T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DİCLE HAVZASINDA YAĞIŞ-AKIŞ İLİŞKİSİNİN MAKİNE ÖĞRENME YÖNTEMLERİYLE BELİRLENMESİ

Selmin DERE

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

ŞANLIURFA
2022

T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DİCLE HAVZASINDA YAĞIŞ-AKIŞ İLİŞKİSİNİN MAKİNE ÖĞRENME YÖNTEMLERİYLE BELİRLENMESİ

Selmin DERE

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

ŞANLIURFA
2022

İÇİNDEKİLER

Sayfa No

ÖZET i
ABSTRACT ii
TEŞEKKÜR iii
ŞEKİLLER DİZİNİ iv
ÇİZELGELER DİZİNİ v
SİMGELER ve KISALTMALAR DİZİNİ vi
1. GİRİŞ 1
2. ÖNCEKİ ÇALIŞMALAR 3
3. MATERYAL ve YÖNTEM 12
3.1. Çalışma Alanı 12
3.2. Yöntem 14
3.2.1. Çoklu doğrusal regresyon (ÇDR) 14
3.2.2. Yapay sinir ağları (YSA) 15
3.2.3. Uyarlanabilir nöro-bulanık çıkarım sistemi (Adaptive neuro-fuzzy inference system-ANFIS) 16
3.2.4. Gen ekspresyon programlama (GEP) 17
3.2.5. Performans değerlendirme kriterleri 18
4.ARAŞTIRMA BULGULARI ve TARTIŞMA 20
4.1. Model 1 (E26A005-17280) 22
4.2. Model 2 (E26A018-17282) 25
4.3. Model 3 (E26A012-17282) 28
4.4. Model 4 (E26A012-17282) 31
4.5. Model 5 (E26A020-17285) 34
4.6. Model 6 (E26A030-17285) 37
4.7. Model 7 (E26A030-17920) 40
4.8. Model 8 (E26A031-17285) 44
4.9. Model 9 (E26A031-17880) 47
4.10. Model 10 (E26A018-17847) 50
4.11. Model 11 (E26A018-17280) 53
4.12. Tartışma 56
5. SONUÇLAR ve ÖNERİLER 57
KAYNAKLAR 60
ÖZGEÇMİŞ 63
EKLER 64

ÖZET

Yüksek Lisans Tezi

DİCLE HAVZASINDA YAĞIŞ-AKIŞ İLİŞKİSİNİN MAKİNE ÖĞRENME YÖNTEMLERİYLE BELİRLENMESİ

Selmin DERE

Harran Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Oğuz ŞİMŞEK
Yıl: 2022, Sayfa:86

Hidrolojik döngünün en önemli bileşeni olan yağış-akış süreci, hidrolojik analiz ve su kaynakları mühendisliği açısından oldukça önemlidir. Son zamanlarda, karmaşık problemlerin modellenmesinde ve çıktıların tahmin edilmesinde başarılı sonuçlar veren yapay zekâ yöntemleri, birçok alanda olduğu gibi hidrolojik olayların modellenmesinde de sıklıkla tercih edilmektedir. Bu çalışmada, Dicle Havzası'nda bulunan 11 adet akım gözlem istasyonuna ait aylık ortalama akım değerleri, meteoroloji gözlem istasyonlarında kaydedilen yağış verilerine bağlı olarak belirlenmeye çalışılmıştır. Yağış ve akım gözlem istasyonlarının ilişkisinin kurulmasında Thiessen Çokgenleri yöntemi kullanılmıştır. Yağış akış ilişkisinin belirlenmesinde farklı girdi modelleri 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) yöntemlerinin başarısı değerlendirilmiştir. Tahmin yöntemlerinin ve girdi modellerinin başarısının belirlenmesinde belirlilik katsayısı (R^2), ortalama karesel hata (OKH) ve Nash-Sutcliffe verimlilik (NSE) kriterleri kullanılmıştır. Kullanılan istasyonlardan ANFIS ve GEP yöntemi ile kurulan modeller, gözlemlenen akış ile yağış parametrelerine bağlı tahmin edilen akış arasındaki ilişkiyi belirlemede diğer yöntemlere kıyasla daha başarılı olmuştur. Çalışma sonucunda elde edilen bulgular yağış-akış ilişkisini belirlemek için, yapay zekâ yöntemlerinin uygulanabilirliğini doğrulamakta aynı zamanda matematiksel bir yöntem olan GEP yönteminin de kullanılabilirliğini göstermektedir.

ANAHTAR KELİMELER: Yağış-akış modellemesi, Dicle havzası, ANFIS, yapay sinir ağları, gen ekspresyon programlama

ABSTRACT

MSc Thesis

DETERMINATION OF RAINFALL-RUNOFF RELATIONSHIP IN TIGRIS BASIN WITH MACHINE LEARNING METHODS

Selmin DERE

Harran University
Graduate School of Natural and Applied Sciences
Department of Civil Engineering

Supervisor: Assoc. Prof. Dr. Oğuz ŞİMŞEK
Year: 2022, Page:86

Rainfall-runoff process, the most crucial component of hydrological cycle, has a significant place in hydrological analysis and water resources engineering. Recently, artificial intelligence methods, which have been in great demand because they bring successful results to complex problems, are preferred in modelling hydrological events as in many areas. In this thesis study, the monthly average flow values of 11 station located within the borders of the Tigris Basin were tried to be determined by using the precipitation data obtained from the meteorological observation stations. For the stations used, models were built using Adaptive Neuro-Fuzzy Inference System (ANFIS), Artificial Neural Network (ANN), Gene Expression Programming (GEP) and Multiple Linear Regression (MLR) and rainfall-runoff relationship was evaluated. The determination coefficient (R^2), Mean Square Error (MSE) and Nash-Sutcliffe Efficiency (NSE) error criterion parameters were used to determine the obtained values. It has been observed that the models established with methods of ANFIS and GEP from stations used give more successful outcomes in evaluating the relationship between the observed runoff and the predicted runoff compared to other methods. The results confirm the applicability of artificial intelligence methods to determine rainfall-runoff relationship, and also show the utilizability of the GEP method, which is a mathematical method.

KEYWORDS: Rainfall-runoff modelling, Tigris basin, ANFIS, artificial neural network, gene expression programming

TEŞEKKÜR

Tez çalışma sürecimde bilgi ve deneyiminden yararlandığım, ilgi ve desteğini benden esirgemeyen kıymetli danışman hocam Doç. Dr. Oğuz ŞİMŞEK'e ve bu çalışmanın meydana gelmesinde emeği geçen hocalarım merhum Dr. Öğr. Üyesi Reşit GERGER ve Doç. Dr. Veysel GÜMÜŞ'e, çalışmanın birçok aşamasında bana yardımcı olan, bilgi ve desteğinden istifade ettiğim Yüksek İnşaat Mühendisi İbrahim Halil İFŞAAT'a, tezin hazırlanması boyunca bana destek veren değerli çalışma arkadaşım Elif Miraç UNCU'ya teşekkürlerimi sunmaktayım.

Eğitim sürecim boyunca sevgi ve desteklerini benden esirgemeyen ve her koşulda arkamda olan anneme ve babama, kardeşlerim Cihan ve Volkan ile tüm aile üyelerime teşekkür ve saygılarımı sunmaktayım.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 3. 1. Çalışma alanı 12
Şekil 3. 2. Üç girdi iki gizli katmana sahip YSA yapısı 15
Şekil 3. 3. İfade ağacı 18
Şekil 4. 1. Dicle havzasında bulunan MGİ'ler için oluşturulmuş Thiessen çokgenleri 20
Şekil 4. 2. ANFIS D3 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 24
Şekil 4. 3. ANFIS D3 için eğitim ve test aşamasına ait saçılım grafikleri 24
Şekil 4. 4. GEP D4 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 27
Şekil 4. 5. GEP D4 için eğitim ve test aşamasına ait saçılım grafikleri 27
Şekil 4. 6. GEP D4 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 30
Şekil 4. 7. GEP D4 için eğitim ve test aşamasına ait saçılım grafikleri 30
Şekil 4. 8. GEP D5 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 33
Şekil 4. 9. GEP D5 için eğitim ve test aşamasına ait saçılım grafikleri 33
Şekil 4. 10. ANFIS D5 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 36
Şekil 4. 11. ANFIS D5 için eğitim ve test aşamasına ait saçılım grafikleri 37
Şekil 4. 12. ANFIS D3 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 39
Şekil 4. 13. ANFIS D3 için eğitim ve test aşamasına ait saçılım grafikleri 40
Şekil 4. 14. GEP D3 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 43
Şekil 4. 15. GEP D3 için eğitim ve test aşamasına ait saçılım grafikleri 43
Şekil 4. 16. ANFIS D4 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 46
Şekil 4. 17. ANFIS D4 için eğitim ve test aşamasına ait saçılım grafikleri 46
Şekil 4. 18. GEP D4 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 49
Şekil 4. 19. GEP D4 için eğitim ve test aşamasına ait saçılım grafikleri 49
Şekil 4. 20. GEP D3 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 52
Şekil 4. 21. GEP D3 için eğitim ve test aşamasına ait saçılım grafikleri 53
Şekil 4. 22. ANFIS D5 için eğitim ve test aşamasına ait zamansal dağılım grafikleri 55
Şekil 4. 23. ANFIS D5 için eğitim ve test aşamasına ait saçılım grafikleri 56

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 3. 1. Meteoroloji gözlem istasyonlarına ait özellikler 13
Çizelge 4. 1. Dicle havzasındaki istasyonlara ait oluşturulan ilişkiler 21
Çizelge 4. 2. Akım tahmini için oluşturulan modeller..... 21
Çizelge 4. 3. 17280-E26A005 için tüm durumlara ait eğitim ve test sonuçları 23
Çizelge 4. 4. 17282-E26A018 için tüm durumlara ait eğitim ve test sonuçları 26
Çizelge 4. 5. 17282-E26A012 için tüm durumlara ait eğitim ve test sonuçları 29
Çizelge 4. 6.17210-E26A024 için tüm durumlara ait eğitim ve test sonuçları 32
Çizelge 4.7. 17285-E26A020 için tüm durumlara ait eğitim ve test sonuçları 35
Çizelge 4. 8. 17285-E26A030 için tüm durumlara ait eğitim ve test sonuçları 38
Çizelge 4. 9. 17920-E26A030 için tüm durumlara ait eğitim ve test sonuçları 41
Çizelge 4. 10. 17285-E26A031 için tüm durumlara ait eğitim ve test sonuçları 45
Çizelge 4. 11. 17880-E26A031 için tüm durumlara ait eğitim ve test sonuçları 48
Çizelge 4. 12. 17847-E26A018 için tüm durumlara ait eğitim ve test sonuçları 51
Çizelge 4. 13. 17280-E26A018 için tüm durumlara ait eğitim ve test sonuçları 54
Çizelge 5. 1. Eğitim ve test sürecine göre tüm istasyonlarda belirlenen en başarılı modeller 58

SİMGELER ve KISALTMALAR DİZİNİ

AGİ	Akım Gözlem İstasyonu
ANFIS	Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
A_{ij}	Hücre Katmanları Arasındaki Bağlantı Ağırlıkları
$\beta_0, \beta_1, \beta_2, \beta_n$	Regresyon Katsayıları
ÇDR	Çoklu Doğrusal Regresyon
GA	Genetik Algoritma
GP	Genetik Programlama
GEP	Gen ekspresyon Programlama
i	Girdi Katman Sayısı
İBGYSA	İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağı
j	Gizli Katman Sayısı
k	Çıktı Katmanı
MGM	Meteoroloji Genel Müdürlüğü
n	Gözlemlenen Verilerin Sayısı
NSE	Nash-Sutcliffe Efficiency
OKH	Ortalama Karesel Hata
OMGH	Ortalama Mutlak Göreceli Hata
$P_{i,}$ (d_0)	Aylık Toplam Yağış Verileri
$P_{i-1,}$ (d_2)	Bir Önceki Aya Ait Toplam Yağış Verileri
$P_{i-2,}$ (d_3)	İki Önceki Aya Ait Toplam Yağış Verileri
$P_{i-3,}$ (d_4)	Üç Önceki Aya Ait Toplam Yağış Verileri
Q	Aylık Akım Verileri
$Q_{i,g}$	Gözlenen Akım Verileri
$Q_{i,t}$	Tahmin Edilen Akım Verileri
Q_{i-1}	Bir Önceki Aya Ait Aylık Akım Verileri
R	Korelasyon katsayısı
R^2	Belirlilik Katsayısı
y	Bağımlı Değişken
YSA	Yapay Sinir Ağı
X_1, X_2, X_n	Bağımsız Değişkenler
$\beta_0, \beta_1, \beta_2, \beta_n$	Regresyon Katsayıları
$\mu_{Ai}(x)$	Üyelik fonksiyonları

1. GİRİŞ

Meteorolojinin inceleme alanlarından biri olan, atmosferde sıvı ve katı halde bulunan suyun belirli şartların bir araya gelmesi ile yeryüzüne düşmesi olayına yağış denir. Yağışın atmosferden yeryüzüne düşmesiyle, bu yağışın bir kısmı sızma ile zemine, oradan da süzülme ile yeraltı birikimine karışır. Yeryüzüne düşen yağış yüzey akışı şeklinde, yeraltı birikiminden de yeraltı akışı şeklinde barındırmış oldukları suyu, akarsu biriktirme sistemlerine göndermektedir. Yüzey akışı, bir miktar yağışın toprağa sızmaması ve kara yüzeyinden yüzey sularına (akarsular, nehirler, göller veya diğer rezervuarlar) doğru akması sonucu oluşur (Sitterson ve ark., 2018). Düşen yağış ile terleme ve buharlaşma gibi faktörlerin haricinde akışa geçen su; deniz, göl ve nehirlere iletildikten sonra buharlaşma yolu ile tekrar atmosfere dönmektedir. Suyun yeryüzünde farklı hallerde bulunup yer kürenin birçok farklı yerinde dönüp durması ve bu hareket halinde izlediği yola hidrolojik çevrim denir.

Hidrolojik çevrimin dengelenmesinde önemli yer tutan akış, fazla yağışı atmosfere geri vermesinin yanında nehir sistemlerine ne kadar su aktığını kontrol ederek hidrolojide önemli bir yer tutmaktadır. Yüzey akışı; taşkın tahmini, su ortamında ekolojik ve biyolojik ilişkiler gibi suyun kalitesi ve miktarına dair birçok problemi çözmekle beraber su kaynaklarını izleyebilmek için merkezi bir ilgi alanı olmuştur (Kokkonen ve ark., 2001). Akış, ayrıca yağmur olayları ile su yollarına karışan tarım alanlarından gelen fazla besin ve tarımsal ilaçlar nedeniyle kirli madde taşınmasında ana unsur olması sebebiyle hidrolojik döngü üzerindeki öneminin yanında ekolojik dengede de önemini korumaktadır. Hidrolojik döngünün en önemli parametrelerini oluşturan ögeler olması sebebiyle yağış-akış ilişkisini doğru ve etkili değerlendirmek konu ile ilgili çalışmalar yürüten mühendis ve yöneticilere de önemli faydalar sağlamaktadır. Bu amaçla, yağış-akış ilişkisini belirlemek üzere birçok çalışmanın yapılması zorunluluk haline gelmiştir.

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 (He ve ark., 2014). Veriye dayalı modellerin tercih edilmesinin başlıca nedeni, fiziksel tabanlı modellerin aksine veriye dayalı teorik modellerin ilgili fiziksel, boyutsal ve doğrusal olmayan süreçleri sayısal olarak belirleyebilmesidir (Kasiviswanathan ve ark., 2016). 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 kullanılmıştır. Yapay Sinir Ağları (YSA), Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System – ANFIS), Gen Ekpresyon Programlama (GEP) ve Dalgacık Tabanlı Sinir ağı gibi birçok model ile bu modellerin hibrit ve modifiye tasarımları literatürde oldukça sık tercih edilen başlıca modellerdendir. Son yıllarda yapılan bilimsel çalışmalarda, yağış-akış ilişkisini belirlemek ve farklı yapay zekâ tekniklerini değerlendirmek için birçok havzanın yağış, akış ve sıcaklık gibi temel parametrelere bağlı olarak değerlendirildiği görülmektedir.

Bu tez çalışması kapsamında, yağış-akış akış ilişkisini değerlendirmek için klasik yöntem olan ve oldukça sık tercih edilen Çoklu Doğrusal Regresyon (ÇDR), yapay zeka yöntemlerinden olan YSA, ANFIS ile beraber son zamanlarda sıklıkça tercih edilen ve matematiksel bir model olan GEP yöntemleri ile Dicle havzasında bulunan 11 adet akım gözlem istasyonuna ait veriler kullanılıp, havzanın yağış akış ilişkisi belirlenmiştir.

2. ÖNCEKİ ÇALIŞMALAR

Dawson ve Wilby (1998), Birleşik Krallık'ta bulunan sele eğilimli Amber ve Mole nehirleri için gerçek hidrometrik verileri kullanarak YSA ile akış tahmininde bulunmuşlardır. Geleneksel akış tahminleriyle ve YSA yönteminin sonuçlarını kıyaslamışlar ve sonuçların operasyonel sistemler ile kıyaslanabilir kalitede olduğunu belirtmişlerdir. YSA'nın kayıp veriler ile başa çıkma yeteneği ve tahmin edilen olaydan gerçek zamanlı olarak öğrenmenin, onu bir geleneksel toplu veya yarı dağıtılmış taşkın tahminlerine çekici bir alternatif model oluşturduğunu ifade etmişlerdir. Ancak, bir havza için akış, hidrolojik ve mevsimsel bağlamda ele alındığında optimum YSA eğitim periyodunu belirlemenin daha fazla araştırmaya ihtiyaç duyduğunu bildirmişlerdir.

Khu ve ark. (2001), göreceli olarak evrimsel bir teknik olan genetik programlamayı (GP), öncesinde sembolik bir regresyon alanı için, ardından Fransa'da bulunan Orgeval havzası için gerçek zamanlı akış tahminine uyarlamışlardır. Çalışmalarında GP ve MIKE11/NAM modeli olarak tanımlanan yağış akış modelini tanımlayacak bir hata güncelleme şeması olarak işlev görmüştür. Dokuz saate kadar olan tahmin uzunlukları için farklı güncelleme aralıklarının saatlik akış tahminlerini gerçekleştirmiş ve önerdikleri güncelleme şemasının, dikkate alınan tüm güncelleme aralıkları için doğru bir şekilde akış tahmini yapabildiğini ifade etmişlerdir. Çalışma sonuçları önceki çalışma sonuçları ile karşılaştırılmış ve GP'nin gerçek zamanlı akış tahmini için daha iyi bir güncelleme aracı olduğunu belirtmişlerdir.

Sivapragasam ve ark. (2001), Danimarka'da bulunan Tryggevalde havzası akış verilerini ve Singapur'a ait yağış verilerini kullanarak, orijinal zaman serilerini bir dizi yüksek ve düşük frekanslı bileşene ayrıştıran Tekil Spektrum Analizi (TSA) ve yüksek boyutlu bir girdi uzayında hesaplama ve genelleme performansıyla verimli sonuçlar alan Destek Vektör Makinesi (DVM) teknikleri ile akışı tahmin etmişlerdir. Çalışma sonuçlarını doğrusal olmayan tahmin yöntemiyle karşılaştırmışlardır. TSA ve DVM

tekniklerinin, doğrusal olmayan tahmin yöntemine göre korelasyon katsayısı daha yüksek olduğunu ve akışı belirlemede daha başarılı olduğunu ifade etmişlerdir.

Keijzer ve Babovic (2002), akışı tahmin etmek için fiziksel modellerin kullanılmasının, uygun verilerin yeterli doğrulukta toplanmasıyla ilgili sorunlar ortaya çıkardığını ve dolayısıyla bu durumun sonucu olarak daha iyi tahminler yapmak adına birçok model ile tahmin çalışmalarının yapıldığını ifade etmişlerdir. Çalışmalarında, veriye dayalı model olarak ve kavramsal modellerle kombinasyon halinde yağış-akış modeli oluşturmak için GP'nin kullanımını ele almışlardır. Çalışma sonucunda, GP'nin yağış tahmini bağlamında güçlü bir araç olduğu bulunmuş ve GP'nin tek ve basit bir denklemle, kısa vadeli tahmine uygun bir yaklaşım olarak kullanılabileceği belirtilmiştir.

Şahin (2007), Karadeniz bölgesinin yağış akış ilişkisini belirlemek istemiş ve ÇDR ile YSA metotlarından genelleştirilmiş regresyon yapay sinir ağı (GRSA), radyal tabanlı fonksiyonlara dayalı yapay sinir ağı (RTYSA) ve ileri beslemeli geri yayılımlı yapay sinir ağı (İBGYSA) kullanarak girdi parametresi olarak yağış, sıcaklık ve akım değerlerini ele alıp akımı tahmin etmeye çalışmıştır. Yaptığı çalışmada YSA yöntemlerinin ÇDR'ye göre daha iyi sonuç verdiğini ancak RTYSA ve İBGYSA'nın akımı tahmin etmede bazı durumlarda negatif sonuçlar verdiğini, GRYSA'da bu durumun gözlenmediğini belirtmiştir.

Aytek ve Alp (2008), Amerika'nın Pensilvanya eyaletinde bulunan Juniata Nehri havzasında yağış akış ilişkisini belirlemek için ileri besleme geri yayılım sinir ağı (İBGYSA) ve genelleştirilmiş regresyon sinir ağı (GRSA) ile gen ifade programlama (GEP) metotlarını kullanmışlardır. Çalışma sonucunda, gen programlama formülasyonunun YSA' dan elde edilen sonuçlara göre oldukça iyi olduğunu ifade etmiş ve YSA' ya alternatif olarak GEP' in kullanılabileceği sonucuna ulaşmışlardır.

Sedki ve ark. (2009), iklimi yarı kurak olan Fas'ta" bir havzadaki yüzey akışını tahmin etmek için geri yayılma algoritması ile hibrit olacak şekilde genetik algoritmayı (GA), girdi değişkenleri için ise yağış ve akış değerlerini kullanmışlardır. Genetik algoritma tabanlı sinir ağının performansını değerlendirmek için, GYSA yöntemini

karşılaştırma amacıyla dahil etmişler ve sonuçların, GA tabanlı sinir ağı modelinin GYSA'ya göre üstün sonuçlar verdiğini ifade etmişlerdir.

Ghumman ve ark. (2011), Pakistan'daki bir havzada toplanan veri kümesinin kısa olduğu ve kalitesinin sorgulanabilir olduğu koşulları karşılamak için YSA'ya dayalı bir yağış-akış modeli geliştirmiş ve uygulamışlardır. YSA modelinin sonuçlarını matematiksel bir kavramsal model ile karşılaştırılmış ve YSA modellerinin genelleştirilmesi için çapraz doğrulama yaklaşımı benimsemişlerdir. Elde ettikleri sonuçlara göre YSA modelinin kavramsal modellere önemli bir alternatif olduğunu ve toplanan veri setinin aralığı kısa ve verilerin düşük standartta olduğu durumlarda kullanılabileceğini ifade etmişlerdir.

El-shafie ve ark. (2011), Japonya'nın Tanakami bölgesinde bulunan bir havzada yağış-akış ilişkisini belirleyebilmek için YSA ve ÇDR yöntemlerini karşılaştırmışlardır. Tahmindeki başarıyı görmek için temel istatistik olarak R, OKH ve R^2 ölçütlerini kullanmışlardır. Elde edilen başarı kriterlerin değerlendirilmesinden, yağış akış ilişkisini belirlemede YSA'nın klasik bir yöntem olan ÇDR'ye göre daha başarılı tahminlerde bulunduğu görülmüştür.

Lafdani ve ark. (2013), ANFIS ve YSA yöntemlerini kullanarak İran'da bulunan Eskandari havzasına ait yağış verileri ile 10 yıllık (1999-2009) akış verisini tahmin etmeye çalışmışlardır. Gama testini kullanarak en iyi giriş kombinasyonunu belirlemişlerdir. MIKE11/NAM model olarak isimlendirilen kavramsal bir hidrolojik model ile yağış verilerini kullanarak akımı tahmin etmeye çalışmışlar ve sonuçları birbirleriyle kıyaslamışlardır. Çalışma sonucunda yağış akış ilişkisinin belirlenmesinde ANFIS modelinin YSA modeline göre daha iyi sonuçlar verdiği sonucuna varmışlardır.

Akrami ve ark. (2013), Malezya'da bulunan Klang Nehir havzasında yağış-akış ilişkisini ANFIS ve modifiye edilmiş ANFIS (MANFIS) ile tahmin etmeye çalışmışlardır. Yapay sinir ağları ve bulanık çıkarım sistemlerini birleştiren ANFIS modelinin modifiye edilerek kullanılması ve yakınsama dönemlerini daha verimli hale

getirmek için geliştirilmiştir. Çalışmalarında iki senaryo üzerinde durulmuş ve ilk olarak aylık yağış, klasik ANFIS için (t) zamandan (t-4) zamana farklı zaman gecikmelerinde tek girdi olarak kullanılmıştır. İkinci senaryoda ise MANFIS kullanılmıştır. Sonuçlar, MANFIS'in geleneksel ANFIS modeline kıyasla daha düşük hata, daha az hesap karmaşıklığı ve daha yüksek yağış tahmini sağladığını göstermiştir.

Chen ve ark. (2013), Çin'de bulunan Sarı Nehir'in büyük bir havzasından alınan çalışma verileri ile DVM dayalı yağış-akış modelinde, yıllık yağış serilerini ayrıştırmak için uyarlanabilir bir veri analizi metodolojisi olan topluluk ampirik mod ayrışımı (TAMA) ile çalışma yapmışlardır. DVM'nin serbest parametrelerini belirlemek için, ek olarak partikül sürüsü optimizasyonu (PSO) kullanmışlardır. Modelin tahmin kabiliyetini belirlemek için ise sıradan en küçük kareler regresyonu ve üç katmanlı İBYSA'yı kıyaslama modeli olarak belirlemişlerdir. Çalışmalarında modellerin performansını değerlendirmek için ise OKH, OMGH, R ve Nash-Sutcliffe verimlilik katsayısı (Nash-Sutcliffe Efficiency Coefficient-NSE) parametrelerini kullanmışlardır. Elde edilen sonuçlara göre, PSO-DVM-TAMA modelin, İBYSA model (%65.99) ve en küçük kareler regresyonu (% 64.4) tahminini geliştirdiğini, OKH (67.7) ve OMGH (%65.38) değerlerini ise azalttığını değerlendirmişlerdir. R ve NSE değerlerinin ise önemli ölçüde geliştirdiğini ifade eden araştırmacılar, incelenen istasyonda sunulan metodolojinin, yağış-akış tahminini önemli ölçüde artırabileceğini ifade etmişlerdir.

Areerachakul ve Junsawang (2014), Tayland'da bulunan Lam Phachi havzasında günlük yağış verileriyle YSA yöntemini kullanarak 2009 ile 2012 yılları arasındaki akımı değerlerini tahmin etmişlerdir. Çalışma için ilk üç yıllık verileri eğitim verisi olarak, sonraki yılların verilerini ise test verisi olarak kullanmışlardır. Bu yöntem kullanılarak elde edilen sonuçlarda belirlilik katsayısını 0.88 olarak elde etmişler ve bu sonuç ile su kaynakları çalışmalarında ve yürütülmesinde problemleri çözmek için YSA'nın kullanılabileceğini değerlendirmişlerdir.

Zahmatkesh ve ark. (2015), New York City'deki Bronx Nehri havzasında farklı belirsizlik kaynaklarını dikkate alarak yağış-akış simülasyonu, yağış tahmini ve gelecekteki yüzey akışı tahminini içeren entegre bir şema geliştirmişlerdir. İlk olarak yağış tahmini için veriye dayalı modeller geliştirmiş ve ikinci adımda girdi verileriyle ilişkili belirsizlikleri model parametreleri ve model yapısı, yağış-akış modellemesi ve simülasyonuna dahil etmişlerdir. Model yapısının belirsizliğini analiz etmek için, K-kümeleme anlamına gelen ağırlıklandırma yöntemi geliştirmişler ve model parametreleri ile girdi belirsizliğini, Uyarlanabilir Markov Zinciri Monte Carlo yöntemi kullanarak incelemişlerdir. Son adımda ise kalibre edilen yağış-akış modellerini, yüzey akışını tahmin etmek için öngörülen yağış miktarı kullanılarak çalıştırmışlardır. Elde ettikleri sonuçlara göre, model parametrelerinin ve girdi belirsizliğinin aynı anda tahmin edilmesinin, parametrelerin olasılık dağılımını önemli ölçüde değiştirdiğini ifade etmişlerdir. Aynı zamanda hidrolojik modellerin çıktılarının, önerilen kümeleme şeması kullanılarak birleştirilmesiyle, yüzey akışın modellemesinin doğruluğunu %50'ye kadar arttırdığını da belirtmişlerdir.

Alizadeh ve ark. (2017), Tolt Nehri havzasında iki aylık süreç için yağış ve yüzey akışını, giriş yapısında gözlemlenen ve tahmin edilen zaman serilerini içeren dalgacık dönüşümü ve yapay sinir ağı (DDYSA) kombinasyonunu dikkate alarak tahmin etmişlerdir. Gelecek iki aydaki akış sürecini modellemek için, gelecek bir ay için en iyi akış tahminleri ve bir ile iki ay sonraki yağış tahminleri girdi değişkenlerine eklemişlerdir. Bir aylık akış için geliştirilen en iyi tahmin modeli, girdi yapısında bir ay öncesi, dağlık bölgelerdeki termal özelliklerin etkisini gösteren tarihsel akış, yağış ve sıcaklık serilerini içermektedir. Tahmin edilen ve gözlemlenen zaman serilerinin her ikisinde de tüm girdi değişkenlerini dalgacık dönüşümü yoluyla ayrıştırmışlar ve YSA modellerine empoze etmişlerdir. Önerilen DDYSA modellerinin performansı ile geleneksel DDYSA (girdi parametreleri olarak sadece gözlemlenen zaman serilerini kullanan) modellerinin performansını karşılaştırmışlar ve tahminlerin güvenirliğini değerlendirmek için belirsizlik analizi uygulamışlardır. Buna göre, yeni modellerin üstün olduğunu ve bu yeni metodoloji uygulandığında bir ve iki ay önceki yağış ve yüzey akışı sürecinin güvenilir bir şekilde tahmin edilebileceğini ifade etmişlerdir.

Nourani (2017), Avustralya'da bulunan Lobbs Hole Creek ve Moselle havzalarına 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 (EANN) ile belirlemeye çalışmıştır. Geleneksel ileri beslemeli yapay sinir ağı modeline göre EANN modelinin daha iyi sonuçlar verdiğini belirtmiştir.

Hu ve ark. (2018), Fen Nehri havzasında 14 yağış istasyonu ve havzadaki bir hidrolojik istasyon aracılığı ile izlenen sel olaylarına dayalı, 1971-2013 yılları arasındaki yağış-akış sürecini modellemek için YSA ve uzun kısa süreli bellek (UKSB) ağ modellerini kullanmışlardır. Deneysel verileri bu dönemdeki 98 yağış-akış olayından almışlar ve bunların 86'sını eğitim periyodu için geri kalanını da test periyodu için kullanmışlardır. Elde ettikleri sonuçlara göre, iki ağ modelinin de yağış-akış uyarlamaları için elverişli olduğunu ve kavramsal ve fiziksel tabanlı modellerden daha iyi olduğunu belirtmişlerdir.

Taşar ve ark. (2019), Amerika'da bulunan Muskegon Nehri havzasındaki yağış akış ilişkisini, 1397 günlük yağış, sıcaklık ve akış verilerini kullanarak Nöro Bulanık (Neuro-Fuzzy- NF) ve DVM yöntemleri ile tahmin etmişlerdir. Sonuçlar, DVM yönteminin yağış akış ilişkisini modellemede yüksek kararlılık ve düşük hata değerleri verdiğini ifade etmişlerdir. Model sonuçlarını, günlük gözlenen veriler ile kıyaslamışlar ve DVM yönteminin klasik yöntemlere alternatif olarak kullanılabileceğini belirtmişlerdir.

Ahmadi ve ark. (2019), İran'da bulunan Tahran'ın batı kesiminde yer alan Kan havzasında yağış-akış sürecini modellemek için günlük, aylık ve yıllık bazda SWAT, IHACRES ve YSA modelini kullanmışlardır. Sonuçlara göre, uygulanan üç modelin performansının genellikle yağış-akış sürecini modellemek için uygun olduğunu ancak en iyi performans gösteren modelin günlük, aylık ve yıllık akış modellemelerinin her üçünde de YSA olduğunu bildirmişlerdir.

Keskin (2020), ABD Waltham Massachusetts'te bulunan Stony Brook havzasında yağış akış ilişkisini ÇDR, İBGYSA ve otogresif hareketli ortalamalar

(ARMA) ile belirlemeye çalışmıştır. Elde elde edilen sonuçlardan İBGYSA yönteminin akışı tahmin etmede diğer yöntemlere kıyasla daha uyumlu olduğunu ifade etmiştir.

İfşaat (2020), Türkiye'nin Fırat havzasında bulunan 28 adet akım gözlem istasyonunda elde edilen akım değerlerini, bölgede bulunan meteoroloji gözlem istasyonlarında elde edilen yağış verileriyle tahmin etmeye çalışmıştır. Yağış verilerine bağlı akış değerlerini tahmin etmek için YSA, GEP ve ÇDR yöntemleri kullanılmıştır. Tahmin yöntemlerinin başarısını değerlendirmede OKH, OMGH ve R kriterleri başarı ölçütü olarak tercih edilmiştir. Çalışma sonucunda, GEP ve YSA yöntemlerinin yağış akış ilişkisini belirlemede ÇDR yöntemine göre oldukça başarılı olduğu belirlenmiştir. Ayrıca, çalışma sonucunda tahmin modellerinde kullanılan girdi parametreleri arasında akım değerinin tahmin edilmesinde bir önceki ayda elde edilen akım değerinin tahmin modelinin başarısını önemli derece arttırdığı bildirilmiştir.

Negi ve ark. (2021), Hindistan'da bulunan dağlık bir havza olan Himachal Pradesh'te yağış-akış ilişkisini modellemek için istatistiksel bir analiz için polinom regresyon ve lineer olmayan regresyon kullanırken, veriye dayalı modeller uygulamak için bulanık mantık (fuzzy logic- FL) ve YSA yöntemlerini kullanmışlardır. Çalışmaları için 15 yıllık (2005-2019) yağış ve yüzey akışı verileri toplamış ve elde ettikleri değerleri, R ile toplam karesel hata (TKH) kriterleri ile değerlendirmişlerdir. Elde edilen sonuçlara göre, R ve TKH değerlerine göre yağış-akış korelasyonu için en iyi sonuçları veren yöntemin YSA olduğunu, FL yaklaşımı ve ikinci dereceden regresyon yöntemi için R değerlerinin neredeyse eşit olduğunu ifade etmişlerdir.

Morales ve ark. (2021), Şili havzasındaki yağış-akış arasındaki ilişkiyi modellemek hem yağış hem de ikinci tur gecikmelerini ve bulanık bir sistemde gerekli üyelik işlevlerinin sayısını seçmenin belirsizliğini azaltmak için Kendini Tanımlama Nöro-Bulanık Çıkarım Sistemi (Self Identification Neuro-Fuzzy Inference Model – SINFIM) yöntemini önermişlerdir. Şili'de bulunan Nuble bölgesine ait Diguillin Nehri'nden alınan 2000-2018 yılları arasındaki günlük ortalama yağış verileri ile çalışmalarını yürütmüş ve yöntemi doğrulamak için Maule'de bulunan Colorado Nehri

havzası ile birlikte çalışmışlardır. Deneysel sonuçlara göre, doğrulama kümesi olarak son üç yılın verileri ile, doğrulama testi olarak ise son bir yılın verileri kullanılarak, ANFIS, YSA ve Uzun Kısa Süreli Bellek (Long Short Term Memory-LSTM) yaklaşımı gibi diğer tahmin modellerinden performansı daha yüksek olan iyileştirilmiş sonuçlar elde ettiklerini ifade etmişlerdir. Bu nedenle, belirli bir havzadaki yağış olaylarından hem düşük hem de pik akış değerlerini tahmin etmek, önceki zaman serisinin gecikmelerini ve bulanık kuralların sayısını belirleme gereksiniminden kaçınmak için önerdikleri yöntemi iyi bir alternatif olarak değerlendirmişlerdir.

Mao ve ark. (2021), yapay öğrenme yöntemleri ile geleneksel hidrolojik modellerin performansını değerlendirmişler ve hidrolojideki histerezis etkileri araştırmışlardır. Elde ettikleri sonuçlara göre, YSA modelin aylık ölçekli simülasyon için daha uygun olduğunu, LSTM modelin ise günlük ölçekte daha iyi performans gösterdiğini belirtmişlerdir. Hidrolojik histerezisin özellikle günlük ölçekte yapay öğrenme yöntemlerini kullanırken akışı modellemek için önemli olduğunu, modellemedeki histerezi dikkate alınarak, OMGH değerinin LSTM için %27, YSA için %21 oranında iyileştirildiğini, sinir ağı yapısının sınırlandırılması nedeniyle YSA'nın gereğinden fazla takılmasının daha kolay olduğunu ve bu yüzden LSTM'nin zaman serisi işlemesi için daha sağlam bir yöntem olduğunu ifade etmişlerdir.

Chiang ve ark. (2022), Tayvan'ın kuzeyinde bulunan Hen Chi havzasında veriye dayalı model eğitimi üzerindeki farklı veri uzunluklarının etki ve kısıtlarını daha iyi anlamak için DVM temel algoritma kabul ederek, yağış-akış simülasyonu üzerine çalışma yürütmüşlerdir. Modelin eğitim aşamasında, çeşitli özellikte seçim stratejileri ve farklı veri uzunlukları kullanmışlardır. DVM ile tahmin edilen sonuçları, fiziksel tabanlı hidrolojik bir modelden (HEC-HMS) türetilen yağış-akış simülasyonu ile kıyaslamışlardır. HEC-HMS, DVM ile aynı veri seti periyodu ile kalibre edilmiş ve sonuçlara göre DVM ile HEC-HMS modellerin yağış-akış simülasyonunun kısa ve uzun dönem periyotları için kullanılabileceğini ifade etmişlerdir. Ancak DVM modelin HEC-HMS modele göre yağış-akış ilişkisini oldukça iyi tahmin ettiğini, HEC-HMS modelin DVM modelin performans seviyesine ulaşmak için daha fazla parametre optimizasyonuna ve çıkarım sürecine ihtiyaç duyduğunu belirtmişlerdir.

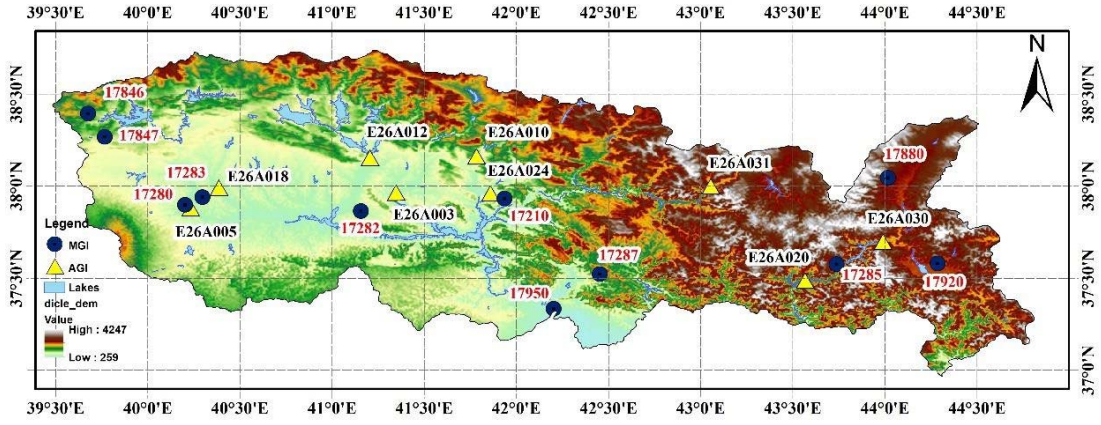
Li ve ark. (2022), Çin'de bulunan dört farklı iklim koşullarına sahip Xiangxi, Jie, Na ve Daxi Nehir havzalarında akış projeksiyonunu geliştirmek için, bazı noktalarda yetersiz kaldığını düşündükleri geleneksel makine öğrenme modellerin yetersizliği üzerine ortak bir olasılıksal yağış-akış modeli (joint probabilistic rainfall-runoff model, JPRR) geliştirmişlerdir. Eşleştirilmiş kopula yapıları ve çok modelli topluluk yaklaşımlarının yardımı ile önerdikleri modelin çeşitli olasılık dağılımlarına sahip yağış zaman serilerine ait bağımlılık ilişkilerini etkili bir şekilde karakterize edebildiklerini belirtmişlerdir. Elde ettikleri sonuçlara göre, JPRR'nin YSA, Uzun Kısa Süreli Bellek gibi iyi bilinen makine öğrenme yöntemlerinden daha iyi performans sergilediğini ve JPRR ile kıyaslama modellerinden elde edilen nehir akışı projeksiyonlarında (2030'dan 2099'a), geleneksel makine öğrenme modellerinden kaynaklı taşkın risklerinin değişen iklim koşullarında hafife alınabileceğini önemli bir fark olarak belirtmişlerdir.

Literatürde bulunan çalışmalar incelendiğinde, Türkiye'nin sınırı aşan sular kapsamına giren Dicle Nehri'nin geçtiği Dicle havzasında yağış-akış ilişkisinin belirlendiği detaylı bir çalışmanın (11 istasyonun ele alındığı) bulunmadığı görülmektedir. Bu tez çalışması, Dicle havzasında meteoroloji ve akım gözlem istasyonları arasındaki yağış-akış ilişkisi GEP, ANFIS, ÇDR ve ANN yöntemleriyle beş farklı girdi kombinasyonunda tahmin edilmeye çalışılmıştır. Dicle havzasının jeolojik ve ekonomik özellikleri gibi temel parametreler göz önünde bulundurulduğunda, havzanın ileriye dönük şekillendirilmesine yardımcı olabilmek adına yağış-akış ilişkisinin yorumlanması ve belirlenmesi konusunda olan eksikliğin giderileceği değerlendirilmiştir.

3. MATERYAL ve YÖNTEM

3.1. Çalışma Alanı

Türkiye'nin Güneydoğusunda yer alan ve farklı kaynaklardan beslenen Dicle Havzası, toplamda yıllık ortalama 50 milyar m^3 su potansiyeline sahiptir. Dicle Havzası'nda, Türkiye'de bulunan kaynaklarının toplam su potansiyeli 21.3 milyar m^3/yıl olarak hesap edilmiştir (Özdemir ve ark., 2002). 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 Havzası'nda bulunan akım gözlem istasyonlarına (AGİ) ait aylık akım değerleri, yine havza içerisinde bulunan meteoroloji gözlem istasyonlarına (MGİ) ait aylık toplam yağış verileri kullanılarak tahmin edilmiştir. Havza sınırları içerisinde bulunan tüm istasyonlar, kullanılan istasyonlar ve havza detayları Şekil 3.1.'de verilmiştir.



Şekil 3. 1. Çalışma alanı

Yapılan çalışma kapsamında kullanılan yağış istasyonlarına ait veriler, Meteoroloji İşleri Genel Müdürlüğü'nden (MGM) sağlanmış olup bu istasyonlara ve akım gözlem istasyonlarına (AGİ) ait coğrafi bilgiler ile ölçüm aralıkları sırasıyla Çizelge 3.1. ve Çizelge 3.2.'de verilmiştir.

Çizelge 3. 1. Meteoroloji gözlem istasyonlarına ait özellikler

MGİ No	Adı	Koordinat		Veri Aralığı	Yükseklik (m)
		Enlem (º)	Boylam (º)		
17210	Siirt	37.9319	41.9354	1945-2020	895
17280	Diyarbakır Havalimanı	37.8973	40.2027	1945-2013	674
17282	Batman	37.8636	41.1562	1959-2020	610
17847	Diyarbakır	38.2670	39.7660	1964-2020	986
17285	Hakkâri	37.5745	43.7388	1961-2020	1727
17880	Başkale	38.0435	44.0173	1959-2020	2286
17920	Yüksekova	37.5785	44.2862	1981-2020	1877

Çizelge 3. 2. Akım gözlem istasyonlarına ait özellikler

AGİ No	Adı	Koordinat		Veri Aralığı	Yağış Alanı (km^2)	Maks Akım m^3/sn	Min Akım m^3/sn	Ort. Akım m^3/sn
		Enlem (º)	Boylam (º)					
E26A003	Garzan Çayı Beşiri	37.9650	41.3458	1946-2002	545	371	0	48.56
E26A005	Dicle Nehri Diyarbakır	37.8800	40.2297	1956-1997	570	526	3.21	71.30
E26A010	Bitlis Çayı Baykan	38.1613	41.7825	1955-2016	910	116	2.02	18.23
E26A012	Batman Çayı Malabadi Köprüsü	38.1544	41.2044	1965-2016	597	596	0.16	116.64
E26A018	Ambar Çayı Beşiri	37.9919	40.3841	1969-1978	595	86.70	0	7.68
E26A020	Zap Suyu Üzümcü	37.4863	43.5655	1971-2012	1072	371	9.07	56.28
E26A024	Kezer Çayı Pınarca	37.9613	41.8572	1972-2016	530	139	0.61	19.73
E26A030	Zap Suyu Teknisyenler	37.6986	43.9883	1986-2011	1425	272	4.32	35.35
E26A031	Çatak Çayı Tüliran	37.9983	43.0544	1988-2016	1482	153	5.77	25.43

3.2. Yöntem

Yağış verilerinden akış parametresinin tahmin edilmesinin konu olduğu çalışmalar incelendiğinde birçok araştırmacı tarafından çeşitli yöntemler ve girdi parametrelerine ait farklı kombinasyonlar kullanılarak analizler gerçekleştirildiği belirlenmiştir. Bu tez çalışması kapsamında akış tahmini çalışmasında girdi parametresi olarak farklı zamanlara ait yağış ve akım verileri kullanılmıştır. Bu çalışmada yağış akış ilişkisinin belirlenmesinde kullanılan yöntemler aşağıda özetlenmiştir.

3.2.1. Çoklu doğrusal regresyon (ÇDR)

İstatistiksel bir analizde, bir dizi bağımsız değişken ile bağımlı değişken arasındaki ilişkiyi belirlemek amacıyla kullanılan klasik bir yöntemdir. ÇDR, Denklem 3.1. ile ifade edilmektedir.

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_n X_n \quad (3.1.)$$

Bu denklemde; $X_1, X_2 \ldots X_n$ bağımsız değişkenleri ve Y ise bağımlı değişkeni ifade etmektedir. $\beta_0, \beta_1 \ldots \beta_n$ ise denkleme ait parametreler olup regresyon katsayılarını ifade etmektedir (Özbayoğlu ve ark., 2008).

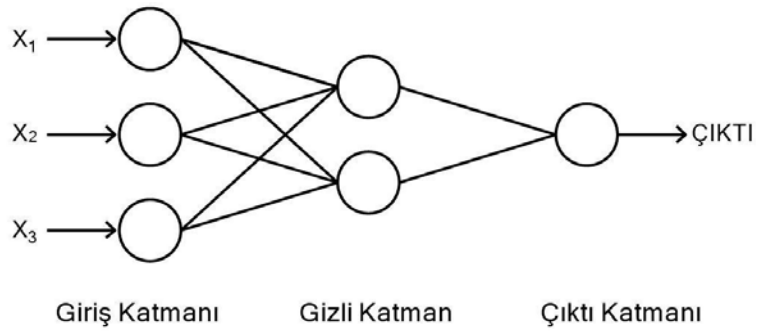
Her bağımsız değişken için en uygun çizgiyi bulmak amacıyla ÇDR; en küçük model hatasına yol açan regresyon katsayıları, genel modelin t-istatistiği ve ilişkili p değerini (bağımlı ve bağımsız değişkenler arasında hiçbir ilişki olmadığına dair sıfır hipotezi doğru olsaydı t-istatistiğinin meydana gelme olasılığı ne kadar) hesaplar. Ardından her bir regresyon katsayısı için t-istatistiğini ve p değerini hesaplar. Böylece bağımsız değişkenin değerini ve bağımsız değişkenler ile bağımlı değişken arasındaki ilişkinin ne kadar kuvvetli olduğuna dair bilgi vermektedir.

3.2.2. Yapay sinir ağları (YSA)

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 (Simon, 1999).

YSA, nöron (düğüm) adı verilen birçok birimden oluşur. Temel yapısını nöronların yanı sıra, ağırlık vektörleri ve aktivasyon (transfer) fonksiyonları oluşturur (Citakoglu, 2015). 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 (Kutlu ve Badur, 2009). 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 (Yüksek ve ark., 2018; He ve ark., 2014) Levenberg-Marquardt algoritması tercih edilmiştir.



Şekil 3. 2. Üç girdi iki gizli katmana sahip YSA yapısı

3.2.3. 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 (Jang, 1993). Sistemin performansını artırmak için doğrudan verilerden ve üyelik fonksiyonu parametrelerinden yararlanarak öğrenme becerisini yakalar (Wang ve ark., 2006). ANFIS mimarisi, beş katmanlı bir ileri beslemeli sinir ağı yapısından ve Sugeno' nun eğer-ise kuralını öne sürdüğü bulanık çıkarım yaklaşımından oluşur (Wei, 2016). Bu katmanlar ve ilgili katmanlara ait ifadeler Denklem 3.2, 3.3, 3.4, 3.5. ve 3.6. ile aşağıda kısaca verilmiştir.

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

$$O_{1,i} = \mu_{Ai}(x) = \frac{1}{1+[(x-c_i/a_i)^2]^{bi}} \quad (3.2.)$$

Burada $O_{1,i}$ uyarlanabilir bir düğümdür, a_i ve 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 Denklem 3.3'e gönderen bir kare düğümdür.

$$O_{2,i} = w_i = \mu_{Ai}(x) = \mu_{Bi}(y) \quad (3.3.)$$

Burada $\mu_{Ai}(x)$ ve $\mu_{Bi}(y)$ 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 normalleştirilmiş ateşleme kuvvetleri olarak adlandırılabilir.

$$o_{3,i} = \overline{w_i} = \frac{w_i}{w_1 + w_2 + w_3} \tag{3.4.}$$

Katman 4: i-inci düğümün çıktısıdır.

$$o_{4,i} = \bar{w}_i = \bar{w}_i(p_i + q_i + r_i) \tag{3.5.}$$

Burada p_i, q_i ve r_i ardışık parametrelerdir.

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

$$o_{5,i} = \sum_i \bar{w}_i f_i \tag{3.6.}$$

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

3.2.4. Gen ekspresyon programlama (GEP)

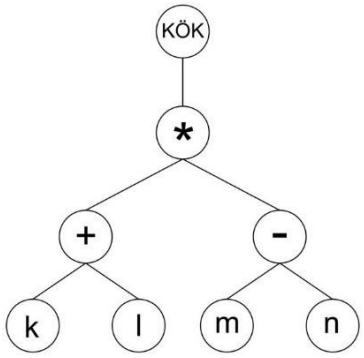
Genetik bireylerin nüfusunu kullanarak onları uygunluğuna göre seçen, bir veya daha fazla genetik operatör yardımıyla genetik varyasyonu sunan genetik programlama ve genetik algoritmaya benzer bir yöntemdir (Kisi ve ark., 2013). Genetik algoritmada bireyler, sabit uzunlukta doğrusal diziler iken, genetik 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

(Citakoglu ve ark., 2020). 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 (Ferreira, 2001).

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 3.7.'de verilen basit bir matematiksel ifade:

$$Q=\sqrt{(k+l)\times(m-n)} \tag{3.7.}$$

ifade ağacında Şekil 3.3.'teki gibi verilmektedir.



Şekil 3. 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.

3.2.5. Performans değerlendirme kriterleri

Çalışma kapsamında en uygun tahmini yapan modelin performansını belirlemek amacıyla belirlilik katsayısı (R^2), ortalama karesel hata (OKH) ve Nash-Sutcliffe efficiency (NSE) hata kriteri parametreleri kullanılmıştır. Bu parametrelerin hesaplanmasında kullanılan eşitlikler sırasıyla Denklem 3.8, 3.9 ve 3.10'da verilmiştir.

Denklemlerde kullanılan $Q_{i,g}$, gözlenen aylık akımı, $Q_{i,t}$ tahmin edilen aylık akımı ve $\bar{Q}_{i,g}$ ise gözlenen aylık akımların ortalamasını ifade etmektedir.

R^2 değerinin 1'e yakın olması, OKH değerinin ise 0'a yakın değerler alması modelin tahmin başarısının yüksek olduğunu ifade etmektedir. Bunun yanında NSE değerinin 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.

$$R^2 = \frac{\sum_{i=1}^{n}(Q_{i,g} - \overline{Q_{i,g}})(Q_{i,t} - \bar{Q}_{i,t})}{\sqrt{\sum_{i=1}^{n}(Q_{i,g} - \overline{Q_{i,g}})^2 (Q_{i,g} - Q_{i,g})^2}} \quad (3.8.)$$

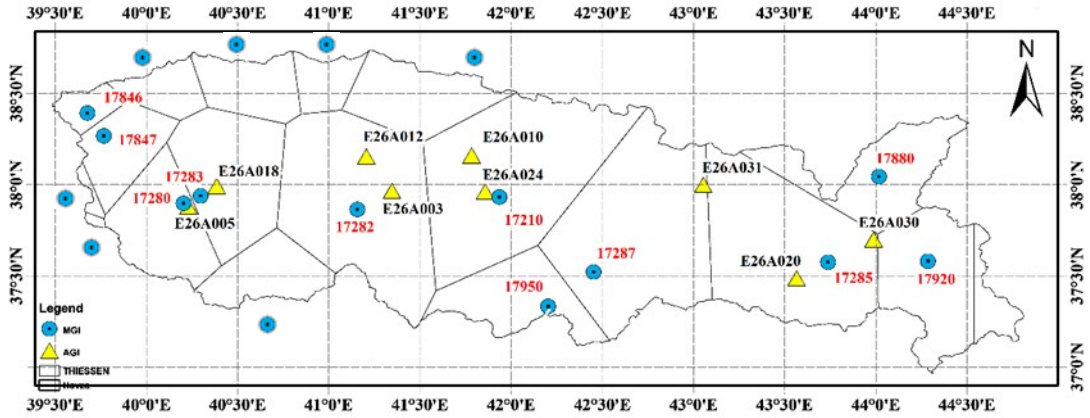
$$OKH = \frac{1}{n}\sum_{i=1}^{n}\left(Q_{i,g} - Q_{i,t}\right)^2 \quad (3.9.)$$

$$NSE = 1 - \frac{\sum_{i=1}^{n}\left(Q_{i,g} - Q_{i,t}\right)^2}{\sum_{i=1}^{n}\left(Q_{i,g} - Q_{i,g}\right)^2} \quad (3.10.)$$

Bu başarı ölçütlerinden OKH parametresi, tahmin yöntemlerinin başarısının belirlenmesinde esas ölçüt olarak kullanılmıştır.

4.ARAŞTIRMA BULGULARI ve TARTIŞMA

Dicle havzası sınırları içerisinde bulunan AGİ'lere ait aylık akımı tahmin etmek ve yağış-akış ilişkisini belirlemek için, havza sınırları içerisindeki ve havzaya yakın mesafede bulunan MGİ'ler kullanılarak oluşturulan Thiessen çokgenleri (Şekil 4.1.) ile, ilgili AGİ'lere ait eşleştirme sağlanarak ilişki kurulmuştur. Alansal ilişki içerisinde bulunan AGİ ve MGİ'lere ait aylık ortalama akım değerleri, ortak yılları kapsayacak şekilde değerlendirilmiştir. Havza içerisinde bulunan, verileri eksik veya yetersiz olan MGİ'ler ile ortak yılları kapsamayan istasyonlar çalışma kapsamının dışında tutulmuştur.



Şekil 4. 1. Dicle havzasında bulunan MGİ'ler için oluşturulmuş Thiessen çokgenleri

Havzada bulunan 11 istasyona ait akım değerlerini tahmin etmek için aylık ortalama yağış verileri ve akım değerleri kullanılmıştır. AGİ'ler ve MGİ'ler arasında Thiessen çokgenleri adı verilen, çokgenler içerisinde kalıp AGİ'lere yakın mesafede bulunan MGİ'ler ile 11 ayrı ilişki kurulmuştur. Model 1'de E26A005 numaralı AGİ ile 17280 numaralı MGİ aynı çokgen içerisinde kalmış olup ve birbirine oldukça yakın bulunduğu için bu iki istasyon arasında ilişki kurulmuştur. Model 2'de, E26A018 numaralı AGİ, 17283 numaralı MGİ ile aynı çokgen içerisinde yer aldığı için ilişki kurulmuştur. Oluşturulan diğer modellerde de benzer şekilde aynı çokgen içerisinde kalıp yakın mesafede bulunan AGİ ve MGİ'ler eşleştirilmiş ve istasyonlar arasındaki bu ilişkiler Çizelge 4.1.'de verilmiştir.

Çizelge 4. 1. Dicle havzasındaki istasyonlara ait oluşturulan ilişkiler

No	AGİ	MGİ	ORTAK YILLAR	VERİ SAYISI
Model 1	E26A005	17280	1956-1997	501
Model 2	E26A018	17282	1969-1978	357
Model 3	E26A012	17282	1965-2016	621
Model 4	E26A024	17210	1972-2016	537
Model 5	E26A020	17285	1971-2012	501
Model 6	E26A030	17285	1986-2011	321
Model 7	E26A030	17920	1986-2011	321
Model 8	E26A031	17285	1988-2016	285
Model 9	E26A031	17880	1988-2016	285
Model 10	E26A018	17847	1969-1978	357
Model 11	E26A018	17280	1969-1978	357

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 %70'i eğitim olarak, %30'u ise test verisi olarak kullanılması önerilmektedir (Gümüş ve ark., 2016). Bu çalışma kapsamında veri setinin %70'i eğitim, %30'u ise test için kullanılmıştır.

Eşleştirilmiş istasyonlara ait akım verilerini tahmin etmek için, ANFIS, YSA, GEP ve ÇDR yöntemleri kullanılmış olup her bir eşleştirme için beş farklı girdi modeli oluşturulmuştur. Bu tahminlere ait oluşturulan modeller Çizelge 4.2.'de verilmiştir. Burada; aylık toplam yağış verileri (P_i) kullanılarak D1 modeli, P_i değerine ek olarak bir ay önceki akım değerleri (Q_{i-1}) kullanılarak D2 modeli, bir ay önceki aylık yağış verileri eklenerek D3 modeli, iki ay önceki aylık yağış verileri eklenerek oluşturulan D4 modeli ve üç ay önceki aylık yağış verileri eklenerek oluşturulan D5 modeli ile akım (Q_i) tahmin edilmeye çalışılmıştır. d_0, d_1, d_2, d_3 ve d_4 ile verilen kısaltmalar ise GEP yöntemi için kullanılan girdi parametrelerini temsil etmektedir.

Çizelge 4. 2. Akım tahmini için oluşturulan modeller

Model	Girdi Parametreleri	Çıktı
D1	(P_i) [d_0]	Q_i
D2	(P_i), (Q_{i-1}) [d_1]	Q_i
D3	(P_i), (P_{i-1}) [d_2], (Q_{i-1})	Q_i
D4	(P_i), (P_{i-1}), (P_{i-2}) [d_3], (Q_{i-1})	Q_i
D5	(P_i), (P_{i-1}), (P_{i-2}), (P_{i-3}) [d_4], (Q_{i-1})	Q_i

4.1. Model 1 (E26A005-17280)

E26A005 numaralı AGİ' ye ait aylık akım değerlerinin tahmini için 17280 numaralı MGİ'ye ait aylık yağış verileri kullanılarak, Çizelge 4.2.'de verilmiş olan beş farklı girdi kombinasyonu ile oluşturulan ÇDR, YSA, ANFIS ve GEP yöntemleri ile elde edilen tahmin sonuçları Çizelge 4.3.'te verilmiştir. Çalışma kapsamında tüm modellerde, eğitim periyodunda veri setinin %70'i (351 veri), test periyodunda ise veri setinin %30'u (150 veri) kullanılmıştır. YSA modelinde transfer fonksiyonu "tansig" olarak kullanılmış ve deneme yanılma yöntemi ile elde edilmiş olan ara katman sayıları Çizelge 4.3.'te model yanında parantez içerisinde verilmiştir. ANFIS yönteminde kullanılan üyelik fonksiyon sayısı da yine model adı yanında köşeli parantez içerisinde bulunmakta ve ANFIS yönteminde üyelik fonksiyonları olarak gaussian üyelik fonksiyonları kullanılmıştır.

Tüm durumlar dikkate alınarak Çizelge 4.3.'te verilen sonuçlar incelendiğinde, en iyi tahmini yapan yöntemin en düşük OKH değerine sahip olan D3 ile ANFIS'in olduğu görülmektedir. ANFIS, D3 modelinde test aşamasında gözlemlenen akım ile tahmin edilen akım arasında R^2 değerini 0.69 olarak elde etmiştir. D3 modeli, aylık yağış verisine (P_i) ek olarak bir ay önceki yağış verileri (P_{i-1}) ile bir ay önceki aylık akım verileri (Q_{i-1}) kullanılarak oluşturan modeldir. ANFIS yöntemiyle D3 modeline ait NSE değerleri test aşamasında 0.679 olarak belirlenmiştir. Bu değerin 0 ile 1 arasında değerler alabileceği dikkate alınarak incelendiğinde, modelin akımı tahmin etmedeki başarısının kabul edilebilir olduğu görülmektedir. Modele ait kullanılan üyelik fonksiyon sayısı 3 olarak verilmiştir.

D4 modelinde en düşük OKH değerine sahip olup en iyi sonucu veren yöntem, GEP olmuştur. GEP D4 modeline ait akışı tahmin etmek için elde edilen ifade Denklem 4.1.'de verilmektedir.

$$Q = \left(\frac{d_0}{1.192} + \sqrt{(5.289 d_0)\left(\sqrt{(d_1^2 + d_2)}\right)} \right) - \frac{7.682 d_0}{d_1} \qquad (4.1.)$$

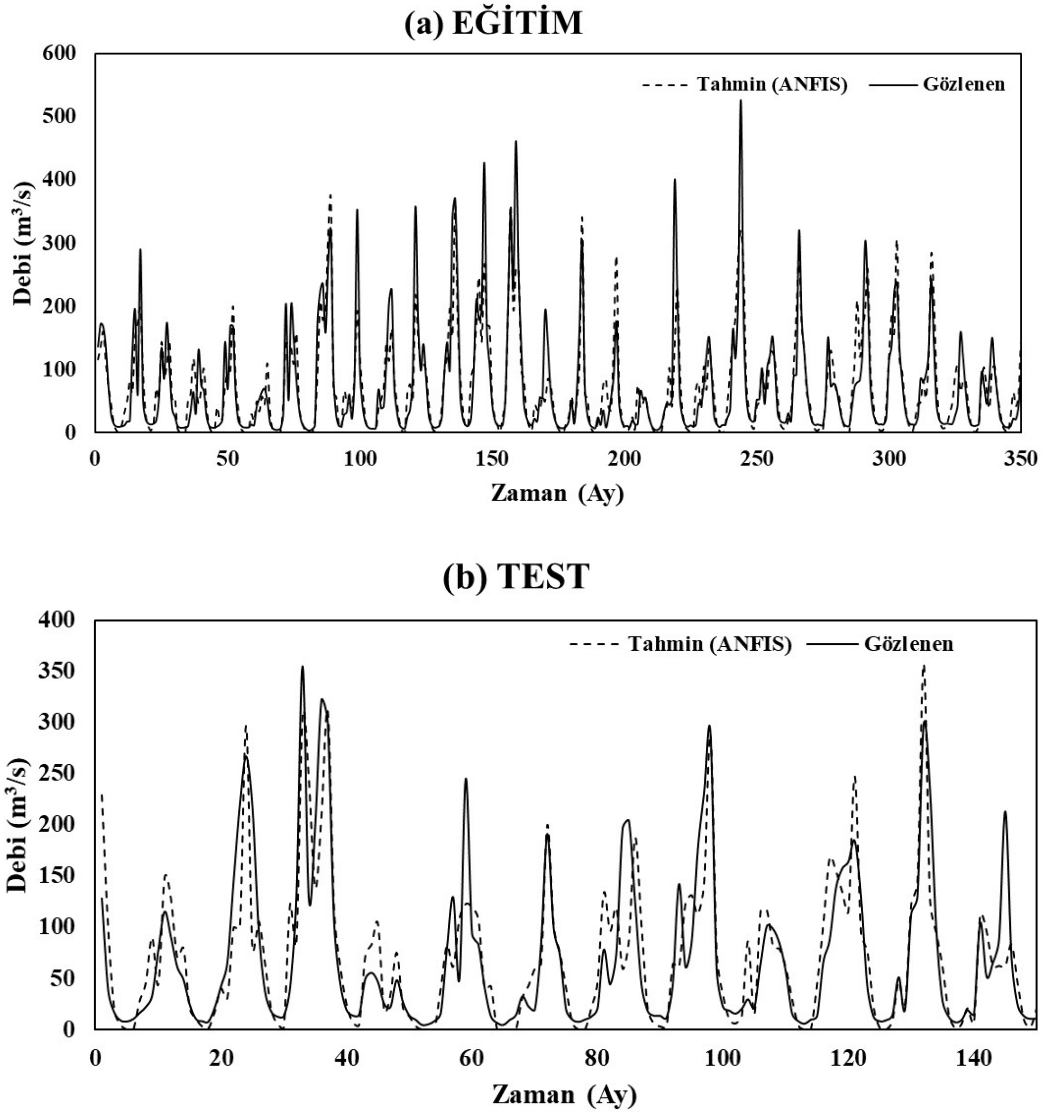
Tüm modellere ait değerler incelendiğinde ÇDR ve YSA yöntemleri ile elde edilen sonuçlardan hiçbirinin akımı tahmin etmek için ANFIS yöntemi kadar başarılı olamadığı görülmektedir.

Çizelge 4. 3. 17280-E26A005 için tüm durumlara ait eğitim ve test sonuçları

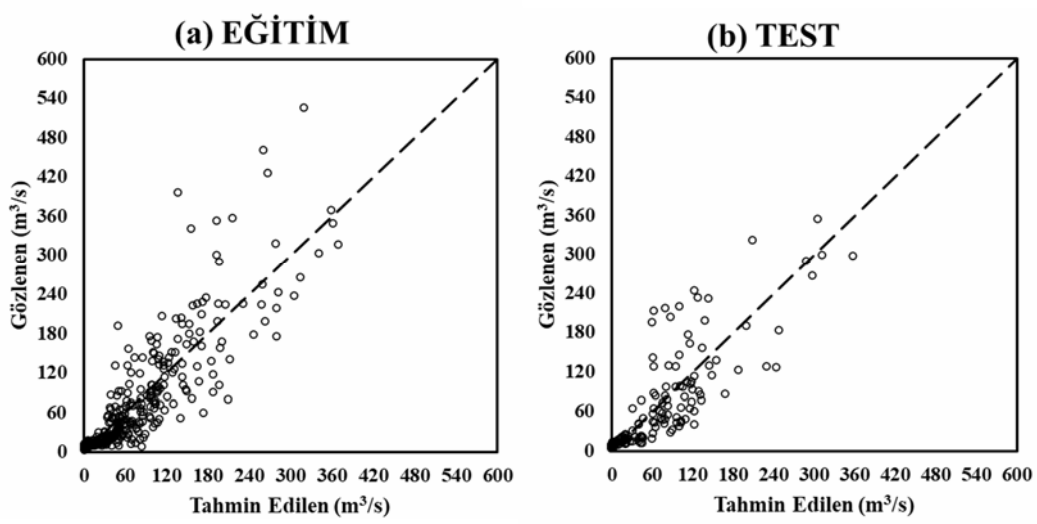
		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [8] (2)	EĞİTİM	0.5542	3318.30	0.554	0.4684	5169.57	0.306
	TEST	0.3637	4227.20	0.277	0.3405	5043.66	0.137
D2 [4] (3)	EĞİTİM	0.745	1898.50	0.745	0.7481	3542.67	0.524
	TEST	0.6736	1949.70	0.666	0.6441	3533.67	0.395
D3 [4] (3)	EĞİTİM	0.7509	1854.50	0.751	0.7471	3556.29	0.522
	TEST	0.6897	1873.10	0.679	0.685	3270.90	0.440
D4 [10] (3)	EĞİTİM	0.7627	1766.20	0.763	0.7347	3492.23	0.531
	TEST	0.6632	2096.50	0.641	0.6424	3397.82	0.419
D5 [2] (3)	EĞİTİM	0.7790	1645.40	0.779	0.774	3419.08	0.541
	TEST	0.6758	1977.00	0.662	0.6666	3414.75	0.416
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.5532	3325.73	0.553	0.5299	3571.31	0.520
	TEST	0.356	4325.62	0.260	0.3658	4352.48	0.255
D2	EĞİTİM	0.7567	1817.63	0.756	0.6914	2327.76	0.687
	TEST	0.6811	1958.47	0.665	0.6044	2364.78	0.595
D3	EĞİTİM	0.7722	1725.13	0.768	0.6919	2326.13	0.688
	TEST	0.6811	1958.47	0.665	0.6081	2337.16	0.660
D4	EĞİTİM	0.7506	1857.23	0.751	0.6996	2293.17	0.692
	TEST	0.6713	2034.71	0.661	0.6072	2350.23	0.598
D5	EĞİTİM	0.775	1676.73	0.775	0.7104	2257.30	0.697
	TEST	0.6564	1982.58	0.648	0.6121	2328.11	0.602

OKH ve R^2 değerleri dikkate alınarak en başarılı tahmin yaptığı belirlenen ANFIS modeliyle D3 modeline ait gözlenen ve tahmin edilen değerlerin zamansal dağılım grafiği Şekil 4.2.'de verilmiştir. Buna göre eğitim aşamasında yakalanan uyum test aşamasında daha zayıf kalmış ve model, eğitim ve test aşamalarının her ikisinde de düşük değerde olan akımları tahmin etmede başarılı performans göstermiş ancak değerlerin çok yüksek olduğu akımları tahmin etmede başarısız kalmıştır.

E26A005 istasyonuna ait en başarılı model olan ANFIS D3 modeli için eğitim ve test aşamasında elde edilen saçılım grafikleri ise Şekil 4.3.'te görülmektedir. Buna göre, gözlenen ile tahmin edilen değerler çoğu yerde yakınsamıştır, fakat değerlerin daha yüksek olduğu durumlarda ANFIS performansında düşüş görülmüştür.



Şekil 4. 2. ANFIS D3 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 3. ANFIS D3 için eğitim ve test aşamasına ait saçılım grafikleri

4.2. Model 2 (E26A018-17282)

E26A018 numaralı AGİ'ye ait akım değerlerini tahmin etmek için, bir önceki çalışmada olduğu gibi ÇDR, GEP, YSA ve ANFIS yöntemleri ile beş model için değerlendirme yapılmıştır. Buna göre sadece yağış verisi (P_i) kullanılarak oluşturulan D1 modeline ait sonuçlar, yüksek OKH ve düşük R^2 değerlerine sahip olup genel olarak çoğu modelde akımı tahmin etmede yetersiz kalmıştır ancak tüm yöntemler arasından en başarılı sonucu veren, OKH=90.40 değerine sahip GEP yöntemidir. Eğitim aşamasında belirlilik katsayısı en yüksek olan YSA modeline ait D5 modeli, test aşamasında eğitim aşamasında ulaştığı değeri yakalayamamış ve OKH değerleri, GEP ve ÇDR modellerinin yukarısında kalmıştır. Durum 2 ve Durum 3'e bakıldığında GEP diğerlerine göre daha iyi performans göstermiştir ancak eğitim aşaması test aşamasına göre akım tahmininde daha yakın sonuçlar elde etmiştir. Tüm modeller arasından en düşük OKH değerine (53.499) sahip P_i, P_{i-1}, P_{i-2} ve Q_{i-1} ile oluşturulan GEP D4 modeli en başarılı model olarak öne çıkmaktadır. Bu modelde R^2 değeri eğitimde 0.741, testte 0.524 değerlerine sahip olup akım değerlerini tahmin etmede eğitim aşamasında teste göre daha uyumlu olmuştur. Aynı zamanda NSE kriterinin 0.503 değerini bulması modelin akımı tahmin etmede kullanılabilir olduğunu desteklemektedir.

Tüm modeller arasından en iyi sonucu veren GEP ile D4 modeline ait akışı tahmin etmek için elde edilen ifade, Denklem 4.2. ile verilmektedir.

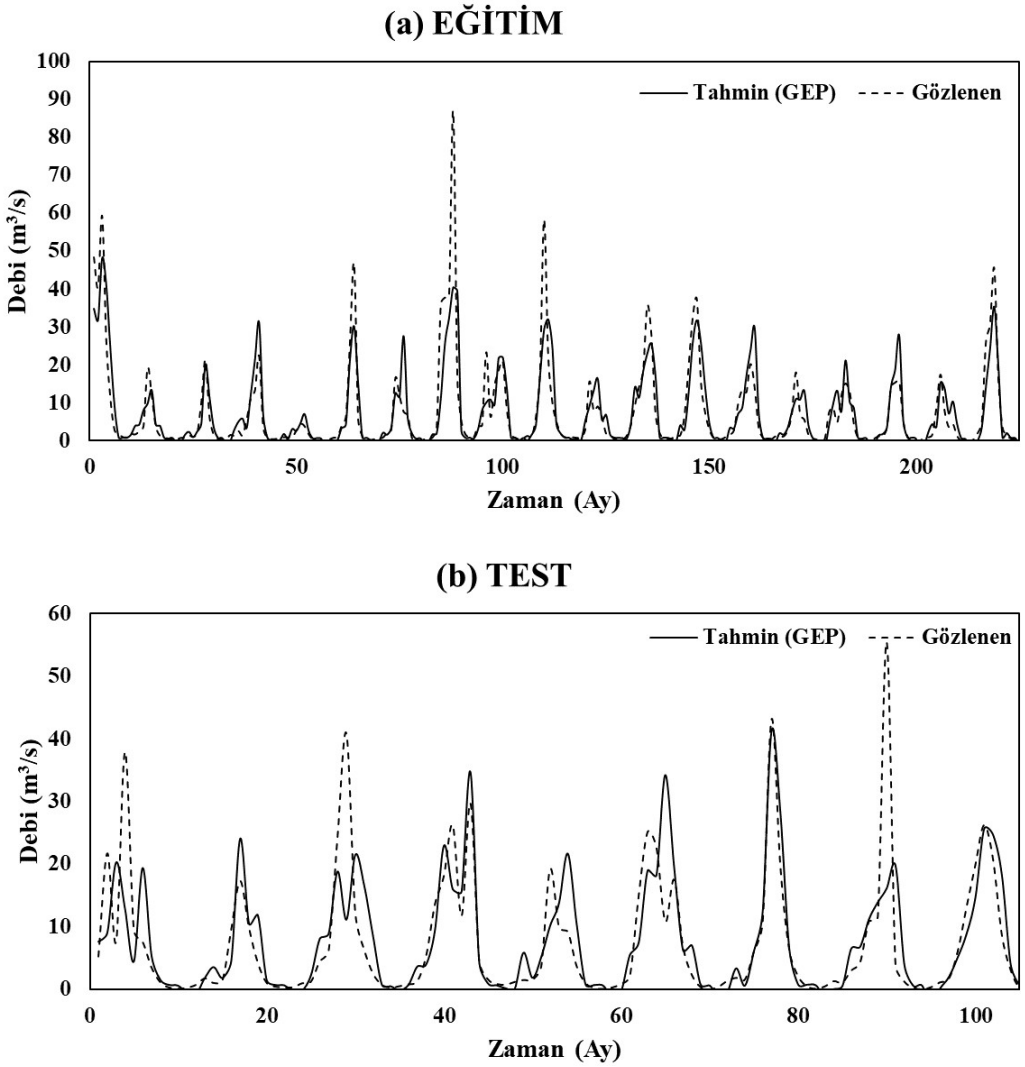
$$Q = \left(\frac{\sqrt[3]{d_0 d_1} - 3.37}{2} \sqrt[3]{d^0} \right) + \tan^{-1}\left(\tanh\left(e^{53.14} \left(\frac{d_0 + \sqrt[3]{d_1}}{2} \right) \right) \right) + \min\left(\frac{\sqrt[3]{d_1^4} + 0.94}{2}, \sqrt[3]{d_0} \right) \qquad (4.2.)$$

Çizelge 4. 4. 17282-E26A018 için tüm durumlara ait eğitim ve test sonuçları

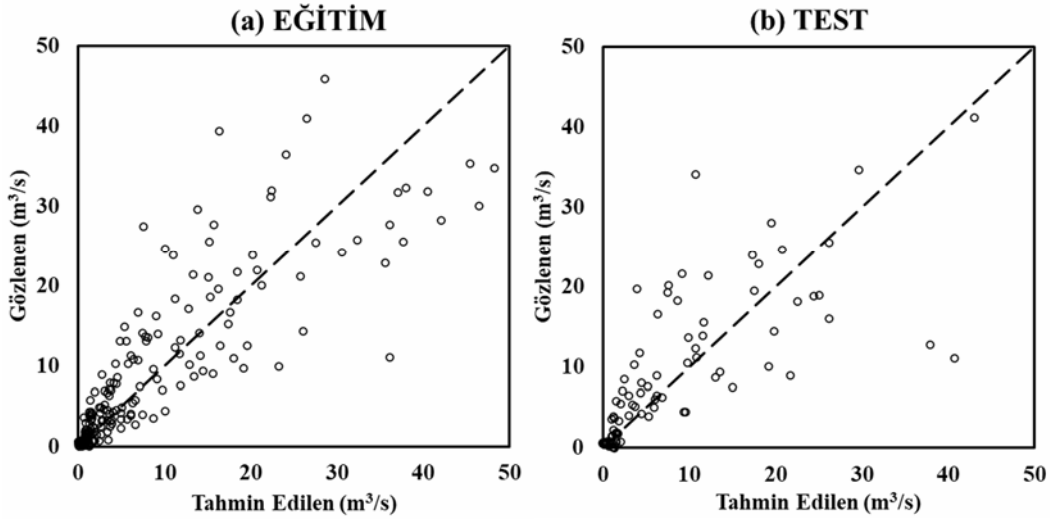
		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [6] (2)	EĞİTİM	0.5561	67.62	0.557	0.539	128.879	0.155
	TEST	0.2103	119.91	-0.114	0.208	147.255	-0.368
D2 [6] (3)	EĞİTİM	0.7192	42.79	0.720	0.746	96.912	0.365
	TEST	0.4055	1014.3	0.285	0.367	109.833	-0.020
D3 [8] (3)	EĞİTİM	0.7056	44.85	0.706	0.674	98.15	0.357
	TEST	0.3830	84.43	0.216	0.249	111.94	-0.04
D4 [6] (3)	EĞİTİM	0.7212	42.46	0.722	0.789	80.484	0.472
	TEST	0.3879	83.05	0.228	0.332	110.528	-0.027
D5 [8] (3)	EĞİTİM	0.7247	41.92	0.725	0.815	81.742	0.464
	TEST	0.3940	81.42	0.243	0.407	110.777	-0.029
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.420	96.41	0.368	0.510	75.169	0.507
	TEST	0.300	90.40	0.160	0.280	96.553	0.103
D2	EĞİTİM	0.769	35.620	0.766	0.640	56.540	0.629
	TEST	0.526	60.790	0.435	0.399	69.954	0.350
D3	EĞİTİM	0.769	35.191	0.769	0.638	56.324	0.631
	TEST	0.491	55.832	0.481	0.382	72.387	0.327
D4	EĞİTİM	0.741	39.385	0.742	0.638	56.046	0.633
	TEST	0.524	53.499	0.503	0.378	72.805	0.324
D5	EĞİTİM	0.764	36.657	0.760	0.638	56.045	0.633
	TEST	0.501	61.367	0.430	0.379	72.699	0.325

OKH ve R^2 değerlerine göre en başarılı tahmini yapan GEP D4 modeline ait gözlenen ve tahmin edilen değerlerin zamansal dağılım grafiği Şekil 4.4.'te verilmiştir. Buna göre eğitim aşamasında 0 ile 30 m^3/s aralığındaki akım değerlerini tahmin ederken oldukça yüksek performans göstermiştir ancak pik debilerde yetersiz kalmıştır. Test aşamasında model performansında tahmin edilen değerler gözlenen değerleri çoğu yerde yakınsamıştır fakat eğitimde olduğu gibi pik değerleri yakınsamada yetersiz kalmıştır.

GEP D4 durumu için E26A018 istasyonuna ait eğitim ve test aşamasında tahmin edilen ve gözlenen değerlerin saçılım grafikleri Şekil 4.5.'te verilmiştir. Bu grafiklerden, eğitim aşamasının test aşamasına göre daha başarılı olduğu sonucuna ulaşılmaktadır. GEP'e ait D4 modeli için saçılım grafiği incelendiğinde, gözlenen ile tahmin edilen değerler çoğu yerde yakınsamıştır, fakat değerlerin daha yüksek olduğu durumlarda GEP performansında düşüş görülmüştür.



Şekil 4. 4. GEP D4 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 5. GEP D4 için eğitim ve test aşamasına ait saçılım grafikleri

4.3. Model 3 (E26A012-17282)

E26A012 numaralı AGİ'ye ait akımı tahmin etmek için ÇDR, GEP, YSA ve ANFIS yöntemleri ile yapılan analizler sonucunda Çizelge 4.5.'te verilmiş olan değerler, test süreçleri dikkate alınarak incelendiğinde GEP yöntemine ait D1, D2 ve D4 modellerde, diğerlerine göre daha iyi sonuçlar elde edildiği, D3 ve D5 modellerde ise ANFIS ile elde edilen sonuçların diğerlerine göre daha başarılı olduğu görülmüştür. D1 modeli en iyi sonucu 10647.17 OMGH değeri ile GEP yönteminde elde etmiştir. Ancak determinasyon katsayısının tüm modellerde olduğu gibi GEP yönteminde de çok düşük çıkması, modelin sadece yağıştan (P_i) akımı tahmin etmenin elverişsiz olduğunu göstermektedir. Aylık yağış verisine ek olarak bir önceki ayın akım verisinin (Q_{i-1}) eklenmesi ile oluşturulan D2 modelde, tahmin performansında artış yaşandığı azalan OKH değerleri ve artan R^2 değerleri ile görülmüştür.

Tüm modeller arasından en iyi sonucu veren model, 5937.87 OKH değerine sahip olan GEP ile D4 modelidir. Model; R^2 değerini eğitim periyodunda 0.720, test periyodunda ise 0.552 olarak elde edilmiştir. Bu modelde aylık toplam yağış (P_i), bir önceki aya ait aylık akış (P_{i-1}), iki önceki aya ait aylık akış (P_{i-2}) ve bir önceki aya ait aylık akım (Q_{i-1}) verileri kullanılmıştır. GEP ile D4 modelde NSE kriteri eğitim aşamasında 0.720 ve test aşamasında 0.538 değerlerini bulmuş buna göre akım tahmini yaparken modelin kullanılabileceği yorumu desteklenmiştir.

GEP D4 modeli ile akımı tahmin etmek için elde edilen formül, Denklem 4.3. ile verilmiştir.

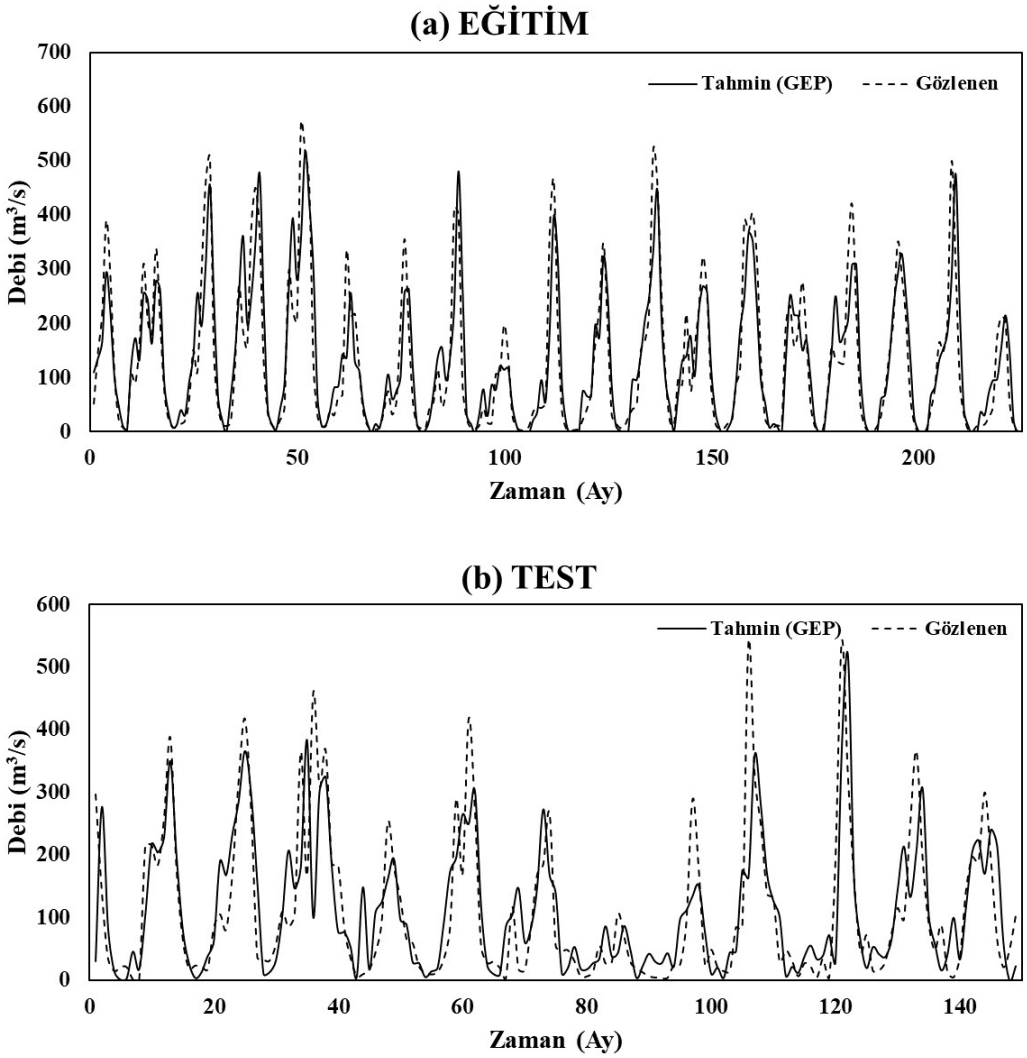
$$Q=(d_0-16.529)+\left(\sqrt[3]{\sqrt[3]{d_2-10.068d_1}}\right)^2+\sqrt[3]{\left(\sqrt[3]{1.758(1.353d_0)d_1}\right)^2} \qquad (4.3.)$$

Çizelge 4. 5. 17282-E26A012 için tüm durumlara ait eğitim ve test sonuçları

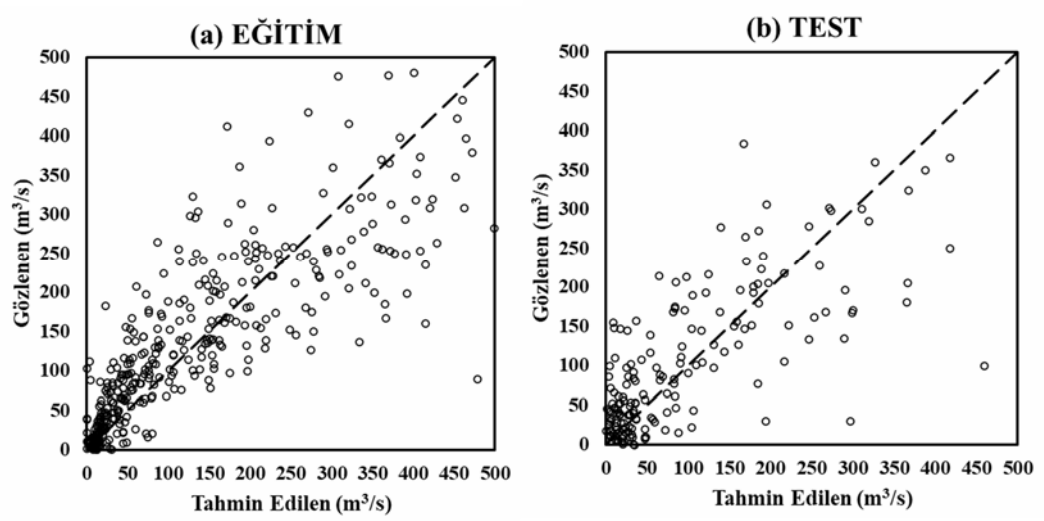
		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [6] (2)	EĞİTİM	0.3775	11870	0.378	0.376	12577.96	0.340
	TEST	0.2182	10901	0.152	0.234	11628.48	0.095
D2 [2] (3)	EĞİTİM	0.7170	5396.5	0.717	0.730	6770.43	0.645
	TEST	0.5416	6337.1	0.523	0.534	7385.24	0.425
D3 [7] (3)	EĞİTİM	0.7261	5224.5	0.720	0.735	6544.45	0.657
	TEST	0.5511	6068.2	0.528	0.550	7201.09	0.440
D4 [7] (3)	EĞİTİM	0.7385	4987.3	0.738	0.726	6502.57	0.659
	TEST	0.5610	5976.5	0.535	0.551	6962.82	0.458
D5 [4] (3)	EĞİTİM	0.7386	4984.5	0.739	0.725	6276.99	0.671
	TEST	0.5634	5939.5	0.538	0.557	6423.52	0.500
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.370	12019.19	0.370	0.363	13125.19	0.312
	TEST	0.230	10647.17	0.172	0.288	11209.37	0.128
D2	EĞİTİM	0.720	5347.82	0.720	0.689	6015.28	0.685
	TEST	0.530	6246.13	0.514	0.520	6348.53	0.506
D3	EĞİTİM	0.719	5362.69	0.719	0.696	5916.99	0.690
	TEST	0.544	6088.92	0.526	0.541	6083.48	0.527
D4	EĞİTİM	0.720	5346.63	0.720	0.695	5913.64	0.690
	TEST	0.552	5937.87	0.538	0.537	6129.02	0.523
D5	EĞİTİM	0.725	5260.03	0.724	0.697	5903.93	0.690
	TEST	0.555	6043.62	0.530	0.539	6114.67	0.523

En başarılı model olan GEP D4 modeline ait zamansal dağılım grafikleri Şekil 4.6.'da verilmiştir. Buna göre eğitim aşamasında 0 ile 100 m^3/sn arasındaki değerler ile daha yüksek değerdeki akımları başarılı bir şekilde yakınsamış ancak diğer akım verilerine göre pik değerde olan verileri yakınsamada yetersiz kalmıştır. Test aşamasında elde edilen değerler incelendiğinde, eğitime göre birçok pik debi başarılı bir şekilde yakınsamış fakat akım değerlerinin dağılım gösterdiği birçok noktada tahmin de gözlemden farklılık göstermiştir. Bununla beraber tahmin edilen akım gözlenen akım değerlerini çoğu yerde yakınsamıştır.

E26A012 istasyonuna ait GEP D4 modeli için eğitim ve test aşamasında değerlendirilen, gözlenen ile tahmin edilen akımların saçılım grafikleri Şekil 4.7.'de verilmiştir. Buna göre, eğitim aşamasında elde edilen uyuma test aşamasında ulaşılamamış ve modeller, test aşamasında eğitime göre daha zayıf kalmıştır.



Şekil 4. 6. GEP D4 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 7. GEP D4 için eğitim ve test aşamasına ait saçılım grafikleri

4.4. Model 4 (E26A012-17282)

E26A024 istasyonuna ait akım tahmini çalışmasında ANFIS, YSA, GEP ve ÇDR yöntemleri ile gerçekleştirilen analizler ile eğitim ve test sonuçları Çizelge 4.6.'da verilmiştir. Buna göre test süreci dikkate alınarak yapılan değerlendirmede, ANFIS ve GEP yöntemleri birbirleri ile yakın sonuçlar gösterse de D1 modeli dışında kalan diğer modellerde GEP yöntemi ANFIS yöntemine kıyasla daha başarılı olmuştur. D1 modeli ile en başarılı sonucu veren yöntem ANFIS'e ait olup bu modelde OKH değeri 335.36 iken R^2 değeri 0.223 olarak bulunmuştur.

D1 modele Q_{i-1} parametresinin eklenmesi ile model performansı yukarı yönde ivmelenme göstermiş ve R^2 0.733 değerine GEP ile ulaşmıştır. Tüm modeller arasından en başarılı performans gösteren model, 112.73 OKH değeri ile 0.736 R^2 değerlerine sahip olan GEP D5 model olarak belirlenmiştir. Modele önceki aylara ait yağış verileri ile akım verisinin eklenmesi, hata yüzdesini düşürmüş ve tahmin performansını artırmıştır. Modele ait GEP yöntemi ile akımı tahmin etmek için elde edilen ifade Denklem 4.4. ile verilmiştir.

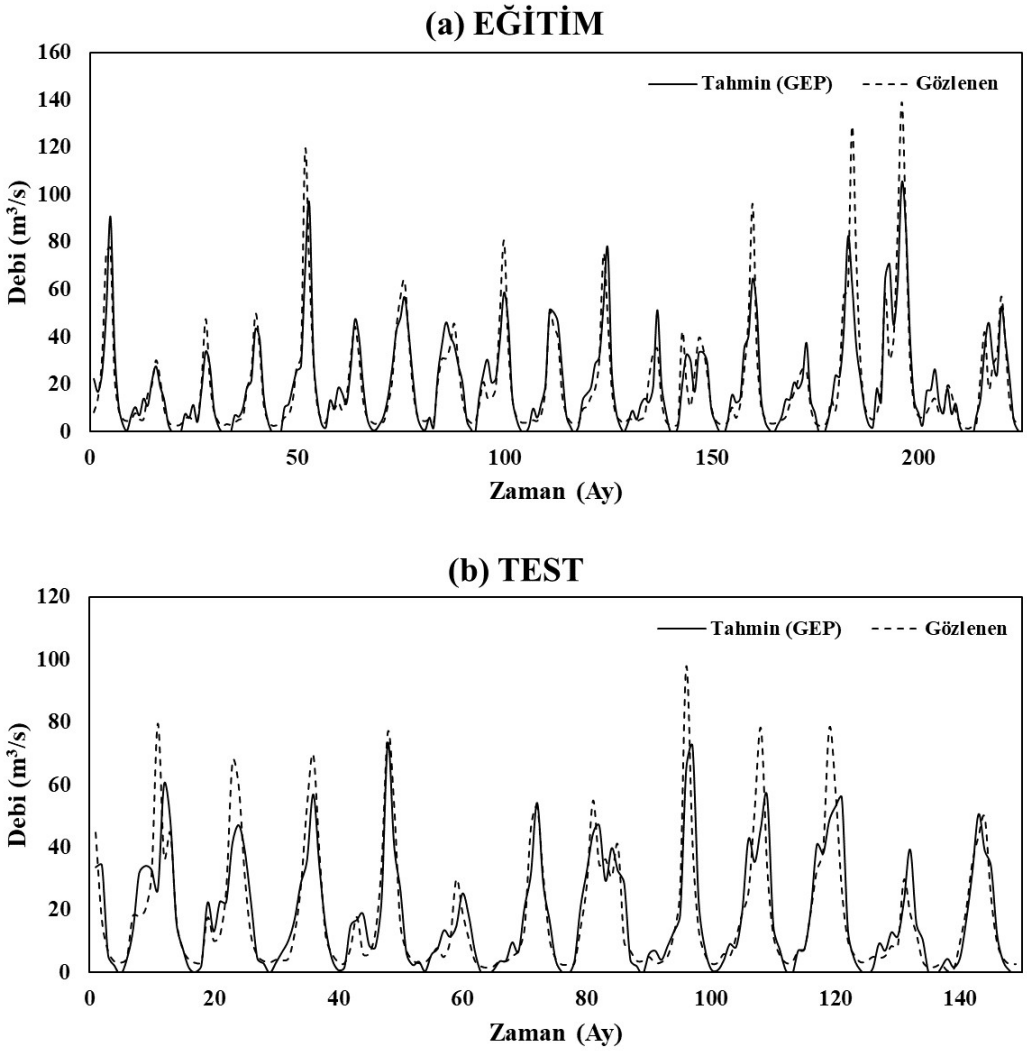
$$Q = \frac{\ln d_1^2 d_3}{14.04} + \sqrt[3]{d_0^3 + d_1 0.262 d_1} + \sqrt[9]{(5.843 - (2.107 d_0)(d_1^3 - d_2)} \qquad (4.4.)$$

Çizelge 4. 6.17210-E26A024 için tüm durumlara ait eğitim ve test sonuçları

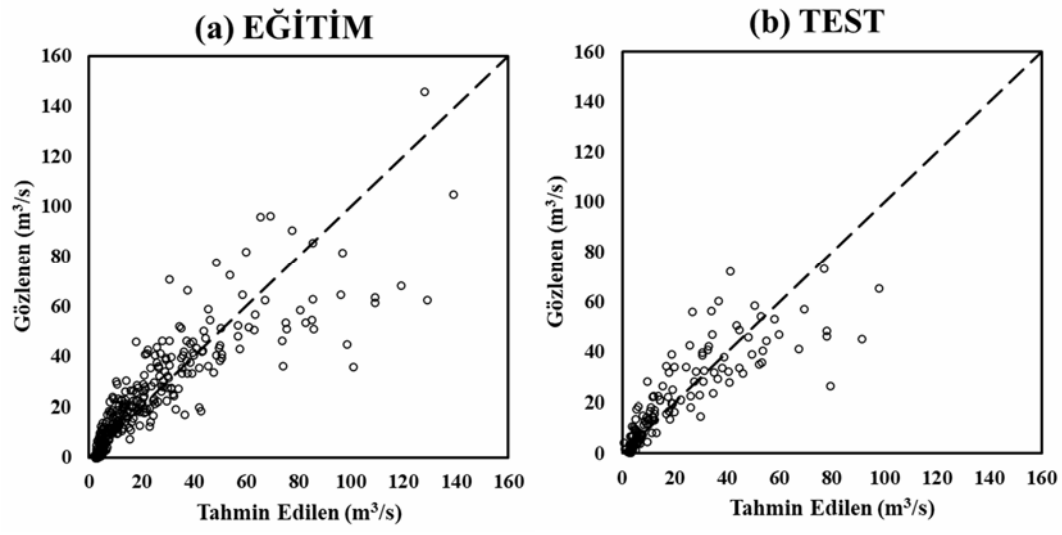
		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [5] (3)	EĞİTİM	0.3475	375.31	0.348	0.315	476.03	0.172
	TEST	0.2296	335.36	0.213	0.269	391.39	0.081
D2 [4] (3)	EĞİTİM	0.8076	110.66	0.808	0.791	231.58	0.597
	TEST	0.7118	123.05	0.711	0.692	224.22	0.474
D3 [9] (3)	EĞİTİM	0.7754	129.19	0.775	0.856	195.93	0.659
	TEST	0.7187	120.43	0.717	0.655	230.45	0.459
D4 [6] (3)	EĞİTİM	0.7910	120.19	0.791	0.811	222.80	0.613
	TEST	0.6954	130.77	0.693	0.736	214.68	0.496
D5 [5] (3)	EĞİTİM	0.7899	120.86	0.790	0.616	257.88	0.552
	TEST	0.6781	138.18	0.676	0.625	213.11	0.500
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.379	357.16	0.379	0.339	400.54	0.304
	TEST	0.225	343.56	0.194	0.232	368.37	0.135
D2	EĞİTİM	0.782	125.44	0.782	0.684	187.56	0.674
	TEST	0.733	113.85	0.733	0.622	163.93	0.615
D3	EĞİTİM	0.776	129.06	0.776	0.688	186.24	0.676
	TEST	0.724	117.97	0.723	0.632	160.16	0.624
D4	EĞİTİM	0.778	127.53	0.778	0.688	186.22	0.676
	TEST	0.732	114.67	0.731	0.633	159.74	0.625
D5	EĞİTİM	0.771	131.90	0.771	0.692	185.69	0.677
	TEST	0.736	112.73	0.735	0.634	160.42	0.624

GEP D5 modeline ait zamansal dağılım grafiği Şekil 4.8.'de eğitim ve test aşaması için verilmiştir. Buna göre hem eğitim hem de test aşamasında gözlenen ile tahmin edilen akım değerleri çoğu yerde başarılı performans göstermiştir. Eğitim aşaması test aşamasına göre daha uyumlu olsa da test aşamasında ulaşılan değerler de çoğu yerde yakınsamış ancak pik debilere ait değerlere ulaşmada düşüş yaşandığı gözlenmiştir.

E26A024 istasyonuna ait eğitim ve test aşamasında değerlendirilen, gözlenen ile tahmin edilen akımların saçılım grafikleri GEP D5 modeli için Şekil 4.9.'da verilmiştir. Grafiklerden, eğitim aşamasında elde edilen uyuma test aşamasında ulaşılamadığı ve modellerin, test aşamasında eğitime göre daha başarısız olduğu görülmüştür.



Şekil 4. 8. GEP D5 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 9. GEP D5 için eğitim ve test aşamasına ait saçılım grafikleri

4.5. Model 5 (E26A020-17285)

E26A020 istasyonuna ait akım tahmini çalışmasında ANFIS, YSA, GEP ve ÇDR yöntemleri ile gerçekleştirilen analizler ile eğitim ve test sonuçları Çizelge 4.7.'de verilmiştir. Test sonuçları dikkate alınarak yapılan değerlendirme neticesinde D1 modelde diğer yöntemlere kıyasla başarılı sonuç ANFIS yöntemi ile elde edilmiştir. Ancak modelde ulaşılan R^{2}'nin çok düşük çıkması ve NSE kriterinin eksili değerlerde kalması akımı tahmin etmek için modelin kullanılamayacağını göstermiştir. Yağış verisine, önceki aylara ait yağış ve akım verilerinin eklenmesi ile model performansı önemli derecede artış göstermiş ve hata yüzdelerinde azalış, R^2 değerinde ise artış yaşanmıştır. YSA yöntemi ile Durum 5'te en yüksek korelasyona (0.707) ulaşılmıştır ancak hata yüzdesinin ANFIS'in yukarısında kalması, YSA'yı geri planda bırakmıştır. Tüm modeller arasından en başarılı sonuç veren model, en düşük OKH değerine (883.14) sahip olan ANFIS ile D5 modelidir. Burada R^2, eğitim aşamasında 0.757 iken test aşamasında 0.695 değerlerini bulmuş, NSE ise eğitim ve test aşamalarında sırasıyla, 0.757 ve 0.688 değerlerini görmüştür. ANFIS'e ait diğer modeller incelendiğinde, sadece yağış verisi ile akımı tahmin etmede yetersiz kaldığını ancak önceki aylara ait yağış ve akım verilerinin eklenmesi ile model performansında artış yaşandığı gözlenmiştir.

D2 model incelendiğinde ANFIS ve ÇDR ile elde edilen sonuçların genel olarak birbirine yakın olduğu ancak daha düşük hata ile veri elde eden ANFIS'in ÇDR'ye göre daha başarılı olduğu görülmektedir. Bununla beraber D3 ve D4 modellerde nispeten başarılı sonuçlara GEP ile ulaşılmıştır. YSA yöntemi ise tüm modellerde diğer tahminlerin ulaştığı performansa erişmede yetersiz kalmıştır.

Akımı tahmin etmek için D3 ve D4 modellerine ait GEP yöntemi ile elde edilen denklemler sırasıyla Denklem 4.5. ve Denklem 4.6. ile verilmiştir.

$$Q = \sqrt[3]{(d_1 - 9.794)\,d_0\,d_2} + \frac{\sin\sqrt{d_1} + d_1}{e^{-2.381}} + \frac{\sqrt[3]{-9.514(2d_2)} - d_1}{1.136} + \frac{}{2.652} \qquad (4.5.)$$

$$Q = \sqrt{\frac{d_0}{d_1 + 21.17}}\, d_1 + \left(\frac{\sqrt[3]{d_3}\sqrt{d_2} + d_1}{2.414} \right) + 38.994 d_1 \qquad (4.6.)$$

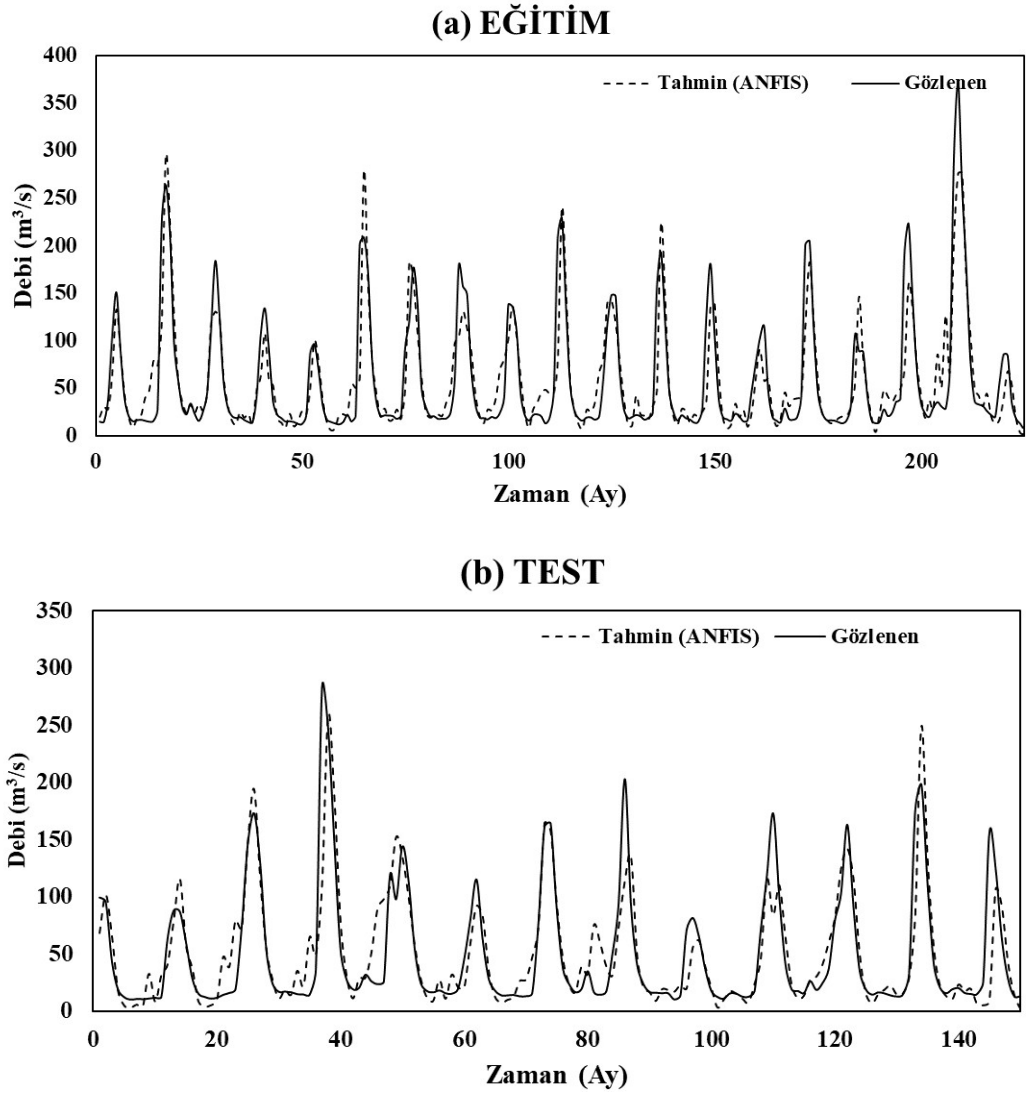
Çizelge 4.7. 17285-E26A020 için tüm durumlara ait eğitim ve test sonuçları

		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [2] (2)	EĞİTİM	0.0190	4490.50	0.019	0.013	4865.78	-0.063
	TEST	0.0221	2878.60	-0.018	0.011	3584.84	-0.268
D2 [6] (2)	EĞİTİM	0.7042	1354.20	0.704	0.736	1993.95	0.564
	TEST	0.5982	1154.20	0.592	0.616	1796.34	0.365
D3 [8] (2)	EĞİTİM	0.7177	1292.20	0.718	0.750	1852.19	0.595
	TEST	0.6459	1017.90	0.640	0.620	1728.79	0.389
D4 [4] (2)	EĞİTİM	0.7563	1115.60	0.756	0.769	1819.26	0.603
	TEST	0.6355	1057.90	0.626	0.687	1686.78	0.404
D5 [9] (2)	EĞİTİM	0.7568	1113.30	0.757	0.681	2013.28	0.560
	TEST	0.6953	883.14	0.688	0.707	1593.73	0.436
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.017	4499.78	0.017	0.015	5661.82	-0.237
	TEST	0.017	2897.63	-0.025	0.019	3768.15	-0.333
D2	EĞİTİM	0.693	1257.18	0.716	0.642	1692.84	0.630
	TEST	0.685	1422.89	0.682	0.550	1306.09	.0538
D3	EĞİTİM	0.757	1113.92	0.757	0.671	1586.80	0.653
	TEST	0.686	910.98	0.678	0.619	1130.95	0.600
D4	EĞİTİM	0.757	1114.58	0.757	0.674	1578.11	0.655
	TEST	0.680	940.75	0.667	0.627	1113.36	0.606
D5	EĞİTİM	0.755	1122.19	0.755	0.673	1566.36	0.658
	TEST	0.681	947.39	0.665	0.619	1122.75	0.603

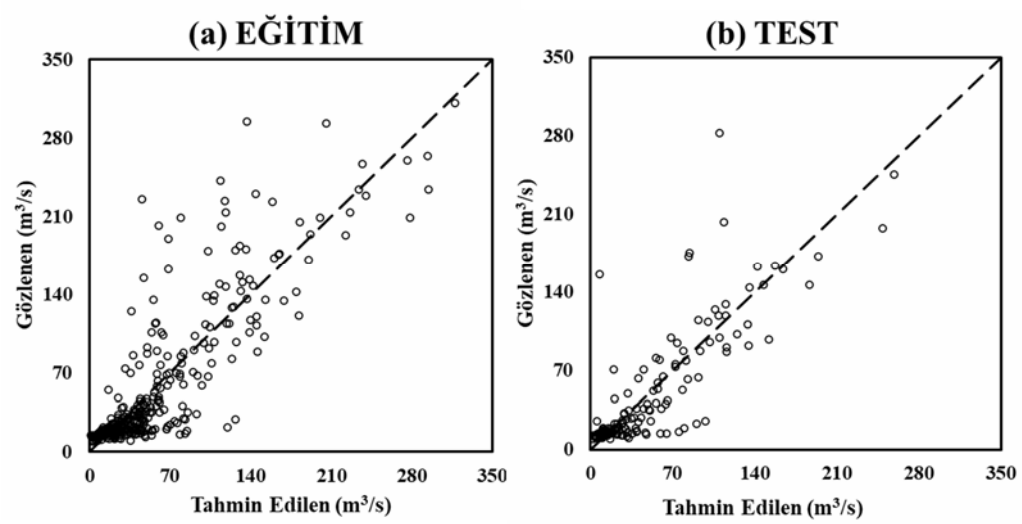
OKH değerine göre en başarılı tahmini yapan ANFIS ile D5 modeline ait zamansal dağılım grafiği Şekil 4.10'da verilmiştir. Buna göre, saçılım grafiğine paralel olarak gözlenen değerlerin tahmin edilen değerlere yakın olduğu, akım değerlerinin birçok noktada yakınsadığı ancak ani değişikliklerin olduğu değerlerde tahmin edilen akımların gözlemden uzaklaştığı değerlendirilmiştir.

E26A020 istasyonu ANFIS D5 modeli için gözlenen ve tahmin edilen akımların eğitim ve test aşamaları için saçılım grafikleri Şekil 4.11'de verilmiştir. Önceki yıllara ait yağış ve akım verilerinin eklenmesi, saçılım grafiklerinde de pozitif yönde eğilim göstermiş ve değerler birbirlerini genel olarak yakınsayabilmiştir ancak debi değerlerinin aşırı yüksek olması uyum sağlamada zayıf kalındığını göstermiştir. Grafikler incelendiğinde, eğitim aşamasında elde edilen uyuma test aşamasında

ulaşılamadığı ve modellerim eğitim aşamasında teste göre daha başarılı olduğu gözlenmiştir.



Şekil 4. 10. ANFIS D5 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 11. ANFIS D5 için eğitim ve test aşamasına ait saçılım grafikleri

4.6. Model 6 (E26A030-17285)

E26A030 numaralı AGİ'ye ait akımı tahmin etmek için ANFIS, YSA, GEP ve ÇDR yöntemleri ile yapılan analizler Çizelge 4.8.'de verilmiştir. Çalışma kapsamında tüm modellerde, eğitim aşamasında veri setinin %70'i (225 veri), test aşamasında ise veri setinin %30'u (96 veri) kullanılmıştır. Buna göre, OMGH değerleri dikkate alınarak sonuçlar incelendiğinde YSA, GEP ve ÇDR yöntemleri ile elde edilen sonuçların genel olarak birbirine yakın değerlerde olduğu görülmüştür. D1 modeli ile başarılı sonuca 1229.07 OKH değeri ile GEP yöntemi ile ulaşılmıştır ancak R^2'nin çok düşük çıkması, NSE kriterinin ise eksili değerlerde kalması akımı tahmin etmek için sadece yağış verisinin kullanılmayacağını göstermiştir.

Modele, önceki aylara ait akım verisinin eklenmesi ile model performansı pozitif yönde ivmelenme göstermiş ve OKH değeri 533'e kadar gerilemiştir. Eğitim aşamasında 0.560, test aşamasında 0.524 R^2 değerlerine sahip olan D2 modeli en başarılı sonucu ÇDR ile elde etmiştir. D2 modele akım ile beraber önceki aya ait yağış verisinin eklenmesi model performansı daha da artırmış ve OKH değerleri daha da azalmış bununla beraber R^2 de test aşamasında 0.598 değerine ulaşmıştır.

YSA yöntemlerinde R^2 değeri GEP yönteminden daha iyi sonuçlar verse de OKH değerleri GEP'in yukarısında kalmıştır. D4 ve D5 modellere ait veriler incelendiğinde D4 modelde başarıya ANFIS ile ulaşılmış, D5 modelde ise en düşük hataya sahip olup en iyi uyum sağlayan yöntemin ÇDR olduğu görülmüştür. Akımı tahmin etmek için ÇDR D5 modeline ait başarılı sonucu veren ifade Denklem 4.7. ile verilmiştir.

$$Q = 0.119P_i + 0.628Q_{i-1} + 0.102P_{i-1} + 0.052P_{i-2} - 0.011P_{i-3} \quad (4.7.)$$

Tüm modeller arasından en başarılı sonuca en düşük OKH değerine sahip ANFIS D3 model ile ulaşılmıştır. Burada (P_i), (P_{i-1}) ve (Q_{i-1})'e ait veriler kullanılmıştır.

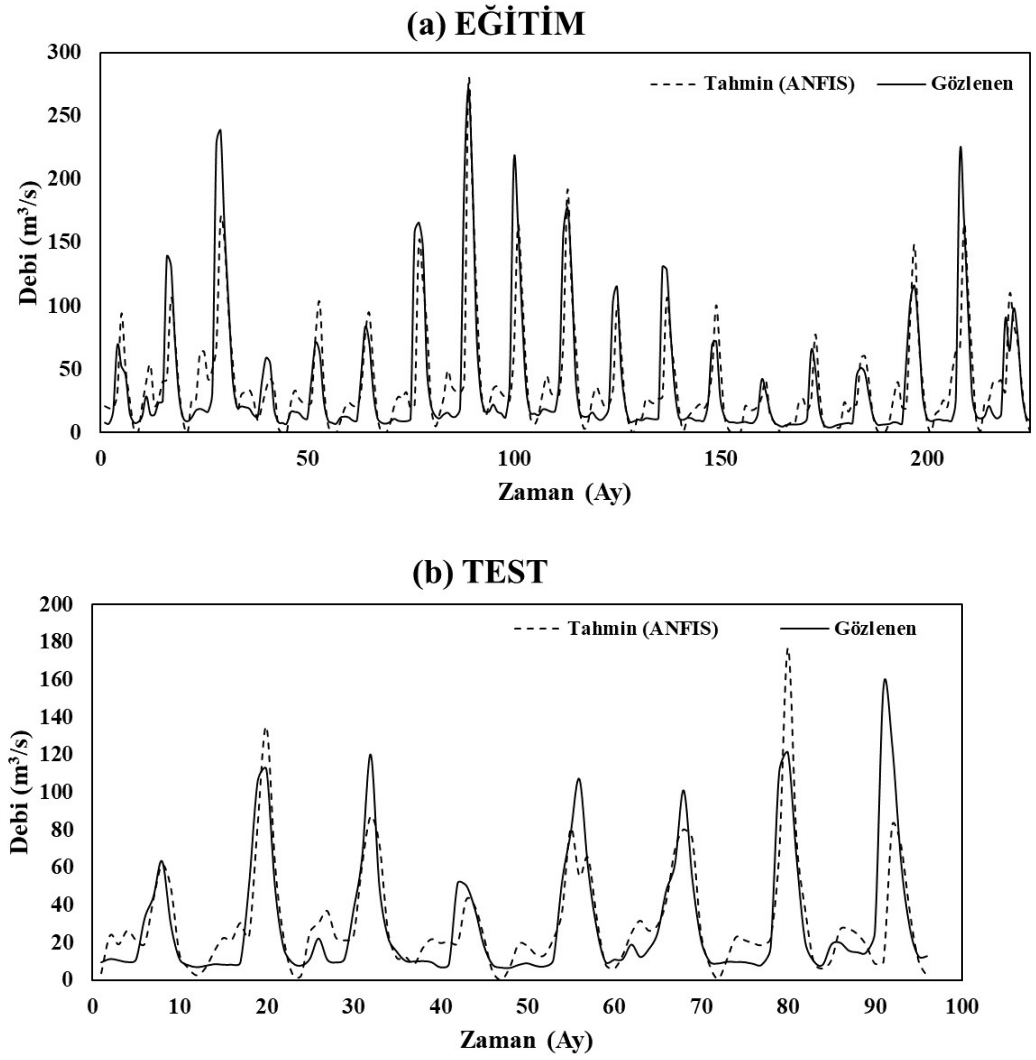
Çizelge 4. 8. 17285-E26A030 için tüm durumlara ait eğitim ve test sonuçları

		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [2] (3)	EĞİTİM	0.0391	2454.1	0.039	0	2618.93	-0.025
	TEST	0.0015	1259.5	-0.136	0.069	1255.29	-0.132
D2 [5] (3)	EĞİTİM	0.6458	905.29	0.646	0.659	1287.27	0.496
	TEST	0.5077	567.34	0.488	0.514	933.26	0.158
D3 [7] (3)	EĞİTİM	0.6324	938.89	0.632	0.509	1453.21	0.431
	TEST	0.5975	456.05	0.589	0.557	902.27	0.186
D4 [8] (3)	EĞİTİM	0.6154	982.29	0.615	0.697	1129.88	0.558
	TEST	0.5841	474.39	0.572	0.481	891.85	0.196
D5 [7] (3)	EĞİTİM	0.6463	903.27	0.646	0.643	1310.68	0.487
	TEST	0.5462	523.69	0.528	0.534	897.57	0.191
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.045	2440.05	0.045	0.027	2898.95	-0.135
	TEST	0	1229.07	-0.108	0.018	1429.33	-0.289
D2	EĞİTİM	0.704	766.50	0.700	0.560	1135.44	0.555
	TEST	0.424	657.91	0.407	0.524	533.09	0.519
D3	EĞİTİM	0.700	767.61	0.699	0.580	1094.03	0.572
	TEST	0.552	505.71	0.544	0.571	486.53	0.561
D4	EĞİTİM	0.678	845.06	0.669	0.584	1087.82	0.574
	TEST	0.470	594.99	0.463	0.562	497.21	0.552
D5	EĞİTİM	0.131	2268.93	0.112	0.583	1087.43	0.574
	TEST	0.181	914.22	0.176	0.561	497.43	0.551

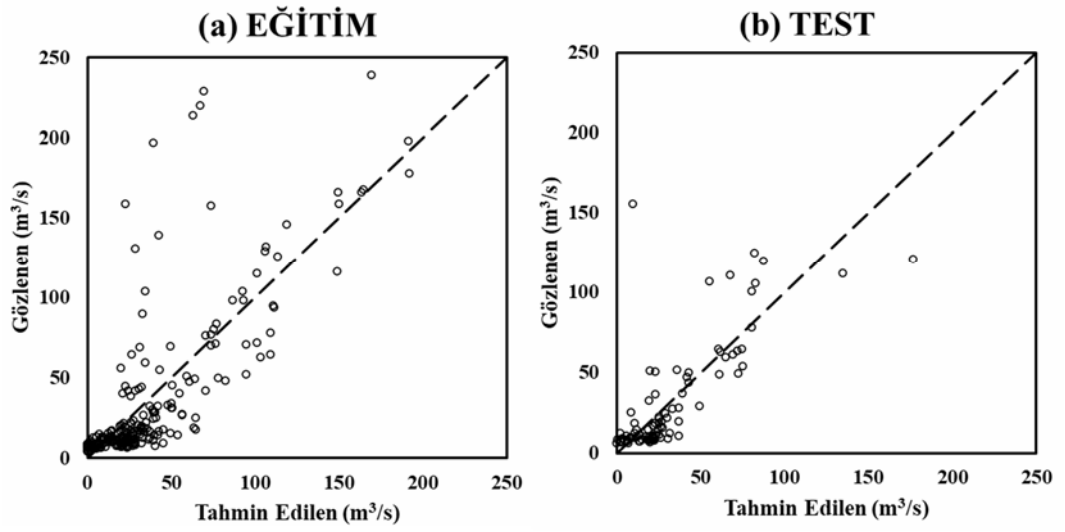
En başarılı sonucu veren ANFIS D3 modele ait zamansal dağılım grafiği Şekil 4.12. ile verilmiştir. Buna göre, akımı tahmin ederken belirlilik katsayısı göz önüne alındığında elde edilen değerin 0.598 olması, grafikte de kendini göstermektedir. Debi

değerleri 0 ile 290 m^3/sn arasında değişmektedir. 0 ile 15 m^3/sn arasında değişen debi değerlerinde tahmin edilen değerler gözlenen değerlerin yukarısında kalmakla beraber çok yüksek debilerde ise tahmin, gözlemden daha düşük değerleri yakalayabilmiştir.

E26A030 istasyonuna ait ANFIS D3 modeli için eğitim ve test aşamasında değerlendirilen, gözlenen ile tahmin edilen akımların saçılım grafikleri Şekil 4.13.'te verilmiştir. Modele ait saçılım grafikleri incelendiğinde, eğitim aşamasının test aşamasına göre daha uyumlu olduğu ve genel olarak düşük debiye sahip olan değerlerde başarılı sonuçlara ulaşıldığı ancak yüksek debiye ait verilerde uyumdan kaçıldığı gözlenmiştir.



Şekil 4. 12. ANFIS D3 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 13. ANFIS D3 için eğitim ve test aşamasına ait saçılım grafikleri

4.7. Model 7 (E26A030-17920)

E26A030 istasyonuna bir önceki çalışmada 17285 MGİ ile akım tahmini çalışması yapılmış ve aynı Thiessen içerisinde kalıp belirli mesafelerde bulunan MGİ'lerin AGİ'ler üzerindeki etkisini ortaya koyabilmek adına 17290 numaralı MGİ kullanılarak da çalışma yapılmıştır. 17290 numaralı MGİ verileri ile ANFIS, YSA, GEP ve ÇDR yöntemleri kullanılarak benzer şekilde Çizelge 4.2.'deki beş model oluşturularak analiz yapılmıştır. Analize ilişkin sonuçlar Çizelge 4.9.'da verilmiştir. Tüm yöntemler açısından D1 modelde en düşük OKH (1124.4), ANFIS yöntemi ile elde edilmiştir ancak R^2'nin çok düşük olması ve NSE kriterin eksili değerde kalması sadece yağıştan akımı tahmin etmenin mümkün olmayacağını göstermiştir. D2 modelde, OKH değeri GEP yönteminde en düşük (404.23) olup test aşamasına ait R^2 0.686 değerindedir. Modele ait NSE kriteri 0.635 değerinde olup performans kriterlerinin D1 modele göre önemli derecede artış göstermesi önceki aya ait akım verilerinin de akım tahmini yaparken kullanılmasının çalışmayı olumlu yönde artırdığını göstermiştir. ANFIS ve YSA yöntemlerin modeller üzerindeki sonuçlarına bakıldığında, R^2'nin ÇDR'ye göre daha iyi uyum yakaladığı, GEP'e ise yakın değerlerde kaldığı görülmüştür ancak hata kriterinin ÇDR ve GEP'in yukarısında kalması, değerlendirme yapmak için doğru olmayacağını göstermiştir.

Çizelge 4.8. ile Çizelge 4.9.'da verilen değerler karşılaştırıldığında 17920 MGİ'ye ait değerlerin, 17285 numaralı MGİ ile elde edilen sonuçlara test aşamasında nispeten yakın olduğu görülmüştür. 17920 istasyonda GEP D3 model, tüm modeller arasından en başarılı sonucu vermiştir. Buna göre, R^2 eğitim aşamasında 0.722 olup test aşamasında 0.669 değerlerini bulmuştur. OKH, eğitimde 712.76 olup testte 385.59'a kadar gerilemiştir. NSE kriteri ise testte 0.652 değerini bulmuş olup akımı tahmin etmek için önceki aylara ait yağış ve akım verilerinin kullanılmasının çalışma için kullanılabileceğini göstermiştir.

Akımı tahmin etmek için en başarılı sonucu veren GEP D3 modele ait elde edilen ifade Denklem 4.8. ile verilmiştir.

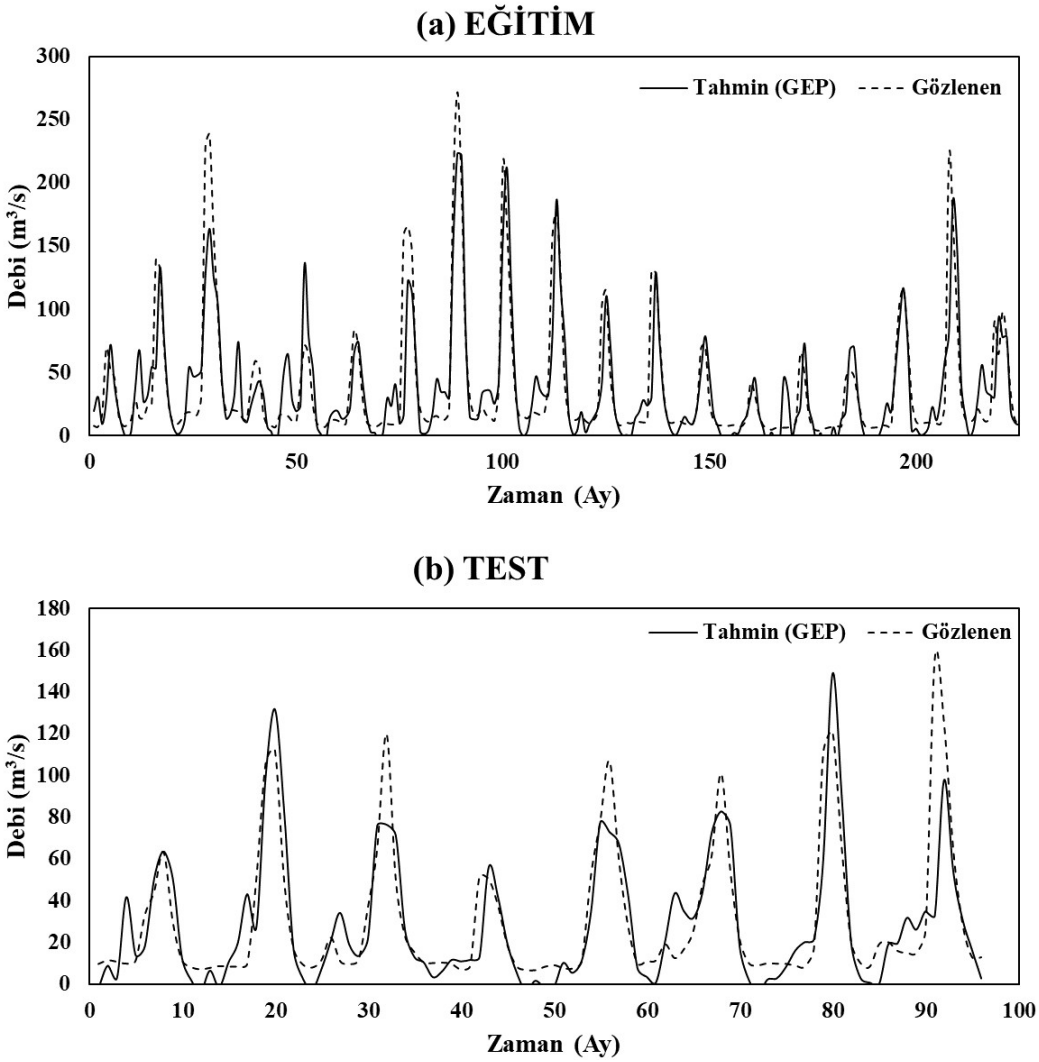
$$Q = \ln d \sqrt[3]{6.321 d\, d \quad d + 9.67} + \sqrt{3.42 d \; d + d} + \sqrt[9]{0.539 + d} \sqrt{d^3} \qquad (4.8.)$$

Çizelge 4. 9. 17920-E26A030 için tüm durumlara ait eğitim ve test sonuçları

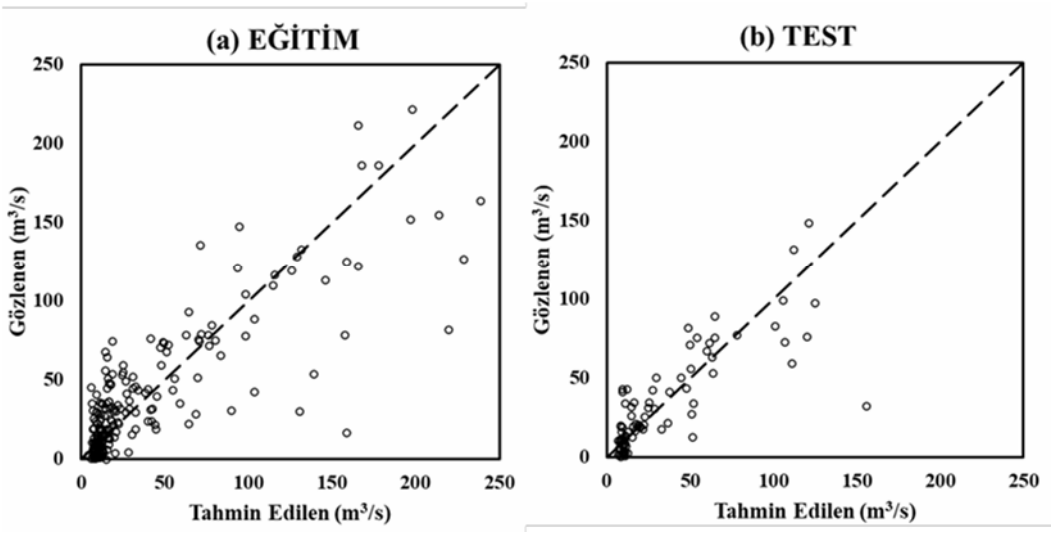
		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [7] (3)	EĞİTİM	0.0480	2431.3	0.048	0.051	2612.23	-0.023
	TEST	0.0395	1124.4	-0.014	0.063	1522.46	-0.373
D2 [7] (3)	EĞİTİM	0.6955	777.62	0.696	0.705	1110.63	0.565
	TEST	0.4861	673.37	0.393	.0456	971.57	0.124
D3 [1] (3)	EĞİTİM	0.6992	768.24	0.699	0.609	1450.08	0.432
	TEST	0.6046	487.83	0.560	0.606	915.75	0.174
D4 [2] (3)	EĞİTİM	0.7009	763.96	0.701	0.660	1241.45	0.514
	TEST	0.6382	466.84	0.579	0.602	820.80	0.260
D5 [4] (3)	EĞİTİM	0.7199	715.41	0.720	0.614	1362.19	0.467
	TEST	0.6310	595.69	0.463	0.573	873.13	0.213
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.148	2178.77	0.147	0.019	2974.06	-0.165
	TEST	0	1356.65	-0.223	0.036	1338.12	-0.207
D2	EĞİTİM	0.699	771.82	0.698	0.557	1142.09	0.553
	TEST	0.686	404.23	0.635	0.547	512.89	0.537
D3	EĞİTİM	0.722	712.76	0.721	0.592	1068.12	0.582
	TEST	0.669	385.59	0.652	0.608	454.47	0.590
D4	EĞİTİM	0.697	780.29	0.694	0.597	1059.36	0.585
	TEST	0.689	434.46	0.608	0.607	458.07	0.587
D5	EĞİTİM	0.679	820.23	0.679	0.596	1056.28	0.586
	TEST	0.597	465.99	0.580	0.605	457.16	0.588

En başarılı sonuç olan GEP D3 modele ait gözlenen ve tahmin edilen değerlerin eğitim ve test aşamalarında zamansal dağılım grafikleri Şekil 4.14'te verilmiştir. Buna göre hem eğitim hem test aşamasında 0 ile 10 m^3/sn arasında kalan değerlerde tahmin değerleri, gözlem değerlerinin aşağısında kalmış ve model performansının yetersiz kaldığı görülmüştür. Çok yüksek değerde olan akım değerlerinde tahmin edilen daha aşağıda kalmış ancak genel olarak akımı tahmin etmede model, gözlem değerlerine yakın sonuçlar vermiştir.

E26A030 istasyonuna ait gözlenen ve tahmin edilen akımların eğitim ve test aşamaları için saçılım grafikleri GEP D3 modeli için Şekil 4.15.'te verilmiştir. Grafikler incelendiğinde, eğitim ve test aşamalarına ait grafiklerin birbirleriyle uyum sağladığı, büyük debi değerleri dışında kalan verilerin genel olarak uyumlu olduğu sonucuna ulaşılmaktadır.



Şekil 4. 14. GEP D3 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 15. GEP D3 için eğitim ve test aşamasına ait saçılım grafikleri

4.8. Model 8 (E26A031-17285)

E26A031 numaralı akım gözlem istasyonuna ait aylık akım değerlerinin, 17285 numaralı istasyona ait aylık yağış verileri kullanılarak, beş farklı girdi kombinasyonu ile ANFIS, YSA, GEP ve ÇDR yöntemi ile tahmin sonuçları Çizelge 4.10.'da verilmiştir. Çalışma kapsamında tüm modellerde eğitim aşamasında verilerin %70'i (200 veri), test aşamasında ise veri setlerinin %30' u (85 veri) kullanılmıştır.

Tüm durumlar dikkate alınarak sonuçlar incelendiğinde, D1 modeline ait belirlilik katsayısının (R^2) çok düşük olduğu ve bu yüzden akımı tahmin etmek kullanılmasının uygun olmadığı değerlendirilmektedir. Kullanılan diğer yöntemlerle kıyaslandığında en düşük OKH değerini vermesi ile ANFIS yönteminin D3 model hariç tüm durumlarda, akımı tahmin etmede diğer yöntemlere göre daha iyi performans sergilediği görülmektedir. Akımı tahmin etmede en başarılı model, en düşük OKH değerine sahip (119.44), aylık toplam yağış verisine (P_i) ek olarak bir ay önceki akım verileri (Q_{i-1}) ile bir ay önceki aylık toplam yağış verileri (P_{i-1}) ve iki ay önceki aylık toplam yağış verileri (P_{i-2}) kullanılarak oluşturulan ANFIS yöntemine ait D4 modeli olarak belirlenmiştir. ANFIS yöntemi ile oluşturulan D4 modelinde, belirlilik katsayısının tüm yöntemler ile oluşturulan modellerin hepsinden daha iyi olduğu (0.755) görülmüştür. R^2 ve OKH değerlerinin yanı sıra 0 ile 1 arasında değerler alan NSE değeri de incelendiğinde, bu değerin 0.753 oluşu modelin performansının akımı tahmin etmede kabul edilebilir olduğunu göstermektedir. Tüm modellere ait sonuçlar incelendiğinde, YSA, ÇDR ve GEP ile oluşturulan modellerin birbirlerine yakın sonuçlar verdiği görülmüştür. Kullanılan yöntemler arasında nispeten başarısız olan yöntem, daha yüksek OKH değerine sahip olduğu görülen YSA'dır. Tüm durumlarda OKH değerlerinin nispeten yüksek oluşu tahmin edilen akım değerlerinin büyük değerlere sahip olması olarak değerlendirilmiştir.

Diğer yöntemlere kıyasla başarılı sonuç veren GEP D3 modeline ait akışı tahmin etmek için elde edilen ifade, Denklem 4.9.'da verilmiştir.

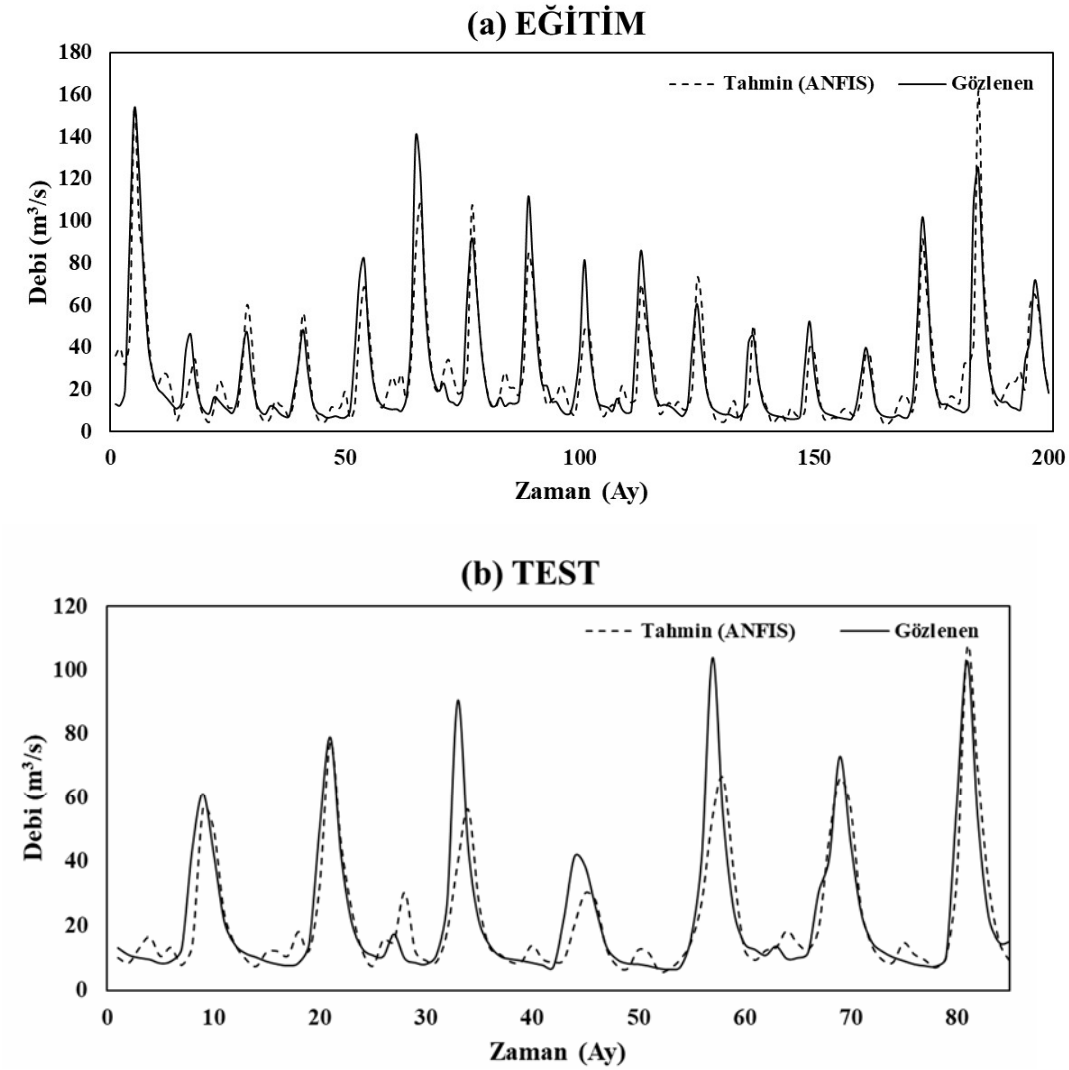
$$Q = \sqrt[9]{\left(d_2^{\,2}\left(d_0 - d_1\right)\right)^2(-10.47)} + \sqrt[9]{10.49(d_0 - 1)^2(-10.49)} + \sqrt[3]{\left(d_2 + 10.03\right)d_1\left(d_1 + 1.176d_0\right)} \qquad (4.9.)$$

Çizelge 4. 10. 17285-E26A031 için tüm durumlara ait eğitim ve test sonuçları

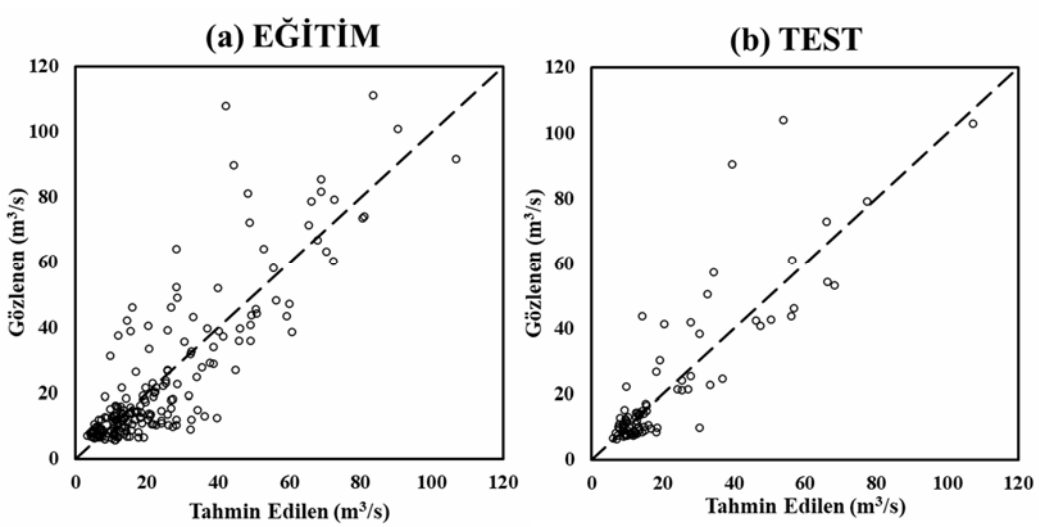
		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [1] (2)	EĞİTİM	0.0088	771.00	0.009	0.0034	827.75	-0.064
	TEST	0.0055	504.14	-0.044	0.0009	613.75	-0.271
D2 [7] (3)	EĞİTİM	0.7706	178.48	0.771	0.7556	305.14	0.608
	TEST	0.5881	200.72	0.584	0.5817	320.50	0.336
D3 [4] (2)	EĞİTİM	0.7892	163.93	0.789	0.8058	282.97	0.636
	TEST	0.7081	151.36	0.687	0.6392	280.86	0.419
D4 [6] (2)	EĞİTİM	0.7951	159.37	0.795	0.7128	338.86	0.564
	TEST	0.7546	119.44	0.753	0.6800	268.99	0.443
D5 [2] (3)	EĞİTİM	0.7902	163.21	0.790	0.8122	269.76	0.653
	TEST	0.6761	168.92	0.650	0.6569	269.56	0.442
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.1285	680.14	0.126	0.0001	1121.29	-0.442
	TEST	0.0002	553.77	-0.146	8E-07	733.00	-0.517
D2	EĞİTİM	0.7377	204.12	0.738	0.5899	321.48	0.587
	TEST	0.5555	217.38	0.550	0.4253	280.31	0.420
D3	EĞİTİM	0.7992	171.14	0.780	0.6404	285.51	0.663
	TEST	0.7162	142.52	0.705	0.5504	218.98	0.547
D4	EĞİTİM	0.7712	180.39	0.768	0.6441	282.83	0.636
	TEST	0.5940	199.34	0.587	0.5483	220.02	0.545
D5	EĞİTİM	0.7873	166.50	0.786	0.6441	282.83	0.636
	TEST	0.6219	201.02	0.584	0.5483	220.02	0.545

ANFIS ile en başarılı sonucu veren D4 modeline ait zamansal dağılım grafiği (Şekil 4.16.), eğitim aşamasında tahmin edilen akıma ait değerlerin ortalama 5 m^3/s ile 160 m^3/s arasında değiştiğini ifade etmektedir. Test aşamasında ise değerler 5 m^3/s ile 100 m^3/s arasında değişmektedir. ANFIS, pik debilerde ve düşük değerdeki verilerde tahminden uzaklaşsa da genel olarak modelin tahmin başarısını yakalamada iyi sonuç vermiştir.

E26A031 istasyonuna ait gözlenen ve tahmin edilen akımların eğitim ve test aşamaları için saçılım grafikleri ANFIS D4 için Şekil 4.17'de verilmiştir. Modele ait gözlenen ve tahmin edilen akım verilerinin saçılım ve zamansal dağılım grafiği (Şekil 4.16.), tahminin hangi değer aralığında yakınsadığı ve uzaklaştığını göstermektedir. E26A031-17285 için verilen saçılım grafiklerinden hem eğitim hem de test aşamasında gözlenen akım ile tahmin edilen akım arasındaki ilişkinin, daha düşük değerdeki akım verilerini tahmin ederken daha başarılı olduğu sonucuna ulaşılmaktadır.



Şekil 4. 16. ANFIS D4 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 17. ANFIS D4 için eğitim ve test aşamasına ait saçılım grafikleri

4.9. Model 9 (E26A031-17880)

E26A031 AGİ'ye ait akımı tahmin etmek için beş farklı model oluşturularak ANFIS, YSA, GEP ve ÇDR yöntemleri ile analizler yapılmış ve ilgili sonuçlar Çizelge 4.11.'de verilmiştir. Buna göre, ANFIS ve YSA yöntemleri ile yapılan analizlerde belirlilik katsayısına ilişkin değerlerin birbirine yakın olduğu ancak YSA'ya ait OKH değerlerinin ANFIS'in yukarısında kaldığı görülmüştür. ANFIS'e ait analiz sonuçları GEP ve ÇDR'ye yakın sonuçlar verse de akımı tahmin etmede sergilediği performans her iki yöntemin gerisinde kalmıştır. Sadece P_i değeri kullanılarak oluşturulan D1 modelinde nispeten başarılı sonucu veren ANFIS yöntemi olmuştur ancak modele ait R^2'nin çok düşük çıkması ve Nash-sutcliffe verimliliğin (NSE) eksili değerler alması performans değerlendirmede yeterli olmayacağını göstermiştir.

P_i verisine Q_{i-1} verisinin eklenmesi ile oluşturulan D2 modelde R^2'ye ait değerlerin dikkat çekici şekilde artış gösterdiği ve OKH değerlerinin de önemli derecede azaldığı görülmüştür. GEP'e ait D2 modelde OKH, eğitimde 237.76 olup testte 282.81 değerlerini bulmuş ve NSE de buna bağlı olarak artmıştır. D3 modele bakıldığında, ANFIS sonuçları R^2 ve OKH kriterleri ile GEP ve ÇDR'den daha iyi sonuçlar vermiş ve gösterdiği performans ile diğer üç modelin önüne geçmiştir. GEP, D5 modelde de tüm yöntemlerden daha iyi sonuçlar vermiş ve belirlilik katsayısı eğitimde 0.808 olup testte 0.577 değerlerini bulmuştur. Buna bağlı olarak OKH da R^2 ile uyum göstermiş ve modelin eğitim aşamasında test aşamasına göre daha başarılı performans gösterdiği görülmüştür. Tüm modeller arasından en düşük OKH değerine (187.28) sahip olan model, GEP D4 model olarak ön plana çıkmaktadır. Burada, eğitimde 0.763 olan R^2, testte 0.618 değerlerinde olup NSE de eğitim ve testte sırasıyla 0.762 ile 0.612 sonuçlarını vermiştir. Önceki aylara ait akım ve yağış verilerinin kullanılmasının akım tahmini çalışması yapmak için önemli parametreler olduğu açıktır.

En düşük OKH değerine sahip olup en başarılı sonuç verdiği değerlendirilen GEP D4 modele ait akışı tahmin etmek için elde edilen ifade Denklem 4.10. ile verilmektedir.

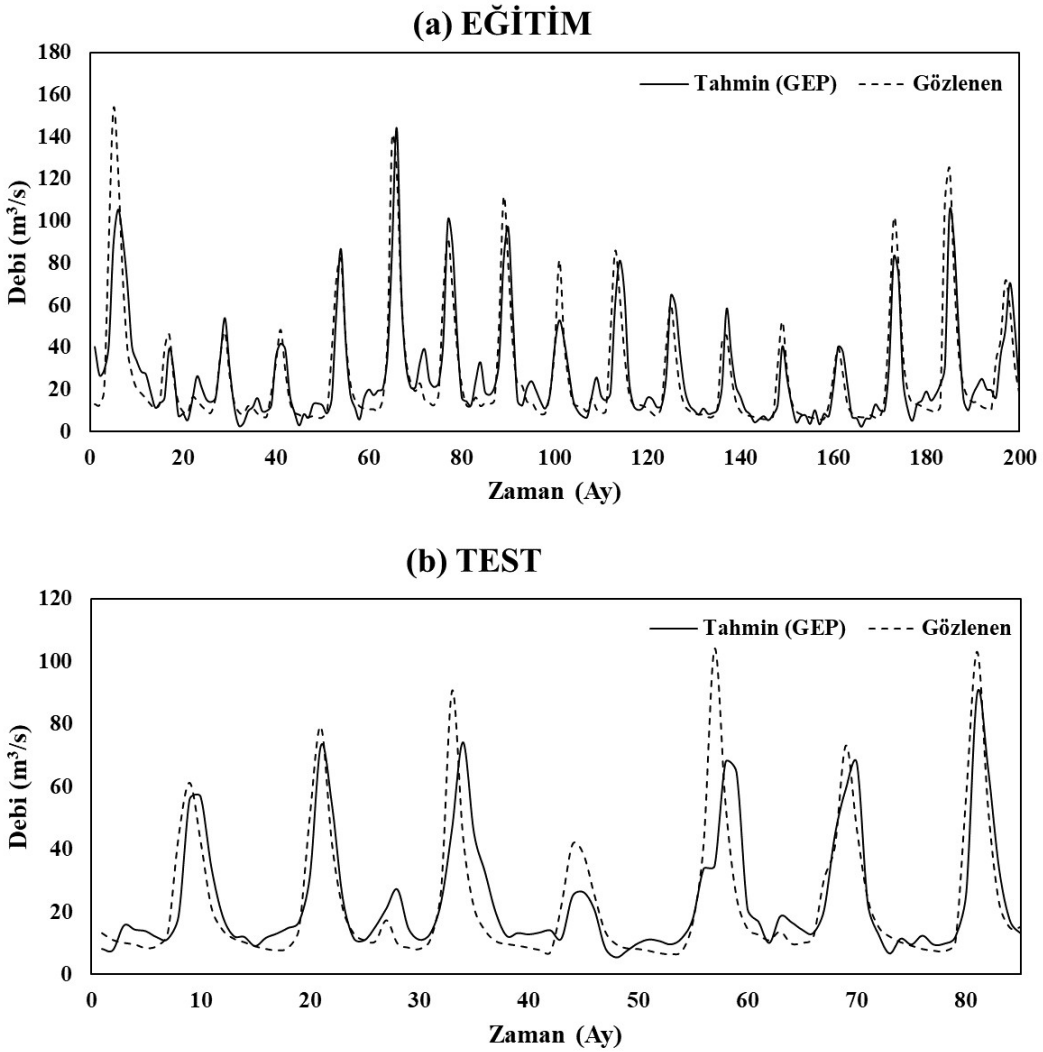
$$Q=\left(\sqrt[3]{d_3-d_1}-\sqrt{d_2}\right)-\sqrt[4]{d_3}+\left(\frac{d_1 d_2}{1.104}+31.13+d_1\right)+\sqrt{\frac{d_1-4.77}{3.177\,d^0}}-\sqrt{d^2} \qquad (4.10.)$$

Çizelge 4. 11. 17880-E26A031 için tüm durumlara ait eğitim ve test sonuçları

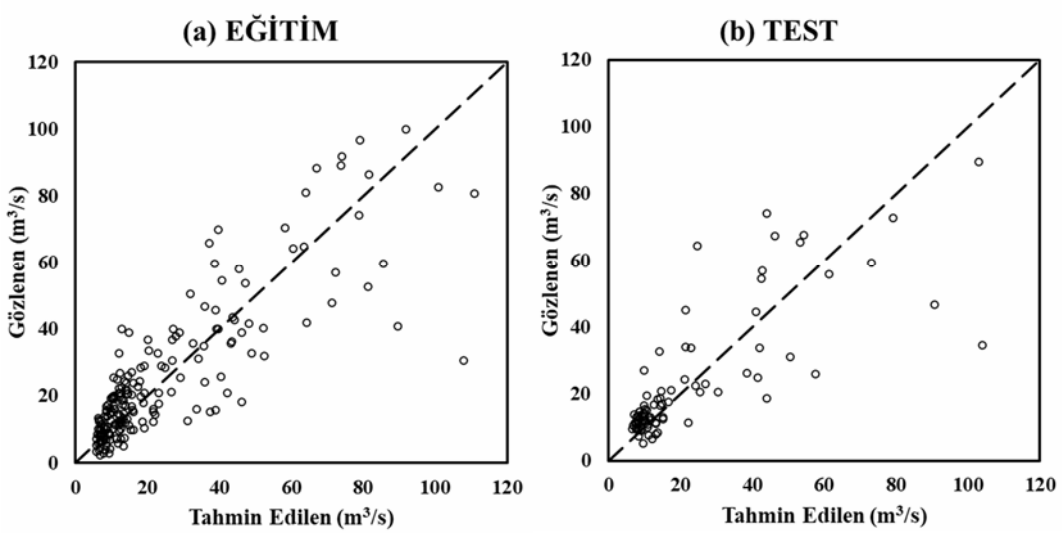
		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [1] (3)	EĞİTİM	0.0685	724.58	0.068	0.026	810.82	-0.042
	TEST	0.0184	503.22	-0.042	0.013	586.97	-0.215
D2 [9] (3)	EĞİTİM	0.6627	262.38	0.663	0.631	365.92	0.530
	TEST	0.4533	288.38	0.403	0.350	384.82	0.203
D3 [10] (3)	EĞİTİM	0.7484	195.69	0.748	0.751	308.11	0.604
	TEST	0.5401	224.32	0.536	0.548	324.83	0.328
D4 [10] (3)	EĞİTİM	0.7468	196.91	0.747	0.774	246.95	0.683
	TEST	0.5466	224.74	0.535	0.640	243.29	0.496
D5 [7] (3)	EĞİTİM	0.7653	182.27	0.765	0.745	315.40	0.595
	TEST	0.5432	229.07	0.526	0.616	300.74	0.377
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.179	638.33	0.179	0.054	888.28	-0.142
	TEST	0.003	600.63	-0.243	0.024	627.29	-0.299
D2	EĞİTİM	0.694	237.76	0.694	0.633	291.18	0.626
	TEST	0.453	282.81	0.415	0.420	288.03	0.404
D3	EĞİTİM	0.425	451.09	0.420	0.6692	254.59	0.673
	TEST	0.450	271.66	0.438	0.525	236.52	0.510
D4	EĞİTİM	0.763	184.79	0.762	0.691	254.54	0.673
	TEST	0.618	187.28	0.612	0.522	237.98	0.507
D5	EĞİTİM	0.808	149.31	0.808	0.698	243.34	0.687
	TEST	0.577	212.86	0.559	0.514	240.29	0.503

GEP D4 modele ait eğitim ve test aşamaları için zamansal dağılım grafiği Şekil 4.18.'de verilmiştir. Burada, tahmin değerlerinin gözlem değerlerine hangi değer aralığında yakınsadığı ve uzaklaştığı görülmektedir. Eğitim aşamasında, tahmin edilen değerlerin gözlenen akım değerlerine test aşamasına göre daha iyi uyum sağladığı görülmektedir.

E26A031 istasyonu GEP D4 modeline ait gözlenen ve tahmin edilen akımların eğitim ve test aşamaları için saçılım grafikleri Şekil 4.18.'de verilmiştir. Buna göre, hem eğitim hem test aşamasında verilerin birbirleriyle genel olarak uyumlu olduğu ancak debi değerlerinin artmasıyla uyumda da sapmalar yaşandığı gözlenmiştir.



Şekil 4. 18. GEP D4 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 19. GEP D4 için eğitim ve test aşamasına ait saçılım grafikleri

4.10. Model 10 (E26A018-17847)

E26A018 numaralı AGİ'ye ait akımı tahmin etmek için ANFIS, YSA, GEP ve ÇDR yöntemleri ile analizler yapılmış olup ilgili sonuçlar Çizelge 4.12'de verilmiştir. Buna göre, D1 modele ait analiz sonuçlarında R^2'ye ait değerler GEP dışındaki yöntemlerde genel olarak birbirleriyle uyumlu sonuç sergilemiştir. Eğitim aşamasında kabul edilebilir nitelikte olan sonuçlar test aşamasında zayıf kalmıştır. Yağış verisine bir önceki aya ait akım verisinin eklenmesiyle oluşturulan D2 modelde, ANFIS ve GEP yöntemleri ile gerçekleştirilen analizlerde eğitim aşamasında sıçrama yaşanmış ve model performansı önemli derecede artmıştır. D1 modeli dışında kalan diğer dört modelde de OKH kriteri temel değerlendirmede esas alındığından GEP modelin bu dört modelin her birinde akımı tahmin etmek için başarılı sonuçlar verdiği sonucuna ulaşılmaktadır. Tüm modeller arasından en iyi sonuca en düşük OKH'a (44.35) sahip olan GEP D3 modeli ile ulaşılmıştır. R^2 eğitim aşamasında 0.846 iken test aşamasında 0.595 değerlerini bulmuş ve OKH değerleri de benzer şekilde eğitim aşamasında teste göre daha başarılı olmuştur. Nash-sutcliffe verimliliği ise eğitim aşamasında 0.846 iken test aşamasında 0.588 değerlerini bulmuştur.

En başarılı model olarak belirlenen GEP D3 modele ait akışı tahmin etmek için elde edilen ifade, Denklem 4.11. ile verilmektedir.

$$Q = \sqrt[9]{\sqrt[3]{d_2^{\,2}(d_0 d_1)}\, d_2} + \frac{\sqrt{d_1 \sin d_0 + d_0}}{1.262} + \frac{d_1 + \sqrt[4]{d_0}}{-2.577 \sin d_0} \qquad (4.11.)$$

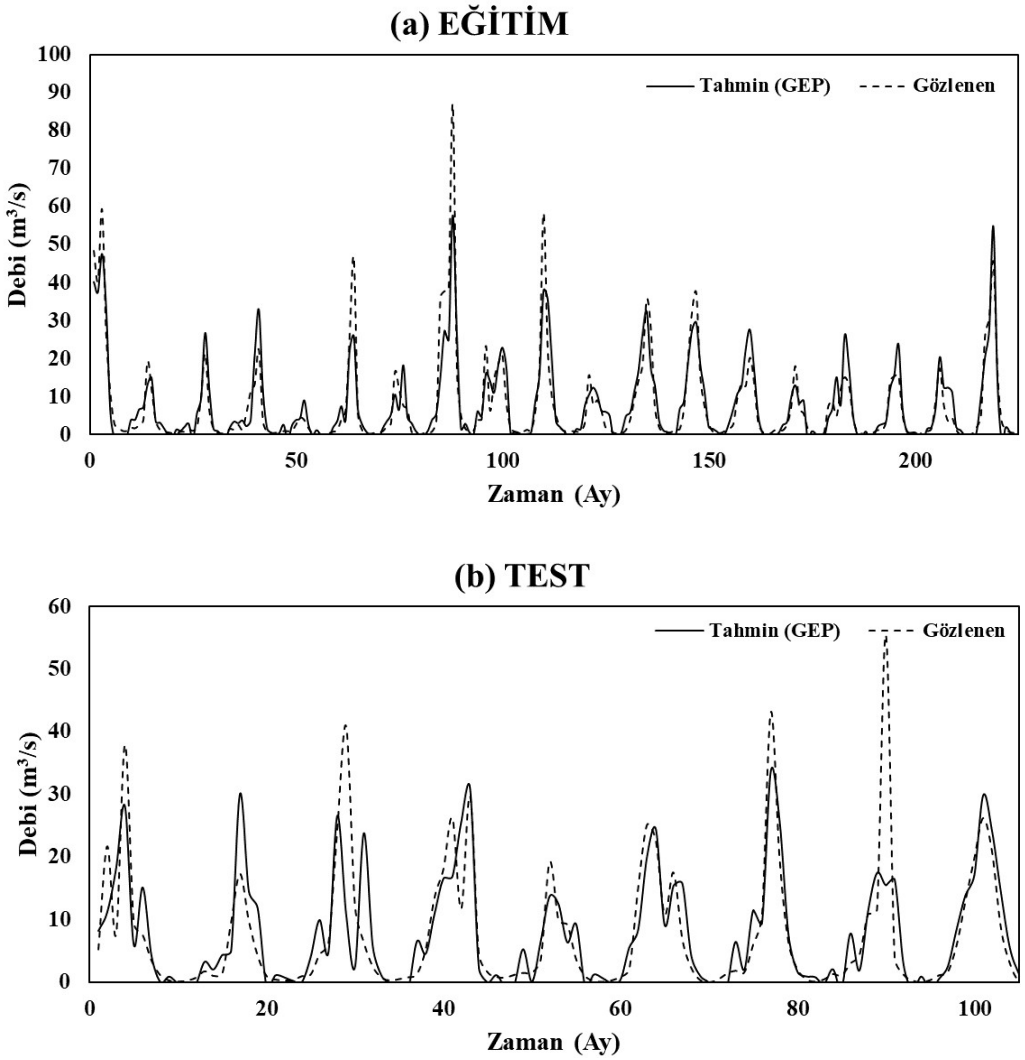
Çizelge 4. 12. 17847-E26A018 için tüm durumlara ait eğitim ve test sonuçları

		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [7] (2)	EĞİTİM	0.4382	85.58	0.439	0.488	135.38	0.112
	TEST	0.2634	87.89	0.183	0.263	128.35	-0.193
D2 [10] (2)	EĞİTİM	0.880	18.27	0.880	0.842	80.61	0.472
	TEST	0.5157	52.87	0.509	0.432	103.63	0.037
D3 [8] (2)	EĞİTİM	0.7443	38.95	0.745	0.841	83.68	0.451
	TEST	0.4642	60.79	0.435	0.484	106.69	0.009
D4 [6] (2)	EĞİTİM	0.7729	34.57	0.773	0.857	74.77	0.510
	TEST	0.5130	54.34	0.495	0.458	97.33	0.096
D5 [5] (2)	EĞİTİM	0.8021	30.13	0.802	0.881	77.75	0.490
	TEST	0.5772	46.53	0.568	0.514	99.73	0.073
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.503	75.79	0.503	0.433	86.56	0.433
	TEST	0.259	96.28	0.105	0.282	84.66	0.213
D2	EĞİTİM	0.830	26.05	0.829	0.672	52.49	0.656
	TEST	0.543	49.61	0.539	0.435	63.24	0.412
D3	EĞİTİM	0.846	23.52	0.846	0.671	52.39	0.565
	TEST	0.595	44.35	0.588	0.423	64.67	0.399
D4	EĞİTİM	0.855	22.12	0.855	0.681	51.69	0.661
	TEST	0.538	49.97	0.536	0.428	64.62	0.400
D5	EĞİTİM	0.832	25.73	0.831	0.688	51.49	0.662
	TEST	0.584	45.18	0.580	0.436	63.84	0.407

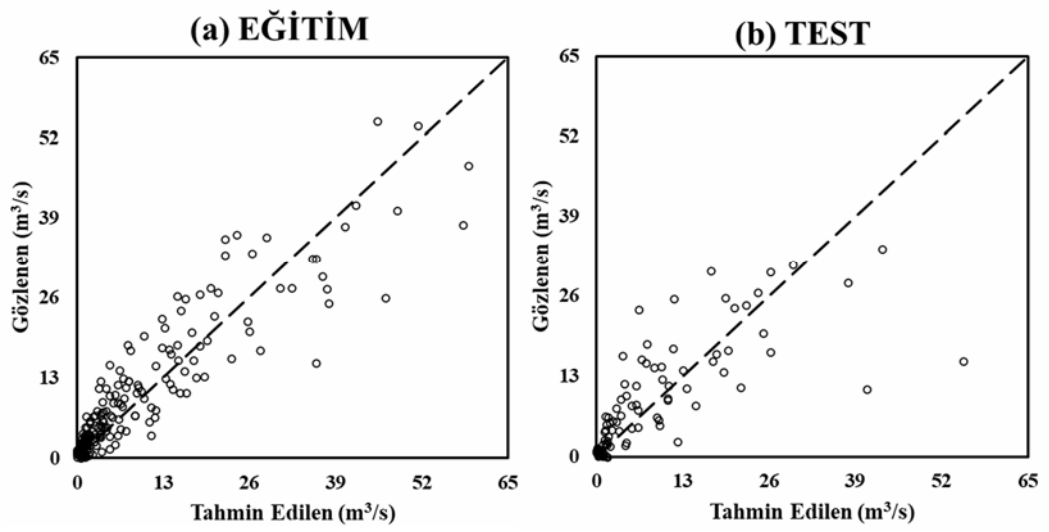
Eğitim ve test aşamalarına ait zamansal dağılım grafiği, GEP D3 model için Şekil 4.20.'de verilmiştir. Buna göre, tahmin değerlerinin gözlem değerlerine hangi değer aralığında yakınsadığı ve uzaklaştığı görülmektedir. Eğitim aşamasında 0 ile 30 m^3/sn arasında değişen verilerde tahmin edilen değerlerin gözlenen akım değerlerine yakınsadığı ancak pik yapan debilerde gözlem değerlerinin tahmin değerlerinin yukarısında kaldığı görülmüştür. Genel olarak eğitim aşamasında elde edilen değerlerde tahmin değerleri başarılı sonuçlar vermiştir. Test aşamasına ait zamansal dağılım grafiğinden tahmin edilen değerlere ait verilerin gözlem değerlerine göre daha yüksek değerler verdiği ancak pik değerlerde seyreden debi değerleri için tahminin yetersiz kaldığı görülmüştür.

E26A018 istasyonuna ait gözlenen ve tahmin edilen akımların eğitim ve test aşamaları için saçılım grafikleri Şekil 4.21.'de GEP D3 için verilmiştir. Buna göre, hem eğitim hem test aşamasında düşük değerlere sahip olan verilerin birbirleriyle

genel olarak uyumlu olduğu ancak akım verilerine ait değerlerin artmasıyla uyumdan da uzaklaştığı görülmüştür.



Şekil 4. 20. GEP D3 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 21. GEP D3 için eğitim ve test aşamasına ait saçılım grafikleri

4.11. Model 11 (E26A018-17280)

E26A018 numaralı AGİ'ye ait akımı tahmin etmek için önceki istasyonlara benzer şekilde 17280 numaralı MGİ istasyonun verileri kullanılarak ANFIS, YSA, GEP ve ÇDR yöntemleri ile analizler yapılmış olup ilgili sonuçlar Çizelge 4.13'te verilmiştir. Buna göre tüm modellerde eğitim aşamasında elde edilen R^2 değerlerin test aşamasına göre daha başarılı olduğu ancak OKH değerlerinin her modelde farklılık sergilemekle beraber nispeten ANFIS ve GEP yöntemlerinde yakın sonuçlar verdiği görülmektedir.

D1 model incelendiğinde diğer yöntemlere kıyasla başarılı sonucu veren ÇDR olmuştur ancak önceki analizlerde de olduğu gibi sadece yağış verisi ile oluşturulan modelin akımı tahmin etmede yetersiz olduğu görülmüştür. D2 modelde test aşamasında D1'e göre önemli derecede artış gözlenmiş ve en başarılı sonucu GEP yöntemi vermiştir. D3 ve D4 modellere bakıldığında, her iki modelde de eğitim aşaması test aşamasına göre daha başarılı olmuş ve yine başarılı performans sergileyen yöntem GEP olmuştur. OKH değerlerine bakılarak GEP'ten sonra nispeten başarılı sonuçlar veren yöntem ANFIS olmuş, bunu sırası ile ÇDR ve YSA takip etmiştir. En düşük OKH değeri ile tüm modeller arasından en başarılı olan model, ANFIS D5 olmuştur. Burada önceki aylara ait akım ve yağış verilerinin modelin performansını

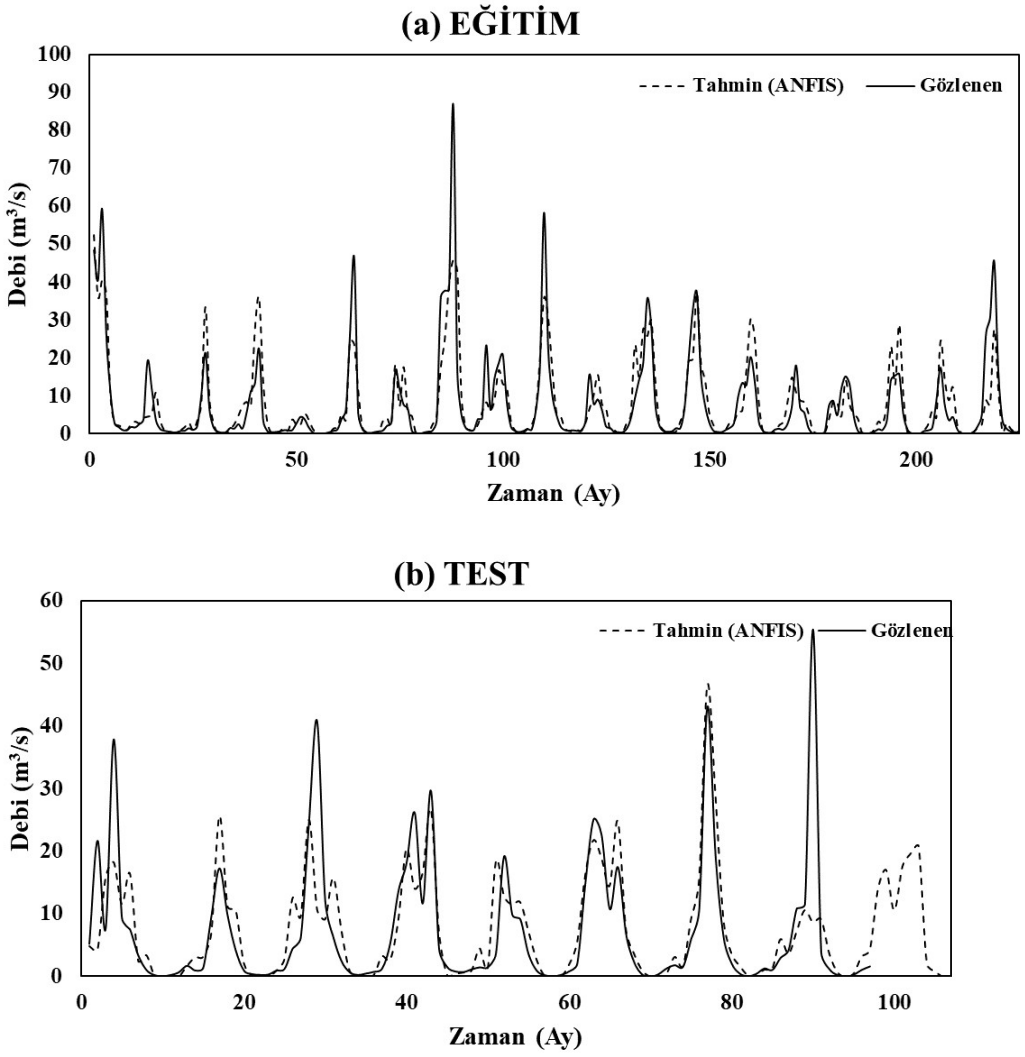
önemli şekilde değiştirdiği görülmüştür. ANFIS D5 model, eğitim aşamasında 41.95 ve test aşamasında 51.38 değerlerini vermiştir. Burada, eğitim aşamasının test aşamasına göre daha başarılı olduğu görülmektedir. R^2 eğitimde 0.725 iken testte, performans düşüklüğü yaşanmış ve 0.527 değerini bulmuştur.

Çizelge 4. 13. 17280-E26A018 için tüm durumlara ait eğitim ve test sonuçları

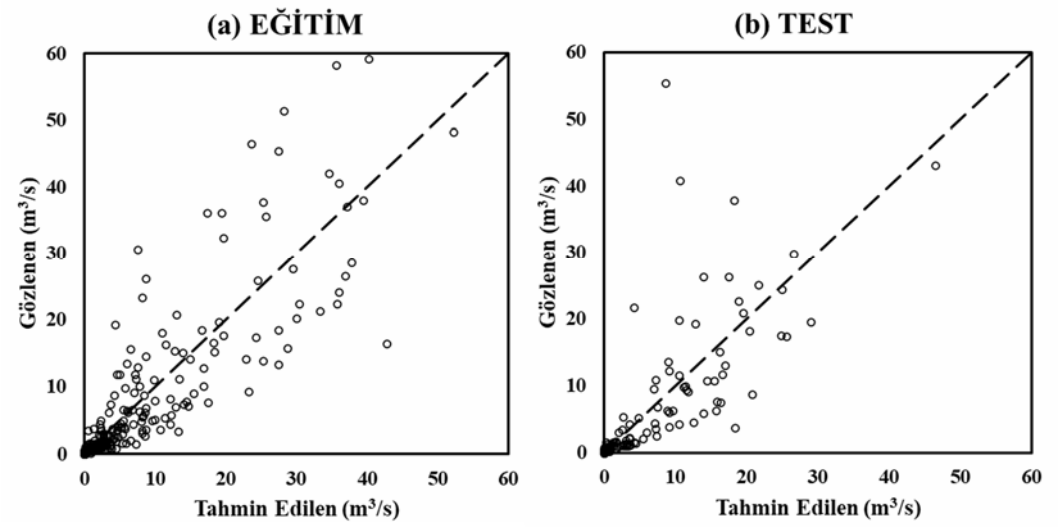
		ANFIS			YSA		
		R^2	OKH	NSE	R^2	OKH	NSE
D1 [3] (2)	EĞİTİM	0.4688	80.92	0.469	0.383	151.97	0.004
	TEST	0.2022	100.23	0.069	0.240	132.79	-0.234
D2 [3] (2)	EĞİTİM	0.7704	34.98	0.771	0.727	92.85	0.391
	TEST	0.4052	64.80	0.398	0.418	105.60	0.019
D3 [9] (2)	EĞİTİM	0.6976	46.05	0.698	0.742	90.95	0.404
	TEST	0.4426	61.26	0.431	0.371	105.79	0.170
D4 [6] (2)	EĞİTİM	0.7167	43.13	0.717	0.714	92.29	0.395
	TEST	0.4587	59.89	0.444	0.329	106.96	0.006
D5 [4] (2)	EĞİTİM	0.7245	41.95	0.725	0.780	90.24	0.408
	TEST	0.5270	51.38	0.523	0.390	109.34	-0.016
		GEP			ÇDR		
		R^2	OKH	NSE	R^2	OKH	NSE
D1	EĞİTİM	0.556	67.85	0.469	0.451	83.68	0.451
	TEST	0.146	133.06	0.069	0.221	95.84	0.110
D2	EĞİTİM	0.781	33.42	0.771	0.638	56.56	0.629
	TEST	0.474	59.57	0.398	0.367	70.82	0.342
D3	EĞİTİM	0.772	34.96	0.698	0.639	56.54	0.629
	TEST	0.448	60.62	0.431	0.374	69.96	0.350
D4	EĞİTİM	0.759	36.87	0.717	0.643	56.37	0.630
	TEST	0.515	54.17	0.444	0.377	69.86	0.351
D5	EĞİTİM	0.796	31.15	0.725	0.644	56.36	0.630
	TEST	0.482	57.84	0.523	0.378	69.66	0.353

OKH değerleri dikkate alınarak en başarılı performans sergileyen ANFIS D5 modeline ait gözlenen ile tahmin edilen akım değerlerine ait zamansal dağılım grafikleri Şekil 4.22.'de verilmiştir. Buna göre, eğitim aşamasında elde edilen zamansal dağılım grafiğinden tahmin edilen akım değerlerine ait verilerin gözlenen akım değerleri ile birçok veride örtüştüğü ancak gözlem değerlerinin pik değerlere ulaştığı noktalarda tahminin yeterli performans sergileyemediği ve gözlemden daha düşük değerler elde ettiği görülmektedir. Test aşamasına ait zamansal dağılım grafiğinden, testin eğitime göre daha zayıf kaldığı ancak ANFIS'in daha çok düşük değerlere sahip akım verilerini tahmin etmede başarılı olduğu görülmüştür.

E26A018 istasyonuna ait gözlenen ve tahmin edilen akımların eğitim ve test aşamaları için saçılım grafikleri ANFIS D5 için Şekil 4.22' de verilmiştir. Elde edilen verilerden ANFIS'in eğitim aşamasının test aşamasına göre daha iyi performans sergilediği görülmektedir. Düşük değerlere ait verilerde daha başarılı olduğu ancak verilere ait değerlerin artması ile saçılımda da uyumsuzluklar gözlendiği açıktır.



Şekil 4. 22. ANFIS D5 için eğitim ve test aşamasına ait zamansal dağılım grafikleri



Şekil 4. 23. ANFIS D5 için eğitim ve test aşamasına ait saçılım grafikleri

4.12. Tartışma

İfşaat (2020) tarafından yapılan çalışmada bu tez kapsamında ele alınan Dicle havzasına sınır olan Fırat havzasında 28 adet akım gözlem istasyonundaki akım değerlerini bölgedeki meteoroloji gözlem istasyonunda elde edilen yağış verilerini kullanarak tahmin etmiştir. Meteoroloji istasyonları ile akım gözlem istasyonlarının ilişkisini belirlerken Thiessen çokgenlerinden yararlanılmıştır. Yağış akış ilişkisinin belirlenmesinde tahmin edilmesinde GEP, ÇDR ve ANN yöntemleri kullanılmıştır. Tahmin yöntemlerinin farklı girdi kombinasyonlarındaki başarısı araştırılmıştır. Model başarısının değerlendirilmesinde OKH, R ve OMGH kriterleri başarı ölçütü olarak kullanılmıştır. Çalışma sonucunda GEP ve ANN yöntemlerinin sırasıyla 12 ve 14 adet istasyonda en başarılı yöntemler olduğu bildirilmiştir. Bu tez kapsamında, Dicle havzasında yağış akış ilişkisinin belirlenmesinde GEP, ÇDR ve YSA yöntemlerine ilave olarak ANFIS yöntemi kullanılmıştır. Elde edilen sonuçlardan GEP yönteminin yanında ANFIS yönteminin bazı istasyonlarda akışın modellenmesinde diğer modellere üstünlük sağladığı belirlenmiştir.

5. SONUÇLAR ve ÖNERİLER

Dicle Havzasında bulunan 11 adet akım gözlem istasyonuna ait akım değerlerini tahmin etmek için havza sınırları içerisinde bulunan AGİ'ler ve MGİ'lerden elde edilen akım ve yağış verileri kullanılmıştır. Yağış akış ilişkisinin belirlenmesinde, akım ve meteoroloji istasyonlarının ilişkilendirilmesinde Thiessen çokgenlerinden yararlanılmıştır. İstasyonların tümünde yapay zekâ yöntemlerinden olan ANFIS ve YSA yöntemleri, matematiksel bir yöntem olan ve lineer olmayan tanımlamalar yapan GEP ve klasik bir değerlendirme yöntemi olan ÇDR yöntemleriyle farklı girdi modelleri için önceki aylara ait akım ve yağış verileri kullanılmıştır. Tahmin yöntemleriyle elde edilen sonuçların karşılaştırılmasında OKH, R^2 ve NSE niceliksel kriterleri kullanılmıştır. OKH kriteri modelin karesel hatasını saptamada temel performans belirleyicisi olarak kabul edilmiş ve R^2 değerleri de modelin göstermiş olduğu uyumu değerlendirmede öne çıkan parametreler olmuştur. Son zamanlarda istatistiksel yöntemleri değerlendiren çalışmalarda yer edinen Nash-Sutcliffe verimliliği de modellere ait sonuçları değerlendirebilmek için bir başka belirleyici araç olarak bu tez çalışmasında kullanılmıştır.

Geçmiş aylara ait akım ve yağış verileri kullanılarak oluşturulan D1, D2, D3, D4 ve D5 modelleri için 11 adet AGİ istasyonunun akım tahmini çalışmalarına ait sonuçları içeren değerler, Çizelge 5.1.'de verilmiştir. Buna göre tüm istasyonlarda en başarılı sonuçlar ANFIS ve GEP yöntemleri ile elde edilmiştir. İlgili modellerden sadece yağış verisi (P_i) ile oluşturulmuş D1 modeli hiçbir istasyonda başarılı sonuç vermemiştir. Bu da akımı tahmin edebilmek için sadece yağış verisi kullanılarak çalışma yürütülmesinin sağlıklı sonuçlar vermeyeceğini göstermiştir. GEP yöntemi ile oluşturulan modellerde D3 model 2 defa, D4 model 3 defa ve D5 model 1 defa en başarılı tahmin yapan modeller olmuştur. ANFIS ile analiz yapılan modellerde ise D3 model 2 defa, D4 model 1 defa ve D5 model 2 defa en başarılı modeller olarak ön plana çıkmıştır. D2 modelde önceki aya ait akım verilerinin akış tahmini yaparken model performansını önemli derecede artırdığı görülse de oluşturulan diğer modellerden zayıf kalmıştır. Buna göre önceki aylara ait akım ve yağış verileri ile tahmin yürütmenin modelin performansını önemli ölçüde artırdığı söylenebilir.

Elde edilen sonuçlardan ANFIS ve GEP yöntemlerinin çalışmada kullanılan diğer tahmin yöntemlerine kıyasla daha başarılı olduğu ve şu anki akım değerinin hesaplanmasında bir önceki akım değerinin ve 2 veya 3 ay önceki yağış değeri arasında önemli bir ilişkinin olduğu belirlenmiştir.

Çizelge 5. 1. Eğitim ve test sürecine göre tüm istasyonlarda belirlenen en başarılı modeller

No	AGİ	MGİ	Yöntem	Model	OKH		R^2	
					Eğitim	Test	Eğitim	Test
Model 1	E26A005	17280	ANFIS	D3	1854.5	1873.1	0.751	0.690
Model 2	E26A018	17282	GEP	D4	39.39	53.49	0.741	0.524
Model 3	E26A012	17282	GEP	D4	5346.63	5937.87	0.720	0.552
Model 4	E26A024	17210	GEP	D5	131.9	112.73	0.771	0.736
Model 5	E26A020	17285	ANFIS	D5	1113.3	883.14	0.757	0.695
Model 6	E26A030	17285	ANFIS	D3	938.89	456.05	0.632	0.598
Model 7	E26A030	17920	GEP	D3	712.76	385.59	0.722	0.669
Model 8	E26A031	17285	ANFIS	D4	159.37	119.44	0.795	0.755
Model 9	E26A031	17880	GEP	D4	184.79	187.28	0.763	0.618
Model 10	E26A018	17847	GEP	D3	23.52	44.35	0.846	0.595
Model 11	E26A018	17280	ANFIS	D5	41.95	51.38	0.725	0.527

Güneydoğu'nun önemli havzalarından olan Dicle havzası için yapılmış olan bu çalışma, bir diğer önemli havza olan Fırat havzası için yapılan çalışma ile karşılaştırıldığında GEP yöntemine ait sonuçların diğer yöntemlere göre daha başarılı sonuçlar verdiği görülmüştür. Fırat havzasında GEP yöntemi ile yapılan analizlerden elde edilen en yüksek R^2 (0.796) ve en düşük OKH (247), yağış ve geçmiş akım değerleri kullanılarak oluşturulan model ile belirlenmiştir. Havzanın içinde bulunduğu durum, yağış, topografik özellikler ve iklim koşulları tüm bu değerlendirmeler üzerinde önemli etkiye sebep olan etkenlerdir. Dicle havzasını dikkate alarak yapılmış olan bu tez çalışmasıyla elde edilen sonuçlardan ANFIS ile oluşturulan modellerin diğer yöntemlere kıyasla başarılı sonuçlar verdiği görülmüştür.

Çizelge 5.1.' de özetlenen sonuçlardan E26A030 numaralı AGİ dikkate alındığında farklı istasyonlar (17285-17920) ile yapılmış analizlerden ANFIS'in 17285 numaralı istasyonda, GEP'in ise 17920 numaralı istasyonda D3 model ile başarılı sonuçlar verdiği ancak GEP modelin ulaştığı uyumun bu iki istasyon kıyaslandığında daha iyi olduğu görülmüştür. Burada, ilgili istasyonun bulunduğu konum itibarıyla sahip olduğu yükselti ve almış olduğu yağışın önemli etkileri analiz üzerinde de kendini göstermiştir.

E26A031 ve E26A018 numaralı AGİ'ler için iki farklı MGİ ile gerçekleştirilen analizlerden elde edilen sonuçlar incelendiğinde, ANFIS ve GEP yöntemleri ile başarılı sonuçlar elde edildiği, eğitim aşamasında değerlerin test aşamasına göre daha yakın olduğu ve E26A018 için 17280 numaralı MGİ'nin 17847 numaralı MGİ'ye göre ilgili AGİ'ye daha yakın olduğu, bu durumun da düşen yağışın akışa geçmesi için gerekli koşullar dikkate alınarak değerlendirildiğinde daha iyi sonuçlar vermiş olduğunu göstermektedir.

Bundan sonraki yapılacak olan yağış-akış ilişkisini değerlendirmeye yönelik çalışmalarda farklı yöntemlerin ve farklı girdi parametrelerinin kullanılarak uyarlamalar yapılması ve ilgili sonuçların mevcut sonuçlar ile karşılaştırılmasına yönelik çalışmaların yapılması önerilmektedir.

KAYNAKLAR

AHMADI, M., MOEINI, A., AHMADI, H., MOTAMEDVAZIRI, B. and ZEHTABIYAN, G. R., 2019. Comparison of the performance of SWAT, IHACRES and artificial neural networks models in rainfall-runoff simulation (case study: Kan watershed, Iran). Physics and Chemistry of the Earth, Parts A/B/C, 111: 65-77.

AKRAMI, S. A., EL-SHAFIE, A. and JAAFAR, O., 2013. Improving rainfall forecasting efficiency using modified adaptive neuro-fuzzy inference system (MANFIS). Water resources management, 27(9): 3507-3523.

ALIZADEH, M. J., KAVIANPOUR, M. R., KISI, O. and NOURANI, V., 2017. A new approach for simulating and forecasting the rainfall-runoff process within the next two months. Journal of Hydrology, 548: 588-597.

AREERACHAKUL, S. and JUNSAWANG, P., Rainfall-Runoff relationship for streamflow discharge forecasting by ANN modelling. World Congress on Sustainable Technologies (WCST-2014), 27-30.

AYTEK, A. and ALP, M., 2008. An application of artificial intelligence for rainfall-runoff modeling. Journal of Earth System Science, 117(2): 145-155.

CHEN, S., CHAU, K.-W., XU, D.-M. and WANG, W.-C., 2013. Improved annual rainfall-runoff forecasting using PSO–SVM model based on EEMD. Journal of Hydroinformatics, 15(4): 1377-1390.

CHIANG, S., CHANG, C.-H. and CHEN, W.-B., 2022. Comparison of Rainfall-Runoff Simulation between Support Vector Regression and HEC-HMS for a Rural Watershed in Taiwan. Water, 14(2).

CITAKOGLU, H., 2015. Comparison of artificial intelligence techniques via empirical equations for prediction of solar radiation. Computers and Electronics in Agriculture, 118: 28-37.

CITAKOGLU, H., BABAYIGIT, B. and HAKTANIR, N. A., 2020. Solar radiation prediction using multi-gene genetic programming approach. Theoretical and Applied Climatology, 142(3): 885-897.

DAWSON, C. W. and WILBY, R., 1998. An artificial neural network approach to rainfall-runoff modelling. Hydrological Sciences Journal, 43(1): 47-66.

EL-SHAFIE, A., MUKHLISIN, M., NAJAH, A. A. and TAHA, M. R., 2011. Performance of artificial neural network and regressiontechniques for rainfall-runoff prediction. International Journal of the Physical Sciences, 6(8): 1997-2003.

FERREIRA, C., 2001. Gene expression programming: a new adaptive algorithm for solving problems. arXiv preprint cs/0102027.

GHUMMAN, A. R., GHAZAW, Y. M., SOHAIL, A. R. and WATANABE, K., 2011. Runoff forecasting by artificial neural network and conventional model. Alexandria Engineering Journal, 50(4): 345-350.

GÜMÜŞ, V., ŞİMŞEK, O., SOYDAN, N. G., AKÖZ, M. S. ve YENİGÜN, K., 2016. Adana istasyonunda buharlaşmanın farklı yapay zeka yöntemleri ile tahmini. Dicle Üniversitesi Mühendislik Fakültesi Dergisi, 7(2): 309-318.

HE, Z., WEN, X., LIU, H. and 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.
HU, C., WU, Q., LI, H., JIAN, S., LI, N. and LOU, Z., 2018. Deep Learning with a Long Short-Term Memory Networks Approach for Rainfall-Runoff Simulation. Water, 10(11).
İFŞAAT, İ. H., 2020. Yapay Zekâ Yöntemleri ile Fırat Havzası Yağış-Akış İlişkisinin Belirlenmesi. Harran Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Şanlıurfa, 187s.
JANG, J.-S., 1993. ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on systems, man, and cybernetics, 23(3): 665-685.
KASIVISWANATHAN, K. S., HE, J., SUDHEER, K. and TAY, J.-H., 2016. Potential application of wavelet neural network ensemble to forecast streamflow for flood management. Journal of hydrology, 536: 161-173.
KEIJZER, M. and BABOVIC, V., 2002. Rainfall Runoff Modelling Based on Genetic Programming. Hydrology Research, 33(5): 331-346.
KESKİN, L., 2020. Yağış–Akış İlişkisinin Yapay Sinir Ağları ve Otoregresif Hareketli Ortalamalar Modelleri ile Tahmini. İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 53s.
KHU, S. T., LIONG, S.-Y., BABOVIC, V., MADSEN, H. and MUTTIL, N., 2001. Genetic Programming and Its Application in Real-Time Runoff Forecasting. Journal of the American Water Resources Association, 37(2): 439-451.
KISI, O., SHIRI, J. and TOMBUL, M., 2013. Modeling rainfall-runoff process using soft computing techniques. Computers & Geosciences, 51: 108-117.
KOKKONEN, T., KOIVUSALO, H. and KARVONEN, T., 2001. A semi-distributed approach to rainfall-runoff modelling—a case study in a snow affected catchment. Environmental Modelling & Software, 16(5): 481-493.
KUTLU, B. ve BADUR, B., 2009. Yapay Sinir Ağlari İle Borsa Endeksi Tahmini. Yönetim-İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadı Enstitüsü Dergisi, 20(63).
LAFDANI, E. K., NIA, A. M., PAHLAVANRAVI, A., AHMADI, A. and JAJARMIZADEH, M., 2013. Research article daily rainfall-runoff prediction and simulation using ANN, ANFIS and conceptual hydrological MIKE11/NAM models. Int. J. Eng. Technol, 1(1): 32-50.
LI, K., HUANG, G., WANG, S., RAZAVI, S. and ZHANG, X., 2022. Development of a Joint Probabilistic Rainfall□Runoff Model for High□to□Extreme Flow Projections Under Changing Climatic Conditions. Water Resources Research, 58(6).
MAO, G., WANG, M., LIU, J., WANG, Z., WANG, K., MENG, Y., ZHONG, R., WANG, H. and LI, Y., 2021. Comprehensive comparison of artificial neural networks and long short-term memory networks for rainfall-runoff simulation. Physics and Chemistry of the Earth, Parts A/B/C, 123.
MORALES, Y., QUERALES, M., ROSAS, H., ALLENDE-CID, H. and SALAS, R., 2021. A self-identification Neuro-Fuzzy inference framework for modeling rainfall-runoff in a Chilean watershed. Journal of Hydrology, 594.
NEGI, A., RAWAT, K. S., NAINWAL, A., SHAH, M. C. and KUMAR, V., 2021. Quality analysis of statistical and data-driven rainfall-runoff models for a mountainous catchment. Materials Today: Proceedings, 46: 10376-10383.

NOURANI, V., 2017. An emotional ANN (EANN) approach to modeling rainfall-runoff process. Journal of Hydrology, 544: 267-277.

ÖZBAYOĞLU, G., ÖZBAYOĞLU, A. M. and ÖZBAYOĞLU, M. E., 2008. Estimation of Hardgrove grindability index of Turkish coals by neural networks. International Journal of Mineral Processing, 85(4): 93-100.

ÖZDEMİR, Y., ÖZİŞ, Ü., BARAN, T., DEMIRCI, N., FISTIKOĞLU, O. ve ÇANGA, R., 2002. Fırat-Dicle havzasının Türkiye, Suriye, Irak, İran'daki su potansiyeli. Türkiye Mühendislik Haberleri, 47: 420-421.

ŞAHİN, M., 2007. Karadeniz Bölgesindeki Yağış-akış İlişkisinin Farklı YSA Metotlarıyla Belirlenmesi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul 86s.

SEDKI, A., OUAZAR, D. and EL MAZOUDI, E., 2009. Evolving neural network using real coded genetic algorithm for daily rainfall–runoff forecasting. Expert systems with applications, 36(3): 4523-4527.

SIMON, H., 1999. Neural networks: a comprehensive foundation, Prentice hall, s.

SITTERSON, J., KNIGHTES, C., PARMAR, R., WOLFE, K., AVANT, B. and MUCHE, M., 2018. An overview of rainfall-runoff model types.

SIVAPRAGASAM, C., LIONG, S.-Y. and PASHA, M., 2001. Rainfall and runoff forecasting with SSA–SVM approach. Journal of Hydroinformatics, 3(3): 141-152.

TAŞAR, B., UNES, F. and VARCIN, H., Prediction of the Rainfall–Runoff Relationship Using NeuroFuzzy and Support Vector Machines. 2019" Air and Water–Components of the Environment" Conference Proceedings, 237-246.

WANG, Z., PALADE, V. and XU, Y., Neuro-fuzzy ensemble approach for microarray cancer gene expression data analysis. 2006 international symposium on evolving fuzzy systems, 241-246.

WEI, L.-Y., 2016. A hybrid ANFIS model based on empirical mode decomposition for stock time series forecasting. Applied Soft Computing, 42: 368-376.

YÜKSEK, Ö., BABACAN, H. T. ve FATIH, S., 2018. Yağış-akış modellemesinde optimum yapay sinir ağı yapısının araştırılması. Türk Hidrolik Dergisi, 2(1): 31-37.

ZAHMATKESH, Z., KARAMOUZ, M. and NAZIF, S., 2015. Uncertainty based modeling of rainfall-runoff: combined differential evolution adaptive metropolis (DREAM) and K-means clustering. Advances in water resources, 83: 405-420.

EKLER

Tüm modeller için elde edilmiş YSA fonksiyonları

MODEL 1

```
function [Y,Xf,Af] = A01_A17280_E26A005_S(X,~,~)
%A01_A17280_E26A005_S neural network simulation function.
%
%
% [Y] = A01_A17280_E26A005_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;3.21;0;0;0];
x1_step1.gain = [0.0105876124933827;0.003825627881176;0.0105876124933827; ↙
0.0105876124933827;0.0105876124933827];
x1_step1.ymin = -1;

% Layer 1
b1 = [-0.69807219770676953718;-2.6830058231124152002];
IW1_1 = [-0.87410020579172997834 -0.7458167814311260635 -0.39904211626790314638 ↙
-0.19943969695786104013 -0.18720909062743401607;-3.5349102064584934091 ↙
4.0227046897974876316 8.2858702759347746536 3.0280848933253410316 ↙
-1.515872941414568853];

% Layer 2
b2 = -0.55476692968623375624;
LW2_1 = [-0.6687732906125413157 -0.19693614710280532565];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.003825627881176;
y1_step1.xoffset = 3.21;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);
```

```
% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

MODEL 2

```
function [Y,Xf,Af] = A03_A17282_E26A012_S(X,~,~)
%A03_A17282_E26A012_S neural network simulation function.
%
%
% [Y] = A03_A17282_E26A012_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;0;0;0;0];
x1_step1.gain = [0.0123304562268804;0.0230680507497117;0.0123304562268804; ↙
0.0123304562268804;0.0123304562268804];
x1_step1.ymin = -1;

% Layer 1
b1 = [-2.0656356245855045373;-9.4945068891433361813;-1.0518821912975804267; ↙
0.53522767064861209718;2.8110789722426230419;-7.8575466068653092577; ↙
0.43189008868165368327;7.812056957149890124];
IW1_1 = [2.0581919463996727337 -1.5964578328663143747 -0.74004038543130878924 ↙
-0.12152892732798209474 -0.14115526038974590683;12.510794090819409519 ↙
-21.976333388852207662 -19.839331544364984694 22.040670862890710424 ↙
-2.8462135147005342972;-4.3394277414234947443 6.2345084437964333191 ↙
-11.315545763386678502 -2.7234550017638401442 -9.3845869382280380222; ↙
-1.2807402391993583102 -0.2044574663621276378 0.5411729050674991548 ↙
0.20359879869682853681 0.23255544297388794361;0.39035230695369349529 ↙
1.4882383246731745174 0.47224916522497678573 1.8783536582932649495 ↙
0.47376110960514877801;4.8801331384986621487 -7.6485684026320504003 ↙
-5.1431093747771718938 0.6991294837116559524 -8.582983854636948351; ↙
-3.8415173580453898516 3.4546475542722951957 -0.58747898056214675755 ↙
1.2934233538435715438 3.423238588743365618;-10.778470794302464242 ↙
13.212118143235315415 2.4688313159899410998 -0.34427530904496972397 ↙
-6.902707218784099652];

% Layer 2
b2 = -0.63475376909837133432;
LW2_1 = [-0.86956895029904757166 -0.005390349827917618151 5 -0.063521176052454109144 ↙
-1.2743273409250801542 0.12609207724491469649 -0.022848715994079813602 ↙
-0.053745309266813139082 -0.035260913443885481822];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0230680507497117;
y1_step1.xoffset = 0;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
```

```
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

MODEL 3

```
function [Y,Xf,Af] = A03_A17282_E26A012_S(X,~,~)
%A03_A17282_E26A012_S neural network simulation function.
%
%
% [Y] = A03_A17282_E26A012_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;0.158;0;0;0];
x1_step1.gain = [0.00771010023130301;0.00335659453345014;0.00771010023130301; ↙
0.00771010023130301;0.00771010023130301];
x1_step1.ymin = -1;

% Layer 1
b1 = [-2.3545632471014927845;0.8017747705755129406;-0.70375346003439898102; ↙
-1.2381205601260125704];
IW1_1 = [0.22528106106528772434 -0.64818971232761679602 -0.82417846567049224404 ↙
-1.6326676137418698609 -0.29354748794968998915;-0.16717336783599140437 ↙
0.52814034650864460918 -1.6412990275625813918 0.60574450617322461721 ↙
-0.15713972394114902875;-0.43301422265922151489 -0.47858607805276698333 ↙
-0.77018826978729515442 0.89966786644275020812 0.076251845537235865558; ↙
-1.8711944125443926712 -1.0540311325699200928 -0.21789086446089039883 ↙
-0.052996618316645593971 0.046410056979495822871];

% Layer 2
b2 = -0.56859359627530459136;
LW2_1 = [-0.21756265163019083975 0.13495525829104321192 -0.21836343197077340283 ↙
-0.53403092648391747854];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.00335659453345014;
y1_step1.xoffset = 0.158;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
```

```
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

MODEL 4

```
function [Y,Xf,Af] = A04_A17210_E26A024_S(X,~,~)
%A04_A17210_E26A024_S neural network simulation function.
%
%
% [Y] = A04_A17210_E26A024_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;1.2;0;0;0];
x1_step1.gain = [0.00687049124012367;0.0145137880986938;0.00687049124012367; ↙
0.00687049124012367;0.00687049124012367];
x1_step1.ymin = -1;

% Layer 1
b1 = [-5.2009020841416528924;0.43654670183243027282;-2.1381754970095641077; ↙
6.6663084550724445165;-10.866875734453527613];
IW1_1 = [-0.2771358163061259372 4.3490590701572529042 -3.5630133082421950874 ↙
-0.29453189387970568625 0.20132704144128027446;-3.5471442366341752184 ↙
-2.8380505417126142831 -1.78400183665586054 -5.2001957828612974666 ↙
-1.4634290143917803029;-1.6863904288703839285 -1.7478750566599765559 ↙
-1.4688052936433260154 -0.24629301339132458892 -0.82638502305536110093; ↙
-3.2409876362247471704 4.4609012193986981032 -5.2254635834357578972 ↙
-0.87707852849309753118 0.47434215217210029536;-1.3538903821527328297 ↙
-9.5770865279202013198 -0.95141518693428128728 -2.8222544209185529418 ↙
-1.6629086040486094067];

% Layer 2
b2 = 0.60311233425432941857;
LW2_1 = [0.562763770255086615 -0.60265444791258548918 -0.2178741812785854326 ↙
-0.11056299630362000086 -0.18970049994807847149];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0145137880986938;
y1_step1.xoffset = 1.2;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
```

```
else
  Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

```
function [Y,Xf,Af] = A05_A17285_E26A020_S(X,~,~)
%A05_A17285_E26A020_S neural network simulation function.
%
% [Y] = A05_A17285_E26A020_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;9.07;0;0;0];
x1_step1.gain = [0.00611246943765281;0.0055259304285359;0.00611246943765281; ↙
0.00611246943765281;0.00611246943765281];
x1_step1.ymin = -1;

% Layer 1
b1 = [-2.4028110395196091709;1.6606717489170703672;1.4120614713830033082; ↙
-0.20700336978232020124;0.073603050770215672216;-0.70973808341147326395; ↙
-0.84104580910410431382;-2.4507662804481413765;-1.4108497319162442984];
IW1_1 = [0.69530927335986036919 -1.8965856985745901397 0.56883727383922555454 ↙
-0.38173587464929564783 -0.17520048445952374205;-0.13582280019119322145 ↙
-1.3303470600306885885 0.18476953118002548138 0.92128984235302602279 ↙
-1.6831668470803904381;-0.050600027668334643383 0.16642098568252927659 ↙
-1.2107380685693289735 -1.7124788640569406084 0.39796837693442321804; ↙
-1.3753541947992882211 -1.068183769530502758 0.86217275440586582658 ↙
0.44434905593734341789 1.1493032436900856297;0.30408646021158503014 ↙
0.61692892999869142212 -1.2034833949342431669 -0.7330643410721112696 ↙
0.36769771647084276145;-0.38448102475709389214 -0.39723690216016033228 ↙
-2.1791394624411988268 -0.30133952604861835578 -0.63867763694983104017; ↙
-2.3158137829566314281 0.51811015116412995063 0.39700664376901573238 ↙
0.26358625033543847671 -1.2517379296383344123;-0.83497466977492551532 ↙
0.091562026403861657142 0.11623311205368590249 1.5786474653475850438 ↙
0.89481811604397443194;0.03429242503232834971 -0.94820852115144260708 ↙
-1.6911256372591503272 -0.36799768136032484644 0.74805732243714695429];

% Layer 2
b2 = -0.10476844457371203845;
LW2_1 = [-0.81303101281634249098 -0.10583586734028510579 -0.89117539579865923116 ↙
-0.024085404849743592692 0.58799202507928760575 -0.45028218368910388758 ↙
-0.21520818061468238724 0.030741772323696431313 -0.54133568402892595639];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0055259304285359;
y1_step1.xoffset = 9.07;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
```

```
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

```
function [Y,Xf,Af] = A06_A17285_E26A030_S(X,~,~)
%A06_A17285_E26A030_S neural network simulation function.
%
%
% [Y] = A06_A17285_E26A030_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;4.32;0;0;0];
x1_step1.gain = [0.00611246943765281;0.00747160789001793;0.00611246943765281; ↙
0.00611246943765281;0.00611246943765281];
x1_step1.ymin = -1;

% Layer 1
b1 = [-8.3177249891462246012;3.8264645432267152536;-6.0816734195085802028; ↙
4.6986555467499115935;-4.0035065702819290223;-0.90146308886288561979; ↙
-1.1101044907488197833];
IW1_1 = [-0.56481441335314852559 -5.0858436011996106529 -0.1867394311062066381 ↙
-1.6900812744020290435 2.6770689465099186677;-4.6545306528633849652 ↙
3.5258631883487390191 1.1514269293121282001 0.54785465324230375739 ↙
-1.1989586512284131636;4.2318787515115703357 2.8202728713924107851 ↙
3.0347021814149508501 5.0108184642798283548 1.6874272658661844115; ↙
-7.0083435280039108051 -2.0590341054871048598 1.4188312551194306455 ↙
3.1889062922143338596 -3.9653625250628135035;-3.2881642821862731019 ↙
2.6841383608316577991 -2.8792289052354047563 4.9791969564183187202 ↙
-7.2185632979687532895;10.707217854200226981 3.636914922424957286 ↙
-10.828923061694171182 1.0756525458167658371 0.84630463129247546217; ↙
-0.91991790954067242936 -1.2111067179467107646 -0.2409572080623418322 ↙
0.068025525770405492754 -0.42485201199697880677];

% Layer 2
b2 = -1.6163196531532677547;
LW2_1 = [-0.98299993883674618989 0.43289470995519302443 -0.63396698177122356999 ↙
-0.68657040536543345599 0.038092627567573297820 0.091720419131531574775 ↙
-0.72804957587713192702];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.00747160789001793;
y1_step1.xoffset = 4.32;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end
```

```
% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

```
function [Y,Xf,Af] = A07_A17920_E26A030_S(X,~,~)
%A07_A17920_E26A030_S neural network simulation function.
%
%
% [Y] = A07_A17920_E26A030_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;4.32;0;0;0];
x1_step1.gain = [0.0056657223796034;0.00747160789001793;0.0056657223796034; ↙
0.0056657223796034;0.0056657223796034];
x1_step1.ymin = -1;

% Layer 1
b1 = [-1.9693883829306570998;0.5126474793869087998;-0.50818452501387090248; ↙
-1.6913897283088688006];
IW1_1 = [0.56754153286675945722 -0.45976656747343397358 -0.22994845674543018532 ↙
-1.597357632937520977 -0.38382774334934199878;-0.098529639153209863656 ↙
0.692118453770101838 -1.5519380693963849005 0.6189468005647296156 ↙
-0.040335465756223286428;-0.44075506439420936156 -1.5789515266703961771 ↙
-0.77676249708178535247 -0.068399889526707516318 0.058288260817462141106; ↙
-1.2673337886711990574 -1.567234429828958886 -0.015960675058028131468 ↙
-0.21738150880887019412 0.0381116284693884394];

% Layer 2
b2 = -0.21853187191143866319;
LW2_1 = [-0.078771528773415921965 0.016359477615219483737 -0.65851313412163736682 ↙
-0.18504218582425349671];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.00747160789001793;
y1_step1.xoffset = 4.32;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
```

```
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

```
function [Y,Xf,Af] = A08_A17285_E26A031_S(X,~,~)
%A08_A17285_E26A031_S neural network simulation function.
%
%
% [Y] = A08_A17285_E26A031_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;5.77;0;0;0];
x1_step1.gain = [0.00677966101694915;0.013584188005162;0.00611246943765281; ↙
0.00611246943765281;0.00611246943765281];
x1_step1.ymin = -1;

% Layer 1
b1 = [-1.0314473852616308225;-1.8754386039741057779];
IW1_1 = [-0.87923851662413277097 -0.98781156149980653414 -1.1630825015496562003 ↙
0.15854515447319486587  0.10142196597811437009;0.63464604114377909383 ↙
-1.8130083558350076345  0.99777542500449478702  -0.2086375059698809542 ↙
-0.25218303484924964319];

% Layer 2
b2 = -0.91341351480425048148;
LW2_1 = [-0.94647639295149299521 -0.9777215149609405076];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.013584188005162;
y1_step1.xoffset = 5.77;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);
```

```
% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

MODEL 9

```
function [Y,Xf,Af] = A09_A17880_E26A031_S(X,~,~)
%A09_A17880_E26A031_S neural network simulation function.
%
% [Y] = A09_A17880_E26A031_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;5.77;0;0;0];
x1_step1.gain = [0.0128369704749679;0.013584188005162;0.00759589821496392; ↙
0.00759589821496392;0.00759589821496392];
x1_step1.ymin = -1;

% Layer 1
b1 = [-2.3254758079335409171;1.2913994885236586008;-0.94288879618079035616; ↙
-0.94232049824340458066;-0.2545528041401265984;0.98037351719531629 08; ↙
-1.6495889579882145881];
IW1_1 = [-0.060842123400393771648 -2.597284724532902711 0.21649248515195540499 ↙
-0.56969450993083636803 0.48641486909105258185;-0.14465004364767614087 ↙
-0.69244713432741011871 -0.28376178281449171426 -1.5065868474897654572 ↙
-1.2554828704561633579;-0.37667754805581438182 -0.8028251502298375808 ↙
-1.3117518846489335527 -1.1269118928821668657 0.32168346329533298311; ↙
-1.6338405735054857271 -2.5583032248452042268 0.73405792113710710556 ↙
-0.46399424356253826662 -0.13463945936070798037;-0.17847771319412950031 ↙
0.017443640796626486839 0.82499811204510253848 1.9562694953192685254 ↙
-2.466452836120498926;0.37477635281939719603 -0.65285631601548577141 ↙
-0.11373075002394504585 -2.1367361705302991837 0.90716057267528626973; ↙
-1.428289898691235793 0.90271074581439625373 -0.32842040626588625551 ↙
-1.0632605340294551954 1.0897524376522542688];

% Layer 2
b2 = -0.75423108853603215707;
LW2_1 = [-0.25322214443013590923 0.10992665933436113201 -0.99404698682359815542 ↙
-0.072531709962599111297 -0.15841282516871818542 0.56996445034758169701 ↙
-0.11834717172048959954];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.013584188005162;
y1_step1.xoffset = 5.77;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end
```

```
% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

MODEL 10

```
function [Y,Xf,Af] = A10_A17847_E26A018_S(X,~,~)
%A10_A17847_E26A018_S neural network simulation function.

%
% [Y] = A10_A17847_E26A018_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;0;0;0;0];
x1_step1.gain = [0.00499001996007984;0.0230680507497117;0.00499001996007984; ↙
0.00499001996007984;0.00499001996007984];
x1_step1.ymin = -1;

% Layer 1
b1 = [-1.8976129914387129816;1.4877686679117045898;-0.59502120164040839256; ↙
-0.75157454468233486633;-1.1319462540141909113];
IW1_1 = [1.7486704289048378147 0.85979719083844330374 -1.9799660341155502774 ↙
-0.73079343903762217227 0.85746357255555394339;-0.38773871264758458244 ↙
-0.81806007118100343423 1.1545651714707814151 -0.50762600629029874799 ↙
-0.67926688032256554717;-1.558864845354809292 -0.13266084933585761685 ↙
-0.56442603682996639325 -0.55394989675192374268 -0.076230719485718162476; ↙
-2.1791592108520769777 0.65284146650674013124 0.43036505159128518594 ↙
-0.17548299682458740056 -1.206205451898409331;2.2790462220568001861 ↙
-2.5728289144099432129 -0.59287242282516128267 0.16105028940275276095 ↙
1.2862211674124750527];

% Layer 2
b2 = 0.13234642147820385727;
LW2_1 = [1.3913121473802352313 0.57370951537433212408 -0.46855206616868100289 ↙
-0.51025268628157161022 -0.68339521176798601054];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0230680507497117;
y1_step1.xoffset = 0;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
```

```
else
  Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```

```
function [Y,Xf,Af] = A11_A17280_E26A018_S(X,~,~)
%A11_A17280_E26A018_S neural network simulation function.
%
%
% [Y] = A11_A17280_E26A018_S(X,~,~) takes these arguments:
%
%   X = 1xTS cell, 1 inputs over TS timesteps
%   Each X{1,ts} = 5xQ matrix, input #1 at timestep ts.
%
% and returns:
%   Y = 1xTS cell of 1 outputs over TS timesteps.
%   Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;0;0;0;0];
x1_step1.gain = [0.0105876124933827;0.0230680507497117;0.0105876124933827; ↙
0.0105876124933827;0.0105876124933827];
x1_step1.ymin = -1;

% Layer 1
b1 = [-3.6040079433116547492;0.23815767798074144457;-5.0966066543192498628; ↙
-1.9937427225873143311];
IW1_1 = [2.3242516439656082383 -4.2587166889833021344 -0.43789487070912846978 ↙
-0.71137006198275187785  0.89695180063529844627;-0.72307682618919566497 ↙
0.054726274328145557702  0.076849704221657239023  -0.031948591901935260995 ↙
-0.21021253298604347659;-1.3131186164624741863  -9.0278117089622025304 ↙
-3.4395176408705001592  -1.0012277288768163253  3.889968255186044388; ↙
-5.8407521209342938562  5.0971484631509804686  -0.72179675649071650678 ↙
0.79617509608593384218  0.17747035053446436059];

% Layer 2
b2 = -0.45827527818624880229;
LW2_1 = [-0.26986287293176519642 -0.94708165200499849767 -0.12013383497376664555 ↙
-0.083236239219972779635];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0230680507497117;
y1_step1.xoffset = 0;

% ===== SIMULATION ========

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
  X = {X};
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
  Q = size(X{1},2); % samples/series
else
  Q = 0;
```

MODEL 11

```
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = tansig_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
  Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS ========

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
  y = bsxfun(@minus,x,settings.xoffset);
  y = bsxfun(@times,y,settings.gain);
  y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
  a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
  x = bsxfun(@minus,y,settings.ymin);
  x = bsxfun(@rdivide,x,settings.gain);
  x = bsxfun(@plus,x,settings.xoffset);
end
```