ve ε değerleri atanmaktadır. Çıktı katmanı, bilgilerin tekrar dış dünyaya aktarıldığı kısımdır ve buraya gelen bilgiler YSA çıktısı olarak dışarı aktarılmaktadır. Nöron bağlantılarına kalıcı olarak w ve ε değerlerinin atanması ile ağın eğitimi tamamlanmaktadır [4].

Nöron bağlantılarındaki w ve ε katsayılarının düzenlenerek ağın ürettiği çıktılarının hata değerini azaltmak için ağ aynı işlemi tersinir yönde yapabilmekte ve öğrenme algoritmasını tekrar çalıştırarak w ve ε değerlerini hata oranına göre düzenlemektedir. Bu şekilde çalışan ağ yapısı İleri Beslemeli Geri Yayılımlı YSA olarak adlandırılmaktadır [21].

Bağlantılar arasında veri hareketini organize eden fonksiyonlar olan transfer fonksiyonları, genellikle sigmoid fonksiyonlardan seçilmekte olup, sigmoid fonksiyon örneği eşitlik 1'de görülmektedir [16, 22].

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

Çalışmada YSA öğrenme algoritması olarak Levenberg-Marquardt (LM), Quasi-Newton (QN) ve

Conjugate-Gradient (CG) algoritmaları kullanılarak üç farklı YSA yapısı tasarlanmıştır. Bu algoritmalar için detay bilgiler sırasıyla [13, 17, 7] nolu kaynaklarda bulunabilir. Farklı eğitim algoritmaları ile oluşturulmuş YSA yapılarında yağış-akış modellemesi için Hiperbolik Tanjant Sigmoid (HTS) ve Logaritmik Sigmoid (LS) transfer fonksiyonları ile gizli katmanda 2, 8 ve 16 nöron denenmiştir.

## 2.2. Performans Analizi

YSA ile kurulan yağış-akış modellerinde bir sonraki gün için Q değerleri tahmin edilmeye çalışılmıştır. Tahmin edilen Q değerleri ( $Q_{i(tahmin)}$ ) ile ölçülmüş değerler ( $Q_{i(ölçüm)}$ ) kıyaslanarak YSA yapılarının performansı değerlendirilmiştir.

Performans analizi için Ortalama Hata Kareleri Karekökü (RMSE), Korelasyon Katsayısı (R) ve Nash-Sutcliffe Belirlilik Katsayısı (E) kullanılmıştır. RMSE, R ve E için kullanılan eşitlikler sırasıyla eşitlik 2, 3 ve 4'te görülmektedir.

Denklemlerde;  $Q_{i(ölçüm)}$  ölçülmüş değeri,  $Q_{i(tahmin)}$  tahmin edilmiş değeri,  $\bar{Q}_{i(tahmin)}$  ve  $\bar{Q}_{i(ölçüm)}$  serilerin ortalama değerlerini ifade etmektedir.

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (Q_{i(ölçüm)} - Q_{i(tahmin)})^2} \quad (2)$$

$$R = \frac{\sum_{i=1}^n (Q_{i(ölçüm)} - \bar{Q}_{i(ölçüm)}) * (Q_{i(tahmin)} - \bar{Q}_{i(tahmin)})}{\sqrt{\sum_{i=1}^n (Q_{i(ölçüm)} - \bar{Q}_{i(ölçüm)})^2 * \sum_{i=1}^n (Q_{i(tahmin)} - \bar{Q}_{i(tahmin)})^2}} \quad (3)$$

$$E = 1 - \frac{\sum_{i=1}^n (Q_{i(ölçüm)} - Q_{i(tahmin)})^2}{\sum_{i=1}^n (Q_{i(ölçüm)} - \bar{Q}_{i(ölçüm)})^2} \quad (4)$$

## 3. ÇALIŞMA ALANI ve YAPILAN ÇALIŞMALAR

### 3.1. Çalışma Alanı: Aksu Deresi Alt Havzası

Aksu Deresi alt havzası, Türkiye'nin üçüncü büyük havzası olan Doğu Karadeniz Havzası içerisinde bulunmaktadır. Aksu Deresi, Giresun İl Merkezi'nin doğu tarafından denize dökülmekte olup akarsu üzerindeki D22A116 Nolu Aksu Deresi Akım Gözlem İstasyonu'nun (AGİ) bazı özellikleri Tablo 1'de sunulmuştur. İlkbaharda kar erimeleri ve orografik yağışların etkisi neticesinde derenin debisi iki kata yakın artmaktadır. Aylık ortalama debiler Mart (16.82 m<sup>3</sup>/sn), Nisan (36.54 m<sup>3</sup>/sn), Mayıs (32.31 m<sup>3</sup>/sn) ve Haziran (21.18 m<sup>3</sup>/sn) ayları akım en yüksek olduğu aylardır. Yıllık ortalama debi 13.64 m<sup>3</sup>/sn, yıllık toplam akım ise 437.7\*10<sup>6</sup> m<sup>3</sup>'tür [1]. Aksu deresi alt havzası Şekil 1'de gösterilmiştir [2, 4].




Şekil 1. Aksu Deresi Alt Havzası.

Tablo 1. D22A116 nolu AGİ özellikleri.

Kot (m)	Drenaj Alanı (km <sup>2</sup> )	Toplam Akarsu Uzunluğu (m)	Drenaj Yoğunluğu (m/km <sup>2</sup> )	Ort. Akarsu Eğimi
248	713.9	155.420	217.7	0.022

### 3.2. Kullanılan Veriler ve İstatistiksel İncelemesi

YSA ile yapılacak çalışmalarda girdi verilerinin seçiminin kurulacak hidrolojik modeller için önemli olduğu önceki çalışmalarda görülmüştür [20]. Bu çalışma kapsamında en iyi girdi setinin araştırılması amacıyla 5 farklı girdi seti oluşturulmuş, veriler (0,1) aralığında ölçeklenmiş ve bir sonraki güne ait ortalama akım değerini belirlemek için kullanılmıştır. Girdi setinde Devlet Su İşleri tarafından işletilen D22A116 numaralı Aksu Akım Gözlem İstasyonu (AGİ) günlük ortalama akım verileri kullanılmıştır. Debi verileri için yapılmış istatistiksel inceleme sonuçları Tablo 2'de ve veri setine ait zaman serisi diyagramı Şekil 2'de sunulmuştur.



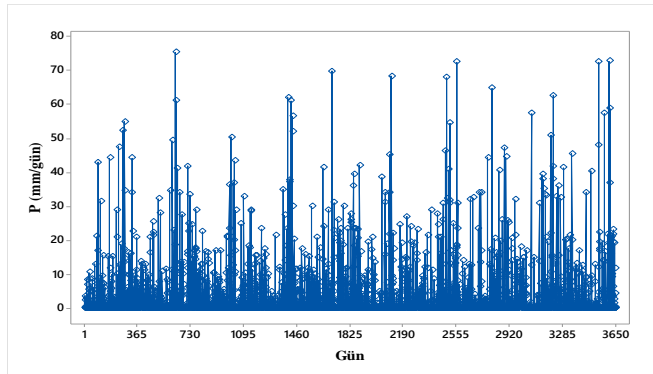
Şekil 2. Debi verileri zaman serisi diyagramı.

Bölgede daha önce Saka ve Yüksek (2017) tarafından yapılan çalışma kapsamında D22A116 Nolu AGİ için meteorolojik verilerin 17034 numaraları Giresun Mİ'dan direkt olarak alınabileceği görüldüğünden, bu istasyonun verileri yağış-akış modelinde kullanılmıştır [18]. Yağış verileri için yapılan istatistiksel analiz sonuçları Tablo 3, bu verilere ait zaman serisi diyagramı Şekil 3'te gösterilmiştir.

Debi ve yağış verileri ilgili istasyonlarda devamlı ölçülmüş en uzun süre belirlenerek 1995 – 2004 yılları arasındaki veriler kullanılmıştır. Analizlerde veri seti %70 eğitim, %15 doğrulama ve %15 test verisi olarak ayrılmıştır. İlk 7 yıllık veri eğitim aşaması, takip eden yaklaşık 1.5 yıllık veri test aşaması, son 1.5 yıllık veri de doğrulama aşaması için kullanılmıştır.

Tablo 2. Akım Verilerinin İstatistiksel İncelemesi.

İSTASYON NO 2213 (AGİ)				
İstatistik Değer	Toplu Veri	Eğitim Veri Seti	Doğrulama Veri Seti	Test Veri Seti
<b>Aritmetik Ortalama</b> (m <sup>3</sup> /sn)	3.45	3.36	3.18	4.14
<b>Mod</b> (m <sup>3</sup> /sn)	0	0	0	0
<b>Medyan</b> (m <sup>3</sup> /sn)	0	0	0	0
<b>Ortalama Sapma</b> (m <sup>3</sup> /sn)	4.8094	4.6443	4.5415	5.8398
<b>Standart Sapma</b> (m <sup>3</sup> /sn)	8.2632	7.8773	8.0922	9.9788
<b>Çarpıklık</b>	4.0395	3.9886	4.4087	3.7246
<b>Basıklık</b>	20.5764	20.4487	24.7197	16.1941
<b>Maksimum</b> (m <sup>3</sup> /sn)	75.4	75.4	72.6	72.8
<b>Minimum</b> (m <sup>3</sup> /sn)	0	0	0	0
<b>Veri Adedi</b>	3649	2555	546	548
<b>Yüzdesi</b> (%)	100	70	15	15



Şekil 3. Yağış verileri zaman serisi diyagramı.

Tablo 3. Yağış verilerinin istatistiksel incelemesi

İSTASYON NO 17034 (Mİ)				
İstatistik Değer	Toplu Veri	Eğitim Veri Seti	Doğrulama Veri Seti	Test Veri Seti
<b>Aritmetik Ortalama</b> (mm)	3.29	3.29	3.48	3.11
<b>Mod (mm)</b>	0	0	0	0
<b>Medyan</b> (mm)	0	0	0	0.1
<b>Ortalama Sapma</b> (mm)	4.5713	4.6023	4.8696	4.1312
<b>Standart Sapma</b> (mm)	7.8902	8.0649	8.3836	6.4176
<b>Çarpıklık</b>	4.3250	4.4315	4.1674	3.2348
<b>Basıklık</b>	28.9929	30.3394	24.9001	16.1778
<b>Maksimum</b> (mm)	103.70	103.70	69.8	50.4
<b>Minimum</b> (mm)	0	0	0	0
<b>Veri Adedi</b>	3649	2555	546	548
<b>Yüzdesi</b> (%)	100	70	15	15

### 3.3. Yağış-Akış Modeli Kurulması

Yağış-akış modeli oluşturmak için YSA yöntemi kullanılmıştır. Kullanılan YSA yöntemi içerisinde LM, QN ve CG eğitim algoritmaları ile 3 farklı ana YSA yapısı oluşturulmuştur. Bu yapıların her biri HTS ve LS transfer fonksiyonları kullanılarak gizli katmanda 2, 8 ve 16 nöron ile denenmiştir.

YSA yöntemi ile oluşturulan yağış-akış modeli ile yapılacak bir sonraki gün akım tahmini için kullanılan girdi setleri Tablo 4'te görülmektedir.

Tablo 4. Yağış-akış modeli girdi setleri

Model	Girdi	Çıktı
M1	$Q_{(t-1)}$	$Q_{(t)}$
M2	$Q_{(t-1)} P_{(t-1)}$	$Q_{(t)}$
M3	$Q_{(t-1)} P_{(t-1)} P_{(t-2)}$	$Q_{(t)}$
M4	$Q_{(t-1)} P_{(t-1)} P_{(t-2)} P_{(t-3)}$	$Q_{(t)}$
M6	$Q_{(t-1)} P_{(t-1)} P_{(t-2)} P_{(t-3)} P_{(t-4)}$	$Q_{(t)}$

Girdi setlerinden görüleceği üzere, yağış-akış modellerinde önceki günlerden kaynaklanacak ve hidrolojik olarak ölçümü zor olan tutmadan kaynaklı sular, yer altı suyundan kaynaklı akım artışları gibi farklı durumların yağış-akış modeline etkisini dahil etmek için tahmin edilecek günden (t) bir önceki güne ait (t-1) akım değeri bağımsız parametre olarak atanmıştır. Yağış değerleri 4 güne kadar gecikmeli olarak bağımsız parametreler halinde atanmıştır.

QN eğitim algoritması kullanılarak eğitilen YSA yapısı (YSA-QN), LM eğitim algoritmasının kullanıldığı YSA yapısı (YSA-LM) ve CG eğitim algoritmasının kullanıldığı YSA yapısı (YSA-CG) ile bir sonraki gün için tahmin edilen  $Q_t$  değerlerinin performans sonuçları sırasıyla Tablo 5, Tablo 6 ve Tablo 7'de görülmektedir.

Tablo 5. YSA-QN performans analizi sonuçları

T	m	2			8			16		
		Md.	RM	R	E	RM	R	E	RM	R
Tanjant Sigmoid	M1	12.087	0.807	0.649	15.338	0.755	0.435	13.922	0.732	0.534
	M2	13.256	0.765	0.578	12.404	0.795	0.630	16.619	0.689	0.336
	M3	13.114	0.771	0.587	12.535	0.789	0.622	12.448	0.794	0.628
	M4	12.112	0.808	0.647	<b>12.090</b>	<b>0.806</b>	<b>0.649</b>	12.679	0.786	0.614
	M5	12.323	0.801	0.635	12.969	0.778	0.596	12.488	0.791	0.625
Log Sigmoid	M1	12.566	0.791	0.620	13.441	0.764	0.566	14.906	0.701	0.466
	M2	12.263	0.801	0.639	12.423	0.793	0.629	13.078	0.779	0.589
	M3	12.899	0.780	0.600	13.075	0.774	0.589	12.324	0.797	0.635
	M4	13.033	0.774	0.592	12.422	0.795	0.629	12.313	0.798	0.636
	M5	13.125	0.771	0.586	13.101	0.777	0.588	12.845	0.780	0.603

Koyu semboller en iyi YSA-QN yapısını göstermektedir.

T: Transfer fonksiyonu

Md.: Model

RM: RMSE

m: Gizli katmandaki nöron sayısı

Tablo 6. YSA-LM performans analizi sonuçları

m		2			8			16		
T	Md.	RM	R	E	RM	R	E	RM	R	E
Tanjant Sigmoid	M1	12.772	0.785	0.608	12.288	0.800	0.637	15.943	0.746	0.389
	M2	12.949	0.777	0.597	12.167	0.803	0.644	13.271	0.760	0.577
	M3	12.389	0.801	0.631	12.380	0.797	0.632	13.422	0.779	0.567
	M4	<b>12.124</b>	<b>0.805</b>	<b>0.647</b>	12.880	0.783	0.601	12.501	0.790	0.624
	M5	12.858	0.781	0.603	12.697	0.787	0.613	12.590	0.790	0.619
Log Sigmoid	M1	13.624	0.748	0.554	12.440	0.794	0.628	14.368	0.714	0.504
	M2	12.899	0.779	0.600	12.759	0.784	0.609	13.485	0.770	0.563
	M3	12.638	0.788	0.616	12.612	0.799	0.618	12.521	0.792	0.623
	M4	12.852	0.781	0.603	12.440	0.797	0.628	13.035	0.775	0.592
	M5	12.963	0.777	0.596	12.585	0.792	0.619	12.515	0.793	0.624

Koyu semboller en iyi YSA-LM yapısını göstermektedir.

T: Transfer fonksiyonu

Md.: Model

RM: RMSE

m: Gizli katmandaki nöron sayısı

Tablo 7. YSA-CG performans analizi sonuçları

m		2			8			16		
T	Md.	RM	R	E	RM	R	E	RM	R	E
Tanjant Sigmoid	M1	12.907	0.780	0.600	14.086	0.728	0.523	16.257	0.693	0.365
	M2	12.216	0.804	0.641	13.114	0.766	0.587	14.632	0.748	0.485
	M3	12.995	0.777	0.594	12.360	0.799	0.633	12.790	0.791	0.607
	M4	13.126	0.772	0.586	12.682	0.790	0.613	13.213	0.765	0.580
	M5	13.570	0.754	0.557	12.389	0.801	0.631	14.981	0.687	0.461
Log Sigmoid	M1	13.235	0.769	0.579	18.368	0.729	0.189	14.831	0.708	0.471
	M2	<b>12.190</b>	<b>0.804</b>	<b>0.643</b>	12.659	0.789	0.615	18.351	0.706	0.191
	M3	13.490	0.758	0.563	13.349	0.757	0.572	13.835	0.742	0.540
	M4	12.660	0.785	0.615	12.529	0.794	0.623	13.628	0.744	0.554
	M5	12.428	0.794	0.629	13.885	0.733	0.537	12.626	0.788	0.617

Koyu semboller en iyi YSA-CG yapısını göstermektedir.

T: Transfer fonksiyonu

Md.: Model

RM: RMSE

m: Gizli katmandaki nöron sayısı

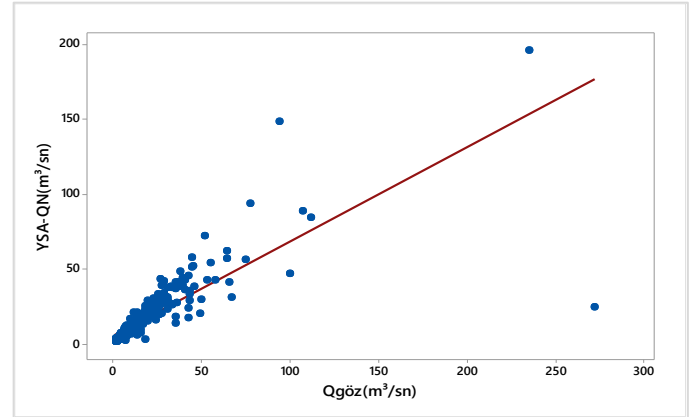
#### 4. BULGULAR VE İRDELEME

Yağış-akış modellemesinde YSA eğitim algoritması olarak seçilen QN, LM, CG eğitim algoritmaları ile birlikte denenen farklı nöron sayıları ve transfer fonksiyonları ile  $Q_t$  tahminleri yapılmıştır. Farklı ağların ürettiği  $Q_t$  çıktıları için yapılan performans analizlerinde, eğitim algoritmaları, farklı nöron sayıları ve farklı transfer fonksiyonları arasında optimum yapının belirlenmesi için kıyaslamalar yapılmıştır.

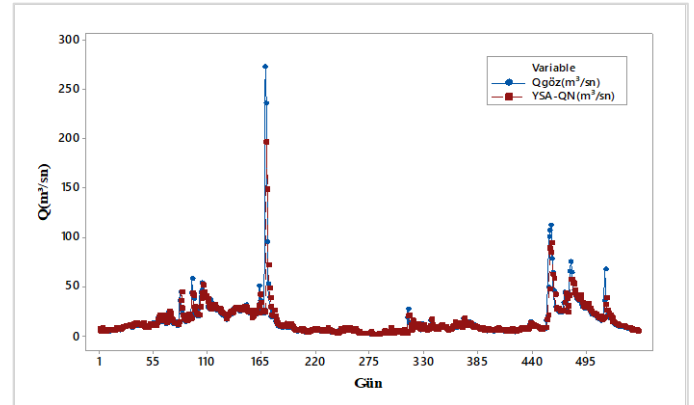
YSA-QN, YSA-LM ve YSA-CG analizleri incelendiğinde bütün modellerin yaklaşık sonuçlar ürettiği görülmektedir. QN ve LM algoritmaları HTS transfer fonksiyonu ile iyi sonuçlar üretmesine karşın, dereceli azalım esasına dayanan CG algoritmasının LS transfer fonksiyonu ile daha iyi sonuç elde ettiği belirlenmiştir. Çalışma kapsamında denenen bütün yağış-akış modellerinin gizli katmandaki nöron

sayısındaki fazla artıştan olumlu etkilenmediği gözlenmiştir.

Çalışmada diğer modellere göre daha iyi olan YSA-QN performans analizi incelendiğinde optimum ağ yapısının; gizli katmanda 8 nöron içeren ve HTS transfer fonksiyonu kullanan yapı, bu YSA-QN yapısı için en iyi  $Q_t$  çıktısını üreten girdi setinin ise M4 olduğu görülmektedir. M4 setine karşılık tahmin edilen  $Q_t$  değerleri ile ölçülmüş  $Q_t$  değerlerinin kıyaslandığı saçılım ve zaman serisi diyagramı Şekil 4(a) ve 4(b)'de görülmektedir.

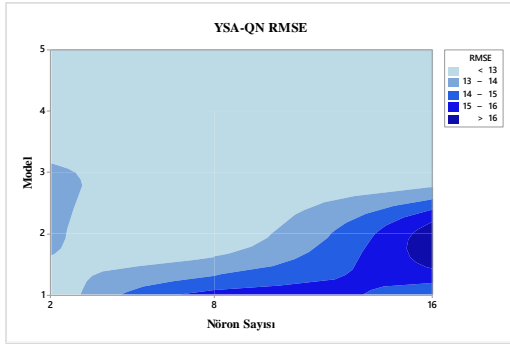


Şekil 4(a). YSA-QN saçılım diyagramı.

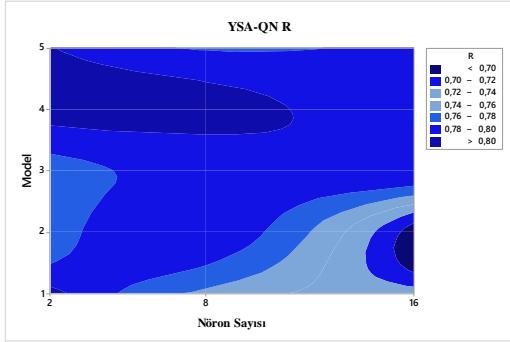


Şekil 4(b). YSA-QN zaman serisi diyagramı.

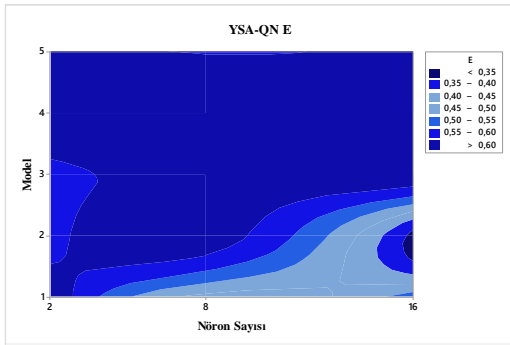
YSA-QN analizinde M4 girdi setinde bir önceki güne ait debi değeri ve 3 güne kadar gecikmeli olarak yağış değerlerinin olduğu görülmektedir. YSA-QN modelinde  $Q_t$  değerinin tahmin edilmesi için yağış değerlerinin önemli olduğu ve 3 günden fazla gecikmenin ağır yapısını olumlu etkilemediği görülmüştür. YSA-QN analizinde nöron sayısındaki artışın ağı olumlu etkilemeyeceği anlaşılmış ve QN eğitim algoritması ile HTS transfer fonksiyonunun daha iyi sonuçlar ürettiği belirlenmiştir. YSA-QN analizinde belirlenen en iyi transfer fonksiyonu olan HTS fonksiyonunda nöron sayısına, modellere göre performans değişimi Şekil 5.a, b ve c'de gösterilmiştir.



Şekil 5(a). YSA-QN RMSE değişim diyagramı.



Şekil 5(b). YSA-QN R değişim diyagramı.



Şekil 5(c). YSA-QN E değişim diyagramı.

## 5. SONUÇ

Yağış-akış modellemelerinde YSA yönteminin etkin sonuçlar üretebileceği görülmüştür. Geleceğe dair yapılacak akım tahminlerinin, yapılacak hidrolik tesislerin planlama, projelendirme ve işletme aşamalarında büyük öneme sahip olduğu düşünüldüğünde, ileriye yönelik yapılacak havza planlamalarında, bu çalışmada diğer modellere göre performansının daha yüksek olduğu belirlenen YSA-QN-HTS yapısının kullanılabilir olduğu belirlenmiştir.

Çalışma sonucunda, QN eğitim algoritması ile HTS transfer fonksiyonunun oluşturduğu yapının gelecekte kurulması planlanan hidroelektrik santrallerin güçlerinin ve rezervuar hacmi su seviyelerinin hesaplamalarında kullanılabilir olacağı, ayrıca bölgede önemli bir risk oluşturan taşkın felaketlerinden koruma yapılarının boyutlandırılması konularında iyi çözümler üretebileceği görülmüştür. YSA-QN, YSA-LM analizlerinin performansının daha yüksek olmasına karşılık, YSA-CG analizi daha az bağımsız değişkene ihtiyaç duyarak diğer modellere yakın performans üretmiştir. Bu durum göz

önünde bulunduğunda, donanım bağımlı olan YSA sistemleri ile oluşturulacak ve veri setinin daha kalabalık olduğu yağış-akış modellemelerinde nispeten daha hızlı sonuçlar üretebileceği düşünülmektedir.

Bu çalışmada kullanılan farklı YSA yapılarının, değişik morfolojik özelliklere sahip farklı havzalara uygulanması, denenilen yöntemlere olan güvenilirliği arttıracaktır.

## Kaynakça

- [1] Aksoy, M. Coşkun, B. (2010). Aksu Vadisi (Giresun) aşağı kesiminde doğal ortam şartlarının taşkın üzerine etkileri. Gazi Türkiyat Türkoloji Araştırmaları Dergisi, 1(7).
- [2] Anılan, T., Satılmış, U., Kankal, M., & Yüksek, O. (2016). Application of artificial neural networks and regression analysis to l-moments based regional frequency analysis in the Eastern Black Sea Basin, Turkey. KSCE Journal of Civil Engineering, 20(5), 2082-2092.
- [3] Antar, M. A., Ellassiouti, I., & Allam, M. N. (2006). Rainfall-runoff modelling using artificial neural networks technique: a Blue Nile catchment case study. Hydrological Processes, 20(5), 1201-1216.
- [4] Babacan, H. T. (2015). Giresun İli Aksu Deresi için farklı parametreler kullanılarak yapay sinir ağları ile akış modellemesi ve ileriye dönük akım tahminleri yapılması. Yayımlanmamış Yüksek Lisans Tezi. Gümüşhane: Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü.
- [5] Bayram, A., Kankal, M., Tayfur, G., & Önsoy, H. (2014). Prediction of suspended sediment concentration from water quality variables. Neural Computing and Applications, 24(5), 1079-1087.
- [6] Dibike, Y. B., & Solomatine, D. P. (2001). River flow forecasting using artificial neural networks. Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere, 26(1), 1-7.
- [7] Gill, P. E., Murray, W., & Wright, M. H. (1981). Practical optimization, Elsevier Academic Press, California, USA.
- [8] Hsu, K. L., Gupta, H. V., & Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-runoff process. Water resources research, 31(10), 2517-2530.
- [9] Keskin, M. E., & Terzi, Ö. (2006). Artificial neural network models of daily pan evaporation. Journal of Hydrologic Engineering, 11(1), 65-70.
- [10] Machado, F., Mine, M., Kaviski, E., & Fill, H. (2011). Monthly rainfall-runoff modelling using artificial neural networks. Hydrological Sciences Journal-Journal des Sciences Hydrologiques, 56(3), 349-361.
- [11] Mohanty, S., Jha, M. K., Raul, S. K., Panda, R. K., & Sudheer, K. P. (2015). Using artificial neural network approach for simultaneous forecasting of weekly groundwater levels at multiple sites. Water Resources Management, 29(15), 5521-5532.
- [12] Mishra, A. K., & Desai, V. R. (2006). Drought forecasting using feed-forward recursive neural network. ecological modelling, 198(1-2), 127-138.
- [13] Moré, J. J. (1978). The Levenberg-Marquardt algorithm: implementation and theory. In Numerical analysis (pp. 105-116). Springer, Berlin, Heidelberg.
- [14] Motahari, M., & Mazandaranizadeh, H. (2017). Development of a PSO-ANN Model for Rainfall-Runoff Response in Basins, Case Study: Karaj Basin. Civil Engineering Journal, 3(1), 35-44.
- [15] Nayak, P. C., Rao, Y. S., & Sudheer, K. P. (2006). Groundwater level forecasting in a shallow aquifer using artificial neural network approach. Water Resources Management, 20(1), 77-90.
- [16] Oztemel, E. (2003). Yapay sinir ağları, Papatya Yayıncılık. İstanbul. pg48.
- [17] Powell, M. J. D. (1977). Restart procedures for the conjugate gradient method. Mathematical programming, 12(1), 241-254.
- [18] Saka, F., & Yüksek, Ö. (2017). Belli aşılma olasılığına sahip debilerinin bölgeselleştirilmesi ve Doğu Karadeniz Havzası

- örneği. Journal of the Faculty of Engineering & Architecture of Gazi University, 32(2).
- [19] Shoaib, M., Shamseldin, A. Y., Khan, S., Khan, M. M., Khan, Z. M., Sultan, T., & Melville, B. W. (2018). A Comparative Study of Various Hybrid Wavelet Feedforward Neural Network Models for Runoff Forecasting. *Water Resources Management*, 32(1), 83-103.
- [20] Singh, V. P., Jain, S. K., & Tyagi, A. (2007, October). Risk and reliability analysis: a handbook for civil and environmental engineers. American Society of Civil Engineers.
- [21] Svozil, D., Kvasnicka, V., & Pospichal, J. (1997). Introduction to multi-layer feed-forward neural networks. *Chemometrics and intelligent laboratory systems*, 39(1), 43-62.
- [22] Uslu, H., & İçaga, Y. (2010). Yapay sinir ağları ile Akarçay akımının modellenmesi. *Electronic Journal of Construction Technologies/Yapı Teknolojileri Elektronik Dergisi*, 6(2).
- [23] Zhao, Y., Nan, J., Cui, F. Y., & Guo, L. (2007). Water quality forecast through application of BP neural network at Yuqiao reservoir. *Journal of Zhejiang University-Science A*, 8(9), 1482-1487.
- [24] Zhu, Y. M., Lu, X. X., & Zhou, Y. (2007). Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *Geomorphology*, 84(1-2), 111-125.