

# **Makine Öğrenmesi İle Aksu Deresi'nde Akış Tahmin Modeli Geliştirilmesi**

## **Development of Streamflow Prediction Model By Using Machine Learning Techniques**

**Hasan Törehan BABACAN<sup>1</sup>, Fatih SAKA<sup>2</sup>**

<sup>1</sup>Ulaştırma Hizmetleri Bölümü, Taşova Yüksel Akın Meslek Yüksekokulu, Amasya Üniversitesi, Amasya

<sup>2</sup>İnşaat Mühendisliği Bölümü, Mühendislik Fakültesi, Karabük Üniversitesi, Karabük

Geliş Tarihi: **23.02.2022** ; Kabul Edildiği Tarih: **30.05.2022** ; Yayımlandığı Tarih: **28.06.2022**

**Türk Hidrolik Dergisi (Tur. J. Hyd.)**, Cilt (Vol) : **6**, Sayı (Number) : **1**, Sayfa 1-11 (Page) : (2022)

e-ISSN: **2636-8382**

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

Sorumlu yazar e-mail: [hasan.babacan@amasya.edu.tr](mailto:hasan.babacan@amasya.edu.tr)

### **Özet**

Bu çalışmada Doğu Karadeniz Havzası'nda bulunan 2020 yılında büyük bir taşkın felaketinin yaşandığı Aksu Deresi alt havzası için gelecek akım modellemesi yapılmıştır. Modelleme için Devlet Su İşlerinden elde edilen akım verileri, Meteoroloji Genel Müdürlüğü'nden elde edilen yağış ve buhar basıncı verileri kullanılmıştır. Oluşturulacak akım modeli için Yapay Sinir Ağları (YSA) ve Klasik Regresyon (KR) yöntemleri tercih edilmiştir. Buhar basıncı, yağış ve geçmiş akış verileri kullanılarak 14 farklı girdi modeli oluşturulmuştur. Oluşturulan bu girdi modelleri Çok Katmanlı YSA (ÇK-YSA) yöntemi ile oluşturulan akış tahmin modeli ile denenmiştir. Akış tahmin modellerinin tahmin performansları Ortalama Hata Kareleri Karekökü (RMSE), Korelasyon Katsayısı ( $r$ ), Rölatif Hata (RH), Nash-Sutcliffe Belirlilik Katsayısı (E) ve Ortalama Mutlak Hata (OMH) kriterleri kullanılarak tespit edilmiş ve ÇK-YSA modelinde performansı en yüksek girdi modeli Klasik Çoklu Regresyon (ÇR) yöntemi ile denenmiştir. Bölgede akış tahmin performansı en yüksek model ÇK-YSA ile oluşturulan M10 girdi seti ile çalıştırılan model olmuştur. Çalışmada geleceğe dönük tahmin edilmiş debi değerleri, taşkın koruma tesisleri, hidroelektrik santral tesisleri, arıtma tesisleri gibi yapıların projelendirme aşamasında proje debisini belirlemek üzere kullanılan aşılma olasılıklarına göre değerlendirilmiştir. Sonuç olarak, ÇR yönteminde makine öğrenmesi gerçekleştiren modellerde olduğu gibi gün gecikmeli girdi seti kullanımının performansı arttırdığı, bölgede akış tahmin modellemesinde ÇK-YSA yönteminin ÇR yönteminden daha başarılı olduğu ve proje debisi belirlemek için uygun olduğu belirlenmiştir.

**Anahtar Kelimeler:** Akış modellemesi, Aksu Deresi, Buhar Basıncı, Çok Katmanlı Algılayıcı

Abstract

In this study, future runoff modeling has been made for the Aksu Stream sub-basin in the Eastern Black Sea Basin, where a major flood disaster occurred in 2020. Runoff data obtained from the State Hydraulic Works, precipitation and vapor pressure data obtained from the General Directorate of Meteorology were used for modeling. Artificial Neural Networks (ANN) and Classical Regression (CR) methods were preferred for the runoff model to be created. 14 different input models were built by using vapor pressure, precipitation and historical discharge data. These input models created were tested with the runoff prediction model created by the Multi Layered ANN (ML-ANN). The estimation performances of the runoff prediction models were determined using the Root Mean Square Error (RMSE), Correlation Coefficient (r), Relative Error (RE), Nash-Sutcliffe Coefficient (E) and Mean Absolute Error (MAE) criteria and their performance in the ML-ANN model was determined. The highest input model was tested with the Classic Multiple Regression (CMR) method. The model with the highest runoff estimation performance in the region was the model operated with the M10 input set created with ML-ANN. In the study, the estimated future runoff rates were evaluated according to the exceedance probabilities used to determine the project runoff rate in the design phase of structures such as flood protection facilities, hydroelectric power plant facilities, treatment facilities. As a result, it has been determined that the use of day-delayed input set increases the performance in the CMR method, as in the models that perform machine learning, the ML-ANN method is more successful than the CMR method for the runoff estimation modeling in the region, and it is suitable for determining the project runoff rate.

Keywords: Runoff Modelling, Aksu River, Vapor Pressure, Multi Layered Perceptron

## 1. GİRİŞ (Introduction)

Hidrolojik olaylar çok sayıda değişkene bağlıdır. Bütün hidrolojik verileri ölçerek elde etmek ekonomik olmayacağı gibi birçok hallerde mümkün olmadığından ölçümlerin bulunmadığı ya da yetersiz olduğu bölgelerde hidrolojik süreçlerin tahmini için bu olayların matematik modellerinin kurulması ve bunların doğruluğunun ölçüm sonuçlarıyla karşılaştırılarak kontrol edilmesi gerekmektedir [25]. Fizik kanunları esas alınarak kurulan bu modeller doğadaki hidrolojik sistemlerin soyutlanmış benzerleri olarak düşünülebilir [9]. Bu modellerin kurulmasında sistem analizi metotları önem kazanmaktadır. Hidrolojik modeller insanların doğada yapacakları değişikliklerin sonucunda hidrolojik büyüklüklerde oluşacak değişimlerin tahmininde sıklıkla kullanılmaktadır [3].

Sürece etkileyen parametre sayısının fazla olması ve parametreler arasındaki kaotik ilişki nedeniyle hidrolojik olayların incelenmesi teorik bir analizden ziyade, yaklaşık yöntemlerin kullanımını zorunlu kılmaktadır [26]. Bu nedenle, problem çözümleri tek bir yöntem ile değil birden fazla yöntem ile yapılabilme ve optimum çözüm belirlenmeye çalışılmaktadır. Elde edilen bulgular arasında en iyi model konusunda bir seçim yapmak, bilgi ve deneyim gerektirmektedir. Kullanılacak yöntem incelenecek olayların genellikle zaman ölçeği ile de ilişkili hale gelmektedir ve hidrolojik olaylar arasında kesin bir bağıntıdan söz etmek neredeyse imkansızdır bu nedenle rastgele bir karakter taşıyan bu olayların incelenmesi ve modellenmesi için bazı istatistiksel metotlar ve bilgisayar destekli algoritmalar kullanılmaktadır [25]. Bu algoritmalar arasında yaygın olarak kullanılan yapay sinir ağları (YSA), akış tahmini ve hidrolojik süreç modellemeleri konusunda başarılı sonuçlar üretmektedir [2-5-9]. YSA ile akış tahmini yapılan modellerde girdi parametresi olarak yağış, sıcaklık ve buharlaşma parametrelerinin yaygın olarak kullanımı görülmektedir ancak yapılan çalışmalarda buharlaşma yerine buhar basıncı kullanılmamıştır.

Çalışma bölgesi olan Aksu Deresi alt havzasında 22 Ağustos 2020 tarihinde yıkıcı bir taşkın felaketi olmuştur. Yaşanan bu taşkın felaketi bölgedeki yaşamı olumsuz etkilemiş, büyük maddi hasara yol açmış ve can kayıplarına neden olmuştur. Taşkın sırasında taşınan sediment ve molozlar akarsu yatağında tıkanıklığa sebep olarak taşkın yıkıcılığını arttırmıştır. Bu durum olası bir taşkın esnasında taşınan sediment yükünün taşkın yıkıcı etkisini arttırdığını göstermiştir. Çalışma bölgesi

yılım 163 günü yağışlı olup yıllık ortalama 693 mm yağış yüksekliğine sahiptir ve Aksu Deresi'ni besleyen yan kolların eğim derecesi yüksek olduğundan Aksu Deresi'nde taşınan su hacmi hızlı bir şekilde artış göstermektedir [30-31]. İklimsel ve topografik özellikler değerlendirildiğinde bölgenin olası taşkın risklerini barındırdığı görülmektedir.

Bu çalışmada topografik özellikleri ve iklimsel karakteristiği nedeniyle önemli bir taşkın riski barındıran Aksu Deresi alt havzası için akış tahmini gerçekleştiren bir model geliştirilmiştir. Geliştirilen bu modelde yağış-akış ilişkilerinin modellenmesinde akış halindeki su yüzeyinden buharlaşmayı temsil eden buhar basıncı tahminleyici parametre olarak kullanılmış olup geliştirilen model ile günlük akış tahminleri gerçekleştirilmiştir. Havzada gelecek debinin tahmin edilmesi debiye bağlı olarak değişen sediment gibi taşkına sebebiyet veren parametrelerin izlenmesi ve gelecekte modellenmesi hususunda katkı sağlayacak olup, su yapılarının projelendirilmesi konusunda bölgeye fayda sağlayacaktır.

## 2. YAPILAN ÇALIŞMALAR (Studies)

Çalışmada D22A071 numaralı Akım Gözlem İstasyonu (AGİ)'nin bulunduğu koordinatlarda hesaplama yapılacağından, AGİ konumuna, Meteoroloji Gözlem İstasyonu (MGİ)'nde kaydedilen, günlük toplam yağış ve günlük ortalama buhar basıncı verilerinin aktarılması için Thiessen Çokgenleri Yöntemi kullanılmıştır. Oluşturulan çokgenler yardımıyla, Doğu Karadeniz Havzası'ndaki MGİ istasyonlarından, D22A071 AGİ konumunu temsil eden alanlar belirlenmiştir. D22A071 AGİ konumunda, 17034 numaralı Meteoroloji Genel Müdürlüğü (MGM) tarafından işletilen MGİ verilerinin etkin olduğu tespit edilmiştir. Bu sebeple günlük toplam yağış (P) ve buhar basıncı (EVT) verileri AGİ konumuna, MGİ'den aynen aktarılmıştır.

### 2.1 Çalışmada Kullanılan Veriler ve Verilerin İstatistiksel İncelemesi (Statistical Review of Data)

#### 2.1.1 D22A071 Numaralı AGİ Verileri (D22A071 Discharge Gauging Station Data)

D22A071 numaralı AGİ'ye ait ölçülmüş, günlük ortalama akım verileri (Q) Devlet Su İşleri (DSİ)'den temin edilmiş ve kullanılmıştır. Temin edilen akım verilerinde ölçüm yapılmamış veya kayda geçilmemiş yıllar olduğundan, en uzun süre devamlı veri grubu olan

1990-1999 yılları arasındaki veriler seçilmiştir. Çalışmada kullanılan AGİ'ye ait özellikler Tablo 1'de sunulmuştur.



Şekil 1. Akсу Deresi alt havzası [29]

Tablo 1. D22A071 AGİ'ye ait bazı özellikler [15]

Kot (m)	Drenaj Alanı (km <sup>2</sup> )	Toplam Akarsu Uzunluğu (m)	Drenaj Yoğunluğu (m/km <sup>2</sup> )	Ort. Akarsu Eğimi
990	297.3	58735	197.6	0.049

Tablo 2. Çalışmada kullanılan Q verilerinin özellikleri

İstatistik Değer	Toplu Veri	Eğitim	Doğ.	Test
Aritmetik Ortalama (m <sup>3</sup> /sn)	7.27	7.27	5.46	9.04
Mod (m <sup>3</sup> /sn)	1.80	1.98	1.57	2.61
Medyan (m <sup>3</sup> /sn)	3.39	3.10	3.39	4.40
Ortalama Sapma (m <sup>3</sup> /sn)	6.1902	6.5870	3.9361	7.1535
Standart Sapma (m <sup>3</sup> /sn)	8.1628	8.2744	5.3956	9.4397
Çarpıklık	1.9383	1.8003	2.0220	1.9403
Basıklık	6.8157	5.9400	7.6743	6.7948
Maksimum (m <sup>3</sup> /sn)	52.3	50.4	39.6	52.3
Minimum (m <sup>3</sup> /sn)	0.9180	0.9180	1.07	1.57
Veri Adedi	3649	2555	546	548
Veri Yüzdesi (%)	100	70	15	15

D22A071 istasyonu için seçilen 3649 adet Q verisi modelleme aşamasında eğitim, doğrulama ve test aşamaları için, sırasıyla %70-%15-%15 olarak seçilmiş ve bu veriler istatistiksel olarak incelenerek Tablo 2' de verilmiştir.

### 2.1.2 17034 Numaralı MGİ Verileri (17034 Meteorological Gauging Station's Data)

İstasyon gözlem türü olarak; otomatik meteorolojik gözlem istasyonudur (OMGİ). Bu istasyonlar belirlenen meteorolojik parametreleri anlık olarak ölçerek, belirlenen formatta yazıya ve grafiklere çevirebilmektedir. MGM entegre sistemine direkt bağlı oldukları için en güvenilir istasyonlardır.

17034 numaralı MGİ ile çevre istasyonlar, Thiessen Yöntemi ile kontrol edilmiş ve diğer istasyonların çalışma alanında etkili olmadığı belirlenerek, herhangi bir katsayı ile çarpılmaksızın 17034 numaralı MGİ verileri aynen kullanılmıştır.

17034 MGİ'den çalışmada kullanılmak üzere ölçülmüş; günlük ortalama EVT (hPa) ve P (mm) verileri alınmıştır. Alınan bu veriler akış verileri ile aynı zamanda olmasına dikkat edilerek 1990-1999 yılları arasında seçilmiştir. Meteorolojik verilerin istatistiksel incelemesi Tablo 3 ve Tablo 4'de sunulmuştur.

**Tablo 3.** 17034 istasyonu yağış verilerinin istatistiksel incelemesi

İstatistik Değer	Toplu Veri	Eğitim	Doğ.	Test
Aritmetik Ortalama (mm)	3.29	3.29	3.48	3.11
Mod (mm)	0	0	0	0
Medyan (mm)	0	0	0	0.1
Ortalama Sapma (mm)	4.5713	4.602	4.869	4.131
Standart Sapma (mm)	7.890	8.065	8.3836	6.418
Çarpıklık	4.325	4.432	4.1674	3.235
Basıklık	28.993	30.339	24.900	16.178
Maksimum (mm)	103.70	103.70	69.8	50.4
Minimum (mm)	0	0	0	0
Veri Adedi	3649	2555	546	548
Veri Yüzdesi (%)	100	70	15	15

Su yüzeyinden buharlaşma miktarı, atmosferde bulunan su buharı miktarı ile yakından ilişkilidir. Sıvı yüzeyinden ayrılan moleküller, atmosferde yayılmaktadır ve sıvı yüzeylerine basınç uygulamaktadır. Su yüzeyindeki basınç ve su üzerine etkiyen basınç arasındaki fark ile buharlaşma miktarı orantılıdır [27]. Buhar basıncı ne kadar küçükse, su yüzeyinden o kadar fazla su kaybedilmektedir. Buharlaşma, MGM tarafından işletilen istasyonlar aracılığıyla ölçülmektedir. Buharlaşma ölçümleri, buharlaşma havuzları içerisindeki kaybolan suyun hesaplanması ile yapılmaktadır. Ölçümde kullanılan havuzun hacminin küçük olması, ısıl değişimlere karşı hassas olmasına neden olmaktadır. Ayrıca durağan bir sistemden ölçülen buharlaşmanın akış halindeki sistemi temsil yeteneğinin az olması sebebiyle, çalışmada buharlaşmaya direkt olarak etki eden, buhar basıncı kullanılmıştır. Buhar basıncı verileri günlük ortalama veriler (hPa biriminde) olarak çalışmaya dahil edilmiştir.

## 2.2 Dönemsellik Bileşeni (Seasonality Coefficient)

Gün serisi oluşturmak, modelin kararlılığını ve tahmin sonuçlarının gözlenen değerlere yakınlığını arttırmak amacıyla dönemsellik bileşeni ( $\alpha$ ) kullanılmıştır [16]. Dönemsellik bileşeni kurulan modelde girdi verisi olarak, veri grubunun yılın hangi gününe ait olduğunu gösterir şekilde kullanılmıştır. Bu parametre ile YSA mimarilerinde çok karşılaşılan ezberleme problemi giderilmeye çalışılmıştır.

**Tablo 4.** 17034 istasyonu buhar basıncı verileri istatistiksel incelemesi

İstatistik Değer	Toplu Veri	Eğitim	Doğ.	Test
Aritmetik Ortalama (hPa)	13.61	13.60	14.83	12.44
Mod (hPa)	8.2	8.2	20.1	6.9
Medyan (hPa)	12.4	12.3	13.6	11.3
Ortalama Sapma (hPa)	5.288	5.295	5.509	4.924
Standart Sapma (hPa)	6.130	6.097	6.405	5.760
Çarpıklık	0.455	0.423	0.483	0.504
Basıklık	2.063	1.979	2.098	2.138
Maksimum (hPa)	29.70	28.70	29.70	25.80
Minimum (hPa)	3	3.5	5	3
Veri Adedi	3649	2555	546	548
Veri Yüzdesi (%)	100	70	15	15

## 2.3 Akış Modelinin Geliştirilmesi (Development of Streamflow Prediction Model)

Yağış-Akış sürecini açıklamak için geliştirilen akış tahmin modeli için kaotik ilişkilerin modellenmesinde sıklıkla kullanılan YSA ve aynı ilişkinin lineer olarak ilişki düzeyini ifade etmek üzere ÇR yöntemleri kullanılmıştır. YSA girdi, gizli ve çıktı katmanları olarak adlandırılan üç temel katmandan oluşan kompleks bir yapıdır. YSA'da girdi verisinden ağa alınan veriler transfer fonksiyonları ve toplama fonksiyonları kullanılarak bir sonraki katman olan gizli katmana aktarılmakta ve buradan da bir çıktı üretecek şekilde çıktı katmanına aktarılmaktadır. Çıktı katmanında elde edilen çıktı, beklenen tahmin çıktısı ile kıyaslanarak ağına hata değeri belirlenmekte ve istenen değerden fazla olması durumunda katmanlar arasındaki veri transferi sırasında bağlantılara atanan katsayılar öğrenme algoritması kullanılarak hata oranına göre optimize edilmekte ve hata oranı hedeflenen hata oranına yakınsayana kadar bu işlem sürdürülür. Bu işlem sonrasında ağına en uygun çıktıyı üretmesi sağlanır [32]. Çalışmada kullanılan diğer bir sayısal yöntem olan ÇR'da seçilen ilişki düzeyine göre oluşturulan eşitlikte tahminleyici bağımsız parametrelere atanan katsayılar, hedeflenen çıktı değerine uygun şekilde optimize edilerek yaklaşık değerler bulunarak bağımlı değişkeni tahmin eden bağımsız değişkenlerin girdi olarak kullanıldığı sayısal eşitlik elde edilir [33].

Çalışmada, DSI'den temin edilmiş günlük akış modellemesi yapılmıştır. Girdi setleri gün gecikmeli olarak, Q, P ve EVT hidrometeorolojik verileri ile  $\alpha$  bileşeninden oluşturulmuştur. Havzaya giren suyun akışa dönüşmesi kompleks bir süreçtir. Bu süreçte havzada yüzeysel akışı etkileyen ancak kesin olarak hesaplanamayan veya ölçülmesi ekonomik olmayan parametrelerin performans olumsuz etkisi, gün gecikmeli model girdi kombinasyonları oluşturularak azaltılmıştır. Oluşturulan girdi setleri ile gelecek akış Q(t) tahmini yapılmıştır.

Analizler kapsamında, Çok Katmanlı YSA (ÇK-YSA) mimarisi içerisinde toplam 14 farklı girdi kombinasyonu denenmiştir. Modellerde sadece geçmiş veriler değil, tahmin edilecek günün verileri de kullanılmıştır. Bu durum modelin kararlılığını yükselterek, gün içinde yaşanacak ani değişimler karşısında, modelin başarılı sonuç üretebilme kabiliyetini arttırması amacıyla.

ÇK-YSA analizlerinden elde edilen performans değerleri incelenerek, her analiz grubu için belirlenen en iyi model girdi veri seti ÇR analizinde lineer ilişkinin belirlenmesi için kullanılmıştır. Girdi setleri Tablo 5'te sunulmuştur. Tabloda (t) tahmin yapılacak günü ifade etmektedir. (t-n) ise n değeri kadar önceki günü temsil eden veriyi ifade etmektedir.

**Tablo 5.** ÇK-YSA girdi modelleri

Model	Girdi Parametreleri	Çıktı
M1	Q(t-1), $\alpha$	Q(t)
M2	Q(t-1), Q(t-2), $\alpha$	Q(t)
M3	Q(t-1), Q(t-2), P(t), $\alpha$	Q(t)
M4	Q(t-1), Q(t-2), P(t), P(t-1), $\alpha$	Q(t)
M5	Q(t-1), Q(t-2), P(t), P(t-1), P(t-2), $\alpha$	Q(t)
M6	Q(t-1), Q(t-2), P(t), P(t-1), P(t-2), P(t-3), $\alpha$	Q(t)
M7	Q(t-1), Q(t-2), P(t), P(t-1), P(t-2), P(t-3), EVT(t), $\alpha$	Q(t)
M8	Q(t-1), Q(t-2), P(t), P(t-1), P(t-2), P(t-3), EVT(t), EVT(t-1), $\alpha$	Q(t)
M9	Q(t-1), Q(t-2), P(t), P(t-1), P(t-2), P(t-3), EVT(t), EVT(t-1), EVT(t-2), $\alpha$	Q(t)
M10	Q(t-1), Q(t-2), P(t), P(t-1), P(t-2), P(t-3), EVT(t), EVT(t-1), EVT(t-2), EVT(t-3), $\alpha$	Q(t)
M11	Q(t-1), Q(t-2), EVT(t), EVT(t-1), EVT(t-2), EVT(t-3), $\alpha$	Q(t)
M12	Q(t-1), Q(t-2), EVT(t), EVT(t-1), EVT(t-2), $\alpha$	Q(t)
M13	Q(t-1), Q(t-2), EVT(t), EVT(t-1), $\alpha$	Q(t)
M14	Q(t-1), Q(t-2), EVT(t), $\alpha$	Q(t)

YSA için kullanılacak verilerin ölçeklenmesi (normalizasyon), ağın performansını yakından etkileyen bir unsurdur [28]. Normalizasyon veri setindeki dağılımı düzenlemektedir. Girdi setinde olan aşırı uç değerlerden tahmin performansının olumsuz etkilenmesi ve farklı birimlerde olan parametrelerin aynı ölçek ile

değerlendirilmek istenmesinden dolayı veri seti ölçeklenmiştir. YSA kesin değerler ile çalışan bir yöntem olduğundan sık gördüğü 0 çarpanı ezberleme ile sabit çıktı üretmesine neden olmaktadır. Yağış veri setinde 0 değerlerinin olması nedeniyle, ağın ezberlemesini önlemek için veriler 0.1 – 0.9 aralığında ölçeklenmiştir. Normalizasyon işleminin yapılması için Eşitlik 1 kullanılmıştır. Normalizasyon işlemi yapılarak veriler boyutsuz hale getirilmiştir [22].

$$x' = 0.8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (1)$$

Çalışma kapsamında tasarımı yapılan, ileri beslemeli geri yayımlı ÇK-YSA mimarisinde transfer fonksiyonu olarak, literatürde seçilmiş ve başarılı fonksiyonlar denenmiştir. Bu fonksiyonlar içerisinde ileri beslemeli geri yayımlı ağlarda daha başarılı olduğu tespit edilen, hiperbolik tanjant sigmoid fonksiyonu tercih edilmiştir [6].

Öğrenme algoritmasının seçimi için, daha önce yapılan çalışmalarda, tasarımcıların en çok tercih ettiği algoritmalarından ikisi olan; eşlenik eğim (Conjugate Gradient) algoritması ve Levenberg-Marquardt algoritması denenmiştir. Eşlenik eğim algoritması, Levenberg-Marquardt algoritmasından daha başarılı sonuçlar üretmediği için Levenberg-Marquardt (LM) algoritması seçilmiştir. Ağda belirlenen bu fonksiyon ve seçilen algoritmaya karşılık, ağın başarısını etkileyecek bir diğer seçim olan ara (gizli) katmandaki nöron sayısı (m) seçimi için; nöron sayıları 1-60 aralığında rastgele olarak denenmiş olup çalışmada eleman 3, 5 ve 10 nöron kullanımından elde edilen bilgiler sunulmuştur. Ağ mimarisinde tahmin sonuçlarını etkileyen en önemli etkenlerden birisi olan ara (gizli) katman sayısı 1-20 aralığında rastgele olarak denenmiş ve 1 ara katman, ağ mimarisine uygun görülmüştür. Kurulan ağ mimarisinde tahmin süresinin kısa olması nedeniyle, iterasyon sayısı çok yüksek seçilmiştir. Bu seçim ile ağın; iterasyon sayısı bitiminde değil, belirlenmiş en küçük hata değerine ulaştığında kendini durdurması amaçlanmıştır. LM için ağ üzerinde doğrulama kontrolü (Validation Check); ağın hedeflenen en küçük hata değerine, belirlenen aralıklar içerisinde en çok yakınsadığı andan itibaren, ağın daha düşük bir hata değeri araması işlemidir. Bu işlem için ağ tasarlanırken, kontrol iterasyonu değeri 100 olarak seçilmiş ve ağın belirlenen sayı kadar kontrol iterasyonu yaparak en düşük hataya ulaşması amaçlanmıştır. ÇK-YSA tasarım parametreleri Tablo 6'da sunulmuştur.

**Tablo 6.** Ağ için kullanılan parametreler ve belirlenen değerler

TF	ÖA	m	I	KI	λ
Hiperbol	LM	3	10000	100	0.01
ik		5			
Tanjant		10			
Sigmoid					

TF: Transfer Fonksiyonu, ÖA: Öğrenme Algoritması, m: Ara Katman Nöron Sayısı, I: max İterasyon Sayısı, KI: Kontrol İterasyonu Sayısı, λ: Marquardt Parametresi

#### 2.4 Kullanılan Hata Değerlendirme Kriterleri (Used Performance Evaluation Criteria)

Ağın eğitilmesi ve örnekler üzerinde tahmin üretebilme yeteneği kazandırılması ile ağın çıktı verileri çeşitli kriterlere göre değerlendirilmiştir. Çıktı verilerinin gözlenen gerçek verilerle korelasyonu ve tahmin edilen değerlerin doğruluğu; RMSE, R, RH, E ve OMH kriterlerine göre değerlendirilmiştir.

RMSE; literatürde en fazla tercih edilen hata değerlendirme kriteridir. Bu kriter ölçülmüş gerçek veriler ile modelin üretmiş olduğu tahmin değerleri arasındaki hata oranını belirlemek için kullanılmaktadır. Bu değer sıfıra yakınsaması modelin, tahmin üretme kabiliyetinin artmasını ifade etmektedir. RMSE değeri (2) numaralı eşitlik yardımı ile hesaplanmaktadır.

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

r; ölçülmüş gerçek değerler ile üretilmiş tahminsel değerler arasında lineer bir ilişkinin varlığını değerlendirmektedir. r değeri [-1,1] aralığında bir değer olabilmektedir. r değerinin 1 olması durumunda, değerler arasında pozitif ve tam doğrusal bir ilişki bulunmaktadır. Bu durumda bir veri grubu artarken diğerinin de artacağı veya bir grup azalırken diğer grubun da azalacağı anlaşılmaktadır. r değerinin -1 olduğu durumda tam ters bir ilişkiden söz edilmektedir. Bu durumda ise veri grubundan birisi artarken diğer grubun azalması veya tam ters ilişki olması beklenmektedir. r değerinin 0 olması durumunda ise veri grupları arasında herhangi bir ilişkiden söz edilememektedir. (3) numaralı eşitlikte korelasyon katsayısının hesaplanması için formül verilmiştir.

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

RH; gözlenen değerler ile ölçülmüş değerlerin mutlak farkının gözlenen değere bölümlerinin, veri sayısına göre oranını göstermektedir. Yüzde veya binde olarak ifade edilebilmektedir. Bu değer sıfıra yakınsaması, tahmin verilerinin gözlem verilerine yakın olduğunu ve yapılan tahminlerin başarılı olduğunu ifade etmektedir. RH (4) numaralı eşitlikte olduğu gibi hesaplanmıştır.

$$RH = \frac{1}{n} * \frac{|Q_{i(\text{ölçüm})} - Q_{i(\text{tahmin})}|}{Q_{i(\text{ölçüm})}} * 100 \quad (4)$$

E; yapılan hidrolojik çalışmalarda sıklıkla kullanılan bir hata değerlendirme parametresidir. Bu katsayı (-∞,1] aralığında bir değer alabilmektedir. Katsayı değerinin 1'e yakınsaması modelin ürettiği tahmin sonuçlarının ölçülmüş değerlere yakınsadığını ifade etmektedir. (5) numaralı eşitlikte E belirlilik katsayısı formülü verilmiştir.

$$E = 1 - \frac{\sum_{i=1}^n (Q_{i(\text{ölçüm})} - Q_{i(\text{tahmin})})^2}{\sum_{i=1}^n (Q_{i(\text{ölçüm})} - \bar{Q}_{(\text{ölçüm})})^2} \quad (5)$$

OMH; ölçülen gerçek değerler ile tahmin edilmiş verilerin mutlak farkları toplamı ortalamasıdır. (6) numaralı eşitlikte OMH formülü verilmiştir.

$$OMH = \frac{\sum_{i=1}^n |Q_{i(\text{ölçüm})} - Q_{i(\text{tahmin})}|}{n} \quad (6)$$

#### 2.5 Ölçülen Debi Değerlerinin Aşılma Olasılıklarına Göre Tahmin Edilmiş Debi Değerleri ile Kıyaslanması (Comparison of Measured Discharge Values with Estimated Discharge Values Based on Exceeding Probability)


Su yapılarının projelendirilmesi için gelecek debinin belirlenmesi gerekmektedir. Yapılacak tesislerin türüne göre, projelendirilmesi için bilinmesi gereken farklı debi değerleri vardır, bunlar da tesisin ekonomik ömrü, bakım maliyetleri, inşaa maliyetleri, uygulanabilirlik ve sağlayacağı fayda gibi birçok etkeni doğrudan etkilemektedir. Çalışmanın bu kısmında, hidrolojik yapıların projelendirilme safhasında kullanılan, bazı aşılma olasılıklarına karşılık gelen debi değerleri için çalışma kapsamında yapılan analizlerin başarısı incelenmiştir.

Aşılma olasılıkları hesaplanırken, her analiz grubunun test setinde bulunan veriler kullanılmıştır. Verilerin aşılma olasılıkları araştırıldığından, veriler veri seti

içerisinde, büyük veriden küçük veriye doğru sıralanmıştır. Sıralanmış olan bu verilerin pozisyon olasılıkları ( $P_i$ ) yüzdelik olarak, (7) numaralı eşitlik kullanılarak hesaplanmıştır. Eşitlikte verinin veri seti içindeki pozisyonu ( $n_i$ ) kullanılmıştır [34]. İncelenecek aşılma olasılıkları, hidrolik projelerde sıklıkla kullanılan değerler göz önüne alınarak seçilmiştir. Seçimlerde %10, %5 ve %2 gibi karşılaşıma ihtimali çok düşük olan debiler için de ağın performansının değerlendirilmesi yapılmıştır.

$$P_i = \frac{n_i}{N + 1} * 100 \quad (7)$$

Yapılan değerlendirme sonuçları analiz grubu için grafik ve tablo olarak sunulmuştur. Tabloda gözlenen veriler ve tahmin edilmiş veriler yer almaktadır. Çalışmada kullanılan; RMSE, r, RH, E ve OMH katsayılarına göre performans değerlendirmesi yapılmıştır.



Şekil 2. ÇK-YSA M10 modeli tahmin değerleri saçılım ve zaman serisi diyagram

### 3. BULGULAR VE TARTIŞMA (Results and Discussion)

Performans kriterlerinden elde edilen sonuçlara göre sınıflandırma yapılarak, en iyi tahmin üreten ağ yapısı belirlenmiştir. Bu tasarım içerisinde en uygun ağ yapısı, gerçek değerlere en yakın sonuçların tahmininde başarılı olan girdi modeli, optimal gün gecikme sayısı ve ara katmanda kullanılacak en uygun nöron sayısı belirlenmiştir.

ÇK-YSA tahmin performansı tüm girdi modelleri ve tüm ağ mimarileri için kabul edilebilir sonuçlar üretmiştir. Tahmin edilen  $Q(t)$  serilerinin gözlenen  $Q$  değerleri ile korelasyonunun çok yüksek olduğu ancak pik değerlerde ve ani yükseliş durumlarında modelin trendi yakaladığı ancak hatalı tahmin yaptığı görülmektedir. ÇK-YSA performans verileri incelendiğinde ara katmanda en uygun nöron sayısının 5 olduğu görülmektedir. ÇK-YSA yapısında nöron sayısındaki daha fazla artışın tahmin performansını olumsuz etkilediği görülmektedir (Tablo 7(a), Tablo 7(b) ve Tablo 7(c)).

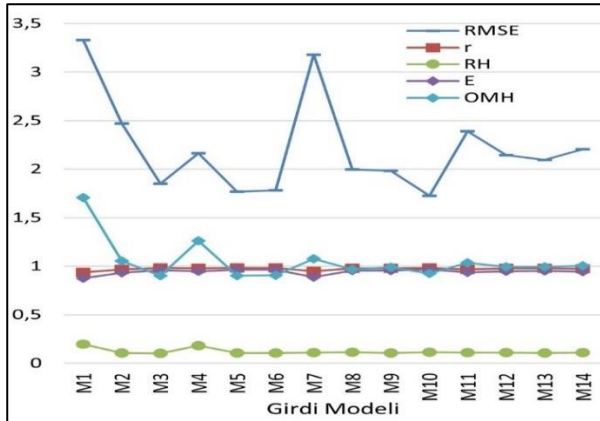
Girdi modellerindeki parametre sayısındaki artışın tahmin performansını olumlu etkilediği görülmüştür. Elde edilen bulgular buhar basıncı parametresinin geçmiş akış ve yağış ile birlikte kullanıldığında model performansını artırıcı etki yaptığını göstermektedir. Bu durum buhar basıncının akış tahmin modelleri için bir

tahminleyici parametre olarak kullanılabilirliğini göstermiştir. ÇK-YSA tahmin modellerinden performansı en yüksek olan M10-5 modelinin AGİ konumunda akım tahmini konusunda en iyi model olduğu belirlenmiştir (Şekil 2). Çalışmada belirlenen optimum gizli katman nöron sayısı için performans kriterlerinin nöron sayısına göre değişimi Şekil 3'te görülmektedir. Belirlenen en iyi modeldeki girdi seti olan M10 ÇR analizlerinde lineer eşitlikte gün gecikmeli girdi setlerinin etkisinin araştırılması için kullanılmıştır. ÇR'de öncelikle tahmin edilen güne ait  $P(t)$ ,  $EVT(t)$  ve  $\alpha$  parametreleri girdi olarak kullanılarak  $Q(t)$  tahmini yapılmıştır (ÇR-1). Daha sonra ÇK-YSA'da performansı en yüksek olan M10 girdi modeli ÇR'de girdi olarak kullanılmıştır (ÇR-2). ÇR-1'den elde edilen tahmin sonuçlarının hidrolojik araştırmalarda kullanılamayacak düzeyde olduğu görülmüş olup lineer modellerin kaotik ilişkileri modellemedeki yetersizliği ortaya koyulmuştur. ÇR-2 performans verileri değerlendirildiğinde, gün gecikmeli girdi setlerinin ÇR performansını önemli ölçüde arttırdığı görülmektedir.

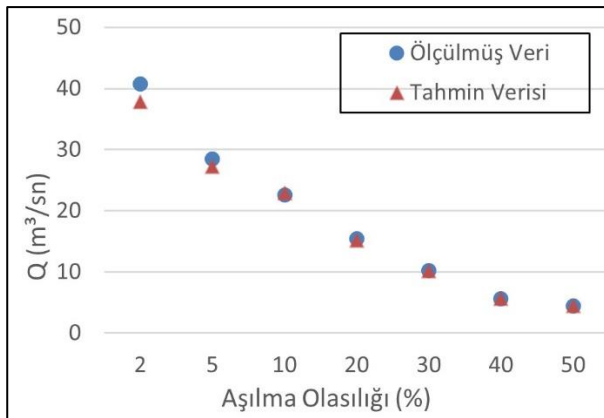
ÇK-YSA ve ÇR analizlerine ait performans verileri Tablo 8'de gösterilmiştir. Aksu Deresi üzerinde bulunan D22A071 AGİ konumunda performans değeri en yüksek akış tahmin modeli olan ÇK-YSA-M10-5 verilerinden belirli aşılma olasılıklarına göre debi değerleri belirlenmiştir. Benzer şekilde aynı aşılma olasılıklarına



göre değerler gözlenmiş veriler kullanılarak elde edilmiştir.



Şekil 3. Ara katman nöron sayısı m=5 için modellere göre performans verileri değişimi



Şekil 4. Aşılma olasılıklarına göre ÇK-YSA debi tahmin performansı

Aşılma olasılıklarına göre ölçülmüş ve tahmin edilmiş debi değerleri Şekil 4'te görülmektedir. Aşılma olasılıklarına göre değerlendirme yapıldığında, YSA yapısının %2, %5 gibi düşük aşılma olasılıklarına karşılık gelen yüksek debilerin tahmininde performans değerinin düşük olduğu ancak daha yüksek aşılma oranlarına karşılık gelen düşük debilerin tahmininde kesinlik oranı yüksek tahminler ürettiği görülmektedir. Tablo 9'da aşılma oranlarına karşılık gözlenmiş verilerden elde edilen debiler ve tahmin edilmiş debiler ile tahmin performansını gösteren performans verileri gösterilmiştir.

Tablo 7(a). ÇK-YSA tahmin performans verileri

Nöron Sayısı		m=3				
Model No	RMSE	r	RH (%)	E	OMH	

M1	3.332	0.936	19.976	0.875	1.709
M2	1.990	0.979	9.866	0.956	0.942
M3	2.646	0.972	11.381	0.921	1.168
M4	1.822	0.982	10.479	0.963	0.930
M5	2.032	0.980	14.704	0.954	1.064
M6	1.830	0.983	10.012	0.962	0.899
M7	1.878	0.981	11.297	0.960	0.957
M8	1.829	0.982	10.837	0.962	0.922
M9	1.739	0.983	10.629	0.966	0.903
M10	1.731	0.983	10.772	0.966	0.902
M11	1.808	0.982	10.672	0.963	0.917
M12	1.936	0.980	10.776	0.958	0.954
M13	1.950	0.980	10.428	0.957	0.949
M14	2.191	0.974	11.451	0.946	1.008

Tablo 7(b). ÇK-YSA tahmin performans verileri

Nöron Sayısı		m=5				
Model No	RMSE	r	RH (%)	E	OMH	
M1	3.331	0.936	19.796	0.875	1.707	
M2	2.469	0.969	10.647	0.932	1.056	
M3	1.849	0.981	10.272	0.962	0.905	
M4	2.164	0.978	18.155	0.947	1.263	
M5	1.766	0.983	10.854	0.965	0.902	
M6	1.784	0.983	10.609	0.964	0.905	
M7	3.180	0.947	10.893	0.887	1.075	
M8	1.996	0.979	11.318	0.955	0.967	
M9	1.982	0.978	10.758	0.956	0.989	
M10	<b>1.726</b>	<b>0.983</b>	<b>11.586</b>	<b>0.967</b>	<b>0.925</b>	
M11	2.392	0.969	10.959	0.936	1.034	
M12	2.143	0.977	11.147	0.948	0.993	
M13	2.095	0.977	10.830	0.951	0.994	
M14	2.206	0.975	11.232	0.945	1.005	

En iyi model performans verileri koyu gösterilmiştir.

Tablo 7(c). ÇK-YSA tahmin performans verileri

Nöron Sayısı		m=10				
Model No	RMSE	r	RH (%)	E	OMH	
M1	3.400	0.933	20.761	0.870	1.743	
M2	2.186	0.976	10.426	0.946	0.997	
M3	2.099	0.979	17.121	0.951	1.152	
M4	2.030	0.983	10.711	0.954	0.985	
M5	1.765	0.983	10.397	0.965	0.892	
M6	2.266	0.972	10.685	0.942	1.040	
M7	1.901	0.980	9.737	0.959	0.909	
M8	2.217	0.974	11.048	0.945	1.021	
M9	2.387	0.969	10.699	0.936	1.018	
M10	1.821	0.983	11.339	0.963	0.944	
M11	2.431	0.966	11.581	0.934	1.067	
M12	2.366	0.970	10.697	0.937	1.026	
M13	2.286	0.973	10.793	0.941	1.015	
M14	2.484	0.967	10.233	0.931	1.063	

2271 analizi için aşılma olasılıklarına karşılık gelen akım değerleri ve bunlara karşılık yapılan tahmin değerlerinin değerlendirilmesi Tablo 9.'da verilmiştir.

**Tablo 8.** ÇDR analizleri ve ÇK-YSA analizi performans değerleri

Yöntem	RMSE	r	RH	E	OMH
ÇK-YSA	1.727	0.98	11.586	0.967	0.925
ÇR-1	9.501	0.10	109.55	-0.013	6.631
ÇR-2	1.754	0.98	12.094	0.965	0.912

**Tablo 9.** Aşılma Olasılıklarına Göre Veri Değerlendirilmesi

Aşılma Olasılığı (%)	Ölçülmüş Gerçek Akım (m <sup>3</sup> /sn)	Tahmin Edilmiş Akım (m <sup>3</sup> /sn)	RMSE	r	RH (%)	E	OMH
2	40.7	37.83	2.874		7.061	0.992	2.874
5	28.5	27.16	1.341		4.705	0.995	1.341
10	22.6	22.92	0.323		1.429	0.999	0.323
20	15.4	15.10	0.305	0.9988	1.980	0.997	0.305
30	10.2	10.09	0.106		1.039	0.991	0.106
40	5.64	5.66	0.015		0.265	0.999	0.015
50	4.4	4.47	0.068		1.545	0.999	0.068

#### 4. SONUÇLAR (Conclusions)

Oluşturulan ileri beslemeli geri yayımlı ÇK-YSA mimarisi, ileriye dönük akım tahminleri yapma konusunda başarılı sonuçlar üretmiştir. İleri beslemeli geri yayımlı ÇK-YSA modellerinin ileriye dönük akım tahminleri yapma, istasyonlardaki eksik verileri tamamlama gibi işlemler için kullanılabilir olduğu belirlenmiştir.

YSA ile oluşturulacak akış tahmin modellerinde girdi setindeki parametre artışının tahmin performansını olumlu etkilediği belirlenmiştir. Buharlaşmaya göre daha kolay yöntemler ile ekonomik bir şekilde ölçümü gerçekleştirilebilen buhar basıncı parametresinin akış tahmin modellemesinde tahminleyici bir parametre olarak kullanılmasının model performansını arttırdığı ve bu durumda buhar basıncının modelleme çalışmalarında kullanılabilir olduğu belirlenmiştir. Kaotik ilişkiye sahip hidrolojik süreçlerin ÇR ile modellenmesi sırasında ÇR'de gün gecikmeli girdi setlerinin kullanılmasının performansını önemli ölçüde arttırdığı belirlenmiştir.

Hidrolik yapıların projelendirme aşamalarında ihtiyaç duyulan belli aşılma olasılıklarına göre debilerin belirlenmesi için, oluşturulan ÇK-YSA mimarisi çok düşük hata oranlarına sahip tahminler yaptığından, bu gibi debilerin tahmini için tercih edilebilir olduğu görülmüştür. Ancak düşük aşılma olasılıklarında YSA'nın tahmin performansının azaldığı görülmektedir.

Aksu Deresi için tasarlanan ÇK-YSA'da başarılı sonuç üreten buhar basıncı parametresinin farklı akış

karakteristiğine sahip bölgelerde denenerek, tahminleyici bir parametre olarak kullanılması durumunun gelecek çalışmalarda irdelenmesi literatüre katkı sağlayacaktır.

#### KAYNAKLAR (References)

- [1] Aksoy, B., Mücahit, C., Aksu Vadisi (Giresun) Aşağı Kesiminde Doğal Ortam Şartlarının Taşkın Üzerine Etkileri, Gazi Türkiyat Türkoloji Araştırmaları Dergisi, 2010, 1-7.
- [2] 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.
- [3] Bayazıt, M., 1999. Hidroloji, İstanbul Teknik Üniversitesi İnşaat Fakültesi Matbaası, İstanbul, 242s.
- [4] De Vos, N. J. (2013). Echo state networks as an alternative to traditional artificial neural networks in rainfall-runoff modelling. *Hydrology and Earth System Sciences*, 17(1), 253-267.
- [5] 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.
- [6] Jeong, D. I., & Kim, Y. O. (2005). Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction. *Hydrological processes*, 19(19), 3819-3835.
- [7] Karstarlı, Ç., Kömürcü, M. İ., Akpınar, A., Uzlu, E., Kankal, M., & Önsoy, H. Doğu Karadeniz Havzasındaki

Hidroelektrik Potansiyelin Analizi, II. Su Yapıları Sempozyumu - 16-18 Eylül 2011, Diyarbakır

[8] Lohani, A. K., Goel, N. K., & Bhatia, K. K. S. (2011). Comparative study of neural network, fuzzy logic and linear transfer function techniques in daily rainfall-runoff modelling under different input domains. *Hydrological Processes*, 25(2), 175-193.

[9] 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.

[10] Mete, T., Kesikli Bir Biyoreaktörde Yapay Sinir Ağlarının Kullanımı, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 2008, 128s.

[11] Nacar, S., Farklı Yapay Zeka Yöntemleriyle Günlük Akarsu Akım Değerlerinin Tahmini-Haldizen Deresi Örneği, Aksaray Üniversitesi Fen Bilimleri Enstitüsü, Aksaray, 2014, 139s.

[12] Öztemel, E., 2006. Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 232s.

[13] Rajurkar, M. P., Kothiyari, U. C., & Chaube, U. C. (2004). Modeling of the daily rainfall-runoff relationship with artificial neural network. *Journal of Hydrology*, 285(1), 96-113.

[14] Riad, S., Mania, J., Bouchaou, L., & Najjar, Y. (2004). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, 40(7), 839-846.

[15] Saka, F., Sentetik Debi Süreklilik Eğrilerinin Matematiksel Yöntemlerle Belirlenmesi ve Doğu Karadeniz Örneği, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon, 2012, 85s.

[16] Sanikhani, H., & Kisi, Ö., River Flow Estimation and Forecasting by Using Two Different Adaptive Neuro-Fuzzy Approaches. *Water Resources Management*, 2012, 26(6), 1715-1729.

[17] Şen, Z., 2002. Su Bilimi Temel Konuları, Su Vakfı Yayınları, İstanbul, 227s.

[18] Şen, Z., 2004. Yapay Sinir Ağları İlkeleri, Su Vakfı Yayınları, İstanbul, 183s.

[19] Turhan, E., 2012. Seyhan Havzasının Yağış-Akış İlişkisinin Yapay Sinir Ağları Yöntemi ile Modellenmesi, Adana, 2012,

[20] Wu, C. L., & Chau, K. W. (2011). Rainfall-runoff modeling using artificial neural network coupled with

singular spectrum analysis. *Journal of Hydrology*, 399(3), 394-409.

[21] Wu, C. L., Chau, K. W., & Li, Y. S. (2009). Methods to improve neural network performance in daily flows prediction. *Journal of Hydrology*, 372(1), 80-93.

[22] Yavuz, S., Deveci, M., 2013, İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi, Erciyes Üniversitesi İİBF Dergisi, Sayı 40, Haziran-Aralık 2012ss. 167-187s.

[23] Yenigün, K., Gümüş, V., 2009. Hidroloji Ders Notları, Harran Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü, Şanlıurfa, 40s.

[24] Yüksek, Ö., Üçüncü, O., Çözülmüş Problemlerle Temel Hidroloji, Akoluk Basım Yayın Dağıtım, Trabzon, 1999.

[25] Beven, K. J. (2011). Rainfall-runoff modelling: the primer. John Wiley & Sons.

[26] Sivakumar, B., Phoon, K. K., Liong, S. Y., & Liaw, C. Y. (1999). A systematic approach to noise reduction in chaotic hydrological time series. *Journal of Hydrology*, 219(3-4), 103-135.

[27] Kucera, C. L. (1954). Some relationships of evaporation rate to vapor pressure deficit and low wind velocity. *Ecology*, 35(1), 71-75.

[28] Chakraborty, G., & Chakraborty, B. (2000). A novel normalization technique for unsupervised learning in ANN. *IEEE transactions on neural networks*, 11(1), 253-257.

[29] Yüksek, Ö., Babacan, H. T., & Saka, F., (2018). Yağış-akış modellemesinde optimum yapay sinir ağı yapısının araştırılması. *Türk Hidrolik Dergisi*, 2(1), 31-37.