

Araştırma Makalesi - Research Article

Dicle Havzasının Yağış Akış İlişkisinin Belirlenmesinde Farklı Yapay Zeka Yöntemlerinin Değerlendirilmesi

The Evaluation of Different Artificial Intelligence Methods in Determination of Tigris Basin's Rainfall Runoff Relationship

Reşit Gerger^{1*}, Veysel Gümüş², Selmin Dere³

Geliş / Received: 23/02/2021

Revize / Revised: 09/04/2021

Kabul / Accepted: 01/05/2021

ÖZ

Hidrolojik döngünün en önemli bileşeni olan yağış-akış süreci, hidrolojik analiz ve su kaynakları mühendisliğinde önemli bir yer edinmektedir. Son zamanlarda, karmaşık problemlere başarılı sonuçlar getirmesi sebebiyle oldukça revaçta olan yapay zekâ yöntemleri, birçok alanda olduğu gibi hidrolojik olayların modellenmesinde de tercih edilmektedir. Bu çalışmada, Dicle Havzasının sınırları içerisinde bulunan iki istasyona ait aylık ortalama akım değerleri, meteoroloji gözlem istasyonlarından edinilen yağış verileri kullanılarak belirlenmeye çalışılmıştır. Kullanılan istasyonlar için Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System – ANFIS), Yapay Sinir Ağları (YSA), Gen Ekspresyon Programlama (GEP) ve Çoklu Doğrusal Regresyon (ÇDR) yöntemleri ile modeller kurulup yağış-akış ilişkisi değerlendirilmiştir. Kullanılan istasyonların birinde gözlemlenen akış ile tahmin edilen akış arasında, GEP' in diğer yöntemlere kıyasla daha iyi performans sergilediği görülmüştür. Bir diğer istasyonda ise ANFIS' in akışı tahmin etmede oldukça yüksek hassasiyet ile daha başarılı olduğu gözlemlenmiştir. Sonuçlar yağış-akış ilişkisini belirlemek için, yapay zekâ yöntemlerinin uygulanabilirliğini doğrulamakta aynı zamanda matematiksel bir yöntem olan GEP' in de kullanılabilirliğini göstermektedir.

Anahtar Kelimeler- Yağış-Akış Modellemesi, ANFIS, Yapay Sinir Ağları, Gen Ekspresyon Programlama, Çoklu Doğrusal Regresyon

ABSTRACT

Rainfall-runoff process, most important component of the hydrologic cycle, has a significant place in hydrologic analysis and engineering of water resources. Recently, artificial intelligence methods which are in demand due to bringing successful outcomes to complex problems are preferred in modelling of hydrological events as in many fields. In this study, monthly average streamflow values that belongs to two stations which is inside of the boundary of the Tigris basin, is tried to determine by using precipitation data which has been obtained from meteorological observation stations. Rainfall-runoff relationship was evaluated by setting up for used stations with Adaptive Neuro-Fuzzy Inference System (ANFIS), Artificial Neural Network (ANN), Gene Expression Programming (GEP) and Multiple Linear Regression (MLR). It was seen that GEP performed better performance compared to other methods between observed streamflow and estimated streamflow at one of the used stations. At another station, it was observed that ANFIS is rather successful at predict the streamflow with high sensitive. The outcomes

^{1*}Sorumlu yazar iletişim: rgerger@harran.edu.tr (<https://orcid.org/0000-0002-8654-4310>)

Harran Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Şanlıurfa, Türkiye

²İletişim: gumus@harran.edu.tr (<https://orcid.org/0000-0003-2321-9526>)

Harran Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Şanlıurfa, Türkiye

³İletişim: slmndere@gmail.com (<https://orcid.org/0000-0001-9768-2324>)

Harran Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği ABD, Şanlıurfa, Türkiye

not only corroborate the feasibility of the intelligence methods, but also show the usability of GEP that is a mathematical method to determine the rainfall-runoff relationship.

Keywords- *Rainfall-Runoff Modelling, ANFIS, Artificial Neural Network, Gene Expression Programming, Multiple Linear Regression*

I. GİRİŞ

Yağış-akış süreci, hidrolojik döngünün en önemli öğelerinden biridir. Yağışın bir havza üzerinde akışa dönüştüğü sürecin doğrusal olmaması, hem zamansal hem de boyutsal olarak farklılık sergilemesi, fiziksel modellerin bu süreç üzerinde uygulanabilirliğini zorlaştırmaktadır. Doğru bir hidrolojik modellemede yağış-akış ilişkisinin tahmini; su kaynaklarının etkin bir şekilde kullanılması, taşkın kontrol önlemlerinin alınması, baraj haznelerinin olası durumlara karşı davranışlarının ve sürdürülebilir su potansiyelinin belirlenmesi için oldukça önem arz etmektedir.

Hidrolojik analizde önemli bir rol oynayan yağış-akış arasındaki ilişkiyi modellemek ve akış tahminlerini iyileştirmek için birçok model geliştirilmiştir. Geliştirilen bu modeller, genel olarak fiziksel tabanlı ve veriye dayalı teorik modeller olarak iki gruba ayrılabilir [1]. Veriye dayalı modellerin tercih edilmesinin başlıca nedeni, fiziksel tabanlı modellerin aksine veriye dayalı teorik modellerin ilgili fiziksel, boyutsal ve doğrusal olmayan süreçleri sayısal olarak yakalayabilmesidir [2]. Hidrolojik sistemlerin karmaşık doğası ve büyük alanlara uygulamadaki zorluğu, akışı tahmin etmek için araştırmacıları, basitleştirmelere dayalı, nispeten daha hızlı ve esnek yapay zekâ tekniklerinin kullanımına yönlendirmiştir. Su kaynakları ve hidroloji mühendisliği ile ilgili çeşitli problemleri çözmek için, başarılı sonuçlar vermesi sebebiyle yapay zekâ tekniklerinin benimsenmesi, teorik modelleme yaklaşımına yeni bir boyut katmış ve son zamanlarda uygulamada çokça yer edinmiştir. Yapay Sinir Ağları (YSA), Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System – ANFIS), Gen Ekspresyon Programlama (GEP) ve Dalgacık Tabanlı Sinir ağı gibi birçok model ile bu modellerin hibrit ve modifiye tasarımları literatürde yer edinen başlıca modellerdendir. Son yıllarda yapılan bilimsel çalışmalarda, yağış-akış ilişkisini belirlemek ve farklı yapay zekâ tekniklerini değerlendirmek için birçok havzanın yağış, akış, sıcaklık gibi temel parametrelere bağlı olarak değerlendirildiği görülmektedir.

Konuyla ilgili olarak yapılan çalışmalar incelendiğinde, Amerika' nın Pensilvanya eyaletinde bulunan Juniata Nehri havzası için Aytek vd. [3], İleri Besleme Geri Yayılım Sinir Ağı (İBGYSA) ve Genelleştirilmiş Regresyon Sinir Ağı (GRSA) ile GEP metotlarını kullanarak yağış-akış ilişkisini belirlemeye çalışmışlardır. Çalışma sonucunda Gen Programlama formülasyonunun, YSA' dan elde edilen sonuçlara göre daha başarılı sonuç verdiğini ifade etmişler ve YSA' ya alternatif olarak GEP' in kullanılabileceği sonucunu ortaya koymuşlardır. El-shafie vd. [4], Japonya' nın Tanakami bölgesinde bulunan bir havzada, yağış-akış ilişkisini belirleyebilmek için YSA' yı kullanıp Çoklu Doğrusal Regresyon (ÇDR) ile karşılaştırmışlardır. Tahmindeki başarıyı görmek için, temel istatistik olarak korelasyon katsayısı (R), ortalama karesel hata (OKH) ve belirlilik katsayısı (R^2) parametrelerini kullanmışlardır. Buldukları sonuçlar, yağış-akış ilişkisini belirlemede YSA' nın klasik bir yöntem olan ÇDR' ye göre daha başarılı tahminler yaptığı üzerinedir. Kişi vd. [5], Türkiye' deki küçük bir havza için yağış-akış ilişkisini, 4 yıllık veriler ile ANFIS, YSA ve GEP yöntemlerini kullanarak modellemeye çalışmışlardır. Bu modelleri klasik ÇDR yöntemi ile karşılaştırmışlar ve sonuç olarak GEP yönteminin yağış-akış sürecini modellemede başarılı olduğunu, buna ek olarak, diğer uygulamalı yapay zekâ modellerine alternatif olarak değerlendirilebileceğini ifade etmişlerdir. Gümüş vd. [6], Orta Fırat Havzasında bulunan bir istasyona ait akım değerlerini, YSA metotlarından İleri Beslemeli Geri Yayılımlı Sinir Ağı (İBGYSA), Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA) ve Radyal Tabanlı Yapay Sinir Ağı (RTYSA) ile tahmin edip ÇDR yöntemi ile karşılaştırmışlardır. Çalışma sonucunda, tüm YSA yöntemlerinin ÇDR yöntemine göre daha iyi sonuç verdiğini ve RTYSA yöntemiyle tahmin edilen akım değerlerinin, diğer YSA yöntemlerine göre daha başarılı olduğunu belirlemişlerdir. Malezya' da bulunan Klang Nehri havzasında yağış-akış ilişkisini, Akrami vd. [7], ANFIS ve modifiye edilmiş ANFIS (MANFIS) ile tahmin etmeye çalışmışlardır. Sonuçlar MANFIS' in geleneksel ANFIS modeline kıyasla daha düşük hata, daha düşük hesap karmaşıklığı ve daha yüksek yağış tahmini sağladığını göstermiştir. Nourani [8], çalışmasında Moselle havzasına ait günlük yağış-akış ilişkisini, geri yayılım algoritmasının modifiye edilmiş bir versiyonu olan ve daha küçük eğitim veri seti tarafından eğitilen duygusal yapay sinir ağı (DYSA) ile belirlemeye çalışmıştır. DYSA modelinin, geleneksel ileri beslemeli yapay sinir ağı modeline göre daha iyi sonuç verdiğini belirtmiştir. Yaseen vd. [9], Malezya' da bulunan Pahang Nehri için aylık akışı, ANFIS' in yeni bir kombinasyonu olan hibrit bir yapı ANFIS-FFA model ile belirlemişlerdir. Geleneksel ANFIS ile kıyaslandığında, aylık akış tahmini için uygulanabileceğini ve FFA' nın hibrit ANFIS-FFA modelin

tahmin doğruluğunu geliştirebildiğini ortaya koymuşlardır. Ayrıca ANFIS-FFA'nın, klasik ANFIS'e nispeten üstünlüğünün yanı sıra daha iyi bir performans sağlamak için, gereken daha az sayıda girdi değişkenini dahil ederek cimri bir modelleme çerçevesi sergilediğini ifade etmişlerdir. Yüksek vd. [10], yağış ve akış ilişkisini modelleyebilmek için, Giresun iline ait Aksu deresi üzerinde akım ve gözlem istasyonlarından yararlanılmışlar ve üç farklı algoritma ile Levenberg-Marquardt (LM), Quasi-Newton (QN) ve Conjugate-Gradient (CG) farklı nöron sayıları deneyerek yapay sinir ağı (YSA) kullanmışlardır. Sonuç olarak, tüm YSA yapılarının iyi sonuçlar verdiğini ancak en iyi yapının Quasi-Newton (QN) olduğunu ifade etmişlerdir. Muskegon Nehri havzasında yağış-akış ilişkisini Taşar vd. [11], günlük yağış, sıcaklık ve akış verilerini kullanarak Nöro Bulanık (Neuro-Fuzzy, NF) ve Destek Vektör Makineleri (Support Vector Machines, SVM) yöntemleri ile tahmin etmişlerdir. Sonuçların yağış-akış ilişkisinin tahmininde, düşük hata ile yüksek belirlilik katsayısı (R^2) verdiğini, bu nedenle klasik yöntemlere alternatif olarak kullanılabilirliğini ifade etmişlerdir. Calp [12], İsviçre Basel'e ait 10 yıllık meteorolojik verilerinden yararlanarak YSA ve hibrit ANFIS-GA modelleri ile bölgesel yağış miktarını tahmin etmeye çalışmıştır. Elde ettiği sonuçların tahmin başarısını yüksek bulması nedeniyle meteorolojik olayların tahmininde kolayca kullanılabilirliğini ifade etmiştir. Keskin [13], ABD Waltham Massachusetts'te bulunan Stony Brook Havzası'nda, yağış-akış ilişkisini ÇDR, İBGYSA ve Otogresif Hareketli Ortalamalar (ARMA) ile belirlemeye çalışmıştır. Elde ettiği sonuçlara göre YSA yönteminin, akışı tahmin etmede diğerlerine kıyasla daha uyumlu olduğunu ifade etmiştir. Literatürde görüldüğü üzere, yapay zekâ yöntemleri ile yağış-akış sürecinin modellenmesi ile ilgili birçok çalışma bulunmaktadır. Özellikle YSA ve ANFIS modellerinin literatürde sıklıkla kullanıldıkları, ancak GEP yönteminin yağış-akış ilişkisini belirlemede kullanımının ise sınırlı olduğu görülmektedir. Bu çalışmada, Türkiye'nin Güneydoğusunda bulunan Dicle Havzasının sahip olduğu nehirler ve üzerinde bulunan önemli barajlar dikkate alınarak, bu havzanın sürdürülebilir su potansiyelini korumak adına, yağış-akış ilişkisi belirlenmiştir. Bu amaçla, belirli yıllar arasında meteoroloji gözlem istasyonlarına ait aylık toplam yağış verileri ve akım gözlem istasyonlarından (AGİ) ölçülen aylık ortalama akım verileri kullanılarak, literatürde sıklıkla kullanılan yapay zekâ yöntemleri ile bu ilişki belirlenmeye çalışılmıştır. Bu amaçla, literatürde sıklıkla kullanılan YSA ve ANFIS yöntemlerinin yanında ilişkiyi matematiksel ifadeler ile veren GEP yöntemi ve klasik bir yöntem olan ÇDR yöntemlerinin, yağış-akış ilişkisi belirlemedeki başarıları belirlenmiştir.

II. ÇALIŞMA ALANI

Türkiye'nin Güneydoğusunda yer alan ve farklı kaynaklardan beslenen Dicle Havzası, toplamda yıllık ortalama 50 milyar m^3 su potansiyeline sahiptir. Dicle Havzasında, Türkiye'den kaynaklanan toplam su potansiyeli 21,3 milyar m^3 /yıl olarak verilmektedir [14]. Bu havzada, önemli nehirler ve barajlar bulunmaktadır.

Havzanın bulunduğu konum, nehirler ve düşen yağış gibi parametreler dikkate alındığında, bölgede yağış ve akış arasındaki ilişkinin belirlenmesi, havza yönetimi açısından önemli bir durum olarak karşımıza çıkmaktadır. Bu nedenle, çalışma kapsamında Dicle Havzasında bulunan E26A005 ve E26A031 numaralı AGİ'lere ait aylık akım değerleri, 17280-17285 numaralı meteoroloji gözlem istasyonlarına (MGİ) ait aylık toplam yağış verileri yardımıyla tahmin edilmiştir. Havzada bulunan tüm istasyonlar, kullanılan istasyonlar ve havza detayları Şekil 1'de verilmiştir.

Mevcut çalışma kapsamında, E26A005 numaralı istasyona ait akımı tahmin etmek için 42 yıllık (1956-1997) aylık toplam yağış verileri; E26A031 numaralı istasyon için ise 29 yıllık (1988-2016) aylık toplam yağış verileri kullanılarak çalışma yapılmıştır. Ele alınan MGİ ve AGİ'lere ait bilgiler Tablo 1 ve 2'de verilmiştir.

Tablo 1. Akım gözlem istasyonlarına ait özellikler


Agi No	Adı	Koordinat		Veri Aralığı	Yağış Alanı (km^2)	Min Akım (m^3/sn)	Maks Akım (m^3/sn)	Ort Akım (m^3/sn)
		Kuzey	Doğu					
E26A005	Dicle Nehri Diyarbakır	40.229722	37.88	1956-1997	5655.2	0	210.3	41.1405
E26A031	Çatak Çayı Tüliran	43.054444	37.998333	1988-2016	2455	0	690.6	69.6677

B. Yapay Sinir Ağları

Doğrusal ve doğrusal olmayan problemlerin matematiksel veya istatistiksel olarak çözümüne ihtiyaç duyulduğu birçok alanda sinir ağları kullanılır. YSA yapısal ve hesaplamalı olarak insan beyninin biyolojik sinir ağlarına benzeyen paralel bilgi işleme sistemidir [16].

YSA, nöron (düğüm) adı verilen birçok birimden oluşur. Temel yapısını nöronların yanı sıra, ağırlık vektörleri ve aktivasyon (transfer) fonksiyonları oluşturur [17]. Ağ yapısı; girdi katmanı, ara katman ve çıktı katmanından oluşur. Ara katman birden çok katmandan oluşabilir. Her bir katmandaki nöron bir üst katmandaki nörona çeşitli ağırlıklar ile bağlıdır. Her bir veri, girdi katmanında ağırlık değeri ile çarpıldıktan sonra gizli katmana gönderilir [18]. Burada ağın yapısına uygun olduğu düşünülen aktivasyon fonksiyonu kullanılır.

Bu çalışma kapsamında her modelde 100 iterasyon ile en iyileme yapılmış, en düşük hata oranını veren ara katman sayısı ise deneme yanılma yoluyla belirlenmiştir. Ayrıca transfer fonksiyonu olarak da tanjant-sigmoid (tansig) kullanılmıştır. Yapay sinir ağı eğitilirken literatürde sıklıkla tercih edilen [10, 19] Levenberg-Marquardt algoritması tercih edilmiştir.



Şekil 2. Üç girdi iki gizli katmana sahip YSA yapısı

C. Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System –ANFIS)

Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi, sinir ağı ve bulanık çıkarım sisteminin bir kombinasyonu olup, bilgiyi yorumlanabilir şekilde temsil etmek için her iki tekniğin avantajlarından faydalanılarak geliştirilmiştir [20]. Sistemin performansını artırmak için doğrudan verilerden ve üyelik fonksiyonu parametrelerinden yararlanarak öğrenme becerisini yakalar [21]. ANFIS mimarisi, beş katmanlı bir ileri beslemeli sinir ağı yapısından ve Sugeno' nun eğer-ise kuralını öne sürdüğü bulanık çıkarım yaklaşımından oluşur [22]. Bu katmanlar aşağıda kısaca verilmektedir.

Katman 1: Bu katman, girdi katmanıdır. Bu katmandaki her girdi seti için üyelik derecesi tanımlanır dolayısıyla birinci katman ($\mu_{A_i}(x)$) olarak verilen üyelik fonksiyonlarına bağlıdır.

$$O_{1,i} = \mu_{A_i}(x) = \frac{1}{1 + [(x - c_i / a_i)^2]^{b_i}} \quad (2)$$

burada $O_{1,i}$ uyarlanabilir bir düğümdür, a_i , b_i ise denkleme ait parametreler olup öncül setlerini ifade etmektedir c_i ise eğrinin merkezini belirtir.

Katman 2: Bu katmandaki her düğüm, gelen sinyalleri çoğaltan ve ürünü denkleme 3' e gönderen bir kare düğümdür.

$$O_{2,i} = w_i = \mu_{A_i}(x) = \mu_{B_i}(y) \quad (3)$$

burada $\mu_{A_i}(x)$ ve $\mu_{B_i}(y)$ üyelik derecelerini ifade etmektedir.

Katman 3: Bu tabakadaki her bir düğüm bir kare düğümdür. i-inci düğümün çıktısının, i-inci kuralın ateşleme gücünün tüm kuralların ateşleme güçlerinin toplamına oranının eşit olduğu, \bar{w} ile ifade edilen katmandır. Bu katmanın çıktısı normalize edilmiş ateşleme kuvvetleri olarak adlandırılabilir.

$$o_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2 + w_3} \quad (4)$$

Katman 4: i-inci düğümün çıktısıdır.

$$o_{4,i} = \bar{w}_i = \bar{w}_i(p_i + q_i + r_i) \quad (5)$$

burada p_i , q_i ve r_i ardışık parametrelerdir.

Katman 5: Bu katmandaki tek düğüm, gelen tüm sinyallerin toplamı olarak çıktığı hesaplar.

$$o_{5,i} = \sum_i \bar{w}_i f_i \quad (6)$$

Bu çalışma kapsamında sugeno tipi ağ sistemi kullanılmış olup, üyelik fonksiyonu olarak da gaussian fonksiyonu kullanılmıştır.


D. Gen Ekspresyon Programlama (GEP)

Genetik bireylerin nüfusunu kullanarak onları uygunluğuna göre seçen, bir veya daha fazla genetik operatör yardımıyla genetik varyasyonu sunan genetik programlama ve genetik algoritmaya benzer bir yöntemdir [23]. Genetik algoritmada bireyler, sabit uzunlukta doğrusal diziler iken, genetik programlamada bireyler, farklı boyut ve şekillerde olup doğrusal olmayan varlıklardır. Genetik programlama ilk olarak, rastgele oluşturulmuş bir bireysel programla başlar, daha sonra programlar, daha iyi uygunluk değerleri elde edilene kadar geliştirilir [24] GEP' te ise bireyler, farklı boyut ve şekillerde (ifade ağaçları ya da basit diyagram gösterimleri) doğrusal olmayan varlıklar olarak ifade edildikten sonra sabit uzunlukta doğrusal diziler (genom veya kromozomlar) olarak kodlanır [25].

Bir veya daha fazla genden oluşan genom veya kromozomlar sabit uzunlukta, lineer ve sembolik dizilerdir. GEP kromozomları sabit uzunluklarına rağmen ifade ağaçları ile kodlanabilir Denklem 7'de verilen basit bir matematiksel ifade:

$$Q = \sqrt{(k+l) \times (m-n)} \quad (7)$$

ifade ağacında Şekil 3'teki gibi verilmektedir.



Şekil 3. İfade ağacı

GEP gibi bir sistemin avantajı açık formül yapısına sahip olmasıdır. Bu özelliği ile GEP, birçok bilimsel çalışmada uygulanmak üzere yer edinmiştir. Bu çalışma kapsamında GeneXpro tools programı ile yağış-akış süreci modellenmiştir.

E. Performans Değerlendirme Kriterleri

Çalışma kapsamında en uygun tahmini yapan modelin performansını belirlemek amacıyla determinasyon katsayısı (R^2), ortalama karesel hata (OKH), ortalama mutlak göreceli hata (OMGH) ve Nash-Sutcliffe efficiency (NSE) hata kriteri parametreleri kullanılmıştır. Bu parametrelere ait denklemler; 8, 9, 10 ve 11 numaralı

denklemlerde verilmektedir. Denklemlerde kullanılan Q_g , gözlenen aylık akımı, Q_t tahmin edilen aylık akımı ve \bar{Q}_g ise gözlenen aylık akımların ortalamasını ifade etmektedir.

R^2 değerinin 1'e yakın olması, OKH ve OMGH değerlerinin ise 0'a yakın değerler alması modelin tahmin başarısının yüksek olduğunu ifade etmektedir. Bunun yanında NSE ise -∞ ile 1 arasında değerler almaktadır. NSE değerinin 1 olması yöntemin yüksek derecede başarılı olduğunu ifade eder. NSE'nin 0 ile 1 arasında değerler alması ise yöntemin kabul edilebilir olduğu anlamına gelir. NSE değerinin 0'dan küçük değerler alması durumunda ise yöntemin, gözlenen akım değerini tahmin etmede yetersiz kaldığı sonucuna varılır.

$$R^2 = \frac{\sum_{i=1}^n (Q_g - \bar{Q}_g)(Q_t - \bar{Q}_t)}{\sqrt{\sum_{i=1}^n (Q_g - \bar{Q}_g)^2 (Q_t - \bar{Q}_t)^2}} \quad (8)$$

$$OKH = \frac{1}{n} \sum_{i=1}^n (Q_g - Q_t)^2 \quad (9)$$

$$OMGH = \frac{1}{n} \sum_{i=1}^n \left(\frac{Q_g - Q_t}{Q_g} \right) \quad (10)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_g - Q_t)^2}{\sum_{i=1}^n (Q_g - \bar{Q}_g)^2} \quad (11)$$

IV. BULGULAR VE TARTIŞMA

E26A031 numaralı AGİ'ye ait aylık akımı tahmin etmek için Dicle Havzası içindeki MGİ'ler ve havzanın dışında olup, yakın mesafede bulunan MGİ'ler kullanılarak oluşturulan Thiessen çokgenleri ile alansal ilişki içerisinde olduğu belirlenen, 17285 numaralı MGİ kullanılmıştır. Akımı tahmin ederken AGİ ve MGİ'deki ortak yıllar değerlendirilmiştir. E26A031-17285 ilişkisi için, 1988-2016; E26A005 ve 17280 için ise 1956-1997 yıllarını kapsayan aylık ortalama veriler dikkate alınarak, beş farklı model kurulmuş olup ÇDR, YSA, ANFIS ve GEP ile akım tahminleri yapılmıştır.

Tablo 3'te verilen durumlarda; Q, tahmin edilecek akım değerini, P, aylık toplam yağış verisini, Q-1, bir önceki ayın akım verisini, P-1, bir önceki ayın aylık toplam yağış verisini, P-2, iki ay önceki aylık toplam yağış verisini, P-3, ise üç ay önceki aylık yağış verisini temsil etmektedir.

Tablo 3. Akım tahmini için oluşturulan modeller

Model	Girdi	Çıktı
D1	(P)	Q
D2	(P), (Q-1),	Q
D3	(P), (P-1), (Q-1)	Q
D4	(P), (P-1), (P-2), (Q-1)	Q
D5	(P), (P-1), (P-2), (P-3) (Q-1)	Q

Tahmin çalışmalarında ağ yapısının doğru modelleme yapıp yapmadığını tespit etmek için veri seti, eğitim ve test verisi olarak ikiye bölünmektedir. Literatürde eğitim için veri setinin %50-%80'inin eğitim olarak, geri kalan kısmın ise test verisi olarak kullanılması önerilmektedir [26]. Bu çalışma kapsamında veri setinin %70'i eğitim, %30'u ise test için kullanılmıştır.

A. E26A031-17285 İlişkisi

E26A031 numaralı akım gözlem istasyonuna ait aylık akım değerlerinin, 17285 numaralı istasyona ait aylık yağış verileri kullanılarak, Tablo3'te verilmiş olan beş farklı girdi kombinasyonu ile ÇDR, YSA, ANFIS ve GEP yöntemi ile tahmin sonuçları Tablo 4'te verilmiştir. Çalışma kapsamında tüm modellerde eğitim aşamasında verilerin %70'i (200 veri), test aşamasında ise veri setlerinin %30' u (85 veri) kullanılmıştır. YSA modelinde transfer fonksiyonu "tansig" olarak kullanılmış ve deneme yanılma yöntemi ile elde edilmiş olan ara katman sayıları Tablo 4 ve 5'te model yanında parantez içerisinde verilmiştir. ANFIS yönteminde kullanılan üyelik fonksiyon sayısı da yine model adı yanında köşeli parantez içerisinde yazılmıştır. ANFIS yönteminde gaussian üyelik fonksiyonları kullanılmıştır.

Tüm durumlar dikkate alınarak sonuçlar incelendiğinde, D1 modeline ait determinasyon katsayısının (R^2) çok düşük olduğu ve bu yüzden akımı tahmin etmek kullanılmasının uygun olmadığı değerlendirilmektedir. Kullanılan diğer yöntemlerle kıyaslandığında en düşük OMGH değerini vermesi ile GEP yönteminin tüm durumlarda, akımı tahmin etmede diğer yöntemlere göre daha iyi performans sergilediği görülmektedir. Akımı tahmin etmede en başarılı model, en düşük OMGH değerine sahip, aylık toplam yağış verisine (P) ek olarak bir ay önceki akım verileri (Q-1) ve bir ay önceki aylık toplam yağış verileri (P-1) kullanılarak oluşturulan GEP yöntemine ait D3 modeli olarak belirlenmiştir. ANFIS yöntemi ile oluşturulan D4 modelinde, determinasyon katsayısının GEP yöntemi ile oluşturulan D3 modeline göre daha yüksek olduğu görülmüştür, ancak OMGH değerinin yine bu modele göre daha yüksek olması, modelin gerçek değerlere erişmede yetersiz olduğunu göstermektedir. R^2 , OKH ve OMGH değerlerinin yanı sıra 0 ile 1 arasında değerler alan NSE değeri de incelendiğinde, bu değer 0.705 oluşu modelin performansının akımı tahmin etmede kabul edilebilir olduğunu göstermektedir. GEP'in ardından diğer tüm modellerde en düşük OMGH değerini veren ÇDR yöntemi, YSA ve ANFIS'e göre daha başarılı olmuştur. Kullanılan yöntemler arasında nispeten başarısız olan yöntem ise daha yüksek OMGH değerine sahip olduğu görülen ANFIS'tir. Tüm durumlarda OKH, OMGH değerlerinin nispeten yüksek oluşu tahmin edilen akım değerlerinin büyük değerlere sahip olması olarak değerlendirilmiştir.

En iyi sonucu veren GEP D3 modeline ait akışı tahmin etmek için elde edilen ifade, Denklem 12 ile verilmektedir.

$$Q = \sqrt[9]{-10.47 \left((d_{p-1})^2 (d_p - d_{q-1})^2 \right)} + \sqrt[9]{(-10.48) \left(-10.48 - (d_p (-10.48)) \right)^2} + \sqrt[3]{(d_{q-1} (d_{p-1} + 10.03)) (d_{q-1} - (d_p - 1.18))} \quad (12)$$

ÇDR'de akımı tahmin etmek için GEP'ten sonra en düşük OMGH değerine sahip olması ile başarılı model olan D3 modeline ait ifade, Denklem 13 ile verilmektedir.

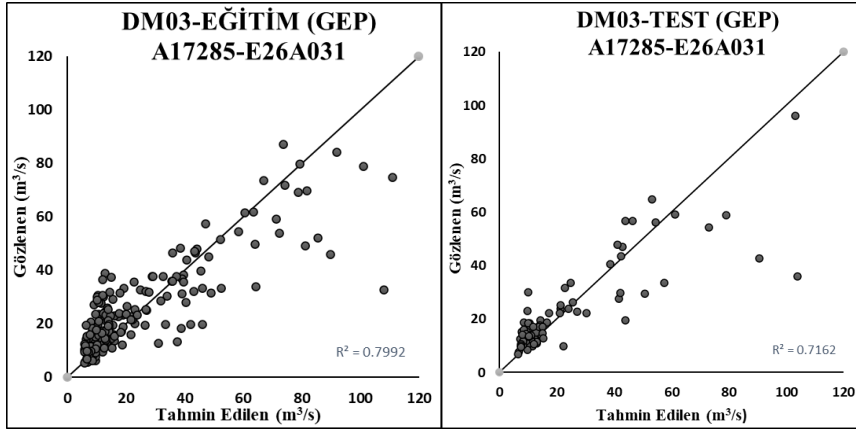
$$y = 0.332P + 0.704(Q-1) + 0.107(P-1) \quad (13)$$

D3 modeline ait gözlenen ve tahmin edilen akım verilerinin saçılım grafiği (Şekil 4) ile zamansal dağılım grafiğinde (Şekil 5), tahminin hangi değer aralığında yakınsadığı ve uzaklaştığı görülmektedir. E26A031-17285 için verilen saçılım grafiğinden, hem eğitim hem de test aşamasında gözlenen akım ile tahmin edilen akım arasındaki ilişkinin, daha düşük değerlerdeki akım verilerini tahmin ederken daha başarılı olduğu sonucuna ulaşılmaktadır.


GEP ile en başarılı sonucu veren D3 modeline ait zamansal dağılım grafiği (Şekil 5), eğitim aşamasında tahmin edilen akıma ait değerlerin, ortalama 5 m³/s ile 160 m³/s arasında değiştiğini ifade etmektedir. Test aşamasında ise değerler, 5 m³/s ile 100 m³/s arasında değişmektedir. GEP, pik debilerde ve düşük değerlerdeki verilerde tahminden uzaklaşsa da genel olarak modelin tahmin başarısını yakalamada iyi sonuç vermiştir.

Tablo 4. 17285-E26A031 için tüm durumlara ait eğitim ve test sonuçları

		ANFIS				YSA			
		R ²	OKH	OMGH	NSE	R ²	OKH	OMGH	NSE
D1 [1] (2)	EĞİTİM	0.0088	771.00	121.49	0.009	0.0034	827.75	121.49	-0.064
	TEST	0.0055	504.14	131.43	-0.044	0.0009	613.75	22.09	-0.271
D2 [7] (3)	EĞİTİM	0.7706	178.48	39.26	0.771	0.7556	305.14	15.29	0.608
	TEST	0.5881	200.72	35.05	0.584	0.5817	320.50	15.82	0.336
D3 [4] (2)	EĞİTİM	0.7892	163.93	45.82	0.789	0.8058	282.97	14.79	0.636
	TEST	0.7081	151.36	40.64	0.687	0.6392	280.86	14.74	0.419
D4 [6] (2)	EĞİTİM	0.7951	159.37	41.40	0.795	0.7128	338.86	15.56	0.564
	TEST	0.7546	119.44	29.60	0.753	0.6800	268.99	14.02	0.443
D5 [2] (3)	EĞİTİM	0.7902	163.21	39.51	0.790	0.8122	269.76	14.43	0.653
	TEST	0.6761	168.92	30.24	0.650	0.6569	269.56	14.29	0.442
		GEP				ÇDR			
		R ²	OKH	OMGH	NSE	R ²	OKH	OMGH	NSE
D1	EĞİTİM	0.1285	680.14	19.25	0.126	0.0001	1121.29	22.64	-0.442
	TEST	0.0002	553.77	18.26	-0.146	8E-07	733.00	18.28	-0.517
D2	EĞİTİM	0.7377	204.12	8.76	0.738	0.5899	321.48	11.78	0.587
	TEST	0.5555	217.38	8.35	0.550	0.4253	280.31	10.79	0.420
D3	EĞİTİM	0.7992	171.14	8.11	0.780	0.6404	285.51	11.23	0.663
	TEST	0.7162	142.52	6.80	0.705	0.5504	218.98	9.94	0.547
D4	EĞİTİM	0.7712	180.39	8.75	0.768	0.6441	282.83	11.17	0.636
	TEST	0.5940	199.34	8.96	0.587	0.5483	220.02	9.98	0.545
D5	EĞİTİM	0.7873	166.50	8.71	0.786	0.6441	282.83	11.17	0.636
	TEST	0.6219	201.02	9.06	0.584	0.5483	220.02	9.98	0.545



Şekil 4. 17285-E26A031 için D3 modeline ait saçılım grafiği (GEP)



Şekil 5. 17285-E26A031 için D3 modeline ait zamansal dağılım grafiği (GEP)

B. E26A005-17280 İlişkisi

E26A005 numaralı AGİ' ye ait akım değerlerinin tahminin 17280 numaralı MGİ kullanılmıştır. Çalışma kapsamında bir önceki bölümdeki modellere benzer olarak eğitim aşamasında veri setinin %70'i (351 veri), test aşamasında ise veri setinin %30' u (150 veri) kullanılmıştır.

Tablo 5'te verilen sonuçlara göre, en iyi tahmini yapan yöntemin en düşük OMGH değerine sahip olan D5 ile GEP' e ait olduğu görülmektedir. GEP, D5 modelinde gözlemlenen akım ile tahmin edilen akım arasında 0.66 R² değeri elde etmiştir. D5 modeli, aylık yağış verisine (P) ek olarak bir ay önceki yağış verisi (P-1), iki ay önceki yağış verisi (P-2) ve üç ay önceki yağış verisi (P-3) ile bir ay önceki aylık akım verileri (Q-1) kullanılarak oluşturulan modeldir. GEP D5 modeline ait NSE değerleri test aşamasında 0.648 olarak belirlenmiştir. Bu değer 0 ile 1 arasında değerler alabileceği dikkate alınarak incelendiğinde modelin, akımı tahmin etmedeki başarısının kabul edilebilir olduğu görülmektedir.

En iyi sonucu veren GEP D5 modeline ait akışı tahmin etmek için elde edilen ifade Denklem 14 ile verilmektedir.

$$Q = \left(\sqrt{d_{Q-1}} + \sqrt[3]{(d_{P-3})((d_{Q-1} - d_P) + (d_{P-2}))} \right) + \sqrt[3]{\frac{(d_{P-3}) - 2.01}{(-2.39)^2 (d_{P-1})} + ((d_{P-1}) - (d_{P-3}))} + \sqrt[3]{\frac{(d_{Q-1}) + (d_{P-3})}{6.89^2} (d_P^3 + 7.12)} \quad (14)$$

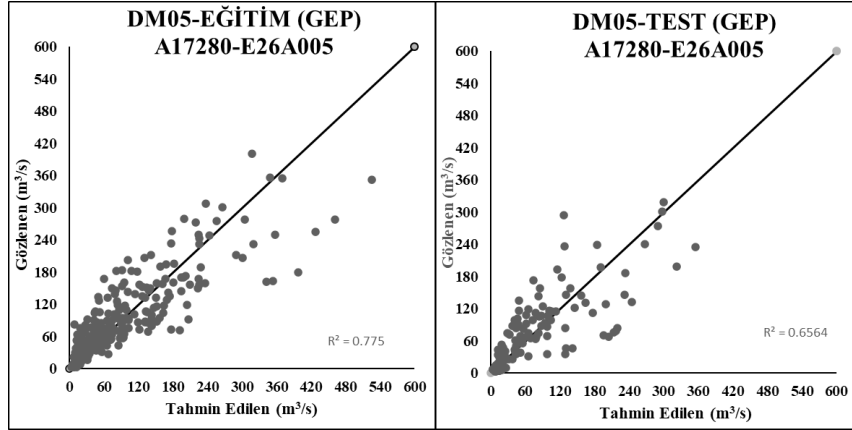
ÇDR' de akımı tahmin etmek için en düşük OMGH değerine sahip olması ile başarılı model olan D3 modeline ait ifade, Denklem 15 ile verilmektedir.

$$y = 1.141P + 0.379(Q - 1) + 0.045(P - 1) \quad (15)$$


Tablo 5. 17280-E26A005 için tüm durumlara ait eğitim ve test sonuçları

		ANFIS				YSA			
		R ²	OKH	OMGH	NSE	R ²	OKH	OMGH	NSE
D1 [8] (2)	EĞİTİM	0.5542	3318.30	101.74	0.554	0.4684	5169.57	61.04	0.306
	TEST	0.3637	4227.20	93.75	0.277	0.3405	5043.66	62.27	0.137
D2 [4] (3)	EĞİTİM	0.745	1898.50	55.76	0.745	0.7481	3542.67	52.47	0.524
	TEST	0.6736	1949.70	55.54	0.666	0.6441	3533.67	54.53	0.395
D3 [4] (3)	EĞİTİM	0.7509	1854.50	59.04	0.751	0.7471	3556.29	52.21	0.522
	TEST	0.6897	1873.10	59.24	0.679	0.685	3270.90	52.47	0.440
D4 [10] (3)	EĞİTİM	0.7627	1766.20	51.55	0.763	0.7347	3492.23	51.77	0.531
	TEST	0.6632	2096.50	52.69	0.641	0.6424	3397.82	53.17	0.419
D5 [2] (3)	EĞİTİM	0.7790	1645.40	49.30	0.779	0.774	3419.08	51.63	0.541
	TEST	0.6758	1977.00	50.51	0.662	0.6666	3414.75	53.89	0.416
		GEP				ÇDR			
		R ²	OKH	OMGH	NSE	R ²	OKH	OMGH	NSE
D1	EĞİTİM	0.5532	3325.73	38.04	0.553	0.5299	3571.31	40.82	0.520
	TEST	0.356	4325.62	43.16	0.260	0.3658	4352.48	45.45	0.255
D2	EĞİTİM	0.7567	1817.63	24.85	0.756	0.6914	2327.76	29.21	0.687
	TEST	0.6811	1958.47	27.84	0.665	0.6044	2364.78	32.26	0.595
D3	EĞİTİM	0.7722	1725.13	26.82	0.768	0.6919	2326.13	29.25	0.688
	TEST	0.6811	1958.47	27.84	0.665	0.6081	2337.16	32.07	0.660
D4	EĞİTİM	0.7506	1857.23	24.75	0.751	0.6996	2293.17	29.66	0.692
	TEST	0.6713	2034.71	29.92	0.661	0.6072	2350.23	32.94	0.598
D5	EĞİTİM	0.775	1676.73	24.10	0.775	0.7104	2257.30	30.02	0.697
	TEST	0.6564	1982.58	27.47	0.648	0.6121	2328.11	33.55	0.602

GEP'e ait D5 modeli için saçılım grafiği incelendiğinde, gözlenen ile tahmin edilen değerler çoğu yerde yakınsamıştır, fakat değerlerin daha yüksek olduğu durumlarda, GEP performansında düşüş görülmektedir. D5 için akımı tahmin etmede, saçılım grafiği (Şekil 6) ve zamansal dağılım grafiğinden (Şekil 7) test aşamasında eğitim aşamasında daha başarılı olduğu sonucuna ulaşılmaktadır.



Şekil 6. 17280-E26A005 için D5 modeline ait saçılım grafiği (GEP)



Şekil 7. 17280-E26A005 için D5 modeline ait zamansal dağılım grafiği (GEP)

V. SONUÇLAR

Türkiye'nin en önemli havzalarından biri olan Dicle Havzasında bulunan iki istasyona ait, yağış-akış ilişkisini belirlemek için ÇDR, YSA, ANFIS ve GEP yöntemleri kullanılmış, R^2 , OKH, OMGH ve NSE parametrelerine göre model performansları değerlendirilmiştir. Ele alınan yöntemlerin akım tahminleri birbirine yakın sonuçlar vermiştir. Çalışma kapsamında iki ayrı istasyon için uygulanan beş ayrı durumda; E26A031 istasyonunda akımı tahmin eden en başarılı model, aylık yağış verileri (P), bir ay önceki aylık yağış verileri (P-1) ve bir ay önceki akım verileri (Q-1) kullanılarak oluşturulan D3 durumuna ait GEP modelidir. Bulanık mantık ve sinir ağı kombinesi olarak daha iyi sonuç vereceği düşünülen ANFIS, daha düşük OMGH değerleri vermesi ve daha yüksek determinasyon katsayısı ile YSA'ya göre daha başarılı olmuştur. Bir yağış-akış modellemesinde ANFIS'in YSA'ya göre daha iyi performans göstermesi, literatürdeki çalışmalar ile de uyumludur. Ancak ANFIS, GEP ile kıyaslandığında R^2 , OKH ve OMGH parametreleri dikkate alınarak incelendiğinde daha başarısız olmuştur. Bir diğer çalışılan istasyon (E26A005) üç ay önceki toplam yağış verileri kullanılarak oluşturulan D5 durumuna aittir. Diğer yöntemlere göre daha düşük OKH ve OMGH değerleri vermesi sebebiyle başarılı performans gösteren model, GEP olmuştur. Her iki istasyon için de GEP' in ardından daha düşük OMGH ve OKH değerleri ile başarılı performans gösteren yöntem ÇDR olmuştur. Çalışma kapsamında elde edilen sonuçlar, bir kara kutu modelin aksine basit matematiksel ifadeler ile sonuçlar veren GEP'in, yapay zekâ modellerine alternatif olarak hidrolojik çalışmalarda kullanılabilen değeri değerlendirilmektedir.

KAYNAKLAR

- [1] He, Z., Wen, X., Liu, H. & Du, J. (2014). A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology*, 509, 379-386.

- [2] Kasiviswanathan, K., He, J., Sudheer, K. & Tay, J. (2016). Potential application of wavelet neural network ensemble to forecast stream flow for flood management. *Journal of Hydrology*, 536, 161-173.
- [3] Aytek, A., Asce, M. & Alp M. (2008). An application of artificial intelligence for rainfall-runoff modelling. *Journal of Earth System Science*, 117(2), 145-155.
- [4] El-shafie, A., Mukhlisin, M., Najah, A. & Taha, M. (2011). Performance of artificial neural network and regression techniques for rainfall-runoff prediction. *International Journal of the Physical Sciences*, 6(8), 1997-2003.
- [5] Kisi, O., Shiri, J. & Tombul, M. (2013). Modeling rainfall-runoff process using soft computing techniques. *Computers & Geosciences*, 51, 108-117.
- [6] Gümüş, V., Soydan, N., Simsek, O., Aköz, M. & Kırkgöz, M. (2016). Yağış-Akış İlişkisinin Belirlenmesinde Farklı Yapay Sinir Ağı Yöntemlerinin Karşılaştırılması. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 28(1), 37-50.
- [7] Akrami, S., El-Shafie, A. & Jaafar, O. (2013). Improving Rainfall Forecasting Efficiency Using Modified Adaptive Neuro-Fuzzy Inference System (MANFIS). *Water Resources Management*, 27(9), 3507-3523.
- [8] Nourani, V. (2017). An Emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology*, 544, 267-277.
- [9] Yaseen, Z.M., Ebtehaj, I., Bonakdari, H., Deo, R.C., Danandeh Mehr, A., Mohtar, W.H.M.W., Diop, L., El-Shafie, A., Singh, V.P. (2017). Novel approach for streamflow forecasting using a hybrid ANFIS-FFA model. *Journal of Hydrology*, 554, 263-276.
- [10] Yüksek, Ö., Babacan, H. & Saka, F. (2018). Yağış-Akış Modellemesinde Optimum Yapay Sinir Ağı Yapısının Araştırılması, *Türk Hidrolik Dergisi*, 2(1), 31-37.
- [11] Taşar, B., Unes, F. & Varcin, H. (2019) Prediction of the Rainfall – Runoff Relationship Using Neuro Fuzzy and Support Vector Machines. Air and Water – Components of the Environment Conference Proceedings, Cluj-Napoca, Romania, 237-246.
- [12] Calp, M. (2019). A Hybrid ANFIS-GA Approach for Estimation of Regional Rainfall Amount. *Gazi University Journal of Science*, 32(1), 145-162.
- [13] Keskin, L. (2020). Yağış – akış ilişkisinin yapay sinir ağları ve otoregresif hareketli ortalamalar modelleri ile tahmini. Yüksek Lisans Tezi. İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü, Hatay.
- [14] Özdemir, Y., Özış, Ü., Baran, T., Demirci, N., Fıstıkoğlu, O. & Çanga, R. (2002). Fırat-Dicle Havzasının Türkiye, Suriye, Irak, İran'daki Su Potansiyeli. *Türkiye Mühendislik Haberleri Dergisi*, 420, 27-34.
- [15] Özbayoğlu, G., Özbayoğlu, A. & Özbayoğlu, M. (2008). Estimation of Hardgrove grindability index of Turkish coals by neural networks. *International Journal of Mineral Processing*, 85(4), 93-100.
- [16] Haykin, S. (1999). 23. Neural Networks A Comprehensive Foundation. *Pearson Education*, Hindistan, 823.
- [17] Çitakoglu, H. (2015). Comparison of artificial intelligence techniques via empirical equations for prediction of solar radiation. *Computers and Electronics in Agriculture*, 118, 28-37.
- [18] Kutlu, B. & Badur, B. (2009).Yapay Sinir Ağları ile Borsa Endeksi Tahmini. *İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Dergisi*, 63, 25-44.
- [19] He, Z., Wen, X., Liu, H. & Du, J. (2014). A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology*, 509, 379-386.
- [20] Jang, J. (1993). ANFIS: adaptive-network-based fuzzy inference system. *Transactions on Systems, Man, and Cybernetics*, 23(3), 665-685.
- [21] Wang, Z., Palade, V. & Xu, Y. (2006). Neuro-Fuzzy Ensemble Approach for Microarray Cancer Gene Expression Data Analysis. 2006 International Symposium on Evolving Fuzzy Systems.
- [22] Wei, L. (2016). A hybrid ANFIS model based on empirical mode decomposition for stock time series forecasting. *Applied Soft Computing*, 42, 368-376.
- [23] Kisi, O., Shiri, J. & Tombul, M. (2013). Modeling rainfall-runoff process using soft computing techniques. *Computers & Geosciences*, 51, 108-117.
- [24] Çitakoglu, H., Babayigit, B. & Haktanir, N. (2020). Solar radiation prediction using multi-gene genetic programming approach. *Theoretical and Applied Climatology*, 142(3-4), 885-897.
- [25] Ferreira, C. (2001).Gene Expression Programming: a New Adaptive Algorithm for Solving. *Problems. Complex Systems*, 13(2), 87-129.
- [26] Okkan, U., Serbeş, Z. & Gedik, N. (2018). MATLAB ile Levenberg-Marquardt algoritması tabanlı YSA uygulaması: Aylık yağış-akış modellemesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9(1), 351-362.