

T.C.  
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

FIRAT – DİCLE HAVZASI İÇİN YAPAY ZEKÂ TEKNİKLERİ  
İLE GÜNLÜK NEHİR AKIMI TAHMİNİ

Sefa Nur YEŞİLYURT

Danışman: Doç. Dr. Hüseyin Yıldırım DALKILIÇ

İnşaat Mühendisliği  
ANABİLİM DALI

ERZİNCAN  
2022  
Her Hakkı Saklıdır.

## ÖZET

Yüksek Lisans Tezi

### FIRAT – DİCLE HAVZASI İÇİN YAPAY ZEKÂ TEKNİKLERİ İLE GÜNLÜK NEHİR AKIMI TAHMİNİ

Sefa Nur YEŞİLYURT

Erzincan Binali Yıldırım Üniversitesi  
Fen Bilimleri Enstitüsü  
İnşaat Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Hüseyin Yıldırım DALKILIÇ

Nehir akımı tahmini ve modellemesi; su kaynaklarının yönetimi, su talebinin karşılanması, sel gibi istenmeyen durumlarda erken uyarının sağlanabilmesi, sulama ve tarım faaliyetleri gibi durumlarda önem arz ettiği için sürekli araştırılmaya ve geliştirilmeye ihtiyaç duyulmuş bir konu olarak literatürde yer almaktadır. Ne yazık ki çok sayıda teknik ile tahmin ve modelleme yapılmaya çalışılsa da evrensel bir teknikten bahsetmek olanaksızdır. Bu durum farklı tekniklerin gelişmesini ve/veya teknikler arası kıyaslama yapılmasını, kullanılan parametreler için en doğru yöntemin saptanmasını zorunlu hale getirmiştir. Bu kapsamda, bu çalışmada Fırat- Dicle Havzasında yer alan on dört istasyonun 1981-2010 yılları akım verilerinin dağılım grafikleri oluşturularak normal dağılıma uygunluğu araştırılmış, verilerin dağılımı dikkate alınarak geçmiş dönem verileri ile mevcut verilerin korelasyonu incelenmiştir. Uyarlamalı Sinirsel Bulanık Mantık Sistemi (ANFIS), Destek Vektör Regresyonu (SVR) teknikleri ile yeni kullanılmaya başlayan; Gauss Süreç Regresyonu (GPR), Aşırı Öğrenme Makinesi (ELM) ve Sezgisel Sinir Ağları (ENN) yapay zekâ teknikleri ile değerlendirme yapılmıştır. Model performansının belirlenebilmesi için sıklıkla kullanılan Kök Ortalama Kare Hatası (RMSE), Ortalama Kare Hatası (MSE), Ortalama Mutlak Hata (MAE) ve korelasyon katsayısı (r) kullanılmıştır. Ayrıca rank analizi ile hangi tekniğin daha iyi sonuç verdiği bulunması amaçlanmıştır. Her ne kadar tüm modeller yüksek performans sergileseler de rank analizi yapılarak teknikler arası en iyi sonuç verenden başlayarak kıyaslama yapıldığında sıralamanın ELM, GPR, ENN, SVR, ANFIS şeklinde olduğu görülmüştür. Sonuçların daha iyi yorumlanabilmesi için Taylor diyagramları ve model çıktılarının zaman serisi grafikleri oluşturulmuştur.

2022, 86 Sayfa

**Anahtar Kelimeler:** ANFIS, ELM, ENN, GPR, Nehir Akımı Modellemesi, SVR

## ABSTRACT

MSc Thesis

### APPLICATION OF SOFT COMPUTING TECHNIQUES IN RIVER FLOW MODELING IN THE CASE OF EUPHRATES-TIGRES BASIN

Sefa Nur YESİLYURT

Erzincan Binali Yıldırım University  
Graduate School of Natural and Applied Sciences  
Department of Civil Engineering

Supervisor: Associate Professor Hüseyin Yıldırım DALKILIÇ

River stream estimation is a subject matter that needs constant research and development since it is all-important in the management of water resources, meeting the water demand, irrigation and agricultural activities, and providing distant signal in unwanted situations such as floods. Unfortunately, a universal technique has been impossible to talk about yet although many techniques have been used for estimation and modeling. This has made it necessary to develop different techniques and / or to make comparisons between techniques and to determine the most accurate method for the parameters used. In this context, in this study, the distribution graphs of the flow data fourteen stations located in the Euphrates-Tigris Basin for the years 1981-2010 were created and their conformity to the normal distribution was investigated. Evaluation has been made with Adaptive Neural Fuzzy Logic System (ANFIS), Support Vector Regression (SVR) techniques and the newly introduced Gaussian Process Regression (GPR), Extreme Learning Machine (ELM) and Emotional Neural Networks (ENN) artificial intelligence techniques. Root Mean Square Error (RMSE), Mean Square Error (MSE), Mean Absolute Error (MAE) and correlation coefficient ( $r$ ), which are frequently used, were used to determine the model performance. In addition, it is aimed to find out which technique gives better results with rank analysis. Although all models work well, the sequence with regards to the comparison outcomes of the techniques obtained from rank analysis was observed to be ELM, GPR, ENN, SVR, ANFIS respectively. In order to better interpret the results, Taylor diagrams and time series graphics of the model outputs were created.

**2022, 86 Pages**

**Keywords:** ANFIS, ELM, ENN, GPR, River Flow Modeling, SVR

## TEŞEKKÜR

Bu çalışmanın hazırlanma sürecinde, lisans ve yüksek lisans eğitimimde, akademik hayatımın her aşamasında yanımda olan, kullandığı her kelime ile hayatıma değer katan saygıdeğer danışmanım Doç. Dr. Hüseyin Yıldırım DALKILIÇ' a sonsuz teşekkürlerimi sunarım. Desteğini benden esirgemeyen ikinci danışmanım Doç. Dr. Pijush SAMUI'e, çalışmamın uygulama aşamalarında bana destek olan Doç. Dr. Umut OKKAN, Dr. Öğr. Üyesi Funda AKAR, Doç. Dr. Gülay ONUŞLUEL GÜL, Doç. Dr. Ali GÜL, Prof. Dr. Adnan KHASHMAN, Öğretim Üyesi Ehsan LOTFI, Öğr. Gör. Dr. F. İrfan BAŞ hocalarıma ve Yüksek Lisans eğitimim boyunca beni "2210 – A Yurt İçi Yüksek Lisans Burs Programı" kapsamında destekleyen Türkiye Bilimsel ve Teknolojik Araştırmalar Kurumu'na (TÜBİTAK) teşekkürlerimi sunarım. Bu çalışmada kullanılan akım verilerini temin ettiğim Devlet Su İşleri (DSİ) ve Elektrik İşleri Etüt İdaresine teşekkür ederim.

Ayrıca tez savunma sınavıma katılarak, tezimin nihai haline görüş ve yorumlarıyla katkı sağlayan tez jüri üyelerine teşekkürlerimi sunarım.

Son olarak desteğini her zaman hissettiğim, yaşadığım tüm sevinç ve zorluklarda yanımda olan başta anne ve babam olmak üzere tüm aileme şükranlarımı sunarım.

Sefa Nur YEŞİLYURT

Haziran, 2022

# İÇİNDEKİLER

	Sayfa
<b>ÖZET</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>İÇİNDEKİLER</b> .....	<b>iv</b>
<b>ŞEKİLLER LİSTESİ</b> .....	<b>vi</b>
<b>TABLolar LİSTESİ</b> .....	<b>vii</b>
<b>SİMGELER ve KISALTMALAR</b> .....	<b>viii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. KAYNAK ÖZETLERİ</b> .....	<b>3</b>
2.1. Hidrolik, Hidroloji ve Su Kaynakları Mühendisliği Alanında Yapay Zekâ Teknikleri ile İlgili Yapılan Çalışmalar.....	3
2.2. Nehir Akımı Modellemesi Konusunda Yapılan Çalışmalar.....	5
<b>3. KURAMSAL TEMELLER</b> .....	<b>7</b>
3.1. Nehir Akımları ve Özellikleri.....	7
3.2. Akarsu Gözlem İstasyonları.....	7
3.3. Akarsu Gözlem İstasyonlarında Akım Ölçümleri.....	8
3.4. Hidrolojik Verilerin Tahmini.....	8
3.5. Yapay Zekâ Tekniklerinin Genel Yapısı ve Özellikleri.....	9
<b>4. YÖNTEM</b> .....	<b>11</b>
4.1. Çalışmada Kullanılan Hidrolojik Veriler ve Havza Özellikleri.....	11
4.2. Seçilen İstasyonlar ve Kullanılan Hidrolojik Veriler.....	12
4.3. Yöntem.....	14
4.3.1. Yapay zekâ teknikleri.....	14
4.3.1.1. Uyarlamalı Sinirsel Bulanık Mantık Sistemi (ANFIS).....	14
4.3.1.2. Aşırı Öğrenme Makinası (ELM).....	16
4.3.1.3. Sezgisel Sinir Ağları (ENN).....	18
4.3.1.4. Destek Vektör Regresyonu (SVM-SVR).....	22
4.3.1.5. Gauss Süreç Regresyonu (GPR).....	24
4.3.2. İstatistiksel model değerlendirme ölçütleri.....	25
4.3.3. Korelasyon analizi.....	25
4.3.4. Verilerin normal dağılıma uygunluğunun incelenmesi.....	26

4.3.5. Taylor diyagramı .....	27
4.3.6. Kullanılan yazılımlar .....	28
<b>5. ARAŞTIRMA BULGULARI .....</b>	<b>30</b>
5.1. Veri Setinin İncelenmesi ve Model Yapılarının Belirlenmesi .....	30
5.2. Model Sonuçların İncelenmesi ve Değerlendirilmesi .....	32
<b>6. SONUÇ ve TARTIŞMA.....</b>	<b>51</b>
<b>KAYNAKLAR.....</b>	<b>53</b>
<b>EKLER.....</b>	<b>60</b>
Ek-1. Fırat- Dicle havzası yükselti haritası .....	60
Ek-2. İstasyonlara ait normal dağılım grafiği .....	61
Ek-3. İstasyonların korelasyon matrisleri.....	68
Ek-4. İstasyonlara ait Taylor diyagramları.....	73
Ek- 5. İstasyonlara ait zaman serileri .....	78
Ek. 6. Tez Çalışması Süresince Yapılan Akademik Çalışmalar.....	85

## ŞEKİLLER LİSTESİ

	<b>Sayfa</b>
<b>Şekil 3.1.</b> Hidrolojik modeller hakkında genel bilgiler.....	9
<b>Şekil 4.1.</b> Fırat-Dicle havzası lokasyonu ve havzada yer alan istasyonlar.....	11
<b>Şekil 4.2.</b> Fırat-Dicle Havzası'nda seçilen akım gözlem istasyonları.....	12
<b>Şekil 4.3.</b> ANFIS yapısı.....	15
<b>Şekil 4.4.</b> Aşırı Öğrenme Makinası Algoritma Yapısı.....	17
<b>Şekil 4.5.</b> ENN ileri besleme hesabında izlenecek yol.....	19
<b>Şekil 4.6.</b> SVM model yapısı için örnek.....	23
<b>Şekil 4.7.</b> Örnek Taylor diyagramı.....	28
<b>Şekil 5.1.</b> 2102 numaralı istasyona ait dağılım grafiği.....	30
<b>Şekil 5.2.</b> 2102 numaralı istasyona ait korelasyon matrisi.....	31
<b>Şekil 5.3.</b> 2102 numaralı istasyonun Taylor diyagramı.....	49
<b>Şekil 5.4.</b> 2102 numaralı istasyonun test sonuçların zaman serisi.....	50

## TABLULAR LİSTESİ

	<b>Sayfa</b>
<b>Tablo 4.1.</b> Çalışma kapsamında seçilen istasyonlara ait bilgiler.....	13
<b>Tablo 4.2.</b> Çalışmada kullanılan yazılımlar .....	29
<b>Tablo 5.1.</b> Çalışma kapsamında oluşturulan modeller.....	32
<b>Tablo 5.2.</b> ANFIS modeli için kullanılan değerler.....	32
<b>Tablo 5.3.</b> ELM modeli için kullanılan parametreler.....	33
<b>Tablo 5.4.</b> SVM modeli için kullanılan parametreler.....	33
<b>Tablo 5.5.</b> GPR modeli için kullanılan parametreler.....	33
<b>Tablo 5.6.</b> 2102 numaralı istasyonun model sonuçları .....	34
<b>Tablo 5.7.</b> 2122 numaralı istasyonun model sonuçları.....	35
<b>Tablo 5.8.</b> 2124 numaralı istasyonun model sonuçları.....	36
<b>Tablo 5.9.</b> 2131 numaralı istasyonun model sonuçları.....	37
<b>Tablo 5.10.</b> 2135 numaralı istasyonun model sonuçları.....	38
<b>Tablo 5.11.</b> 2145 numaralı istasyonun model sonuçları.....	39
<b>Tablo 5.12.</b> 2149 numaralı istasyonun model sonuçları.....	40
<b>Tablo 5.13.</b> 2151 numaralı istasyonun model sonuçları.....	41
<b>Tablo 5.14.</b> 2156 numaralı istasyonun model sonuçları.....	42
<b>Tablo 5.15.</b> 2158 numaralı istasyonun model sonuçları.....	43
<b>Tablo 5.16.</b> 2164 numaralı istasyonun model sonuçları.....	44
<b>Tablo 5.17.</b> 2166 numaralı istasyonun model sonuçları.....	45
<b>Tablo 5.18.</b> 2610 numaralı istasyonun model sonuçları.....	46
<b>Tablo 5.19.</b> 2612 numaralı istasyonun model sonuçları.....	47
<b>Tablo 5.20.</b> Toplam rank değerleri.....	48

## SİMGELER ve KISALTMALAR

### Simgeler

$Y_{AvPAT}$	Algoritma Desenlerinin Ortalama Deęeri (ENN)
$x_{max}$ ve $y_{max}$	X Ve Y Yönlendeki En Yüksek Piksel Sayıları (ENN)
$\Delta_j$	Çıktı Nöronlarının Sinyali (ENN)
$\beta_j$	Çıkış Nöronu (ELM)
$\theta_f$	Genlik (GPR)
$\theta_t$	Uzunluk (GPR)
$\Sigma$	Toplam
$\mu_{Ai}(x)$ ve $\mu_{Bi}(y)$	Üyelik Dereceleri (ANFIS)
$\mu_i$	Her Bir Kural Düğümünün Çıktısı (ANFIS)
$b$	Yanlılık (SVM)
$b_i$	Gözlemlenen Deęer
$b_j$	Eęilim (Sapma) (ELM)
$H$	Gizli Katman Çıktı Matrisi (ELM)
$h$	Gizli Katman Nöronu (ENN)
$i$	Düğüm Sayısı (ANFIS)
$jj$	Hata Terimi (ENN)
$j_h$	Gizli Nöronları Bağlayan Aęırlık Deęeri (ELM)
$K(x,x')$	Kovaryans Fonksiyonu (GPR)
$L$	Gizli Düğüm (ANFIS)
$Q$	Akım
$r$	Korelasyon Katsayısı
$w$	Aęırlık Vektörü
$x$	Hiper Düzlem Üzerinde Bir Nokta (SVM)
$y_i$	Modeller Tarafından Üretilen Çıktılar
$\eta$	Öğrenme Katsayısı (ENN)
$\mu$	Kaygı Katsayısı (ENN)
$f$	Moore-Penrose Genelleştirilmiş Ters (ELM)
$E$	Geri Besleme Hatası (ENN)

$N$	Desen (Veri) Sayısı (ENN)
$TP_{hb}$	Gizli Katman Nöronları Ve İlgili Ağırlıklar (ENN)
$TP_{hc}$	Geleneksel Toplam Potansiyel Değeri (ENN)
$TP_{hm}$	Gizli Katmanın Sezgisel Nöronları Ve İlgili Sezgisel Ağırlıklar (ENN)
$XH_h$	Gizli Katmanın Giriş Verileri (ENN)
$Xl_i$	Giriş Katmanının Girdi Değeri (ENN)
$YH_H$	Gizli Katmanın Çıktı Verileri (ENN)
$Yl_i$	Giriş Katmanının Çıktı Değeri (ENN)
$i$	Giriş Katmanı Nöronu (ENN)
$j$	Çıkış Katmanı Nöronu (ENN)
$k$	Güven Sayısı (ENN)
$p$	Desen İndeksi (ENN)
$\varepsilon$	Hata Değeri (SVM)
$\xi_i, \xi_i^*$	Gevşeklik Değişkenleri (SVM)

### **Kısaltmalar**

$A-D$	Anderson Darling Testi
$AGİ$	Akım Gözlem İstasyonları
$ANFIS$	Uyarlamalı Sinirsel Bulanık Mantık Sistemi
$ARIMA$	Bütünleşik Otoresif Hareketli Ortalama
$BP$	Geri Yayılım Algoritması
$CART$	Regresyon Ağaçları
$DSİ$	Devlet Su İşleri
$EİE$	Elektrik İşleri İdaresi
$ELM$	Aşırı Öğrenme Makinası
$ENN$	Sezgisel Sinir Ağları
$FA$	Ateşböceği Algoritması
$FS$	İleri Besleme
$GL$	En Küçük Kare Tahminleyicisi
$GO$	Genetik Algoritma
$GPR$	Gauss Süreç Regresyonu
$KNN$	K-En Yakın Komşular algoritması

<i>K-S</i>	Kolmogorov-Smirnov Testi
<i>MARS</i>	Çok Değişkenli Uyarlanabilir Regresyon
<i>MLR</i>	Çoklu Doğrusal Regresyon
<i>MNLR</i>	Çoklu Doğrusal Olmayan Regresyon
<i>MPMR</i>	Minimax Olasılık Makinesi Regresyonu
<i>MSE</i>	Ortalama Kare Hatası
<i>PSO</i>	Parçacık Sürüsü Optimizasyonu
<i>RMSE</i>	Kök Ortalama Kare Hatası
<i>RVM</i>	Uygunluk Vektör Makinesi
<i>SLFN</i>	Tek Katmanlı İleri Beslemeli Sinir Ağı
<i>SPEI</i>	Standardize Yağış Evopotranspirasyon İndeksi
<i>SPI</i>	Standardize Yağış İndeksi
<i>SVM, SVR</i>	Destek Vektör Regresyonu
<i>VDM</i>	Varyasyon Modu Araştırması
<i>WMO</i>	Dünya Meteoroloji Örgütü
<i>WNN</i>	Dalgacık Sinir Ağı
<i>XgBoost</i>	Aşırı Gradyan Arttırma Algoritması
<i>YSA</i>	Yapay Sinir Ağları

## 1. GİRİŞ

Yaşamın ana unsuru olan su, sahip olduğu potansiyel sayesinde canlıların yaşamlarını devam ettirebilmesi için gereken enerjinin sağlanmasında kullanılan vazgeçilmez bir kaynaktır. Bu nedenle canlı yaşamı için büyük öneme sahiptir. Ancak hem Dünyada hem de ülkemizde su kaynakları düşünülmeden veya planlama yapılmadan kullanılacak miktarda değildir. Mevcut su kaynaklarının verimli kullanılması, su yapılarının geliştirilmesi, farklı maksatlar için yapılması planlanan su yapılarının inşası öncesinde su kaynağının durumunun incelenmesi gibi durumlarda akım modellemesi ve tahmini gerekmektedir. Aynı zamanda hidrolojik olayların oluşumunda bilinmeyen birçok etken olması, çalışma yapılan alandaki değişiklikler, nehir sistemlerindeki ve akım verilerindeki düzensizlikler de araştırmacılar tarafından model oluşturulmasını ve geleceğe yönelik tahminde bulunulmasını zorunlu hale getirmiştir. Bazı matematiksel yöntemlerle yapılabilen bu tahminler; yapay zekâ teknikleri ile daha başarılı sonuçlar vermekte ve daha kısa zaman içinde gerçekleştirilebilmektedir. Bu nedenle akış serilerinin tahmin ve modellemesi yapılırken yapay zekâ teknikleri sıklıkla kullanılmaktadır (He vd., 2014; Rezaeiezadeh vd., 2014; Yaseen vd., 2016,2019,2020; Zhou vd., 2019; Adnan vd., 2021; Chaudhury vd., 2022; İbrahim vd., 2022).

Ancak akış serilerinin stokastik karakteri sebebiyle modelleme yapılmadan önce zaman serilerine en uygun model ve dağılımın seçilmesi gerekmektedir. Ayrıca karmaşık bir yapıya sahip olan akış serilerinin; geleneksel yöntemlerle tahmininde yanılma payı yüksek olarak görülmekte ve zaman serilerindeki anlık değişimler doğrusal modellerin bazılarının yetersiz kalmasına sebep olmaktadır. Bu nedenle yapılan çalışmaların büyük bir çoğunluğu metotlar arasında kıyaslama yapmayı ve en iyi sonucu bulabilmeyi amaçlamaktadır (Farmer, 2016; Yaseen vd., 2019).

Sunulan bu çalışmada da nehir akımlarının genel özellikleri, hidrolojik verilerin tahmin ve modellemesi, yapay zekâ teknikleri genel hatlarıyla incelenmiş ve Fırat-Dicle Havzasında yer alan on dört meteoroloji istasyonuna ait günlük akım verileri kullanılarak günlük akım değerlerinin modellemesi yapılmıştır. Çalışma kapsamında ilk olarak akım verilerinin dağılım durumları incelenerek, verilerin normal dağılıma uyup uymadığı incelenmiştir. Verilerin normal dağılıma uymadığı Kolmogorov-Smirnov Testi (K-S

Testi), Geliştirilmiş K-S testi (K-S Modified Test) ve Anderson-Darling Normallik Testi (A-D Testi) ile belirlenmiştir. Sonrasında zaman serilerinin korelasyon matrisi normal dağılım varsayımına ihtiyaç duymayan Spearman korelasyon katsayısı ile incelenerek mevcut akımlarla en fazla ilişkiye sahip olan dönemler incelenmiş ve girdi kombinasyonları belirlenmiştir. Kullanılan yapay zekâ tekniklerinin kıyaslanması ve verilere en uygun metodun belirlenmesi amaçlanan çalışmada Uyarlamalı Sinirsel Bulanık Mantık Sistemi (ANFIS), Aşırı Öğrenme Makinası (ELM), Sezgisel Sinir Ağları (ENN), Destek Vektör Regresyonu (SVM - SVR) ve Gauss Süreç Regresyonu (GPR) kullanılmıştır. Korelasyon katsayısı ( $r$ ), Kök Ortalama Kare Hata (RMSE), Ortalama Kare Hatası (MSE) ve Ortalama Mutlak Hata (MSE) ile model performansları değerlendirilen çalışmada rank (sıralama) analizi ile en iyi model yapısı belirlenmiştir. Rank analizi sayesinde tek bir ölçütle model performansının belirlenmesinden ziyade tüm ölçütler dikkate alınarak performansın belirlenmesi sağlanmıştır. Ayrıca model sonuçlarının görsel olarak daha net sunulabilmesi amacıyla Taylor diyagramları ve model çıktılarının zaman serisi grafiği oluşturulmuştur.

## 2. KAYNAK ÖZETLERİ

### 2.1. Hidrolik, Hidroloji ve Su Kaynakları Mühendisliği Alanında Yapay Zekâ Teknikleri ile İlgili Yapılan Çalışmalar

Yapay zekâ tekniklerinin kullanım alanları sadece nehir akımı modellemesi ile sınırlı değildir. Her ne kadar ELM, ENN ve GPR metotları yeni kullanılmaya başlayan metotlar olsalar da literatürde yapay zekâ teknikleri kullanılarak yapılmış çok sayıda çalışma vardır. Örneğin, yağış tahmini (Akrami vd., 2014; Mokhtarzad vd., 2017; Choubin vd., 2018; Li vd., 2018) evapotranspirasyon tahmini (Tao vd., 2018; Ferreira vd., 2019; Han vd., 2019), kuraklık (Mokhtarzad vd., 2017; Khan vd., 2020; Zhang vd., 2020a), hava kalitesi (Ghasemi ve Amanollahi, 2019; Bhardwaj ve Pruthi, 2020), toprak nemi (Li vd., 2019; Ji vd., 2020), su seviyesi tahmini (Khan ve Coulibaly, 2006; Hipni vd., 2013; Deo ve Şahin, 2016), su kalitesi (Azad vd., 2019), buharlaşma (Mohamadi vd., 2020) gibi çok sayıda konuda ve çalışmada kullanılmış olan teknikler, farklı teknikler ile kıyaslanmış veya geliştirilmiştir.

Aynı zamanda su kaynakları mühendisliği için büyük önem arz eden hidrolik yapıların geliştirilmesi için çalışılan açık kanallarda tortu taşınması (Safari vd., 2019), açık kanallarda deşarj katsayısı (Azimi vd., 2017) gibi konularda da kullanılan yöntemler su kaynakları mühendisliğinin geliştirilmesine büyük katkı sağlamışlardır.

Bu çalışmalar detaylı olarak incelendiğinde Akrami vd., (2014) dalgacık ayrıştırma yönteminin ANFIS ve Yapay Sinir Ağları (YSA) ile birleştirilmesiyle aylık yağış verilerinin tahmin edilmesini önermektedir. Çalışma sonucunda dalgacık ayrışımına dayalı ANFIS modelinin YSA ve ANFIS modellerinden daha yüksek performansa sahip olduğu belirtilmiştir. Mokhtarzad vd., (2017) tarafından yapılan ve giriş parametresi olarak sıcaklık, nem, yağış verilerinin kullanıldığı çalışmada; kuraklık değerlerinin tahmin edilmesi amacıyla Standardize Yağış İndeksi (SPI) çıktı parametresi olarak kullanılmıştır. Yapay zekâ tekniklerinden YSA, SVM ve ANFIS kullanılan çalışmada en yüksek performansa sahip olan modelin SVM olduğu görülmüştür. Choubin vd., (2018) tarafından yapılan çalışmada ise Sınıflandırma ve Regresyon Ağaçları (CART), Bütünleşik Ototregresif Hareketli Ortalama (ARIMA) ve ANFIS kullanılarak yağış tahmini yapılmış ve en iyi sonuca CART yöntemi ile ulaşılmıştır. Li vd., (2018)

tarafından yapılan çalışmada ise aylık yağış zaman serisinin tahmini için ELM, Geri Yayılım Algoritması (BP) ve Varyasyon Modu Araştırması (VDM) kullanılmıştır. Çalışmada kıyaslanan algoritmalar arasında en yüksek performansa sahip algoritmanın ELM olduğu belirtilmiştir. Evopotranspirasyon tahmini üzerine çalışılan bir çalışmada ise SVM kullanılmıştır. Bunun yanı sıra meteoroloji istasyonlarını gruplandırmak için K-Ortalamlar ve Kümeleme yöntemi de kullanılmıştır. Bu uygulama sayesinde model performansının iyileştirildiği belirtilmiştir (Ferreira vd., 2019). Tao vd., (2018) tarafından yapılan başka bir çalışmada ise hibrit bir ANFIS modeli olan ANFIS-FA (Ateşböceği Algoritması) günlük evopotranspirasyon tahmini için önerilmiştir. Çok sayıda meteorolojik girdi parametresi kullanılan çalışmada iyi bir performans seviyesine ulaşılmıştır. Han vd., (2019) tarafından Çin’de yapılan bir başka çalışmada ise aylık evopotranspirasyon değerlerinin tahmini için Aşırı Gradyan Arttırma Algoritması (XgBoost), Çok değişkenli Uyarlanabilir Regresyon Eğrileri (MARS) ve GPR kullanılmıştır. Çalışmada en yüksek performansa MARS modelinde ulaşılmıştır.

Kuraklık tahmini üzerine yapılan çalışmalar incelendiğinde ise, Khan vd., (2020) tarafından Pakistan için ilk kez yapay sinir ağları ile kuraklık tahmininde bulunulmuştur. SVM ve K-En Yakın Komşular algoritması (KNN) kullanılan çalışmada Standardize Yağış Evopotranspirasyon İndeksi (SPEI) değerleri tahmin edilmiştir. Zhang vd., (2020b) yaptıkları çalışmada ise Otoregresif Entegre Hareketli Ortalama (ARIMA), Dalgacık Sinir Ağı (WNN) ve ANFIS kullanılarak SPEI kuraklık indeksi tahmin edilmiştir. 3 aylık kuraklık değerlerinin tahmini üzerine çalışılan bir diğer çalışmada ise ANN, SVR ve ANFIS kullanılmıştır. Elde edilen sonuçlar SVR modelinin daha iyi sonuç verdiğini göstermiştir (Mokhtarzad vd., 2017).

Hava kalitesi üzerine 2019 yılında yapılan bir çalışmada ise İleri Besleme (FS) ve ANFIS kullanılarak hava kalitesi irdelenmiştir (Ghasemi ve Amanollahi, 2019). Hindistan’ da hava kirletici bir maddenin analizi üzerine çalışılan bir başka çalışmada ise ANFIS, Genetik Algoritma (GO) ve Parçacık Sürüsü Optimizasyonu (PSO) ile çalışılmıştır. Bu çalışmalarda da görüldüğü gibi seçilen yapay zekâ teknikleri çeşitli konularda kullanılabilmekte ve başarı sağlayabilmektedir.

## 2.2. Nehir Akımı Modellemesi Konusunda Yapılan Çalışmalar

Bu tezin de konusu olan nehir akımı modellemesi ve tahmini için de yapılmış çok sayıda çalışma yer almaktadır. Bu çalışmalar detaylı olarak incelendiğinde Zhou vd., (2019) çalışmada GA ve En Küçük Kare Tahminleyicisi (GL) ile ANFIS yapısını birleştirmiş ve kullanılan zaman serisi için ANFIS-GL yapısının daha iyi sonuç verdiği gözlemlenmiştir. Aylık nehir akımı verileriyle yapılan başka bir çalışmada ise ANN, ANFIS ve SVR kullanılmıştır. Karmaşık topografyaya sahip bölgelerde bu yöntemlerin kullanılabilceği belirtilmiştir. Ayrıca çalışma sonucunda SVR yapısının daha yüksek performans gösterdiği belirtilmiştir (He vd., 2014). Çoklu Doğrusal Regresyon (MLR), Çoklu Doğrusal Olmayan Regresyon (MNLR), ANN ve ANFIS kullanılan başka bir çalışmada ise maksimum günlük akım değerleri tahmin edilmiştir. Çalışma sonucunda MNLR modelinin en yüksek performansı gösterdiği belirtilmiştir (Rezaeianzadeh vd., 2014). Bu çalışmada da kullanılan ELM modelinin nehir akımı modellemesi için ilk defa önerildiği çalışmada ise; Yaseen vd., (2016) ELM, SVR ve Tek Katmanlı İleri Beslemeli Sinir Ağı (SLFN) kullanılmıştır. Çalışma sonucunda ELM algoritmasının nehir akımı modellemesi için uygun olduğu belirtilmiştir. ELM modeli bir başka çalışmada geliştirilerek EELM şeklinde kullanılmış, EELM, ELM, SVR modelleri kıyaslanmıştır. Çalışma sonucunda EELM modelinin daha yüksek performans sağlayacak şekilde geliştirilebildiği belirtilmiştir (Yaseen vd., 2019). Adnan vd., (2021) ise hibrit ELM modelleri kullanarak aylık akış verilerini tahmin etmiştir. Çalışma sonucunda modellerin aylık akış tahmini için tavsiye edilme potansiyelinin yüksek olduğunu belirtilmiştir. Yaseen vd., (2020) tarafından yapılan çalışmada ise ENN algoritması nehir akımı tahmini için ilk kez önerilmiştir. Çalışmada saatlik nehir akımları kullanılmış ve ENN algoritması ile Çok Değişkenli Uyarlanabilir Regresyon (MARS), Minimax Olasılık Makinesi Regresyonu (MPMR), Uygunluk Vektör Makinesi (RVM) algoritmaları kıyaslanmıştır. Sun vd., (2014) yapılan çalışmada ise günlük nehir akımı verileri MOPEX havzaları için kullanılmıştır. Çalışmada uzun dönem nehir akımı verileri kullanıldığında GPR algoritmasının iyi performans gösterdiği belirtilmiştir.

Bu tez çalışmasında ise ANFIS SVM, ELM ENN, GPR yöntemleri kullanılarak günlük akış tahmini yapılmıştır. Çalışma için Türkiye'nin sınır aşan sulara sahip olması, en kurak havzalardan biri olması gibi sebeplerden ötürü en önemli havzalarından biri olan Fırat –

Dicle Havzasında yer alan on dört akım gözlem istasyonu seçilmiştir. Veriler kullanılmadan önce normal dağılıma uygunluğu değerlendirilerek, geçmiş dönemlere göre korelasyon durumu incelenmiştir. Çalışmada model performanslarının değerlendirilmesi için Korelasyon katsayısı ( $r$ ), Kök Ortalama Kare Hata (RMSE), Ortalama Kare Hatası (MSE) ve Ortalama Mutlak Hata (MSE) metrikleri kullanılmıştır. Bu metrikler arasında bir üstünlük olmadığından metrikler arası rank analizi uygulanarak en iyi model yapısının ve en iyi algoritmanın seçilmesi amaçlanmıştır.



### **3. KURAMSAL TEMELLER**

#### **3.1. Nehir Akımları ve Özellikleri**

Ülkemiz yer şekilleri, iklim koşulları ve çeşitli meteorolojik sebeplerden ötürü sık bir akarsu ağına sahiptir. Bu akarsuların büyük bir bölümü dağlardan doğmakta, bir kısmı ise ova ve yaylalardan doğarak havzalara yönelmektedir. Türkiye'deki havzaların genel özellikleri incelendiğinde; akarsu havzalarının dar olduğu, az yağış aldığı, taşıdıkları su miktarının az olduğu ve yataklarının fazla eğimli olduğu görülmektedir. Ayrıca akarsularımızın akış seyri incelendiğinde, akış seyri ile kullanım seyri arasında ters bir ilişkinin var olduğu görülmektedir. Çünkü akarsularımızın çok büyük bir kısmında su seviyesi maksimum seviyede olduğu dönem ilkbaharken, su ihtiyacının en fazla olduğu aylarda ise su seviyeleri minimumdur. Uzun süreli kuraklıklara ve taşkınlara sebep olan bu durum maddi ve manevi kayıplara neden olmaktadır. Bu durum dikkate alınarak ülke genelinde çok sayıda su yapıları yapılmıştır. Ancak bu yapıların yapılabilmesi için su yapılarının doğru şekilde planlanması, projelerinin hazırlanması, akarsu akışının uzun dönem etüt edilmesi gerekmektedir.

Bu kapsamda Devlet Su İşleri (DSİ) ve Elektrik İşleri İdaresi (EİE) tarafından akım gözlem istasyonları (AGİ) yardımıyla akım durumları tespit edilmekte ve bu verilerin kullanılmasıyla geleceğe yönelik tahminler yapılarak doğru planlama yapılmaya çalışılmaktadır (Gündüz, 2011).

#### **3.2. Akarsu Gözlem İstasyonları**

Günlük su seviyelerinin doğru şekilde belirlenebilmesi amacıyla akarsulara kurulan yardımcı tesislere Akım Gözlem İstasyonu (AGİ) denilmektedir. Hidrometrik aletlerle donatılmış ve belirli zamanlarda debi ölçümlerinin yapılmasını sağlayan AGİ'lerde akarsu hakkında hidrometrik veriler toplanmaktadır. Bu tesislerin kurulumundaki temel amaç akarsuyun istasyonun belirli bir kesiminden geçirdiği su miktarının tespit edilmesidir. AGİ'ler DSİ ve EİE tarafından işletilmektedir (Gündüz,2011).

AGİ'ler seviye ölçüm tesisleri, akım ölçüm tesisleri ve kontrol kesitleri olarak isimlendirilen üç ögeye sahiptir. Ayrıca ülkemiz genelinde AGİ'ler aracılığıyla akarsu

seviyesi ölçümü, su kalitesinin belirlenmesi, hava sıcaklığının belirlenmesi, su sıcaklığının belirlenmesi, akarsu akımı ölçümü, sediment miktarının tespiti, yüzeysel sular için buzlanma tespiti, hava ve su durumu, akarsu yatağındaki oyulma, dolma durumları tespit edilebilmektedir (EİE,2006).

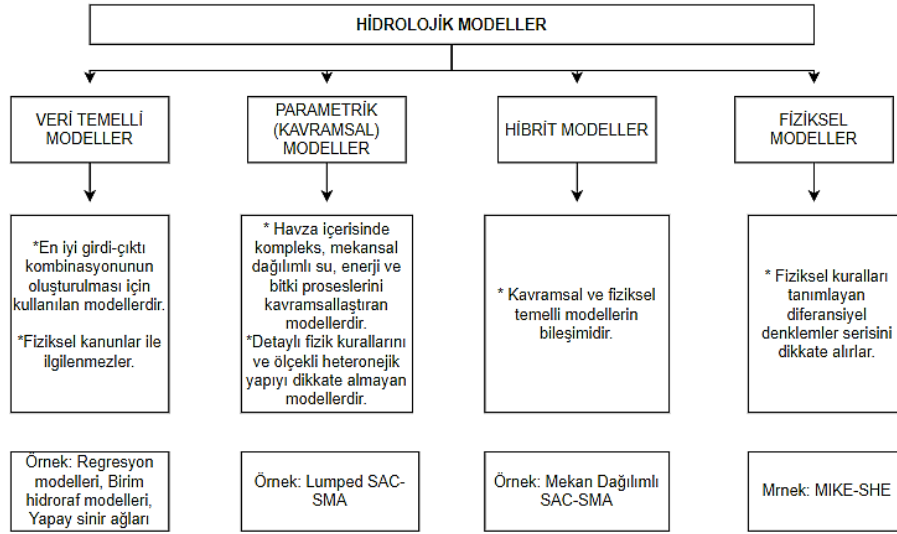
### **3.3. Akarsu Gözlem İstasyonlarında Akım Ölçümleri**

Akarsu gözlem istasyonlarından elde edilen akarsu debisi, akarsuyun belirli bir kesitinden geçen suyun metre küp cinsinden değerini ifade etmektedir. Akarsu akımını bulmak amacıyla akarsuyun enine kesiti yeterli düzeyde parçaya ayrılır, derinlik ve ara mesafelerin alanları hesaplanır, bu alanların ortalama hızları tespit edilir, debi hesabı yapılır, kesitten geçen toplam debi bulunur. Akarsu debisi ölçümü için flatörler, boya ve tuz metotları kullanılabilir de en güvenilir ve tercih edilen ölçüm şekli mulinerlerle yapılan ölçüm şeklindedir. EİE ve DSİ; Dünya Meteoroloji Örgütü (World Meteorology Organization, WMO) tarafından geliştirilen standartlara uygun olarak ölçüm yapmaktadır (EİE, 2006-2008).

### **3.4. Hidrolojik Verilerin Tahmini**

Mühendislik çalışmalarında kullanılan ve mühendislik yapılarının tasarımı, planlanması, projelendirilmesi gibi aşamalarda büyük öneme sahip olan hidrolojik verilerin tahmini ve modellenmesi için öncelikle doğal verilerin ölçülmesi gerekmektedir. Hidrolojik veriler zaman serisi şeklinde hazırlanarak verilerin eğilimi (trend), çevrimsel bileşenleri, mevsimsel bileşenleri dikkate alınır. Ölçümler sonucunda elde edilen bu gözlem verilerinin incelenmesi ve tahmini için lineer sistemler, lineer olmayan (non-linear) sistemler, açık ve kapalı sistemler, deterministik ve stokastik sistemlere dayalı birçok yöntem kullanılmaktadır. Bu sistemler girdi-çıkı kombinasyonları oluşturarak bir tür sebep sonuç ilişkisi oluşturmayı hedefler. Sistemlerin çıktıları; sistemin doğası, fizik kanunları ve girdiler belirler. Klasik yaklaşımlarda fizik kanunları gibi belirleyiciler ile modellerin kurulması sağlansa da karmaşık yapıdaki veriler için bu sağlanamaz. Bu sistemler içerisinde oluşturulacak olan veri temelli modeller, parametrik modeller, hibrit modeller ve fiziksel modeller aracılığıyla hidrolojik verilerin modellenmesi ve tahmini gerçekleştirilebilmektedir. Bu modellerin genel yapısı hakkında bilgilere Şekil 3.1

aracılığıyla ulaşılabilmektedir. Bu çalışma kapsamında kullanılan modeller kara kutu sistemler olarak da bilinen veri temelli modeller arasından seçilmiştir.



**Şekil 3.1.** Hidrolojik modeller hakkında genel bilgiler (Gündüz, 2011; Latifoğlu,2017)

Bu şema içinde verilen SAC-SMA modeli Topaklanmış Sacramento Toprak Nemi Hesaplama Modeli iken, MIKE-SHE modeli dinamik kanal akışı için birleştirilmiş fizik tabanlı bir modeldir.

### 3.5. Yapay Zekâ Tekniklerinin Genel Yapısı ve Özellikleri

İnsanların düşünme yeteneklerini, insan beyninin çalışma mekanizmasını hatta canlı davranışlarının taklit edilmesini sağlayan yapay zekâ teknikleri; bu davranışları ve özellikleri bilgisayar ortamına aktararak verilerin modellemesini yapmakta; bu modelleme sayesinde bilgisayarlara bir öğrenme yeteneği kazandırmayı amaçlamaktadır. Yapay zekâ teknikleri çok sayıda ve çok farklı bileşenlere sahip olmalarına rağmen temelde 4 bileşene ayrılmaktadır. Uzman sistemler, bulanık mantık sistemleri, yapay sinir ağları, genetik algoritma sistemlerinden oluşan bu bileşenler farklı özelliklere sahip olduğundan incelenmesi ve teknikler üzerinde çalışılması büyük önem arz etmektedir (Leungh vd., 1997).

Uzman sistemler (Expert Systems) kural tabanlı sistemler olarak tanımlanabilmekte ve aslında bilgisayarda düzenlenmiş danışma sistemleri olarak da düşünülebilmektedir.

Tanımlama, kavramsallaştırma, formüle etme (yazılım) ve test etme, değerlendirme aşamaları ile oluşturulan Uzman sistemler çoğunlukla tıp ve biyomedikal alanlarda kullanılmaktadır (Heiss vd., 2002).

Bulanık mantık sistemler (Fuzzy Logic) ise insan düşüncesinin esnek ve değişken yapısını dikkate almakta ve bilgiler arasında kurduğu sebep-sonuç ilişkisi ile mantıklı sonuçlar üretmeyi amaçlamaktadır. Bu işlem için belirlenen veriler belirli sınırlar içerisinde gruplandırılarak bulanık kümeler oluşturulur, tüm durumlar dikkate alınır ve kural tabanlı bir sistem oluşturulur. Bu kurallar kontrol algoritmasına bağlı olarak değerlendirilir ve bir çıkış değerine ulaşılır. Bulanık mantık içlerinde mühendislik uygulamalarının da olduğu çok sayıda alanda ve çalışmada (kalite kontrol sistemleri, ürün planlaması, taşıma ulaşım, oyun kuramı, ziraat, bankacılık, tıp gibi) sıklıkla kullanılan yöntemler arasındadır (Nauck vd., 1997).

Yapay sinir ağları (Artificial Intelligence Networks-ANN) ise örnekler yardımı ile çalışmakta olan ve örnekler hakkında bilgi toplayıp genellemeler yaptıktan sonra hiç görmediği örnekler hakkında yorum yapabilen sistemlerdir. Bu yeteneği sayesinde günümüzde birçok çalışmada kullanılmakta olan yapay sinir ağları karmaşık problemlerin çözümünde oldukça iyi sonuç verebilmektedir. Sinir ağı olarak isimlendirilmesinin sebebi insan beynindeki nöronlara benzer şekilde oluşması olan ANN; sinir ağları arasında değişik bağlantılar kurarak sonuç bilgilerini oluşturmaktadır (Nauck and Kruse, 1998; Bonaccorso, 2017).

Genetik algoritma (Genetic Algorithm) canlılarda yaşanan genetik sürecin bilgisayar ortamında gerçekleştirilmiş halidir. Parametre kümelerini kodlayarak çalışan genetik algoritma amaç fonksiyonu bilgisi ile çalışmaktadır. Doğada iyi olanın hayatta kalması prensibine dayanan genetik algoritma, olasılıksal ve sezgisel bir arama metodudur. Genel çözüm teknikleri ile çözülemeyen ve çözümü zor olan problemlere başarı ile uygulanabilmektedir (Goldberg ve Samtani, 1986).

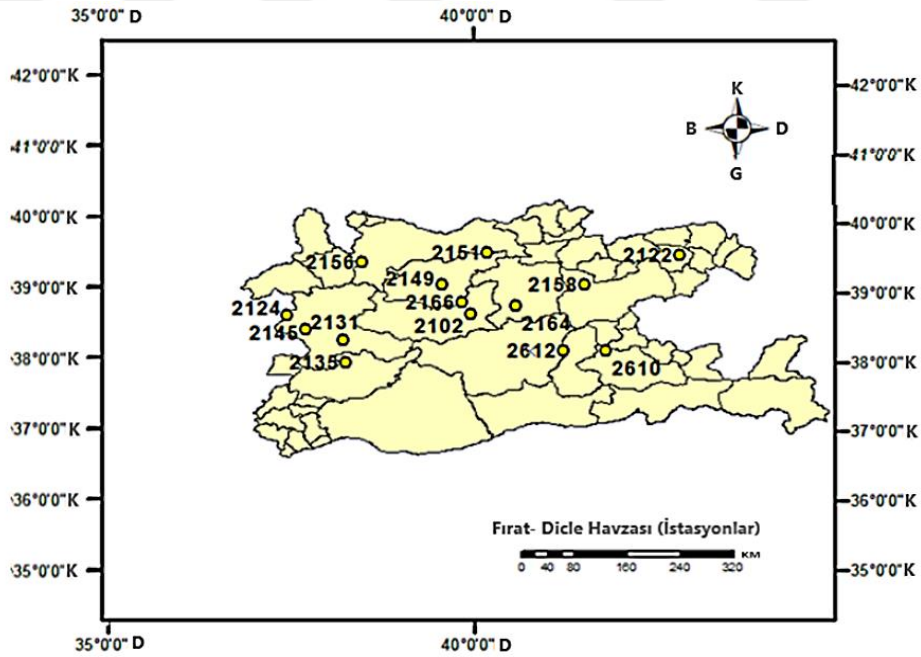
Bu çalışmada kullanılan yöntemlerden ANFIS bulanık mantık sistemleri, ELM, ENN, SVM ve GPR yapay sinir ağları içerisinde yer almaktadır. Bu çalışmada mühendislik çalışmalarında sıklıkla kullanılan iki yapay zekâ tekniği grubunun incelenmesi amaçlanmıştır.



Türkiye’den doğarak birçok kola ayrılan Dicle Havzası ise; Türkiye’nin en önemli havzalarından biridir. Ayrıca havza Fırat nehri ile birleşerek Basra Körfezine dökülen Dicle Nehrinden ismini almaktadır. Havza hidrolojik yapısı, sınır aşan sulara sahip olması ve konumu sebebiyle son derece önemlidir (Karaca, 2020).

#### 4.2. Seçilen İstasyonlar ve Kullanılan Hidrolojik Veriler

Bu çalışmada akım modellemesi ve tahmini yapmak için kullanılan veriler Elektrik İşleri Etüt İdaresi Genel Müdürlüğü ve Devlet Su İşleri Akım Gözlem yıllıklarından alınmıştır. Bu veriler 2102, 2122, 2124, 2131, 2135, 2145, 2149, 2151, 2156, 2158, 2164, 2166, 2610 ve 2612 istasyonlarında ölçülmüştür. Çalışmada Hükümetler Arası İklim Değişikliği Paneli (Intergovernmental Panel on Climate Change, IPCC) AR6 raporunda verilen senaryo aralıklarından biri olan 1981 ile 2010 yılları arasındaki akım verileri kullanılmıştır. Çalışma kapsamında her iki havzayı da temsil ettiği düşünülen ve eksik veri oranı az olan (%10’un altında) on dört AGİ kullanılmıştır. Seçilen istasyonlara ait bilgiler Tablo 4.1.’de, istasyon konumları ve havzadaki dağılımı ise Şekil 4.2’de gösterilmiştir. Ayrıca havzaya ait yükselti haritası Ek 1.1’de sunulmuştur.



Şekil 4.2. Fırat-Dicle havzasında seçilen akım gözlem istasyonlar

**Tablo 4.1.** Çalışma kapsamında seçilen istasyonlara ait bilgiler

İstasyon No	İsim	Enlem-Boylam	Gözlem Süresi (Yıl)	Ortalama (akım) (m <sup>3</sup> /sn)	Maksimum (akım) (m <sup>3</sup> /s)	Minimum (akım) (m <sup>3</sup> /s)	Standart sapma (akım)
2102	Murat Nehri - Palu	(39° 56' 22" D - 38° 41' 49" K)	1936-2011	179,230	997	12,100	207,606
2122	Murat Nehri- Tutak	(42° 46' 49" D - 39° 32' 19" K)	1953-2011	47,480	821	1,970	73,041
2124	Tohma- Yazıkoy	(37° 26' 33" D - 38° 40' 21" K)	1954-2011	6,605	59,8	0,425	3,855
2131	Bey Çayı- Kılalık	(38° 12' 36" D - 38° 19' 21" K)	1956-2011	1,343	38,8	0,110	1,894
2135	Bulam Nehri - Fatopasa	(38° 14' 13" D - 37° 59' 38" K)	1957-2011	3,624	27,3	0,844	2,438
2145	Tohma- Hisarcık	(37° 41' 08" D - 38° 28' 32" K)	1962-2011	20,019	251	5,530	13,285
2149	Munzur- Miskısag	(39° 32' 35" D - 39° 06' 29" K)	1963-2011	24,714	274	5,530	23,045
2151	Fırat Nehri- Demirkapı (Sansa )	(40° 10' 05" D - 39° 34' 41" K)	1963-2011	58,863	712	4,070	74,378
2156	Karasu- Asagıkagdaric	(38° 26' 55" D - 39° 25' 57" K)	1968-2011	150,927	980	54,800	116,844
2158	Bingöl Nehri - Abdurrahman paşa Köprüsü	(41° 29' 14" D - 39° 06' 30" K)	1968-2011	18,496	338	1,300	29,181
2164	Goynuk Nehri - Çayagzı	(40° 33' 17" D - 38° 48' 06" K)	1968-2011	32,497	630	0,450	56,143
2166	Perı - Logmar	(39° 48' 50" D - 38° 51' 31" K)	1968-2011	76,742	967	0,550	96,458
2610	Bitlis Nehri- Baykan	(41° 46' 57" D - 38° 09' 41" K)	1954-2011	17,969	420	1,950	24,602
2612	Batman Nehri -Malabadı Köprüsü	(41° 12' 16" D - 38° 09' 16" K)	1957-2011	112,848	990	0,015	150,300

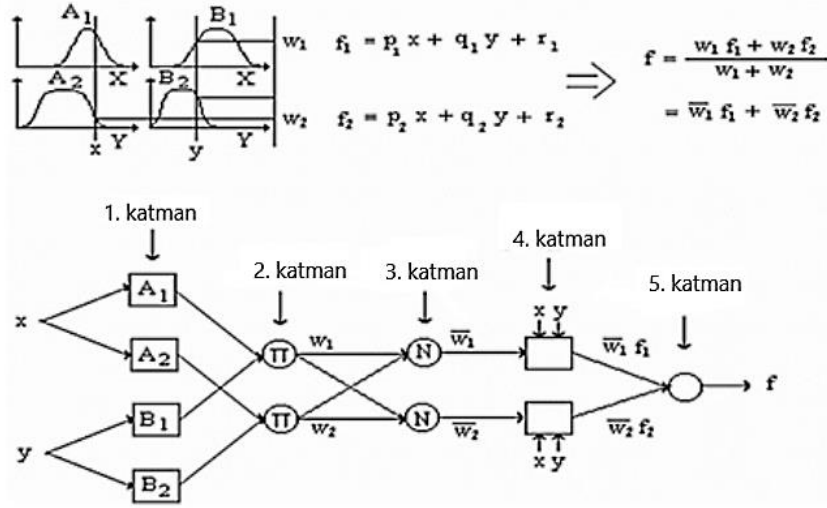
### 4.3. Yöntem

#### 4.3.1. Yapay zekâ teknikleri

Bu çalışma kapsamında Uyarlamalı Sinirsel Bulanık Mantık Sistemi (ANFIS), Aşırı Öğrenme Makinası (ELM), Sezgisel Sinir Ağları (ENN), Destek Vektör Regresyonu (SVR) ve Gauss Süreç Regresyonu (GPR) yapay zekâ yöntemleri kullanılmıştır. Bu başlık altında yöntemlerin genel yapıları hakkında bilgi verilecektir.

##### 4.3.1.1.Uyarlamalı Sinirsel Bulanık Mantık Sistemi (ANFIS)

Takagi-Sugeno Kang çıkarım sistemini temel alarak oluşturulan ANFIS, Jang tarafından doğrusal olmayan fonksiyonların modellenmesinde, kontrol sistemlerinde, doğrusal olmayan bileşenlerin belirlenmesinde ve kaotik zaman serilerinin tahmininde kullanılmak üzere geliştirilmiştir (Jang, 1993). ANFIS yapısında değerlendirilen bulanık mantık çıkarım sistemi; adaptif ağlara dönüştürülüp bir öğrenme algoritması ile en uygun koşulu oluşturulmaktadır. Sinirsel uyarlanabilir öğrenme teknikleri, bulanık modelleme için seçilen veri setini kullanarak ilgili sistemi “öğrenen” bir model geliştirmektedir. Yani ANFIS girdi / çıktı veri setini yapay sinir ağlarında kullanılan geri yayımlı algoritmayı tek başına ya da en küçük kareler yöntemi ile birlikte kullanarak üyelik fonksiyonu parametrelerini düzenleyerek bir bulanık çıkarım sistemi (fuzzy inference system - FIS) oluşturur. Bu düzenleme bulanık sistemimizin modellediği veriler yardımıyla ilgili sistemi öğrenmesini sağlar. Yani kendini modelleyeceği veriye göre uyarlar / adapte eder. Bu yapı sayesinde, hem sistem hakkındaki çevresel bilgiyi kullanarak, hem de sisteme ilişkin giriş çıkış verisinden faydalanarak kendi kendini güncelleme yeteneği edinmiş olan ANFIS yapısı Şekil 4.3.’de gösterildiği gibidir (Jang & R., July 1991).



Şekil 4.3. ANFIS yapısı (Demuth, 2000)

1. katman; girdi katmanı olarak adlandırılmaktadır. Bu katmandaki her düğümün alınan giriş sinyalleri diğer katmanlara aktarılır. Her bir  $i$  düğümü için çıkış değerleri (Eşitlik 4.1-4.2);

$$O_{(1,i)} = \mu A_i(x) \quad i=1,2,\dots,n \quad (4.1)$$

$$O_{(1,i)} = \mu B_{(i-2)}(y) \quad i=1,2,\dots,n \quad (4.2)$$

şeklinde ifade edilir.

2. katman; bulanıklaştırma katmanı olarak adlandırılır. Burada, her bir düğümün çıkışı, giriş değerlerine ve kullanılan üyelik fonksiyonuna bağlı olan üyelik derecelerinden oluşmaktadır. 2. katmandan elde edilen üyelik dereceleri  $\mu A_i(x)$  ve  $\mu B_i(y)$  şeklinde gösterilir.

3. katman; kural katmanıdır. Sugeno bulanık mantık çıkarım sistemine göre oluşturulan kuralları ve sayısını ifade etmek için düğümler kullanılır. Her bir kural düğümünün çıkışı  $\mu_i$ , 2. katmandan gelen üyelik derecelerinin çarpımı olmaktadır.

4. katman; normalizasyon katmanıdır.

5. katman; her bir düğümde verilen bir kuralın ağırlıklandırılmış sonuç değerleri hesaplanmaktadır. 5. katmandaki  $i$ . düğümün çıkış değeri ise (Eşitlik 4.3),

$$y_i^5 = \bar{\mu}_i [p_i x_1 + q_i x_2 + r_i] i = (1, n) \quad (4.3)$$

şeklinde olmaktadır. Buradaki ( $p_i$ ,  $q_i$ ,  $r_i$ ) değişkenleri,  $i$ . kuralın sonuç parametreleri kümesidir.

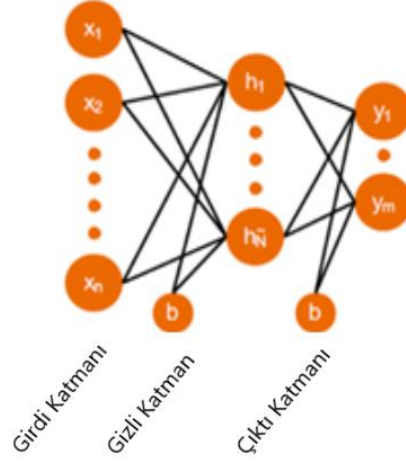
6. Katman; Toplam katmandır. Bu katmanda sadece bir düğüm vardır ve  $\sum$  ile etiketlenmiştir. Sistemin çıkış katmanıdır (Demuth, 2000; Fırat ve Güngör, 2007; Acar vd., 2008).

ANFIS modelinin en büyük avantajları matematiksel analizlerdeki etkinliği, uyarlama işlemindeki başarısı ve sayısal verilerdeki başarılı sonuç çıkarımı olarak gösterilebilirken, ANFIS parametrelerinin eğitiminin oldukça uzun sürmesi ve modelin çok sayıda kurala sahip olan bir yapıda olmasından dolayı insan müdahalesinin çok fazla olması dezavantajı olarak gösterilebilmektedir.

#### 4.3.1.2. Aşırı Öğrenme Makinası (ELM)

ELM, Huang tarafından 2006 yılında geliştirilen ve girdi katmanı, gizli katman ve çıktı katmanından oluşan tam bağlı bir yapay sinir ağı modelidir (Huang vd., 2006). Yaygın olarak kullanılan gradyan temelli ağ yapılarının aksine ELM, giriş ağırlıkları ve eşik değerleri rastgele üretilen ancak çıktı ağırlıkları analitik olarak üretilen ve model ağırlıklarını bulmanın ötesinde modelin analitik bir denklemini oluşturan bir ağıdır. Bu sebeple diğer yöntemlerde meydana gelen öğrenme sürecinin uzun zaman alması ve hataların yerel bir noktada tıkanabilmesi gibi sorunları ortadan kaldırmaktadır. Bu sayede hem diğer yöntemlere göre daha iyi performans sağlamakta hem de model üretim sürecini hızlandırmaktadır. Aynı zamanda diğer öğrenme algoritmaları uygun olmayan öğrenme oranı, aşırı öğrenme ve ezberleme durumu, yerel minimuma takılma durumu gibi istenmeyen durumlarla karşılaşabildikleri için modelin eğitimini erken durdurma, regülasyon parametreleri ekleme, ağırlık bozma ya da geçerlilik seti kullanma gibi yöntemleri uygulamak zorunda kalırken; ELM, ara işlem olmadan doğrudan çözüme ulaştığından bu tarz sorunlar ile karşılaşmamaktadır. Tüm bu avantajların yanı sıra türevi alınabilen, alınamayan ya da kesikli birçok aktivasyon fonksiyonu da kullanabilme imkânı sunan ELM yönteminin yapısı Şekil 4.4.'de görüldüğü gibi verilerin okunduğu

giriş katmanı, sınıfların belirlendiği çıktı katmanı ve ara işlemlerin yapıldığı gizli katmandan oluşmaktadır.



**Şekil 4.4.** Aşırı Öğrenme Makinası algoritma yapısı (Jin vd., 2020)

ELM yapısı yinelemeli optimizasyona ihtiyaç duymaksızın Moore-Penrose genelleştirilmiş ters gizli matrisi ile çıktı ağırlığını hesaplayabilir.  $L$  gizli düğümü simgelerken  $\beta_j$  çıkış nöronlarını ve  $j$ th gizli nöronları bağlayan ağırlık değeri olarak simgelenirse ELM yapısı (Eşitlik 4.4);

$$\sum_{j=1}^L \beta_j h_j(x_i) = y_i, \quad i = 1, \dots, n \quad (4.4)$$

olarak ifade edilebilir.  $J$ th gizli düğüm çıktısı için özelliklerin haritalanması  $h_j(x_i)$  (Eşitlik 4.5);

$$h_j(x_i) = \frac{1}{1 + \exp(-(w_j^T x_i + b_j))} \quad (4.5)$$

olarak ifade edilir. Bu denklemde kullanılan giriş nöronlarını bağlayan ağırlık vektörü  $w_j$ ;

$w_j = [w_{j1}, \dots, w_{jD}]^T \in \mathbb{R}^D$  ve  $J$ th gizli nöron,  $b_j$  eğilim (sapma) terimi olarak ifade edilir. Denklem (1)'de verilen denklem daha sade şekilde ifade edilmek istenirse (Eşitlik 4.6, 4.7);

$$H\beta = y, \quad \beta = [\beta_1, \dots, \beta_L]^T \in \mathbb{R}^L, \quad y = [y_1, \dots, y_N]^T \in \mathbb{R}^N \quad (4.6)$$

$$H(w_1, \dots, w_L, b_1, \dots, b_L, x_1, \dots, x_N) = \begin{bmatrix} h_1(x_1) & \dots & h_L(x_1) \\ \vdots & \ddots & \vdots \\ h_1(x_N) & \dots & h_L(x_N) \end{bmatrix} \in \mathbb{R}^{N \times L} \quad (4.7)$$

Bu denklemlerde kullanılan  $H$  gizli katman çıktı matrisini belirtmektedir. ELM farklı geleneksel öğrenme algoritmaları içinden hatanın ve çıkış ağırlığının en düşük olduğu durumu seçmektedir. Rastgele başlatılmış olan  $w_j$  gizli düğüm parametreleri ve  $b_j$  ( $j = 1; \dots, L$ )' dir ve denklem (3)'e ait en küçük kareler çözümü (Eşitlik 4.8);

$$\beta = H^\dagger \quad (4.8)$$

Burada  $\dagger$  Moore-Penrose genelleştirilmiş tersini belirtmektedir. ELM yapısının yeni test örneği olan  $\hat{x}$ 'in yazılabilmesi için bir oluşturulacak olan karar fonksiyonu;

$$\hat{y} = \text{sign}(h(\hat{x})\beta) \quad (4.9)$$

olarak ifade edilebilmektedir (Jin vd., 2020)(Eşitlik 4.9).

#### 4.3.1.3. Sezgisel Sinir Ağları (ENN)

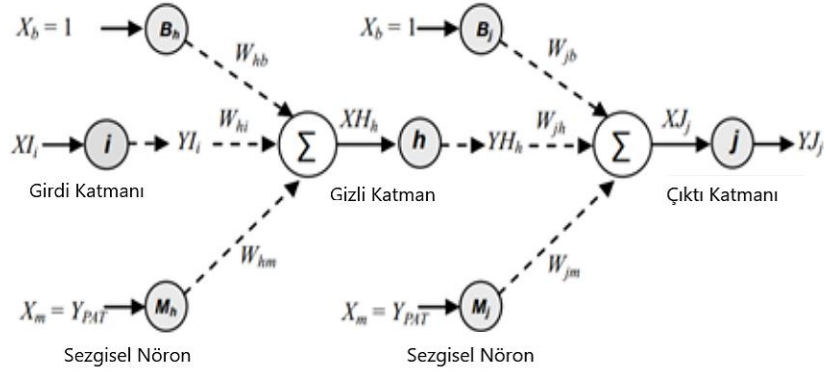
Bu bölümde sezgisel sinir ağı algoritması (EmNN veya ENN) açıklanacaktır. ENN, geleneksel geri yayılım algoritmasının (BP-Back Propagation) değiştirilmiş hali olan sezgisel geri yayılım algoritmasına (EmBP- Emotional Back Propagation) dayanmaktadır. BP metodu uygulama basitliği ve özellikle yeterli veri tabanına sahip olduğunda hızlı çalışması nedeniyle sıklıkla tercih edilmektedir (Rumelhart vd., 1986). Üç katmandan oluşan ENN algoritmasının ait bilgi akış katmanlarına göre açıklanır. ENN algoritmasına ait katmanlar:

$i$ : giriş katmanı nöronları

$h$ : gizli katmanı nöronları

$j$ : çıkış katmanı nöronları

olarak isimlendirilir. ENN hesaplamalarının ileri besleme hesabı yapılırken izlenecek olan yol Şekil 4.5'de gösterildiği gibidir (Khashman, 2009a).



**Şekil 4.5.** ENN ileri besleme hesabında izlenecek yol (Khashman, 2009a)

İleri besleme hesaplamaları;

Sinir ağında giriş katmanından çıkış katmanına kadar olan veri işlemleri aşağıda açıklandığı gibidir. İleri besleme hesaplamaları bir ağın çalışması sırasında uygulanır.

1. Giriş katmanı nöronları;

Giriş katmanı nöronları işlenmeyen nöronlardır. Bu nedenle giriş katmanının girdi değeri  $Xl_i$ ,  $Yl_i$  ise giriş katmanının çıktı değeri tanımlanırsa giriş değerleri çıkış değerlerine eşit olur (Eşitlik 4.10).

$$Xl_i = Yl_i \quad (4.10)$$

2. Gizli katman nöronları;

Giriş katmanındaki her bir nöron gizli katmanda aktif hale getirilir.  $XH_h$  gizli katmanın giriş verileri ise  $YH_H$  gizli katmanın çıkış verileri olarak tanımlanır (Eşitlik 4.11).

$$YH_H = \left\{ \frac{1}{1 + \exp(-XH_h)} \right\} \quad (4.11)$$

$XH_h$  verisinin hesaplanabilmesi için ise o nörona giren toplam potansiyel giriş değerlerinin ( $TP_h$ ) kullanılması gerekir. Burada üç farklı girdi grubu olduğundan üç farklı toplam potansiyel değeri vardır. Bu potansiyel değerleri;

$TP_{hc}$ : giriş katmanının çıkış değerleri ve konvansiyonel ağırlık matrisi kullanılarak elde edilen geleneksel toplam potansiyel değeri

$TP_{hb}$ : gizli katman nöronları ve bunlarla ilişkili ağırlıklar

$TP_{hm}$ : gizli katman sezgisel nöronları ve bunlarla ilişkili sezgisel ağırlıklardır (Eşitlik 4.12-4.14).

$$TP_{hc} = \sum_{i=1}^r W_{hi} \cdot Y_{li} \quad (4.12)$$

$$TP_{hb} = W_{hb} \cdot X_b, X_b = 1 \quad (4.13)$$

$$TP_{hm} = W_{hm} \cdot X_m \quad (4.14)$$

Burada kullanılan  $W_{hi}$ ,  $h$  katmanı tarafından  $i$  katmanına aktarılan ağırlık,  $W_{hb}$ ,  $h$  katmanı tarafından sağlanan ağırlık ve  $W_{hm}$  ise  $h$  katmanı tarafından gizli katman sezgisel nöronu  $m$ 'ye aktarılan ağırlık,  $X_m$  değeri ortalama değeri temsil eder.  $x_{max}$  ve  $y_{max}$  ise  $P(x,y)$  görüntüsünün  $x$  ve  $y$  yönlerindeki en yüksek piksel sayılarıdır (Khashman, 2009b) (Eşitlik 4.15 - 4.16).

$$X_m = Y_{PAT} = \sum_{x=1, y=1}^{x_{max}, y_{max}} \frac{P(x,y)}{x_{max} \cdot y_{max}} \quad (4.15)$$

$$XH_h = TP_{hc} + TP_{hb} + TP_{hm} \quad (4.16)$$

### 3. Çıkış katmanı nöronları;

Çıkış katmanında da gizli katmanda olduğu gibi her bir nöronun aktif hale getirilmesi gerekmektedir.  $XJ_i$  ve  $YJ_i$  sırasıyla nöron çıkış katmanının ( $j$ ) giriş ve çıkış değerleri olarak tanımlanırsa (Eşitlik 4.17, 4.18);

$$XJ_i = TP_{jc} + TP_{jb} + TP_{jm} \quad (4.17)$$

$$YJ_i = \left\{ \frac{1}{1 + \exp(-XJ_i)} \right\} \quad (4.18)$$

$W_{ji}$  gizli katmandan çıkış katmanına aktarılan ağırlık,  $YH_h$  gizli katmanın çıkış değerleri ve  $W_{jb}$  gizli katmandan  $B_j$  ye aktarılan ağırlık,  $X_b$  eğilimli nöronların giriş

değerleri,  $W_{jm}$  gizli katmandan  $M_j$  'ye aktarılan sezgisel ağırlık ,  $X_m$  sezgisel nöronun giriş değeri ise (Eşitlik 4.19-4.22);

$$TP_{jc} = \sum_{h=1}^1 W_{jh} \cdot YH_h \quad (4.19)$$

$$TP_{jb} = W_{jb} \cdot X_b \quad (4.20)$$

$$TP_{jm} = W_{lm} \cdot X_m \quad (4.21)$$

$$XJ_j = TP_{jc} + TP_{jb} + TP_{jm} \quad (4.22)$$

#### 4. Sezgisel parametreler;

Sezgisel parametreler mevcut öğrenme katsayısı ( $\eta$ ) ve  $\alpha$  momentum oranı ile birlikte kullanılır. ( $\mu$ ) kaygı katsayısı ve  $k$  güven katsayısı olarak tanımlanır ve her yeni görevin öğrenilmesinde bu iki parametrenin nasıl davrandığını gözlemlenir. Güven düzeyi arttıkça endişe düzeyi azalır. Her iki katsayı da 0 ile 1 arasında normalize edilmiş değerlere sahiptir.

Anksiyete seviyesi, giriş deseninin ortalama değerine ve her bir dönemin hata göstergesine bağlıdır. Burada kullanılan ortalama giriş değeri her zaman pozitif olmak zorundadır çünkü piksel değerleri 0-1 arasında değerlere normalize edilmiştir. Aynı zamanda kararsız bir durum mevcutsa hata göstergesi olumsuz bir geri bildirim de sağlayabilir. Bu durumda sezgisel ağ, geleneksel ağlara benzer şekilde hem güvenilirmez hem de kararsız olacaktır. Bu nedenle kararlı bir öğrenme bulunana kadar üç önemli parametre ayarlanır. Ayarlanabilir bu üç parametre; öğrenme oranı, momentum oranı ve gizli nöronların sayısıdır. Burada öğrenme ilerledikçe kaygı oranı düşer ve güven katsayısının değeri artar (Khashman, 2009a).

Kaygı katsayısı aşağıdaki gibi tanımlanabilir (Eşitlik 4.23):

$$\mu = Y_{AvPAT} + E \quad (4.23)$$

$Y_{AvPAT}$ , ENN algoritmasında sunulan desenlerin ortalama değeri olarak tanımlanır.

$p$  ,desen indeksi , N bir periyotta sunulan toplam desen sayısı ve  $E$  geri besleme hatası ise (Eşitlik 4.24-4.26);

$$Y_{AvPAT} = \sum_{p=1}^{N_p} Y_{PAT} / N \quad (4.24)$$

$$E = \sum_{j=1}^{N_j} (T_j - Y_{J_j})^2 / N_p \cdot N_j \quad (4.25)$$

$k$  güven katsayısı;

$$k = \mu_0 - \mu_i \quad (4.26)$$

$\mu_0$ : birinci iterasyonun sonundaki kaygı katsayısı değeri

$\mu_i$ : sonraki iterasyonların sonlarındaki kaygı katsayısıdır.

Geri yayılım hesaplamaları;

ENN uygulanırken istenilen hata düzeyine erişilene kadar hesaplama yapılmalıdır. Bu hesaplamalarda  $E_p$ ,  $T_{pj}$  (hedef değeri olarak adlandırılan çıkış değeri) ile  $Y_{pj}$  (ileri besleme hesaplamaları sonucunda sahip olunan değer) arasındaki farka bağlı bir  $jj$  hata terimi olarak tanımlanmıştır (Rumelhart vd., 1986; Biswas vd.,2019) (Eşitlik 4.24 – 4.29).

$$E_p \sum_{j=1}^{N_j} (T_{pj} - Y_{pj})^2 \quad (4.27)$$

$$Y_{J_j} = f(XJ_j) \quad (4.28)$$

Çıktı nöronları için hata göstergesi (sinyali) ise;

$$\Delta_j = f'(XJ_j) \cdot (T_j - Y_{J_j}) = Y_{J_j} \cdot (1 - Y_{J_j}) \cdot (T_j - Y_{J_j}) \quad (4.29)$$

şeklinde tanımlanmaktadır.

#### 4.3.1.4. Destek Vektör Regresyonu (SVM-SVR)

Optimizasyona dayalı bir algoritma olan SVM; hatayı minimize eden bir sınıflandırma algoritması olarak Vapnik tarafından tasarlanmıştır (Vapnik, 1998). Daha sonra algoritma SVR ismi ile regresyon amacıyla kullanılmaya başlanmıştır. SVM çekirdek

fonksiyonlarına bağlı olduğu için parametrik olmayan bir teknik olarak kabul edilmektedir. Maksimum değerin yapı içine alınması ile oluşturulan SVM; bu özelliği sayesinde diğer regresyon modellerinden daha verimli hale gelmiştir. Yapı içerisindeki ağırlık vektörü  $w$ , hata değeri ise  $\varepsilon$  olarak ifade edildiğinde minimizasyon işlemi;

$$\min 1/2\|w\|^2 \quad \text{denklemi } y_i - (w, x_i + b) \leq \varepsilon \text{ ve } (w, x_i + b) - y_i \leq \varepsilon \quad (4.30)$$

denklemlerine bağlı olarak ifade edilir (Eşitlik 4.30).

$x$ ; hiper düzlem üzerinde bir nokta,


$b$ ; yanlılık olarak adlandırıldığında kısıt denklemi;

$$f(x) = y_i(w, x_i + b) \quad (4.31)$$

şeklinde oluşturulur ve model marj değeri tüm verileri içinde tutacak şekilde hesaplanmak istenirse minimizasyon kullanılır (Eşitlik 4.31). Ancak tüm değerlerin bu şekilde kullanılması mümkün değildir. Bu durumda gevşeklik değişkenleri (slack) ( $\xi_i$ ,  $\xi_i^*$ ) kullanılır (Eşitlik 4.32).

$$\min 1/2\|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (4.32)$$

denklemi  $y_i - (w, x_i + b) \leq \varepsilon + \xi_i$  ve  $(w, x_i + b) - y_i \leq \varepsilon + \xi_i$  denklemlerine bağlı olarak oluşturulmaktadır.  $C > 0$  sabiti kullanılmakta ve  $f$  denkleminin  $\pm\varepsilon$  değerinden büyük olduğu değerler Şekil 4.6'da gösterildiği gibi tolere edilmektedir (Burges, 1998).



Şekil 4.6. SVM model yapısı için örnek (Chanklan, 2018)

Uygulama kolaylığı ve hem doğrusal hem de doğrusal olmayan verilerle uyum sağlamasından dolayı yaygın olarak tercih edilen SVM, model parametrelerinin yorumlanmasındaki zorluklar ve model eğitimin uzun sürmesi gibi dezavantajlara da sahiptir.

#### 4.3.1.5. Gauss Süreç Regresyonu (GPR)

Doğrusal olmayan regresyon problemlerinin çözümünde kullanıma uygun, parametrik olmayan bir model olan GPR; Gauss dağılımında ön bilgi (prior) fonksiyonlarının, son olasılık dağılımı (posterior) fonksiyonlarına dönüştürülmesi temeline dayanmaktadır (McDuff, 2019) GP fonksiyonlar üzerine olasılık dağılımını tanımlamakta ve;

$M(x)$ ; ortalama,  $K(x, x')$ ; kovaryans fonksiyonu olarak ifade edildiğinde;

$$f(x) \sim GP(m(x), K(x, x')) \quad (4.33)$$

eşitliği kurulmaktadır (Eşitlik 4.33). Bu denklemde  $m(x)$  ve  $K(x, x')$ ;

$$m(x) = \mathbb{E}[f(x)] \quad (4.34)$$

$$K(x, x') = \mathbb{E}[(f(x) - m(x))(f(x') - m(x'))^T] \quad (4.35)$$

şeklinde ifade edilmektedir (Eşitlik 4.34-4.36).  $\theta_f$  x- ölçekleme (genlik) ve  $\theta_y$  y- ölçekleme (uzunluk) olarak belirtilirse kovaryans fonksiyonu;

$$K = \theta_f^2 \exp\left(-\frac{1}{\theta_y^2} \|x - x'\|^2\right) \quad (4.36)$$

eşitliği ile ifade edilmektedir (Murphy, 2012; Richardson, 2017) (Eşitlik 4.36).

Kovaryans matrisi;

$$K = \mathcal{K}((x_1, \dots, x_n), (x_1, \dots, x_n)) = \begin{bmatrix} \mathcal{K}(x_1, x_1) & \mathcal{K}(x_1, x_2) & \dots & \mathcal{K}(x_1, x_n) \\ \mathcal{K}(x_2, x_1) & \mathcal{K}(x_2, x_2) & \dots & \mathcal{K}(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ \mathcal{K}(x_n, x_1) & \mathcal{K}(x_n, x_2) & \dots & \mathcal{K}(x_n, x_n) \end{bmatrix} \quad (4.37)$$

şeklinde ifade edilmektedir (Eşitlik 4.37).

### 4.3.2. İstatistiksel model değerlendirme ölçütleri

Kullanılan algoritmaların model performanslarının değerlendirilmesi için çeşitli istatistiksel kriterler kullanılmıştır. Bu kriterler Kök Ortalama Kare Hata (RMSE), Korelasyon Katsayısı (r), Ortalama Mutlak Hata (MAE) ve Ortalama Kare Hata (MSE) olarak seçilmiştir. Bu kriterlere ait seçim çalışmalardaki yaygın kullanım dikkate alınarak yapılmıştır.  $b_i$  modellerin gözlemlenen değerlerini,  $y_i$  modeller tarafından üretilen çıktılarını, avg ortalama değeri ifade ederse modeller Eşitlik 4.38-4.41 aracılığı ile değerlendirilebilir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (b_i - y_i)^2} \quad (4.38)$$

$$r = \frac{\sqrt{\sum_{i=1}^n (b_i - b_{avg})^2 - \sum_{i=1}^n (b_i - y_i)^2}}{\sum_{i=1}^n (b_i - b_{avg})^2} \quad (4.39)$$

$$MAE = \frac{1}{n} \sum_{j=1}^n |e_j| \quad (4.40)$$

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (4.41)$$

Rank analizi ise bu indeksler arasında en iyi değere en yüksek puanı vererek toplamda en yüksek puana erişen model yapısının belirlenmesi için kullanılan bir analizdir (Pradeep vd., 2021). Model sayısı ile orantılı olarak en optimum değere en yüksek puanın verilmesi esasına dayanan rank analizi uygulanan bu çalışmada en optimum değere 5 puan, en düşük performansa ise 1 puan verilerek hesaplamalar yapılmıştır.

### 4.3.3. Korelasyon analizi

Korelasyon analizi, veriler arasındaki ilişki durumunu incelemek için kullanılan bir yöntemdir. Nicel veya nitel bağlantılar arasında ilişki olup olmadığını ve ilişkinin gücünü belirler. Korelasyon katsayısı 0-1 aralığında değişmekte ve 1 olması mükemmel bir ilişki olduğunu göstermektedir. Literatürde sıklıkla kullanılan üç tip korelasyon katsayısı vardır.

Pearson korelasyon katsayısı; iki deęişkenin doğrusal ilişkisinin ölçümünde kullanılmaktadır. Bu katsayı deęişkenlerin tümünün normal dağılım göstermesi durumunda kullanılmaktadır. Normallik varsayımı için çarpıklık ve basıklık durumu incelenmektedir. Normallik varsayımı için çarpıklık ve basıklık deęerleri (-1, +1) aralığında olmalıdır.

Veri setlerinin normallik varsayımını karşılamadığı durumlarda ise Spearman sıra korelasyon katsayısı kullanılmaktadır.

Aynı şekilde parametrik olmayan korelasyon ölçülerinden bir de Kendall'ın Tau korelasyon katsayısıdır (Katipoęlu, 2020). Ancak bu katsayı tahmin karmaşıklığı sebebiyle çok fazla kullanılmamaktadır. Çalışmada veri setlerinin dağılım grafiklerinin ve korelasyon matrislerinin oluşturulması için OriginPro yazılımı kullanılmıştır.

#### 4.3.4. Verilerin normal dağılıma uygunluęunun incelenmesi

Mevcut dönem verilerinin ( $Q(t)$ ) geçmiş dönem verileri ( $Q(t-1)$ ,  $Q(t-2)$ ...,  $Q(t-n)$ ) ile korelasyon durumlarının incelenebilmesi için verilerin normal dağılıp dağılmadığının bilinmesi gerekmektedir. Bu nedenle çalışmada Kolmogorov-Smirnov Testi (K-S Testi), Geliştirilmiş K-S testi (K-S Modified Test) ve Anderson-Darling Normallik Testi (A-D Testi) kullanılarak verilerin dağılımları incelenmiştir. Bu testler literatürde sıklıkla kullanıldıkları ve kolay uygulanabildikleri için tercih edilmiştir (Dallal ve Wilkinson, 1986; Massey, 1951; Lilliefors, 1967; Katipoęlu ve Acar 2021). Ayrıca verilerin standart sapma, varyans, ortalama, çarpıklık, basıklık gibi istatistiki bilgileri de verilmiştir.

Bu testlerin içerisinde Kolmogorov-Smirnov Testi (K-S Testi) gözlem verilerinin eklenik dağılımının uygunluęunu deęerlendirmektedir.

$F^*(x_i)$ ;  $i/N$  formülü ile hesaplanan eklenik frekans dağılımını ordnatları,  $F(x_i)$  ise  $x_i$  deęerine karşılık gelen ordnatlar olarak simgelendiğinde  $\Delta$  istatistięi Eşitlik 4.42'de verildięi gibi ifade edilebilmektedir.

$$\Delta = \max |F(x_i) - F^*(x_i)| \quad (4.42)$$

$\Delta$  testinde, test istatistięinin dağılımı rastgele deęişkenin dağılımından bağımsız olarak verilmektedir. Testte dağılım sadece  $N$  eleman sayısına baęlı olarak deęişmektedir.

Hesaplanan test istatistiği, aşılma olasılığı (kritik değer) olarak ifade edilen  $\Delta_\alpha$  değerinden küçükse dağılımın uygunluğu kabul edilmekte, aksi halde reddedilmektedir (Massey, 1951; Katipoğlu ve Acar, 2021).

K-S Testi en iyi bilinen ve en çok kullanılan testlerden birisidir. Ancak orijinal haliyle normal dağılım gibi varsayımsal dağılımların bir ya da birden fazla parametresini tahmin eden bir testtir. Bu nedenle kritik değer in geçerliliği konusunda şüpheler içerebilmektedir. Bu parametrelerin belirlenebilmesi için örnek ortalama ve örnek varyans seçimi önerilmiştir (Massey, 1951; Lilliefors, 1967; Dallal ve Wilkinson, 1986). Ancak bu öneriler en iyi sonuca ulaştırma konusunda kesin değildir. Bu varsayımlar yerine normal dağılımın ampirik dağılımla en yakın uyum sağladığı değerlerine göre ortalama ve varyans değerlerinin ayarlanması esasına dayanan geliştirilmiş K-S Testi kullanılabilir. K-S testi ayarlamadan sonra hala normallikten sapma gösteriyorsa, verilerin normal dağılımla örneklemediği varsayımı sonucuna varılmaktadır (Drezner vd., 2010).

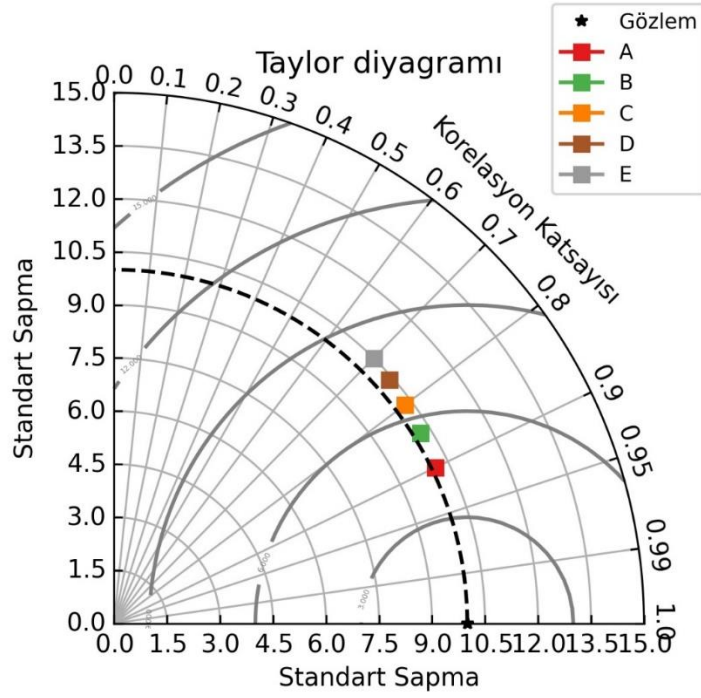
Anderson Darling Testi (A-D) ise denenen dağılımın kritik değerini kullanan bir testtir. Test için her dağılıma ayrı olacak şekilde kritik değer hesaplanmaktadır. A-D testi dağılımların uç kısımlarına daha duyarlı olduğu için çalışmalarda sıklıkla tercih edilmektedir (Adamson, 1979). Ayrıca A-D testi tek yönlü bir test olup, test istatistiği olarak elde edilen değer kritik değerden büyükse sıfır hipotezinin reddedildiği anlamı taşımaktadır (Karahana ve Özkan, 2013).

Bu çalışmada üç test uygulanmış ve normal dağılıma uygunlukları elde edilen sonuçların çoğunluğuna göre test edilmiştir.

#### **4.3.5. Taylor diyagramı**

Taylor diyagramı model sonuçlarının grafiksel özetinin sağlanması amacıyla oluşturulan diyagramdır. Diyagramda modeller sonucunda elde edilen verilerin korelasyonları, standart sapmaları ve RMSE değerleri gösterilmektedir. Birçok modelin yer aldığı karmaşık çalışmalarda model performanslarının daha rahat karşılaştırılabilmesi amacıyla oluşturulmaktadır (Taylor 2001, 2005).

Örnek olarak 5 model çıktısına ait Taylor diyagramı Şekil 4.7’de gösterilmektedir.



**Şekil 4.7.** Örnek Taylor diyagramı

Şekil 4.7’de görüldüğü gibi Taylor diyagramı x ve y eksenlerinde standart sapma değerlerini, çeyrek daire yayı üzerinde korelasyon katsayısını ve diyagram içerisinde de RMSE değerlerini göstermektedir. Yıldız ile simgelenen değerler gözlem verilerini temsil etmektedir. Gözlem verilerinin korelasyon katsayısı 1 olarak verilmekte, standart sapma değeri ise kesikli çizgilerle belirtilmektedir. Bu örnekte gözlem verisinin standart sapması 10 iken; A çıktısının standart sapması 10.1, korelasyon katsayısı 0.9, RMSE değeri ise yaklaşık 4.5’dir. E çıktısının ise standart sapma değeri 10.5, korelasyon katsayısı 0.7 ve RMSE değeri yaklaşık 7.5 olarak verilmiştir. Bu çalışmada Taylor diyagramları Phyton yazılımı yardımı ile oluşturulmuştur.

#### 4.3.6. Kullanılan yazılımlar

Çalışmada kullanılan Erzincan Üniversitesi tarafından lisanslı olarak sağlanan yazılımlar, öğrenci sürümü ile kullanılan yazılımlar veya ücretsiz olarak kullanılabilen yazılımlardan oluşmaktadır (Bkz. Tablo 4.2).

**Tablo 4.2.** Çalışmada kullanılan yazılımlar


<b>Konu</b>	<b>Kullanılan Yazılım</b>
Verilerin düzenlenmesi ve istatistiksel olarak incelenmesi	MS Excell 2013
Verilerin dağılımının belirlenmesi	OriginPro 2022
Verilerin korelasyon matrislerinin oluşturulması	OriginPro 2022
Yapay zeka tekniklerinin oluşturulması	Matlab 2019b
Taylor diyagramlarının oluşturulması	Phyton 3.10.4.
Havza haritasının oluşturulması	ArcMap 10.8



## 5. ARAŞTIRMA BULGULARI

### 5.1. Veri Setinin İncelenmesi ve Model Yapılarının Belirlenmesi


Fırat-Dicle Havzası içerisindeki on dört istasyon verileri ile yapılan bu çalışmada günlük akım verileri aşırı öğrenme sorununa sebep olmayacak ve tahmin sürecinin hassasiyetini arttırabilecek şekilde %70 eğitim ve %30 test olacak şekilde ayrılmıştır. Veri setlerinin tümünün normal dağılıma uyup uymadıkları incelenmiştir. Örnek olarak 2102 numaralı istasyona ait dağılım grafiği Şekil 5.1.'de verilmiştir. Diğer istasyonlara ait dağılım grafikleri ise Ek-2.1-13' te verilmiştir.



Şekil 5.1. 2102 numaralı istasyona ait dağılım grafiği

Şekil 5.1 incelendiğinde basıklık ve çarpıklık değerinin 1'in üzerinde olduğu görülmektedir. Ayrıca her üç test sonucunda da normal dağılım koşulları karşılanmamaktadır. Tüm istasyonların dağılım grafikleri incelendiğinde veri setlerinin normal dağılıma uymadığı görülmektedir. Ayrıca yine tüm grafikler incelendiğinde verilerin çoğunlukla basıklık değerinin yüksek olduğu her üç testte de görülmektedir

(Şekil Ek-1.1-13). Bu nedenle veri setlerinin önceki dönemler ile korelasyon durumları incelenirken Spearman yöntemi seçilmiştir. Dağılım grafiği örnek olarak verilen 2102 numaralı istasyon için korelasyon matrisi Şekil 5.2’de verilmiştir. Ek-3.1-13 ise diğer istasyonlara ait korelasyon matrisleri ve değerleri sunulmuştur.



Şekil 5.2. 2102 numaralı istasyona ait korelasyon matrisi

Korelasyon durumları incelendiğinde bir, iki ve üç gün önceki akım verilerinin mevcut akım verileri ile ilişkilerinin daha yüksek olduğu görülmüştür. Ayrıca önceki dönemlere gittikçe korelasyonun azaldığı da görülmüştür (Bir yıl öncesine kadar inceleme yapılmış ve bir yıl önceki veriler ile mevcut veriler arasındaki korelasyon değerinin 0.77 düzeylerine kadar gerilediği görülmüştür.). Ayrıca ham verilerin otokorelasyon durumu da incelenmiş ve aynı doğrultuda sonuçlara ulaşılmıştır.

Bu durum göz önüne alınarak üç girdi kombinasyonu oluşturulmuştur. Bu girdi kombinasyonlarından ilki girdi olarak bir gün önceki akım verilerini (Q(t-1)) kullanırken çıktığı olarak şuan ki akım verilerini (Q(t)) içermekte, ikinci kombinasyon girdi olarak bir ve iki gün önceki akım verilerini Q(t-2)+Q(t-1) ve üçüncü kombinasyon ise girdi olarak

bir, iki ve üç gün önceki akım verilerini  $Q(t-3), Q(t-2), Q(t-1)$  içermektedir. Model numaraları ve girdi-çıkıtı bilgisi Tablo 5.1’de verilmiştir.

**Tablo 5.1.** Çalışma kapsamında oluşturulan modeller

Model No	Girdi	Çıktı
M1	$Q(t-1)$	$Q(t)$
M2	$Q(t-2), Q(t-1)$	$Q(t)$
M3	$Q(t-3), Q(t-2), Q(t-1)$	$Q(t)$

## 5.2. Model Sonuçların İncelenmesi ve Değerlendirilmesi

Tüm istasyonlar için algoritmalar en iyi sonucun bulunduğu hiper-parametrelere göre belirlenmiştir. Algoritma sonuçları RMSE, R, MAE ve MSE ölçütleri ile değerlendirilmiştir. Ayrıca bu ölçütlerin birbirlerine karşı bir üstünlüğü olmadığı ve en iyi sonucun net olarak görülebilmesinin istendiği göz önüne alınarak rank analizi uygulanmıştır.

Çalışmada kullanılan ANFIS algoritması MATLAB R2014b sürümünden itibaren kullanılmaya başlanan Neuro- Fuzzy Designer yardımı ile çalışılmıştır. Model yapısı oluşturulurken en iyi sonucun bulunması için herhangi bir kural olmadığından hata toleransı, devir sayısı, MF sayısı ve tipi gibi parametreler değiştirilerek çok sayıda deneme yapılmış ve en iyi sonucu veren Tablo 5.2’deki değerler kullanılmıştır.

**Tablo 5.2.** ANFIS modeli için kullanılan değerler

En uygun optimizasyon	Hata Toleransı	Döngü (devir) sayısı	MF sayısı ( $Q(t) / Q(t-1) + Q(t) / Q(t-2) + Q(t-1) + Q(t)$ )	Mf tipi
backpropa	0.01	1000	3 / 3 3 / 3 3 3	Trimf /linear

ELM yapısı için Nanyang Teknoloji Üniversitesi tarafından sağlanan ve 2015-2019 yılları arasında kullanılan ve birçok yayının da oluşturulmasını sağlayan Matlab ELM kodları

kullanılmıştır (NTU). ANFIS modelinde olduğu gibi ELM modelinde de parametreler değiştirilerek çok sayıda deneme yapılmış ve Tablo 5.3’ de verilen parametrelerin en iyi sonucu verdiği gözlemlenmiştir.

**Tablo 5.3.** ELM modeli için kullanılan parametreler

<b>En uygun metod</b>	<b>Gizli nöron sayısı</b>	<b>Aktivasyon fonksiyonu</b>
ELM regresyon	1-100 arası en iyi sonuç alınmıştır.	sigmoid

ENN yöntem için ise (Lotfi ve ark., 2014) tarafından hazırlanan çalışmada kullanılan verilere uygun hale getirilerek kullanılmıştır. Kullanılan kodlarda hiper-parametreler kodlar tarafından optimize edilerek en iyi değerlere ulaşılmıştır.

SVM-SVR ve GPR modelleri için hem daha hızlı model oluşturabilme yeteneğinden dolayı hem de yönteme ait tüm parametreleri gösterebilmesinden dolayı MATLAB Regression Learner uygulaması kullanılmıştır. Her iki yöntem için de çok sayıda deneme yapılmış en iyi sonucu veren SVM tipinin Fine Gaussion SVM; en iyi GPR tipinin ise Exponential GPR olduğu görülmüştür ve en iyi sonucu veren model yapısı Tablo 5.4. ve Tablo 5.5.’de gösterilmiştir .

**Tablo 5.4.** SVM modeli için kullanılan parametreler

<b>En iyi sonuç veren SVM tipi</b>	<b>Kernel Fonksiyonu</b>	<b>Kernel skalası</b>
Fine Gaussion SVM	Gaussion	0,25

**Tablo 5.5.**GPR modeli için kullanılan parametreler

<b>En iyi sonuç veren GPR tipi</b>	<b>Temel fonksiyonu</b>	<b>Kernel fonksiyonu</b>
exponential GPR	Constant (sürekli)	Exponential (üstel)

Bu parametreler kullanılarak beş farklı yöntem havzada bulunan on dört istasyon ve üç girdi kombinasyonu için uygulanmıştır. 2102 numaralı istasyon için model sonuçları Tablo 5.6’da sunulmuştur.

**Tablo 5.6.** 2102 numaralı istasyonun model sonuçları

		EĞİTİM							TEST											
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2102	ELM	M1	62,028	4	3847,498	4	0,987	4	<b>0,116</b>	5	53,095	3	2819,063	3	0,981	4	0,702	4	31	
		M2	56,358	4	3176,189	4	0,990	4	<b>0,231</b>	5	46,024	4	2118,198	4	0,985	4	1,563	3	32	<b>89</b>
		M3	67,346	2	4535,520	2	0,988	2	<b>0,284</b>	5	49,817	4	2481,694	4	0,982	3	2,172	4	26	
	ANFIS	M1	63,015	3	3970,924	3	0,987	3	0,944	3	53,074	4	2816,832	4	0,981	3	<b>0,273</b>	5	28	
		M2	76,591	1	5866,186	1	0,982	1	3,273	3	60,499	1	3660,166	1	0,974	1	5,285	2	11	51
		M3	100,599	1	10120,118	1	0,975	1	3,312	3	75,099	1	5639,932	1	0,963	1	6,886	3	12	
	SVM	M1	66,038	1	4361,100	1	0,980	1	22,745	2	<b>50,584</b>	5	<b>2558,787</b>	5	0,981	2	2,156	2	19	
		M2	61,649	2	3800,500	2	0,985	3	19,597	2	<b>45,679</b>	5	<b>2086,614</b>	5	0,985	3	<b>1,001</b>	5	27	72
		M3	62,897	3	3956,000	3	0,985	3	28,959	1	<b>47,153</b>	5	<b>2223,445</b>	5	0,985	4	8,445	2	26	
GPR	M1	<b>50,099</b>	5	<b>2509,900</b>	5	<b>0,990</b>	5	0,449	4	54,328	1	2951,490	1	0,980	1	0,849	3	25		
	M2	<b>6,930</b>	5	<b>1,483</b>	5	<b>0,999</b>	5	1,937	4	55,421	2	3071,471	2	0,983	2	1,449	4	29	84	
	M3	<b>1,267</b>	5	<b>1,604</b>	5	<b>0,999</b>	5	0,484	4	57,627	2	3320,827	2	0,979	2	<b>1,217</b>	5	30		
ENN	M1	65,823	2	4332,700	2	0,982	2	23,269	1	54,118	2	2928,300	2	<b>0,984</b>	5	21,976	1	17		
	M2	61,141	3	3738,200	3	0,985	2	20,755	1	50,037	3	2503,700	3	<b>0,986</b>	5	20,314	1	21	64	
	M3	61,016	4	3723,000	4	0,985	4	20,694	2	49,817	3	2481,800	3	<b>0,986</b>	5	20,104	1	26		

2102 numaralı istasyona ait sonuçlar incelendiğinde en yüksek performansa sahip olan algoritmanın ELM olduğu sonucuna ulaşılmıştır. Ayrıca tüm istasyona ait tüm R değerlerinin yüksek olduğu görülmüştür. Diğer istasyonlara ait sonuçlar da rank analizi ile inceleneceğinden tüm istasyonlar detayı olarak çalışma içerisinde sunulmuştur. 2122 numaralı istasyon için sonuçlar Tablo 5.7.'de verilmiştir.

**Tablo 5.7.** 2122 numaralı istasyonun model sonuçları

		EĞİTİM							TEST											
		M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP
2122	ELM	M1	17,601	4	309,780	4	0,967	4	<b>0,000</b>	5	24,389	2	594,799	2	0,917	1	<b>0,051</b>	5	27	
		M2	16,718	4	279,483	4	0,970	4	<b>0,000</b>	5	<b>21,554</b>	5	<b>464,585</b>	5	0,948	4	0,336	3	34	<b>95</b>
		M3	16,873	4	284,699	4	0,967	2	<b>0,000</b>	5	<b>21,667</b>	5	<b>469,475</b>	5	0,947	4	<b>0,354</b>	5	34	
	ANFIS	M1	17,713	3	313,752	3	0,967	3	0,296	4	<b>22,148</b>	5	<b>490,552</b>	5	0,939	4	0,100	4	31	
		M2	19,366	1	375,060	1	0,961	1	0,920	3	23,953	2	573,759	2	0,926	2	0,627	2	14	59
		M3	22,983	1	528,230	1	0,943	1	0,991	3	28,280	3	799,731	1	0,895	1	0,547	3	14	
	SVM	M1	18,396	1	338,400	1	0,964	1	5,671	2	23,428	3	548,852	3	0,931	3	1,034	2	16	
		M2	18,104	2	327,740	2	0,964	2	6,181	1	23,739	3	563,554	3	0,932	3	0,317	4	20	56
		M3	17,976	2	323,140	2	0,970	4	5,099	2	23,659	2	559,727	3	0,934	3	0,791	2	20	
	GPR	M1	<b>13,602</b>	5	<b>185,000</b>	5	<b>0,980</b>	5	4,705	3	24,764	1	613,251	1	0,927	2	0,803	3	25	
		M2	<b>2,469</b>	5	<b>6,094</b>	5	<b>0,999</b>	5	0,636	4	26,193	1	686,075	1	0,916	1	<b>0,114</b>	5	27	80
		M3	<b>0,850</b>	5	<b>0,723</b>	5	<b>0,999</b>	5	0,209	4	24,023	1	577,086	2	0,934	2	0,389	4	28	
ENN	M1	18,373	2	337,577	2	0,966	2	5,961	1	23,418	4	548,389	4	<b>0,956</b>	5	7,433	1	21		
	M2	17,888	3	319,996	3	0,968	3	5,707	2	23,102	4	533,717	4	<b>0,957</b>	5	7,164	1	25	70	
	M3	17,455	3	304,668	3	0,969	3	5,623	1	22,805	4	520,071	4	<b>0,958</b>	5	7,083	1	24		

Tablo 5.7.'de yer alan sonuçlar incelendiğinde yine en yüksek performansa ELM algoritmasında erişildiği görülmektedir. 2124 numaralı istasyon için sonuçlar Tablo 5.8.'de sunulmuştur.

**Tablo 5.8.** 2124 numaralı istasyonun model sonuçları

		EĞİTİM							TEST											
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2124	ELM	M1	1,011	4	1,021	4	0,931	2	<b>0,000</b>	5	2,883	1	8,310	1	0,849	1	2,193	1	19	
		M2	0,961	4	0,923	4	0,945	2	<b>0,000</b>	5	0,678	4	0,460	4	<b>0,961</b>	5	<b>0,070</b>	5	33	<b>78</b>
		M3	0,953	4	0,908	4	0,942	2	<b>0,000</b>	5	0,737	3	0,544	3	0,956	3	0,262	2	26	
	ANFIS	M1	1,030	3	1,060	3	0,931	1	0,004	4	<b>0,679</b>	5	<b>0,461</b>	5	<b>0,956</b>	5	<b>0,060</b>	5	31	
		M2	1,239	1	1,536	1	0,886	1	0,007	4	0,778	2	0,606	2	0,942	2	0,150	3	16	62
		M3	1,595	1	2,542		0,818	1	0,038	4	0,895	2	0,802	2	0,920	1	0,217	4	15	
	SVM	M1	1,035	1	1,072	1	0,954	4	0,260	2	0,684	4	0,468	4	0,955	3	0,088	4	23	
		M2	1,028	2	1,057	2	0,954	3	0,253	2	<b>0,673</b>	5	<b>0,453</b>	5	0,957	3	0,091	4	26	74
		M3	1,023	2	1,047	2	0,954	3	1,047	1	0,676	4	0,457	4	0,957	4	<b>0,120</b>	5	25	
	GPR	M1	<b>0,684</b>	5	<b>0,468</b>	5	<b>0,980</b>	5	0,220	3	2,238	2	5,007	2	0,877	2	1,728	2	26	
		M2	<b>0,340</b>	5	<b>0,116</b>	5	<b>0,995</b>	5	0,120	3	1,747	1	3,050	1	0,931	1	1,290	1	22	71
		M3	<b>0,234</b>	5	<b>0,055</b>	5	<b>0,999</b>	5	0,078	3	1,099	1	1,207	1	0,937	2	0,611	1	23	
ENN	M1	1,032	2	1,065	2	0,954	3	0,276	1	0,715	3	0,511	3	0,956	4	0,371	3	21		
	M2	1,023	3	1,047	3	0,954	4	0,277	1	0,704	3	0,496	3	0,958	4	0,375	2	23	74	
	M3	1,002	3	1,004	3	0,956	4	0,267	2	<b>0,669</b>	5	<b>0,448</b>	5	<b>0,957</b>	5	0,258	3	30		

Tablo 5.8 incelendiğinde diğer algoritmalarla yakın rank değerlerine sahip olmasına rağmen, ELM modelinin biraz daha yüksek performansa sahip olduğu görülmektedir. 2131 numaralı istasyon için sonuçlar Tablo 5.9.'da sunulmuştur.

**Tablo 5.9.** 2131 numaralı istasyonun model sonuçları

		EĞİTİM							TEST											
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2131	ELM	M1	0,627	4	0,393	4	0,953	4	<b>0,000</b>	5	0,662	1	0,438	1	0,844	1	<b>0,016</b>	5	25	<b>81</b>
		M2	0,620	4	0,384	4	0,957	4	<b>0,000</b>	5	0,640	2	0,410	2	0,856	2	0,020	3	26	
		M3	0,631	3	0,398	4	0,951	3	<b>0,000</b>	5	0,639	4	0,408	4	0,861	3	0,019	4	30	
	ANFIS	M1	0,635	3	0,404	3	0,952	3	0,006	4	<b>0,622</b>	5	<b>0,386</b>	5	0,867	4	0,020	3	30	68
		M2	0,683	1	0,466	1	0,942	1	0,013	4	<b>0,613</b>	5	<b>0,375</b>	5	0,873	4	0,035	2	23	
		M3	0,767	1	0,589	1	0,931	1	0,011	4	0,658	2	0,433	2	0,850	2	0,042	2	15	
	SVM	M1	0,645	1	0,416	1	0,949	2	0,160	2	0,633	3	0,401	3	0,863	3	0,024	2	17	60
		M2	0,646	2	0,418	2	0,949	3	0,160	2	0,639	3	0,409	3	0,864	3	0,018	4	22	
		M3	0,640	2	0,410	2	0,949	2	0,157	2	0,642	3	0,412	3	0,862	4	0,023	3	21	
	GPR	M1	<b>0,528</b>	5	<b>0,279</b>	5	<b>0,964</b>	5	0,140	3	0,657	2	0,432	2	0,858	2	0,019	4	28	80
		M2	<b>0,249</b>	5	<b>0,062</b>	5	<b>0,990</b>	5	0,068	3	0,678	1	0,460	1	0,842	1	<b>0,011</b>	5	26	
		M3	<b>0,177</b>	5	<b>0,031</b>	5	<b>0,995</b>	5	0,042	3	0,683	1	0,466	1	0,846	1	<b>0,012</b>	5	26	
	ENN	M1	0,644	2	0,415	2	0,948	1	0,173	1	0,632	4	0,400	4	<b>0,886</b>	5	0,170	1	20	71
		M2	0,633	3	0,401	3	0,950	2	0,167	1	0,625	4	0,390	4	<b>0,888</b>	5	0,167	1	23	
		M3	0,624	4	0,390	3	0,951	4	0,165	1	<b>0,634</b>	5	<b>0,402</b>	5	<b>0,884</b>	5	0,167	1	28	

2135 numaralı istasyon için sonuçlar Tablo 5.10.'da sunulmuştur.

**Tablo 5.10.** 2135 numaralı istasyonun model sonuçları

	EĞİTİM								TEST											
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2135	ELM	M1	0,851	4	0,725	4	0,927	1	<b>0,000</b>	5	2,090	1	4,368	1	0,915	3	<b>0,010</b>	5	24	79
		M2	0,826	4	0,683	4	0,937	3	<b>0,000</b>	5	1,160	2	1,345	3	0,909	4	<b>0,017</b>	5	30	
		M3	<b>0,837</b>	5	<b>0,701</b>	5	0,928	3	<b>0,000</b>	5	1,380	1	1,904	1	0,920	3	0,057	2	25	
	ANFIS	M1	0,852	3	0,725	3	0,927	2	0,024	4	1,091	3	1,189	3	0,916	4	0,018	2	24	56
		M2	0,888	2	0,789	2	0,919	1	0,008	4	1,192	1	1,420	2	<b>0,910</b>	5	0,002	4	21	
		M3	1,025	1	1,050	1	0,870	1	0,011	3	1,282	2	1,642	2	0,899	1	0,011	4	11	
	SVM	M1	0,899	1	0,809	1	0,938	4	0,289	2	0,990	4	0,980	4	0,901	1	0,013	4	21	68
		M2	0,909	1	0,826	1	0,933	2	0,284	2	<b>0,995</b>	5	<b>0,990</b>	5	0,900	1	0,013	3	20	
		M3	0,890	3	0,793	3	0,938	4	0,284	2	0,978	4	0,957	4	0,904	2	<b>0,010</b>	5	27	
	GPR	M1	<b>0,812</b>	5	<b>0,659</b>	5	<b>0,949</b>	5	0,280	3	1,156	2	1,337	2	<b>0,917</b>	5	0,016	3	30	80
		M2	<b>0,438</b>	5	<b>0,192</b>	5	<b>0,985</b>	5	0,168	3	1,268	3	1,609	1	0,906	3	0,014	2	27	
		M3	0,978	2	0,957	2	0,904	2	0,010	4	1,234	3	1,523	3	0,921	4	0,021	3	23	
	ENN	M1	0,898	2	0,807	2	0,937	3	0,309	1	<b>0,987</b>	5	<b>0,974</b>	5	0,906	2	0,284	1	21	73
		M2	0,867	3	0,751	3	0,941	4	0,293	1	0,998	4	0,997	4	0,904	2	0,269	1	22	
		M3	0,847	4	0,718	4	<b>0,944</b>	5	0,295	1	<b>0,971</b>	5	<b>0,909</b>	5	<b>0,943</b>	5	0,266	1	30	

2145 numaralı istasyon için sonuçlar Tablo 5.11.'de sunulmuştur,

**Tablo 5.11.** 2145 numaralı istasyonun model sonuçları

		EĞİTİM							TEST											
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2145	ELM	M1	3,190	4	10,178	4	0,956	2	<b>0,000</b>	5	1,823	2	3,323	2	0,966	4	<b>0,048</b>	5	28	
		M2	3,068	4	9,413	4	0,958	2	<b>0,000</b>	5	1,736	3	3,014	3	0,971	3	<b>0,038</b>	5	29	<b>84</b>
		M3	3,163	3	10,003	3	0,956	2	<b>0,000</b>	5	1,799	3	3,237	3	0,969	3	<b>0,042</b>	5	27	
	ANFIS	M1	3,218	3	10,353	2	0,956	1	0,003	4	<b>1,779</b>	5	<b>3,164</b>	5	0,967	2	0,068	4	26	
		M2	3,904	1	15,243	1	0,938	1	0,135	4	2,249	1	5,057	1	0,944	1	0,450	2	12	50
		M3	5,092	1	25,928	1	0,920	1	0,060	4	2,678	1	7,171	1	0,920	1	0,707	2	12	
	SVM	M1	3,224	1	10,391	1	0,975	4	1,001	2	1,793	3	3,215	3	0,967	1	0,120	3	18	
		M2	3,176	2	10,089	2	0,975	3	0,958	2	<b>1,676</b>	5	<b>2,811</b>	5	0,972	4	0,133	3	26	70
		M3	3,165	2	10,020	2	0,975	3	0,961	2	<b>1,676</b>	5	<b>2,809</b>	5	0,972	4	0,145	3	26	
	GPR	M1	<b>2,453</b>	5	<b>6,015</b>	5	<b>0,985</b>	5	0,863	3	1,862	1	3,466	1	0,970	3	0,124	2	25	
		M2	<b>0,994</b>	5	<b>0,987</b>	5	<b>0,999</b>	5	0,387	3	2,067	2	4,274	2	0,961	2	0,119	4	28	81
		M3	<b>0,664</b>	5	<b>0,440</b>	5	<b>0,999</b>	5	0,225	3	1,935	2	3,743	2	0,964	2	0,075	4	28	
ENN	M1	3,205	2	10,275	3	0,975	3	1,012	1	1,790	4	3,204	4	<b>0,973</b>	5	0,778	1	23		
	M2	3,128	3	9,785	3	0,976	4	0,980	1	1,704	4	2,903	4	<b>0,975</b>	5	0,715	1	25	75	
	M3	3,120	4	9,734	4	0,976	4	0,976	1	1,702	4	2,897	4	<b>0,975</b>	5	0,712	1	27		

2149 numaralı istasyon için sonuçlar Tablo 5.12.'de sunulmuştur,

**Tablo 5.12.** 2149 numaralı istasyonun model sonuçları

	EĞİTİM										TEST									
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2149	ELM	M1	4,984	4	24,844	4	0,979	2	<b>0,001</b>	5	<b>5,731</b>	5	<b>32,839</b>	5	0,966	1	0,107	4	30	
		M2	4,874	4	23,759	4	0,979	2	<b>0,000</b>	5	<b>5,640</b>	5	<b>31,805</b>	5	0,971	3	<b>0,022</b>	5	33	<b>94</b>
		M3	4,801	4	23,051	4	0,980	2	<b>0,000</b>	5	<b>5,673</b>	5	<b>32,186</b>	5	0,970	2	0,106	4	31	
	ANFIS	M1	5,003	3	25,025	3	0,978	1	0,021	4	5,743	4	32,982	4	0,967	2	0,154	3	24	
		M2	5,985	1	35,817	1	0,969	1	0,230	4	6,932	1	48,060	1	0,948	1	0,404	2	12	48
		M3	8,136	1	66,188	1	0,940	1	0,040	4	10,264	1	105,352	1	0,924	1	0,373	2	12	
	SVM	M1	5,097	1	25,977	1	0,980	4	1,467	2	5,883	3	34,609	2	0,967	3	0,187	2	18	
		M2	5,085	2	25,859	2	0,980	3	1,447	1	5,952	3	35,432	3	0,972	4	0,084	3	21	60
		M3	5,022	2	25,223	2	0,980	3	1,409	2	5,940	3	35,283	3	0,971	3	0,143	3	21	
	GPR	M1	<b>3,952</b>	5	<b>15,619</b>	5	<b>0,990</b>	5	1,296	3	7,244	1	52,475	1	0,973	4	<b>0,098</b>	5	29	
		M2	<b>1,088</b>	5	<b>1,184</b>	5	<b>0,999</b>	5	0,453	3	6,339	2	40,184	2	0,960	2	0,031	4	28	88
		M3	<b>0,731</b>	5	<b>0,535</b>	5	<b>0,999</b>	5	0,260	3	6,191	2	38,324	2	0,972	4	<b>0,070</b>	5	31	
ENN	M1	5,086	2	25,867	2	0,980	3	1,493	1	5,846	2	34,181	3	<b>0,987</b>	5	1,900	1	19		
	M2	5,010	3	25,103	3	0,980	4	1,447	2	5,746	4	33,012	4	<b>0,988</b>	5	1,803	1	26	70	
	M3	4,907	3	24,083	3	0,981	4	1,467	1	5,777	4	33,375	4	<b>0,988</b>	5	1,815	1	25		

2151 numaralı istasyon için sonuçlar Tablo 5.13.'de sunulmuştur,

**Tablo 5.13.** 2151 numaralı istasyonun model sonuçları

		EĞİTİM								TEST										
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2151	ELM	M1	12,858	4	165,339	4	0,977	1	<b>0,000</b>	5	14,422	2	208,007	2	0,976	3	0,075	3	24	
		M2	11,797	4	139,159	4	0,978	2	<b>0,000</b>	5	<b>12,162</b>	5	<b>147,908</b>	5	0,980	4	<b>0,207</b>	5	34	<b>93</b>
		M3	6,433	4	41,380	4	0,994	4	<b>0,013</b>	5	<b>11,931</b>	5	<b>142,349</b>	5	0,982	3	<b>0,130</b>	5	35	
	ANFIS	M1	12,931	3	167,215	3	0,978	2	0,170	4	<b>13,381</b>	5	<b>179,060</b>	5	0,976	4	<b>0,005</b>	5	31	
		M2	15,911	1	253,169	1	0,974	1	0,914	4	16,493	1	272,020	1	0,962	1	1,111	2	12	56
		M3	17,585	1	309,242	1	0,982	1	0,539	4	20,944	1	438,634	1	0,949	1	0,458	3	13	
	SVM	M1	13,151	1	173,080	1	0,985	3	4,821	2	13,765	4	189,469	3	0,976	2	0,958	2	18	
		M2	12,165	2	147,980	2	0,985	3	4,360	2	12,844	3	164,973	3	0,979	3	0,265	4	22	59
		M3	11,826	2	139,850	2	0,990	3	4,175	2	12,400	3	153,766	3	0,981	2	0,811	2	19	
	GPR	M1	<b>10,087</b>	5	<b>101,740</b>	5	<b>0,990</b>	5	4,104	3	15,325	1	234,846	1	0,966	1	0,054	4	25	
		M2	<b>2,168</b>	5	<b>4,702</b>	5	<b>0,999</b>	5	0,988	3	14,576	2	212,449	2	0,975	2	0,315	3	27	82
		M3	<b>0,874</b>	5	<b>0,765</b>	5	<b>0,999</b>	5	0,965	3	12,905	2	166,540	2	0,982	4	0,157	4	30	
	ENN	M1	13,041	2	170,075	2	0,985	4	4,872	1	13,704	3	187,804	4	<b>0,979</b>	5	4,898	1	22	
		M2	12,125	3	147,015	3	0,987	4	4,404	1	12,774	4	163,176	4	<b>0,982</b>	5	4,564	1	25	70
		M3	11,679	3	136,399	3	0,988	2	4,371	1	12,065	4	145,571	4	<b>0,984</b>	5	4,554	1	23	

2156 numaralı istasyon için sonuçlar Tablo 5.14'te sunulmuştur,

**Tablo 5.14.** 2156 numaralı istasyonun model sonuçları

	EĞİTİM										TEST									
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2156	ELM	M1	19,229	4	369,765	4	0,979	1	<b>0,000</b>	5	<b>20,280</b>	5	<b>411,275</b>	5	0,974	3	0,120	3	30	
		M2	17,726	4	314,211	4	0,980	2	<b>0,000</b>	5	<b>18,858</b>	5	<b>355,643</b>	5	0,978	4	0,233	3	32	<b>95</b>
		M3	17,844	4	318,403	4	0,980	2	<b>0,000</b>	5	<b>18,769</b>	5	<b>352,294</b>	5	0,978	4	0,185	4	33	
	ANFIS	M1	19,778	1	391,177	1	0,979	2	0,387	4	20,500	2	420,259	2	0,974	4	<b>0,004</b>	5	21	
		M2	25,583	1	654,467	1	0,972	1	0,525	4	25,945	1	673,159	1	0,960	1	0,141	4	14	46
		M3	36,130	1	1305,366	1	0,956	1	0,782	3	34,638	1	1199,792	1	0,938	1	1,733	2	11	
	SVM	M1	19,442	2	377,990	2	0,985	3	8,052	1	20,466	3	418,867	3	0,973	2	0,842	2	18	
		M2	18,081	2	326,950	2	0,990	4	7,359	1	19,123	3	365,682	3	0,976	2	<b>0,119</b>	5	22	63
		M3	18,064	2	326,320	2	0,990	4	7,245	1	19,069	3	363,634	3	0,977	3	<b>0,004</b>	5	23	
	GPR	M1	<b>16,004</b>	5	<b>256,120</b>	5	<b>0,990</b>	5	6,950	3	21,151	1	447,373	1	0,973	1	0,075	4	25	
		M2	<b>3,809</b>	5	<b>14,510</b>	5	<b>0,999</b>	5	1,266	3	21,481	2	461,422	2	0,977	3	0,268	2	27	80
		M3	<b>1,263</b>	5	<b>1,595</b>	5	<b>0,999</b>	5	0,398	4	21,129	2	446,418	2	0,976	2	0,325	3	28	
	ENN	M1	19,297	3	372,358	3	0,987	4	7,876	2	20,378	4	415,257	4	<b>0,983</b>	5	8,234	1	26	
		M2	17,950	3	322,194	3	0,988	3	7,108	2	19,020	4	361,767	4	<b>0,985</b>	5	7,457	1	25	76
		M3	17,865	3	319,160	3	0,989	3	7,055	2	18,812	4	353,891	4	<b>0,986</b>	5	7,447	1	25	

2158 numaralı istasyon için algoritma bazlı sonuçlar Tablo 5.15’de sunulmuştur,

**Tablo 5.15.** 2158 numaralı istasyonun model sonuçları

	EĞİTİM								TEST											
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2158	ELM	M1	8,663	4	75,043	4	0,957	4	<b>0,001</b>	5	6,953	2	48,349	2	0,956	2	0,248	3	26	
		M2	8,518	4	72,549	4	0,957	4	<b>0,000</b>	5	<b>6,641</b>	5	<b>44,097</b>	5	0,962	4	0,246	4	35	<b>95</b>
		M3	8,728	4	76,182	4	0,957	4	<b>0,001</b>	5	6,645	4	44,156	4	0,962	4	<b>0,162</b>	5	34	
	ANFIS	M1	8,811	3	77,634	3	0,953	3	0,200	4	<b>6,847</b>	5	<b>46,882</b>	5	0,958	4	0,425	2	29	
		M2	9,049	3	81,881	3	0,952	2	0,321	4	7,188	2	51,661	2	0,953	2	0,565	2	20	60
		M3	10,093	1	101,866	1	0,946	1	0,539	3	7,767	1	60,329	1	0,945	1	0,827	2	11	
	SVM	M1	9,344	1	87,300	1	0,949	1	2,703	2	6,889	4	47,464	4	0,957	3	0,233	4	20	
		M2	9,486	1	89,981	1	0,949	1	2,514	2	6,918	3	47,858	3	0,957	3	0,373	3	17	58
		M3	9,385	2	88,083	2	0,949	2	2,628	2	6,854	3	46,972	3	0,958	3	0,218	4	21	
	GPR	M1	<b>7,566</b>	5	<b>57,247</b>	5	<b>0,970</b>	5	2,398	3	7,513	1	56,449	1	0,944	1	<b>0,204</b>	5	26	
		M2	<b>1,145</b>	5	<b>2,087</b>	5	<b>0,999</b>	5	0,513	3	7,632	1	58,241	1	0,948	1	<b>0,186</b>	5	26	80
		M3	<b>0,404</b>	5	<b>0,163</b>	5	<b>0,999</b>	5	0,093	4	7,618	2	58,029	2	0,947	2	0,247	3	28	
	ENN	M1	9,337	2	87,188	2	0,951	2	2,917	1	6,891	3	47,487	3	<b>0,963</b>	5	2,661	1	19	
		M2	9,165	2	83,997	2	0,953	3	2,796	1	6,728	4	45,270	4	<b>0,965</b>	5	2,522	1	22	67
		M3	8,938	3	79,886	3	0,955	3	2,776	1	<b>6,625</b>	5	<b>43,888</b>	5	<b>0,966</b>	5	2,517	1	26	

2164 numaralı istasyon için algoritma bazlı sonuçlar Tablo 5.16’da sunulmuştur,

**Tablo 5.16.** 2164 numaralı istasyonun model sonuçları

		EĞİTİM										TEST								
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2164	ELM	M1	19,771	4	390,888	4	0,929	2	<b>0,000</b>	5	18,137	4	328,962	4	0,935	4	0,393	4	31	
		M2	19,697	4	387,986	4	0,922	2	<b>0,000</b>	5	<b>17,651</b>	5	<b>311,566</b>	5	<b>0,941</b>	5	<b>0,396</b>	5	35	<b>99</b>
		M3	19,455	4	378,505	4	0,929	2	<b>0,000</b>	5	<b>17,746</b>	5	<b>314,921</b>	5	0,942	4	0,307	4	33	
	ANFIS	M1	19,959	3	398,375	3	0,924	1	0,326	4	<b>17,824</b>	5	<b>317,683</b>	5	<b>0,937</b>	5	0,662	3	29	
		M2	20,752	2	430,644	2	0,917	1	0,349	4	18,214	3	331,752	3	0,935	4	0,835	3	22	62
		M3	23,110	1	534,063	1	0,888	1	0,536	3	19,286	1	371,955	1	0,922	1	1,158	2	11	
	SVM	M1	20,872	1	435,620	1	0,933	4	6,356	2	18,383	2	337,935	2	0,927	2	0,817	2	16	
		M2	21,066	1	443,760	1	0,933	3	5,928	2	18,555	2	344,275	2	0,927	1	1,541	2	14	51
		M3	20,853	2	437,840	2	0,933	3	6,999	1	18,371	3	337,506	3	0,929	2	<b>0,088</b>	5	21	
	GPR	M1	<b>15,424</b>	5	<b>237,910</b>	5	<b>0,964</b>	5	5,201	3	20,642	1	426,087	1	0,916	1	<b>0,293</b>	5	26	
		M2	<b>2,933</b>	5	<b>8,602</b>	5	<b>0,999</b>	5	0,604	3	21,500	1	462,258	1	0,929	2	0,402	4	26	83
		M3	<b>1,245</b>	5	<b>1,550</b>	5	<b>0,995</b>	5	0,215	4	18,720	2	350,424	2	<b>0,947</b>	5	0,323	3	31	
	ENN	M1	20,845	2	434,519	2	0,932	3	6,906	1	18,366	3	337,293	3	0,931	3	6,518	1	18	
		M2	20,643	3	426,140	3	0,934	4	6,602	1	18,012	4	324,430	4	0,934	3	6,250	1	23	65
		M3	20,235	3	409,460	3	0,937	4	6,487	2	17,832	4	317,996	4	0,935	3	6,187	1	24	

2166 numaralı istasyon için sonuçlar Tablo 5.17’de sunulmuştur,

**Tablo 5.17.** 2166 numaralı istasyonun model sonuçları

	EĞİTİM								TEST											
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2166	ELM	M1	29,479	4	869,000	4	0,962	2	<b>0,000</b>	5	27,787	2	772,090	2	0,930	3	0,503	3	25	<b>95</b>
		M2	<b>11,626</b>	5	<b>135,159</b>	5	<b>0,995</b>	5	<b>0,003</b>	5	27,842	4	775,184	3	<b>0,930</b>	5	0,714	4	36	
		M3	29,449	4	867,248	4	0,958	2	<b>0,003</b>	5	<b>27,546</b>	5	<b>758,783</b>	5	<b>0,932</b>	5	0,892	4	34	
	ANFIS	M1	29,716	3	883,047	3	0,962	3	0,499	4	27,745	3	769,782	3	<b>0,931</b>	5	<b>0,244</b>	5	29	68
		M2	31,337	1	981,987	1	0,963	3	0,712	4	<b>27,734</b>	5	<b>769,158</b>	5	0,926	3	2,015	2	24	
		M3	35,895	1	1288,440	1	0,955	1	1,152	3	28,297	2	800,696	2	0,920	3	3,101	2	15	
	SVM	M1	30,823	1	950,080	1	0,959	4	11,038	2	<b>27,359</b>	5	<b>748,529</b>	5	0,931	4	0,803	2	24	66
		M2	31,048	2	963,950	2	0,954	1	11,204	1	28,338	2	803,063	1	0,927	4	<b>0,081</b>	5	18	
		M3	30,659	2	940,000	2	0,959	3	10,789	2	28,151	3	792,483	3	0,928	4	<b>0,663</b>	5	24	
	GPR	M1	<b>24,537</b>	5	<b>602,080</b>	5	<b>0,975</b>	5	9,835	3	28,912	1	835,914	1	0,921	2	0,426	4	26	77
		M2	12,849	4	165,100	4	0,995	4	4,984	3	30,709	1	943,016	4	0,915	2	1,280	3	25	
		M3	<b>2,079</b>	5	<b>4,295</b>	5	<b>0,995</b>	5	0,398	4	30,886	1	953,955	1	0,919	2	2,029	3	26	
ENN	M1	30,799	2	948,593	2	0,957	1	11,415	1	27,393	4	750,400	4	0,915	1	15,515	1	16	54	
	M2	30,279	3	916,807	3	0,959	2	11,188	2	27,962	3	781,884	2	0,912	1	15,853	1	17		
	M3	29,675	3	880,603	3	0,960	4	11,178	1	27,572	4	760,213	4	0,915	1	15,738	1	21		

2610 numaralı istasyon için sonuçlar Tablo 5.18’de sunulmuştur,

**Tablo 5.18.** 2610 numaralı istasyonun model sonuçları

	EĞİTİM										TEST									
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2610	ELM	M1	9,857	4	97,153	4	0,926	3	<b>0,000</b>	5	<b>8,954</b>	5	<b>80,167</b>	5	0,896	4	0,261	2	32	<b>99</b>
		M2	9,710	4	94,275	4	0,928	4	<b>0,000</b>	5	<b>8,813</b>	5	<b>77,674</b>	5	0,898	4	0,254	3	34	
		M3	9,703	4	94,140	4	0,931	4	<b>0,000</b>	5	8,850	4	78,319	4	0,896	4	0,166	4	33	
	ANFIS	M1	9,862	3	97,264	3	0,927	4	0,018	4	8,963	4	80,339	4	0,895	3	0,151	3	28	65
		M2	10,024	2	100,491	2	0,926	3	0,180	4	8,979	4	80,629	4	0,893	3	0,340	2	24	
		M3	10,785	1	116,317	1	0,917	1	0,216	3	9,407	1	88,495	1	0,883	2	0,423	3	13	
	SVM	M1	10,226	1	104,570	1	0,917	2	3,186	2	9,279	2	86,108	2	0,885	2	<b>0,096</b>	5	17	50
		M2	10,285	1	105,790	1	0,917	1	3,212	1	9,309	2	86,664	2	0,884	2	0,067	4	14	
		M3	10,124	2	102,500	2	0,917	2	2,068	2	9,164	3	83,984	3	0,889	3	0,664	2	19	
	GPR	M1	<b>7,450</b>	5	<b>55,500</b>	5	<b>0,954</b>	5	2,592	3	9,756	1	95,175	1	0,884	1	0,149	4	25	80
		M2	<b>0,903</b>	5	<b>0,815</b>	5	<b>0,996</b>	5	0,272	3	10,465	1	109,508	1	0,865	1	<b>0,025</b>	5	26	
		M3	<b>0,339</b>	5	<b>0,115</b>	5	<b>0,997</b>	5	0,094	4	9,294	2	86,384	2	0,878	1	<b>0,034</b>	5	29	
	ENN	M1	10,216	2	104,367	2	0,915	1	3,409	1	9,270	3	85,937	3	<b>0,913</b>	5	3,278	1	18	66
		M2	10,010	3	100,192	3	0,919	2	3,192	2	9,129	3	83,333	3	<b>0,916</b>	5	3,055	1	22	
		M3	9,759	3	95,230	3	0,923	3	3,096	1	<b>8,759</b>	5	<b>76,719</b>	5	<b>0,923</b>	5	2,957	1	26	

2612 numaralı istasyon için sonuçlar Tablo 5.19’da sunulmuştur,

**Tablo 5.19.** 2612 numaralı istasyonun model sonuçları

	EĞİTİM										TEST									
	M	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	RMSE	RANK	MSE	RANK	r	RANK	MAE	RANK	TP	TP	
2612	ELM	M1	59,207	4	3505,434	4	0,934	3	<b>0,000</b>	5	66,600	2	4435,605	2	0,871	2	1,745	2	24	
		M2	57,374	4	3291,787	4	0,935	4	<b>0,001</b>	5	77,848	2	6060,305	2	0,828	1	<b>1,238</b>	5	27	<b>77</b>
		M3	58,080	4	3373,276	3	0,933	3	<b>0,004</b>	5	68,778	2	4730,362	2	0,867	3	1,522	4	26	
	ANFIS	M1	59,587	3	3550,613	3	0,935	4	0,311	4	65,929	3	4346,570	3	0,871	3	1,464	3	26	
		M2	62,217	1	3870,936	1	0,928	2	0,157	4	<b>64,241</b>	5	4126,946	3	0,874	4	2,302	4	24	76
		M3	69,227	1	4792,365	4	0,920	1	0,511	3	<b>64,673</b>	5	<b>4182,581</b>	5	0,878	4	3,689	3	26	
	SVM	M1	61,441	1	3775,000	1	0,933	2	22,321	2	65,015	4	4226,993	4	0,871	4	<b>0,575</b>	5	23	
		M2	61,328	2	3761,100	2	0,933	3	24,701	1	68,728	4	<b>4723,566</b>	5	0,859	3	5,041	3	23	68
		M3	60,788	2	3695,200	1	0,933	2	19,739	2	68,338	4	4670,065	4	0,864	2	<b>1,513</b>	5	22	
	GPR	M1	<b>51,774</b>	5	<b>2677,500</b>	5	<b>0,954</b>	5	19,329	3	67,800	1	4596,848	1	0,864	1	1,217	4	25	
		M2	<b>8,605</b>	5	<b>74,051</b>	5	<b>0,996</b>	5	1,854	3	82,845	1	6863,292	1	0,829	2	8,815	2	24	73
		M3	<b>1,766</b>	5	<b>3,118</b>	5	<b>0,996</b>	5	0,492	4	86,715	1	7519,522	1	0,828	1	10,175	2	24	
ENN	M1	61,432	2	3773,900	2	0,931	1	22,933	1	<b>64,963</b>	5	<b>4220,100</b>	5	<b>0,894</b>	5	34,183	1	22		
	M2	60,347	3	3641,800	3	0,933	3	22,052	2	68,869	3	4742,900	2	<b>0,883</b>	5	35,550	1	22	66	
	M3	59,329	3	3520,000	2	0,936	4	21,588	1	68,462	3	4687,000	3	<b>0,885</b>	5	35,407	1	22		


Tablo 5.6-5.19 incelendiğinde tüm istasyonlarda en yüksek performansa ELM algoritmasında ulaşılmıştır, Bu değerlendirmenin daha iyi yapılabilmesi için toplam rank değerleri Tablo 5.20’de sunulmuştur,

**Tablo 5.20.** Toplam rank değerleri

İSTASYON	TOPLAM RANK														
	M1					M2					M3				
	ELM	ANFIS	SVM	GPR	ENN	ELM	ANFIS	SVM	GPR	ENN	ELM	ANFIS	SVM	GPR	ENN
<b>2102</b>	<b>31</b>	28	19	25	17	<b>32</b>	11	27	29	21	26	12	26	<b>30</b>	26
<b>2122</b>	27	<b>31</b>	16	25	21	<b>34</b>	14	20	27	25	<b>34</b>	14	20	28	24
<b>2124</b>	19	<b>31</b>	23	26	21	<b>33</b>	16	26	22	23	26	16	25	23	<b>30</b>
<b>2131</b>	25	<b>30</b>	17	28	20	<b>26</b>	23	22	<b>26</b>	23	<b>30</b>	15	21	26	28
<b>2135</b>	24	24	21	<b>30</b>	21	<b>30</b>	21	20	27	22	25	15	27	23	<b>30</b>
<b>2145</b>	<b>28</b>	26	18	25	23	<b>29</b>	12	26	28	25	27	12	26	<b>28</b>	27
<b>2149</b>	<b>30</b>	24	18	29	19	<b>33</b>	12	21	28	26	<b>31</b>	12	21	<b>31</b>	25
<b>2151</b>	24	<b>31</b>	18	25	22	<b>34</b>	12	22	27	25	<b>35</b>	13	19	30	23
<b>2156</b>	<b>30</b>	21	18	25	26	<b>32</b>	14	22	27	25	<b>33</b>	11	23	28	25
<b>2158</b>	26	<b>29</b>	20	26	19	<b>35</b>	20	17	26	22	<b>34</b>	11	21	28	26
<b>2164</b>	<b>31</b>	29	16	26	18	<b>35</b>	22	14	26	23	<b>33</b>	11	21	31	24
<b>2166</b>	25	<b>29</b>	24	26	16	<b>36</b>	24	18	25	17	<b>34</b>	15	24	26	21
<b>2610</b>	<b>32</b>	28	17	25	18	<b>34</b>	24	14	26	22	<b>33</b>	13	19	29	26
<b>2612</b>	24	<b>26</b>	23	25	22	<b>27</b>	24	23	24	22	<b>26</b>	<b>26</b>	22	24	22
<b>TOPLAM</b>	<b>376</b>	<b>387</b>	<b>268</b>	<b>366</b>	<b>283</b>	<b>450</b>	<b>249</b>	<b>292</b>	<b>368</b>	<b>321</b>	<b>427</b>	<b>196</b>	<b>315</b>	<b>385</b>	<b>357</b>
<b>KOMBİNASYON TOPLAM RANK DEĞERİ</b>	1680					1680					1680				
<b>TOPLAM ELM</b>	<b>1253</b>		<b>TOPLAM ANFIS</b>	832	<b>TOPLAM SVM</b>	875	<b>TOPLAM GPR</b>	1119	<b>TOPLAM ENN</b>	961					

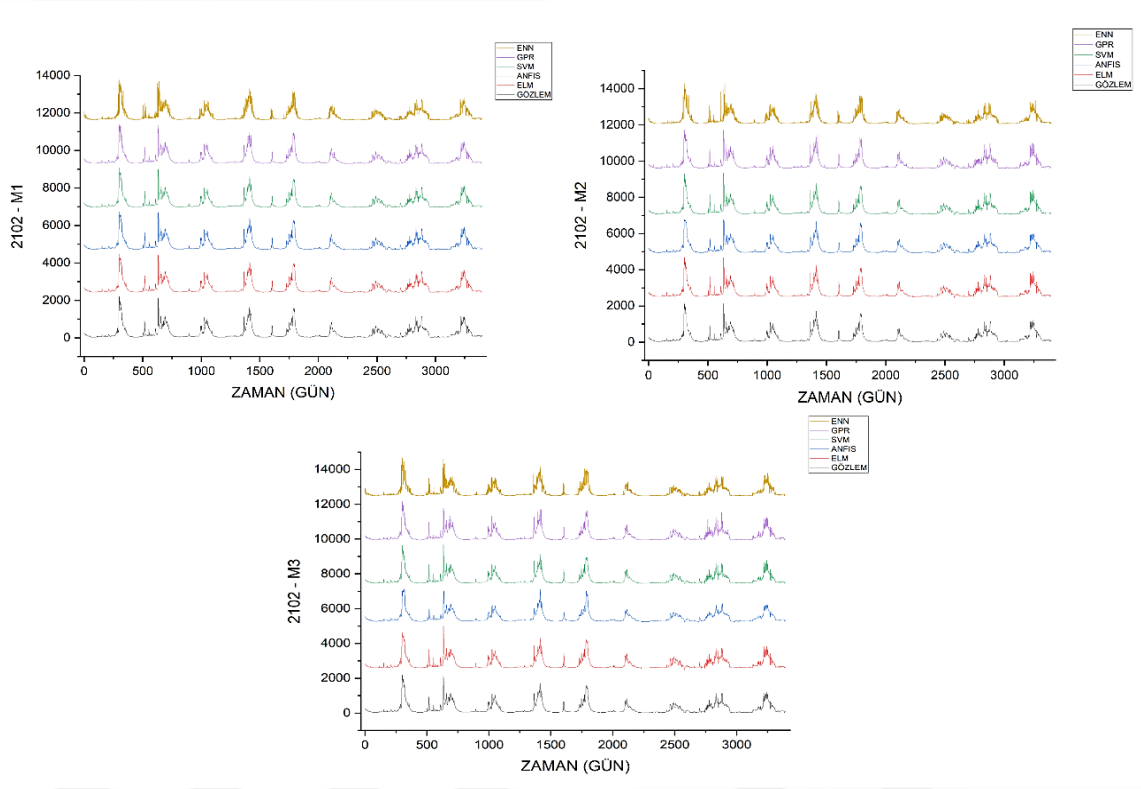
Tüm sonuçlar incelendiğinde yapay zekâ tekniklerinin tümünün çok iyi sonuç verdiği ve günlük akım modellemesinde kullanılabileceği görülmüştür, En iyi algoritma yapısının ELM olduğu görülmüştür, Algoritmalar sıralandığında en iyiden en kötüye ELM, GPR, ENN, SVM ve ANFIS şeklinde sıralandığı görülmektedir, Bu sıralama dikkate alındığında SVM ve ANFIS gibi geleneksel yöntemlerin bazı sorunları çözülerek daha iyi sonuçlar elde edilmesinin mümkün olduğu görülmektedir,

Ayrıca çalışma kapsamında istatistiksel analiz sonuçlarının grafik özeti sağlanması amacıyla algoritma test sonuçlarının Taylor Diyagramları sunulmuştur, Algoritmalar arasında performans farkları olsa da tüm algoritmaların gözlem değerlerine yakın sonuçlar verdiğinin görülmesi için ise test sonuçlarının zaman serisi grafikleri oluşturulmuştur, Örnek olarak 2102 numaralı istasyona ait diyagram Şekil 5.3'de verilmiştir, Diğer istasyonlara ait diyagramlar ise Ek-4.1-13'de sunulmuştur,



Şekil 5.3. 2102 numaralı istasyonun Taylor Diyagramı

2102 numaralı istasyona ait zaman serisi grafikleri ise Şekil 5.4’de verilmiştir, Diğer istasyonlara ait grafikler ise Ek-5.1-13’de verilmiştir,



Şekil 5.4. 2102 numaralı istasyonun test sonuçlarının zaman serisi

Şekil 5.3 ve 5.4 incelendiğinde modellerin birbirine yakın çıktılar sağladığı ve bu çıktılar gözlem verileri ile uyumlu olduğu görülmektedir, Ayrıca standart sapmaya bağlı olarak RMSE ve MSE değerlerinin değiştiği görülmüştür,

## 6. SONUÇ ve TARTIŞMA

Çalışma kapsamında Türkiye'nin konumu ve sınır aşan sulara sahip olması sebebiyle en önemli havzalarından biri olarak görülen Fırat-Dicle havzasının günlük akım modellenmesi gerçekleştirilmiştir, Havzayı en iyi temsil ettiği düşünülen ve eksik veri oranı en az olan (%10 ve altında) on dört istasyona ait günlük akım verileri ile hazırlanan çalışmanın ilk aşamasında verilerin normal dağılıma uygunluğu incelenmiştir, Elde edilen sonuçlar verilerin genellikle basık bir şekilde dağıldığını ve normal dağılıma uymadığını göstermiştir, Bu sonuç hidrolojik verilerin genellikle normal dağılıma uymaması bilgisi ile örtüşmektedir.

Bu nedenle ikinci aşamada girdi kombinasyonları belirlenirken verilerin dağılımı dikkate alınarak Spearman korelasyon durumu incelenmiştir, Mevcut günlük akım verilerinin geçmiş dönemlerdeki veriler ile korelasyonu incelendiğinde 1-12 gün arasındaki veriler ile yüksek ilişki olduğu görülmüştür, Ancak on ikinci gün kadar gidildiğinde korelasyonun sürekli azaldığı görüldüğünden ilk üç gün ile girdi kombinasyonları oluşturulmuştur, Aradaki gün sayısı arttıkça, korelasyon değeri düştüğünden bir, iki ve üç gün önceki verilerin kullanımı yeterli görülmüştür.

Üçüncü aşama olarak model yapıları oluşturulmuş ve tüm algoritmaların yüksek performansa sahip oldukları görülmüştür, RMSE, MSE, MAE ve r indeksleri arasında bir üstünlük bulunmadığından rank analizi uygulanarak performans değerlendirmesi yapılmıştır, Rank analizinden elde edilen sonuçlar ELM algoritmasının diğer algoritmalarından daha iyi sonuç verdiğini göstermiştir, Algoritmalar en yüksek performanstan başlanarak sıralandığında sıralamanın ELM, GPR, ENN, SVM ve ANFIS şeklinde ilerlediği görülmüştür, Bu durum literatürde sıklıkla kullanılan ANFIS ve SVM algoritmaları yerine kullanımı daha yeni olan ELM, GPR ve ENN algoritmalarının kullanımının daha iyi sonuçlar verebileceğini göstermektedir, Elde edilen bu sonuçlar hidrolojik yapıların tasarımı ve kar erimesi gibi hidrolojik hesaplamaların yapılabilmesi için büyük öneme sahiptir.

Literatürde yer alan diğer çalışmalar incelendiğinde; bu çalışmada elde edilen sonuçların gelenekselleşmiş yöntemleri geliştirici yönde olduğu görülmektedir, Ayrıca literatürde yer alan birçok çalışmaya nazaran bu çalışmada daha geniş bir alan ve fazla sayıda

istasyon tercih edilerek sayısal modellerin genelleme özelliğine katkı sağlamayı amaçlamaktadır (Rezaeianzadeh vd., 2014; Zhou vd., 2019; Yaseen vd., 2020; Adnan vd., 2021).



## KAYNAKLAR

- Acar, R., Çelik, S., and Senocak, S. (2008) "Rainfall intensity-duration-frequency (IDF) model using an artificial neural network approach", *CSIR*, 198-202.
- Adamson, P.T. (1979) "Probability distributions of best fit to South African flood data," *Water SA*, 5(2), 70-76.
- Adnan, R.M., Liang, Z., Trajkovic, S., Zounemat-Kermani, M., Li, B. and Kisi, O. (2019) "Daily streamflow prediction using optimally pruned extreme learning machine", *Journal of Hydrology*, 577, 123981, <https://doi.org/10.1016/j.jhydrol.2019.123981>
- Akrami, S. A., Nourani, V. and Hakim, S. J. S. (2014) "Development of nonlinear model based on wavelet-ANFIS for rainfall forecasting at Klang Gates Dam", *Water resources management*, 28(10), 2999-3018.
- Azad, A., Karami, H., Farzin, S., Mousavi, S.F. and Kisi, O. (2019) "Modeling river water quality parameters using modified adaptive neuro fuzzy inference system", *Water Science and Engineering*, 12(1), 45-54.
- Azimi, H., Bonakdari, H. and Ebtehaj, I. (2017) "Sensitivity analysis of the factors affecting the discharge capacity of side weirs in trapezoidal channels using extreme learning machines", *Flow Measurement and Instrumentation*, 54, 216-223.
- Bhardwaj, R. and Pruthi, D. (2020) "Evolutionary techniques for optimizing air quality model", *Procedia Computer Science*, 167, 1872-1879.
- Biswas, R., Samui, P., and Rai, B. (2019) "Determination of compressive strength using relevance vector machine and emotional neural network", *Asian Journal of Civil Engineering*, 20(8), 1109-1118.
- Bonaccorso, G. (2017) "Machine learning algorithms", *Packt Publishing Ltd.*
- Burges, C. J. (1998) "A tutorial on support vector machines for pattern recognition", *Data mining and knowledge discovery*, 2(2), 121-167.
- Chaudhury, S., Samantaray, S., Sahoo, A., Bhagat, B., Biswakalyani, C. and Satapathy, D. P. (2022) "Hybrid ANFIS-PSO Model for Monthly Precipitation Forecasting, In *Evolution in Computational Intelligence*", **Springer**, Singapore, 349-359.
- Choubin, B., Zehtabian, G., Azareh, A., Rafiei-Sardooi, E., Sajedi-Hosseini, F. and Kişi, Ö. (2018) "Precipitation forecasting using classification and regression trees (CART) model: a comparative study of different approaches", *Environmental earth sciences*, 77(8), 1-13.

- Dallal, G. E., and Wilkinson, L. (1986) "An analytic approximation to the distribution of Lilliefors's test statistic for normality," *The American Statistician*, 40(4), 294-296.
- Demuth, H.B. (2000) "Fuzzy logic toolbox for use with MATLAB" *User's Guide Version 4, MA*.
- Deo, R.C. and Şahin, M. (2016) "An extreme learning machine model for the simulation of monthly mean streamflow water level in eastern Queensland", *Environmental monitoring and assessment*, 188(2), 1-24.
- Drezner, Z., Turel, O. and Zerom, D. (2010) "A modified Kolmogorov–Smirnov test for normality," *Communications in Statistics—Simulation and Computation*, 39(4), 693-704.
- EİE (2006) "Hidrometri Kurs Notları", *Elektrik İşleri Etüt İdaresi*, Ankara.
- EİE (2008) "Su Akımları Aylık Ortalamaları(1935-2005)", *Elektrik İşleri Etüt İdaresi*, Ankara.
- Farmer, W.H. (2016) "Ordinary kriging as a tool to estimate historical daily streamflow records", *Hydrology and Earth System Sciences*, 20(7), 2721-2735.
- Ferreira, L.B., da Cunha, F.F., de Oliveira, R.A, and Fernandes Filho, E.I, (2019) "Estimation of reference evapotranspiration in Brazil with limited meteorological data using ANN and SVM—A new approach", *Journal of Hydrology*, 572, 556-570, <https://doi.org/10.1016/j.jhydrol.2019.03.028>
- Firat, M., and Güngör, M. (2007) "River flow estimation using adaptive neuro fuzzy inference system", *Mathematics and Computers in Simulation*, 75(3-4), 87-96.
- Ghasemi, A. and Amanollahi, J. (2019) "Integration of ANFIS model and forward selection method for air quality forecasting", *Air Quality, Atmosphere & Health*, 12(1), 59-72.
- Goldberg, D.E. and Samtani, M.P. (1986) "Engineering optimization via genetic algorithm," *In Electronic computation* , ASCE, 471-482.
- GÜNDÜZ, A. (2011) "Fırat-Dicle havzasında günlük nehir akımlarının farklı yapay zeka yöntemleri ile tahmini/Prediction of daily river flows in Fırat-Dicle basin using different artificial intelligence methods", Yüksek Lisans Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 69 sayfa.
- Han, Y., Wu, J., Zhai, B., Pan, Y., Huang, G., Wu, L. and Zeng, W. (2019) "Coupling a bat algorithm with xgboost to estimate reference evapotranspiration in the arid and semiarid regions of china", *Advances in Meteorology*, 2019.
- 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.
- Heiss, J.E., Held, C.M., Estevez, P.A., Perez, C.A., Holzmann, C.A. and Perez, J.P. (2002) “Classification of sleep stages in infants: a neuro fuzzy approach”, *IEEE Engineering in Medicine and Biology Magazine*, 21(5), 147-151.
- Hipni, A., El-shafie, A., Najah, A., Karim, O.A., Hussain, A. and Mukhlisin, M. (2013) “Daily forecasting of dam water levels: comparing a support vector machine (SVM) model with adaptive neuro fuzzy inference system (ANFIS)”, *Water resources management*, 27(10), 3803-3823.
- Huang, G.B., Zhu, Q.Y. and Siew, C.K. (2006) “Extreme learning machine: theory and applications”, *Neurocomputing*, 70(1-3), 489-501, <https://doi.org/10.1016/j.neucom.2005.12.126>
- Ibrahim, K.S.M.H., Huang, Y. F., Ahmed, A. N., Koo, C.H. and El-Shafie, A. (2022) “A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forecasting”, *Alexandria Engineering Journal*, 61(1), 279-303.
- IPCC. (2021) “Sixth Assessment Report (AR6)”, *The Intergovernmental Panel on Climate Change*.
- Jang, J.S. (1993) “ANFIS: adaptive-network-based fuzzy inference system”, *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- Jang, J.S.R. (1991) “Fuzzy modeling using generalized neural networks and kalman filter algorithm”, *In AAAI* , 91, 762-767.
- Ji, W., Liu, Y. and Zhen, J.Q. (2020) “Prediction of soil humidity based on random weight Particle Swarm Optimized Extreme Learning Machine”, *In Journal of Physics: Conference Series*, 1486(4), IOP Publishing, 042043.
- Jin, Z., Zhou, G., Gao, D. and Zhang, Y, (2020) “EEG classification using sparse Bayesian extreme learning machine for brain–computer interface”, *Neural Computing and Applications*, 32(11), 6601-6609.
- Karaca, Ö.F. (2021) “Fırat-Dicle Havzasındaki Akım ve Sediment Taşınımının Yapay Sinir Ağları İle Tahmini”, Doktora Tezi, *Tokat Gazi Osmanpaşa Üniversitesi*, Tokat, 196 sayfa.
- Karahan, F. and Ozkan, S. (2013) “On the persistence of income shocks over the life cycle: Evidence, theory, and implications,” *Review of Economic Dynamics*, 16(3), 452-476.
- Katipoğlu, O.M. (2020) “Fırat Havzası’nda ki Meteorolojik ve Hidrolojik Kuraklıkların Analizi”, *Atatürk Üniversitesi Fen Bilimleri Enstitüsü*, Doktora Tezi, Erzurum.

- Katipoğlu, O.M. ve Acar, S. (2021) “Standartlaştırılmış yağış indeksi hesabında kullanılan dağılım fonksiyonu etkisinin ve kuraklık karakteristiklerinin araştırılması” , *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11(3), 828-844.
- Khan, M.S. and Coulibaly, P. (2006) “Application of support vector machine in lake water level prediction”, *Journal of Hydrologic Engineering*, 11(3), 199-205.
- Khan, N., Sachindra, D.A., Shahid, S., Ahmed, K., Shiru, M.S. and Nawaz, N. (2020) “Prediction of droughts over Pakistan using machine learning algorithms”, *Advances in Water Resources*, 139, 103562.
- Khashman, A. (2009a) “Application of an emotional neural network to facial recognition”, *Neural Computing and Applications*, 18(4), 309-320.
- Khashman, A. (2009b) “Blood cell identification using emotional neural networks”, *Journal of Information Science & Engineering*, 25(6).
- Latifoğlu, L., (2017) “Hidrolojik Zaman Serilerinin Hibrit Yöntemlerle Tahmini”, Doktora Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri, 166 sayfa.
- Leung, S.C. and Fulcher, J. (1997) “Classification of user expertise level by neural networks”, *International Journal of Neural Systems*, 8(02), 155-171.
- Li, G., Ma, X. and Yang, H. (2018) “A hybrid model for monthly precipitation time series forecasting based on variational mode decomposition with extreme learning machine”, *Information*, 9(7), 177, Doi: 10.3390/info9070177
- Li, Z., Deng, C., Zhao, B., Tian, Y. and Huang, Y. (2019) “Hyperspectral inversion for soil moisture and temperature based on gaussian process regression”, **In 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP)**, IEEE, 1-4.
- Lilliefors, H.W. (1967) “On the Kolmogorov-Smirnov test for normality with mean and variance unknown”, *Journal of the American statistical Association*, 62(318), 399-402.
- Massey Jr, F, J, (1951) “The Kolmogorov-Smirnov test for goodness of fit,” *Journal of the American statistical Association*, 46(253), 68-78.
- McDuff D. (2019, February 22), “Gaussian Processes [online]”.
- Mohamadi, S., Ehteram, M. and El-Shafie, A. (2020) “Accuracy enhancement for monthly evaporation predicting model utilizing evolutionary machine learning methods”, *International Journal of Environmental Science and Technology*, 17(7), 3373-3396.
- Mokhtarzad, M., Eskandari, F., Jamshidi Vanjani, N. and Arabasadi, A. (2017) “Drought forecasting by ANN, ANFIS, and SVM and comparison of the models”, *Environmental earth sciences*, 76(21), 1-10.

- Mokhtarzad, M., Eskandari, F., Jamshidi Vanjani, N. and Arabasadi, A. (2017) “Drought forecasting by ANN, ANFIS, and SVM and comparison of the models”, *Environmental earth sciences*, 76(21), 1-10.
- Nauck, D. and Kruse, R. (1998) “NEFCLASS-X—a soft computing tool to build readable fuzzy classifiers,” *BT Technology Journal*, 16(3), 180-190.
- Nauck, D., Klawonn, F. and Kruse, R. (1997) ”*Foundations of neuro-fuzzy systems*”, *John Wiley & Sons, Inc.*
- NTU. “*Extreme Learning Machine*”, [https://www.ntu.edu.sg/home/egbhuang/elm\\_random\\_hidden\\_nodes.html](https://www.ntu.edu.sg/home/egbhuang/elm_random_hidden_nodes.html)  
Son erişim tarihi;01.12.2021
- Pradeep, T., Bardhan, A., Burman, A. and Samui, P. (2021) “Rock Strain Prediction Using Deep Neural Network and Hybrid Models of ANFIS and Meta-Heuristic Optimization Algorithms,” *Infrastructures*, 6(9), 129.
- Rezaeianzadeh, M., Tabari, H., Arabi Yazdi, A., Isik, S. and Kalin, L. (2014) “Flood flow forecasting using ANN, ANFIS and regression models”, *Neural Computing and Applications*, 25(1), 25-37, <https://doi.org/10.1007/s00521-013-1443-6>
- Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986) “Learning internal representations by error propagation, Parallel Distributed Processing”, Vol, 1, *Foundations, MIT Press*, Cambridge.
- Sun, A.Y., Wang, D., and Xu, X. (2014) “Monthly streamflow forecasting using Gaussian process regression”, *Journal of Hydrology*, 511, 72-81.
- Tao, H., Diop, L., Bodian, A., Djaman, K., Ndiaye, P.M. and Yaseen, Z.M. (2018) “Reference evapotranspiration prediction using hybridized fuzzy model with firefly algorithm: Regional case study in Burkina Faso”, *Agricultural water management*, 208, 140-151, <https://doi.org/10.1016/j.agwat.2018.06.018>
- Taylor, K.E. (2001) “Summarizing multiple aspects of model performance in a single diagram,” *Journal of Geophysical Research: Atmospheres*, 106(7), 7183-7192.
- Taylor, K.E. (2005) “Taylor diagram primer”, *Work, Pap*, 1-4.
- Vapnik, V.N. (1999) “An overview of statistical learning theory” *IEEE transactions on neural networks*, 10(5), 988-999.
- Yaseen, Z.M., Jaafar, O., Deo, R.C., Kisi, O., Adamowski, J., Quilty, J. and El-Shafie, A. (2016) “Stream-flow forecasting using extreme learning machines: a case study in a semi-arid region in Iraq”, *Journal of Hydrology*, 542, 603-614, <https://doi.org/10.1016/j.jhydrol.2016.09.035>
- Yaseen, Z.M., Naganna, S.R., Sa’adi, Z., Samui, P., Ghorbani, M.A., Salih, S. Q., and Shahid, S. (2020) “Hourly river flow forecasting: application of emotional neural

network versus multiple machine learning paradigms”, *Water Resources Management*, 34(3), 1075-1091, Doi: 10,1007/s11269-020-02484-w

Yaseen, Z.M., Sulaiman, S.O., Deo, R.C. and Chau, K.W. (2019) “An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction”, *Journal of Hydrology*, 569, 387-408, <https://doi.org/10,1016/j.jhydrol,2018,11,069>

Yıldırım, A. (2006) “Karakaya Barajı Ve Doğal Çevre Etkileri”, *Dicle Üniversitesi Ziya Gökalp Eğitim Fakültesi Dergisi*, (6), 32-39.

Zhang, H., Zhou, J., Jahed Armaghani, D., Tahir, M.M., Pham, B.T, and Huynh, V.V.(2020) “A combination of feature selection and random forest techniques to solve a problem related to blast-induced ground vibration”, *Applied Sciences*, 10(3), 869, <https://doi.org/10,3390/app10030869>

Zhang, Y., Yang, H., Cui, H. and Chen, Q. (2020) “Comparison of the ability of ARIMA, WNN and SVM models for drought forecasting in the Sanjiang Plain, China”, *Natural Resources Research*, 29(2), 1447-1464, <https://doi.org/10,1007/s11053-019-09512-6>

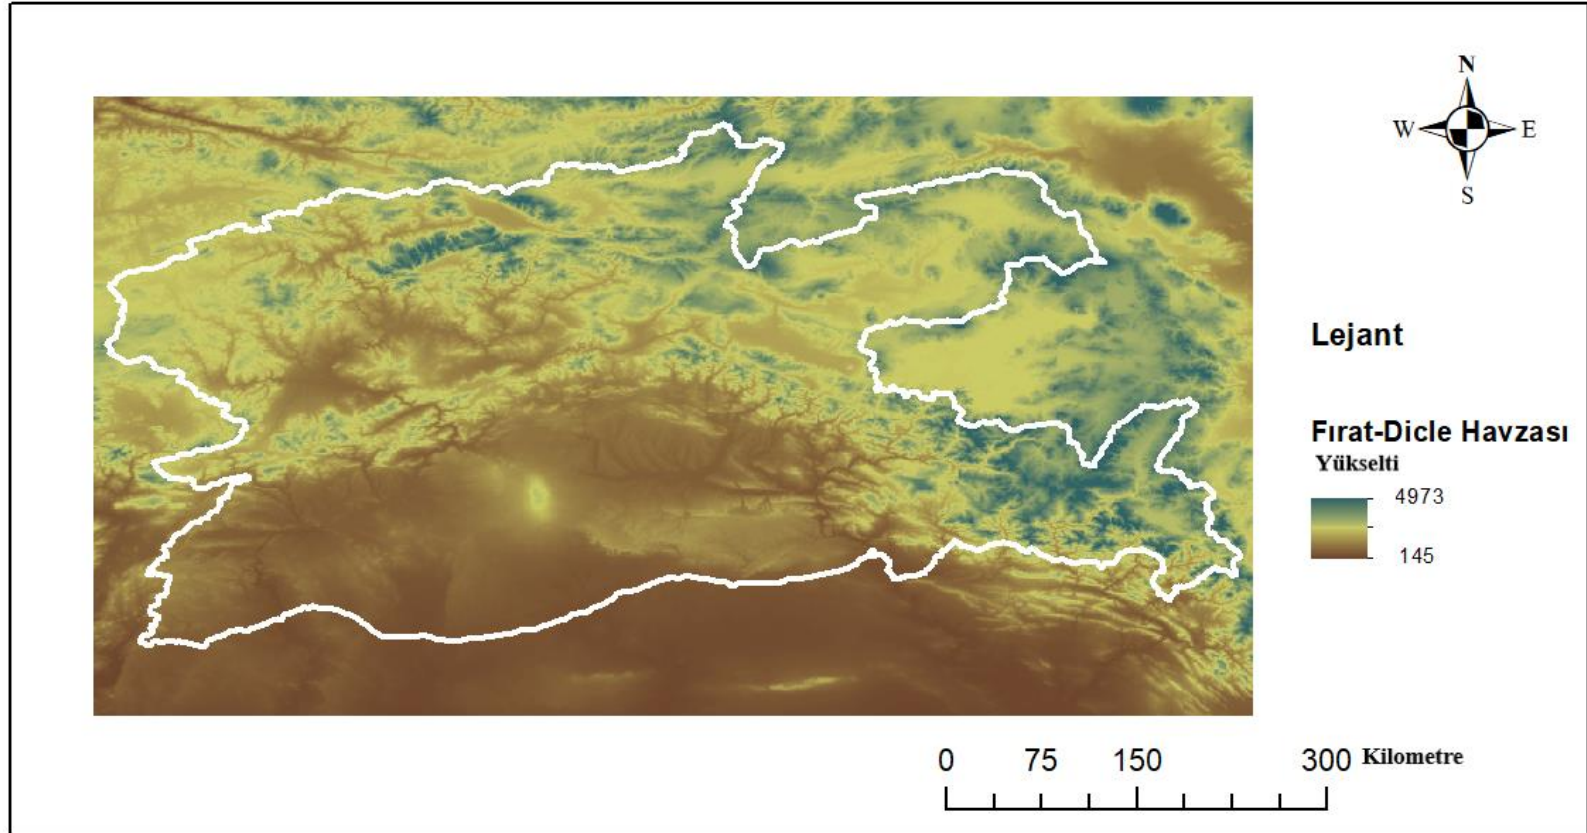
Zhou, Y., Guo, S. and Chang, F.J. (2019) “Explore an evolutionary recurrent ANFIS for modelling multi-step-ahead flood forecasts”, *Journal of hydrology*, 570, 343-355, <https://doi.org/10,1016/j.jhydrol,2018,12,040>



**EKLER**


## EKLER

Ek-1. Fırat- Dicle havzası yükselti haritası




Ek-1.1. Fırat-Dicle havzası yükselti haritası

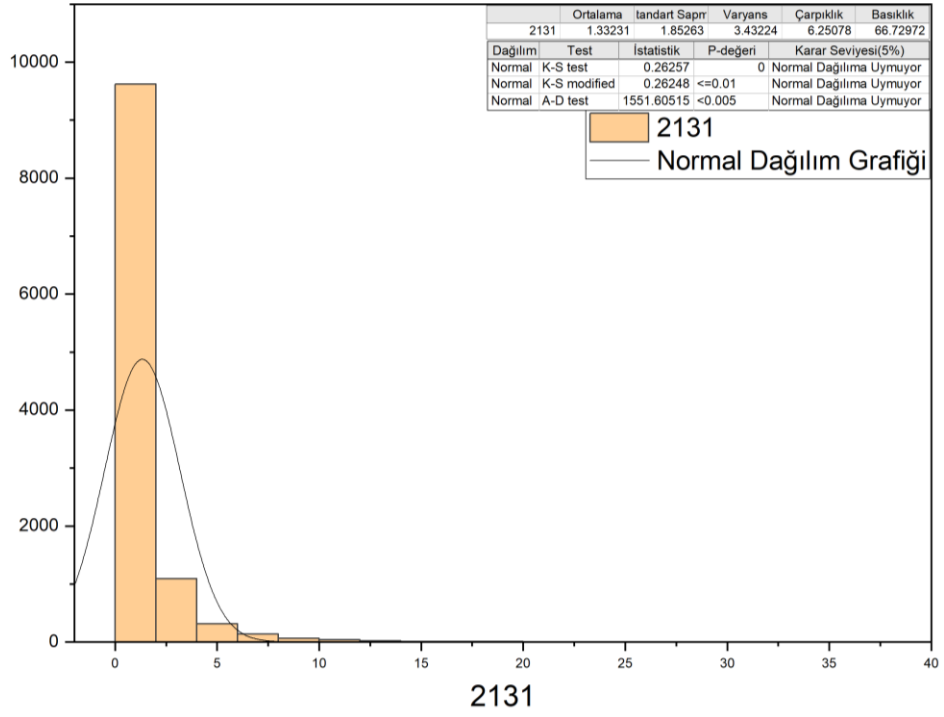
## Ek-2. İstasyonlara ait normal dağılım grafiği




### Ek-2.1. 2122 numaralı istasyona ait dağılım grafiği




### Ek-2.2. 2124 numaralı istasyona ait dağılım grafiği




**Ek-2.3.** 2131 numaralı istasyona ait dağılım grafiği




**Ek-2.4.** 2135 numaralı istasyona ait dağılım grafiği




Ek-2.5. 2145 numaralı istasyona ait dağılım grafiği




Ek-2.6. 2149 numaralı istasyona ait dağılım grafiği




**Ek-2.7.** 2151 numaralı istasyona ait dağılım grafiği




**Ek-2.8.** 2154 numaralı istasyona ait dağılım grafiği



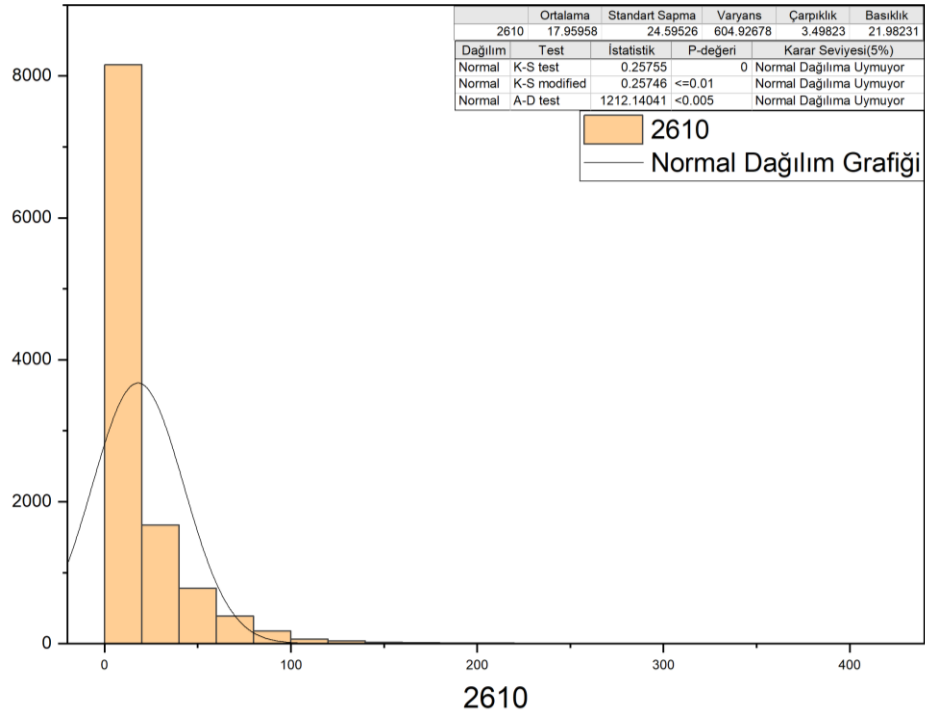
**Ek-2.9.** 2158 numaralı istasyona ait dağılım grafiği



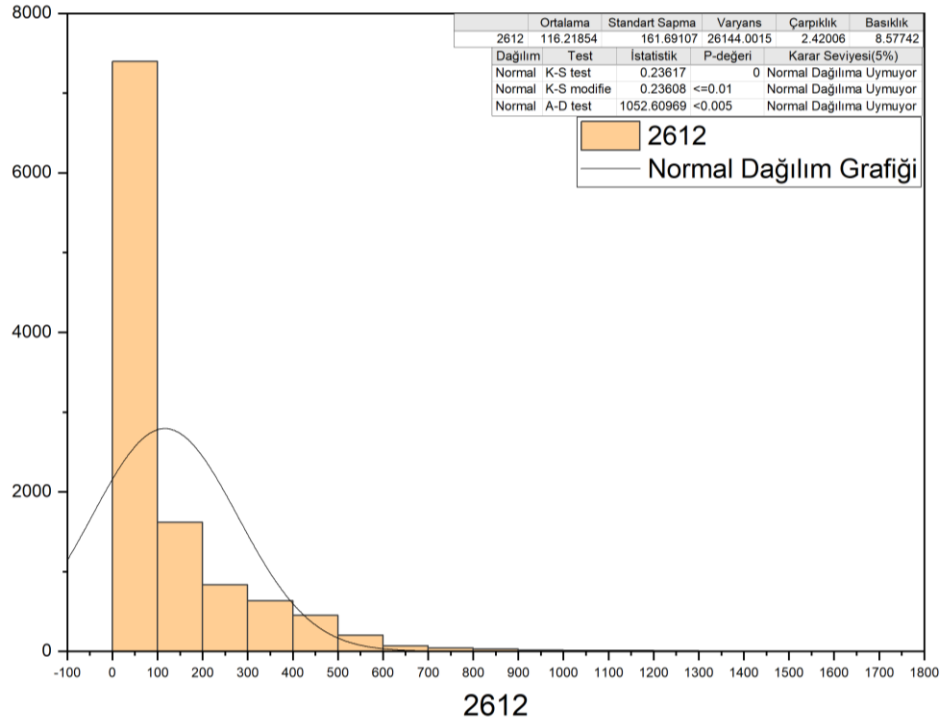
**Ek-2.10.** 2164 numaralı istasyona ait dağılım grafiği



**Ek-2.11.** 2166 numaralı istasyona ait dağılım grafiği




**Ek-2.12.** 2610 numaralı istasyona ait dağılım grafiği

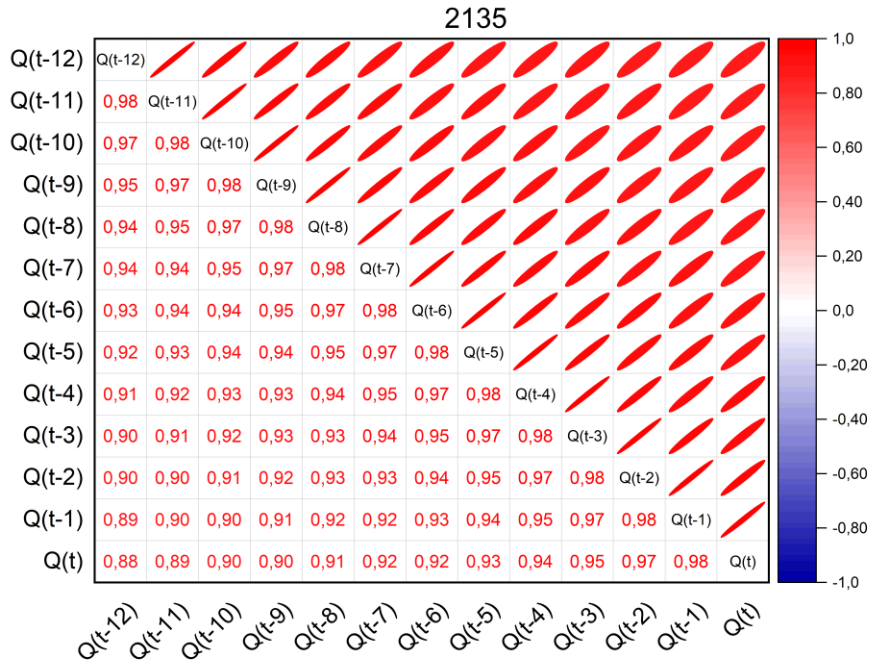


**Ek-2.13.** 2612 numaralı istasyona ait dağılım grafiği

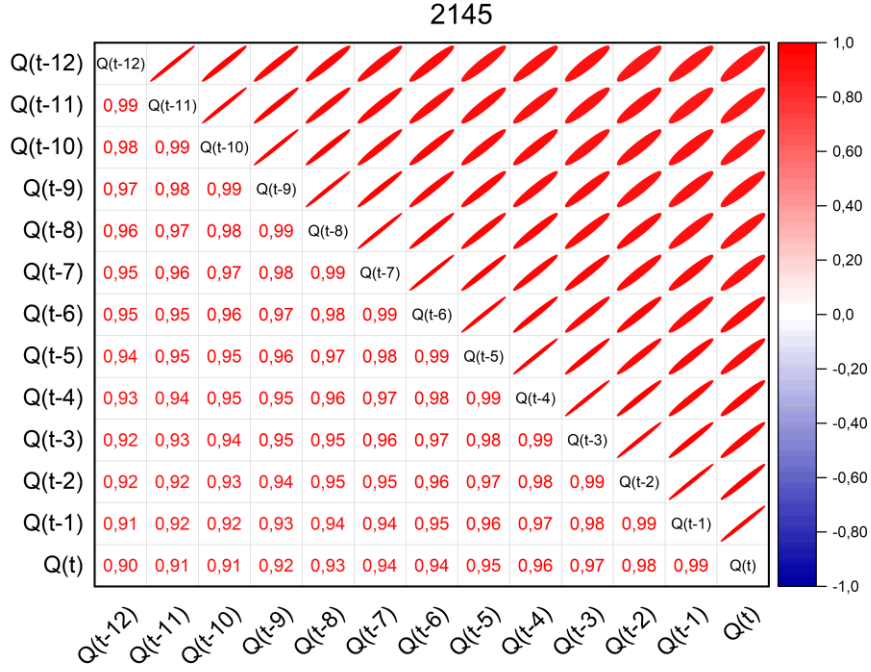





Ek-3.3. 2131 numaralı istasyona ait korelasyon matrisi




Ek-3.4. 2135 numaralı istasyona ait korelasyon matrisi



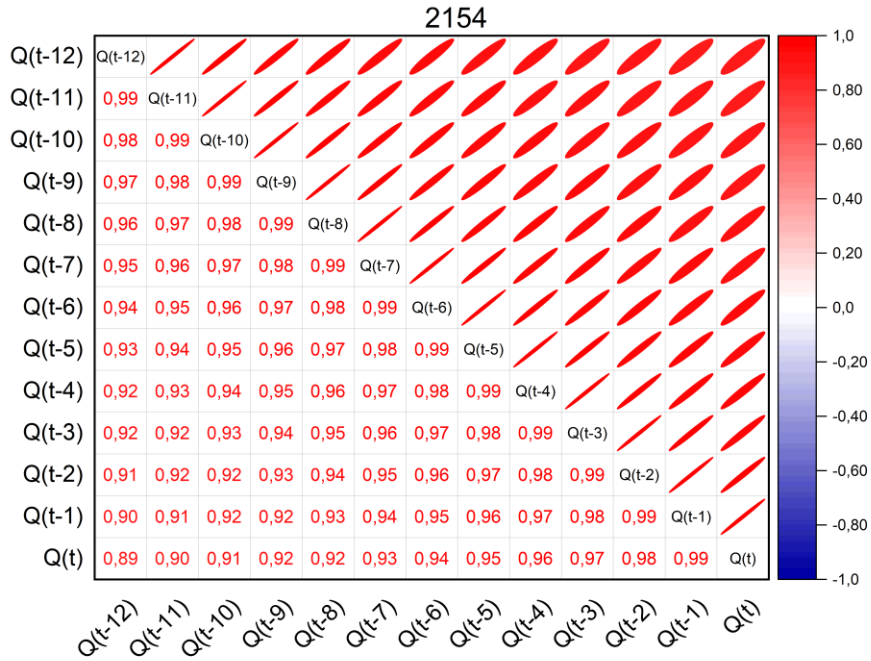
Ek-3.5. 2145 numaralı istasyona ait korelasyon matrisi



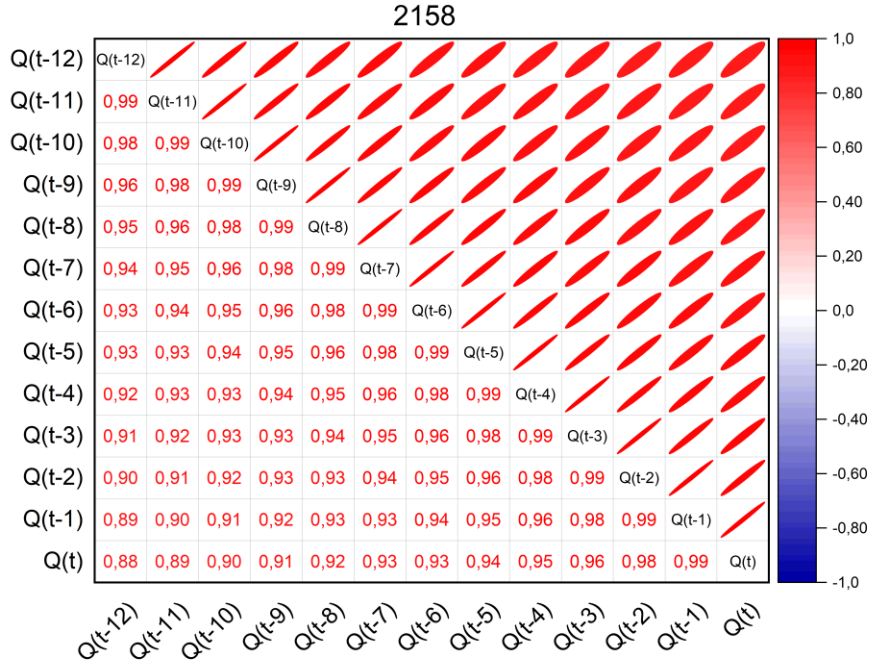
Ek-3.6. 2149 numaralı istasyona ait korelasyon matrisi




**Ek-3.7.** 2151 numaralı istasyona ait korelasyon matrisi




**Ek-3.8.** 2154 numaralı istasyona ait korelasyon matrisi



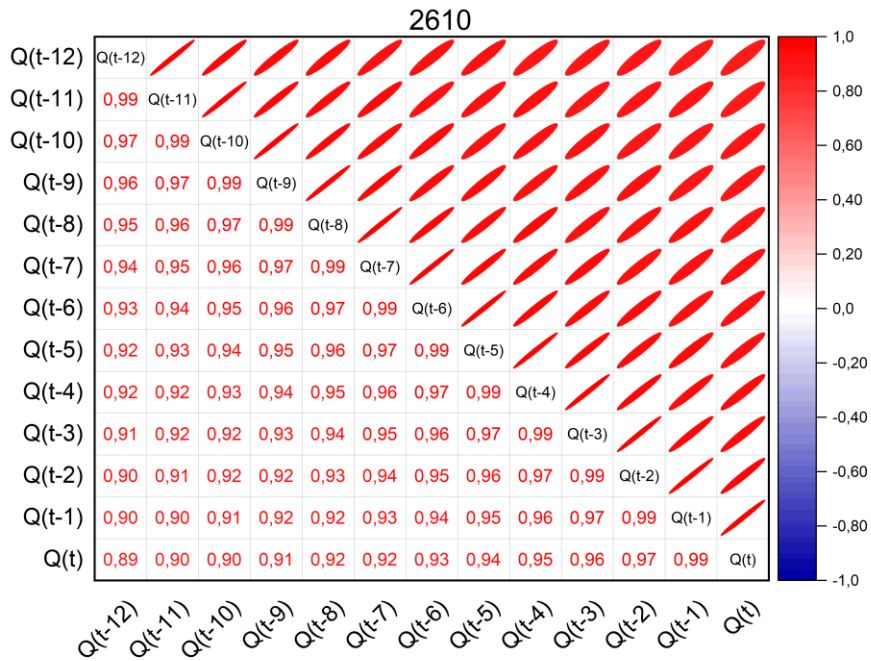
**Ek-3.9.** 2158 numaralı istasyona ait korelasyon matrisi



**Ek-3.10.** 2164 numaralı istasyona ait korelasyon matrisi




**Ek-3.11.** 2166 numaralı istasyona ait korelasyon matrisi




**Ek-3.12.** 2610 numaralı istasyona ait korelasyon matrisi

2612




Ek-3.13. 2612 numaralı istasyona ait korelasyon matris


#### Ek-4. İstasyonlara ait Taylor diyagramları




#### Ek-4.1. 2122 numaralı istasyonun Taylor Diyagramı




#### Ek-4.2. 2124 numaralı istasyonun Taylor Diyagramı




**Ek-4.3.** 2131 numaralı istasyonun Taylor Diyagramı




**Ek-4.4.** 2135 numaralı istasyonun Taylor Diyagramı




**Ek-4.5.** 2145 numaralı istasyonun Taylor Diyagramı




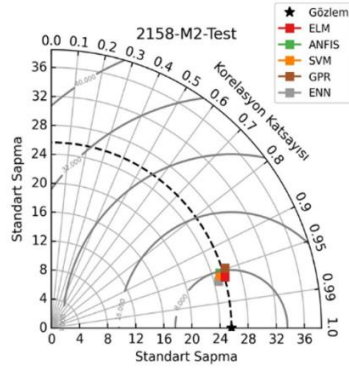

**Ek-4.6.** 2149 numaralı istasyonun Taylor Diyagramı






**Ek-4.7.** 2151 numaralı istasyonun Taylor Diyagramı






**Ek-4.8.** 2156 numaralı istasyonun Taylor Diyagramı




**Ek-4.9.** 2158 numaralı istasyonun Taylor Diyagramı




**Ek-4.10.** 2164 numaralı istasyonun Taylor Diyagramı



**Ek-4.11.** 2166 numaralı istasyonun Taylor Diyagramı

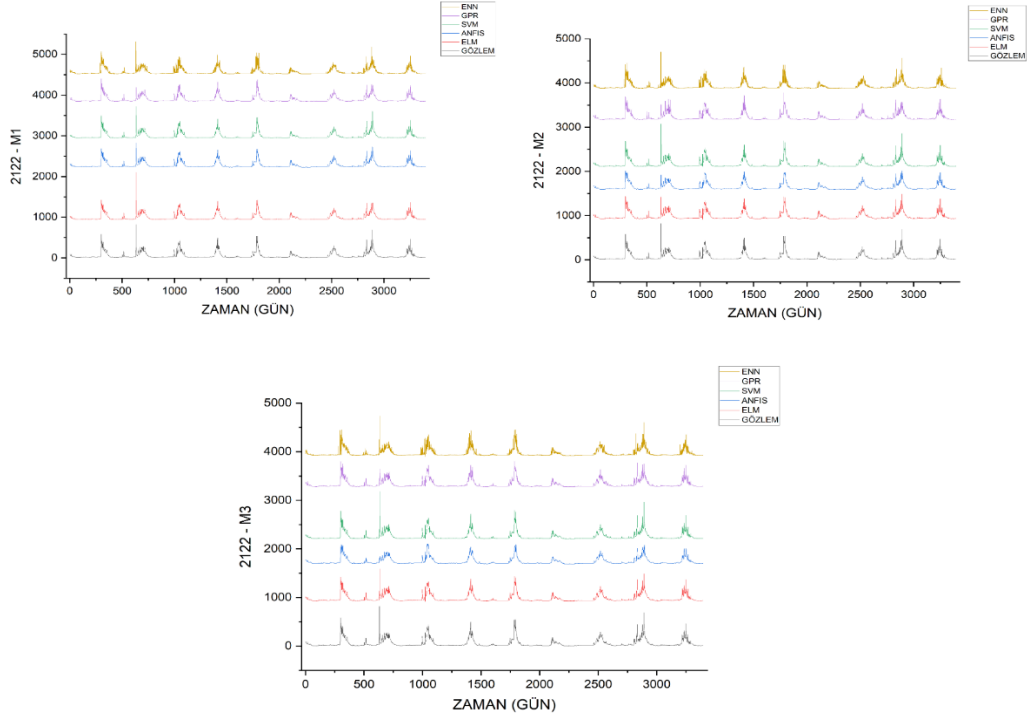


**Ek-4.12.** 2610 numaralı istasyonun Taylor Diyagramı

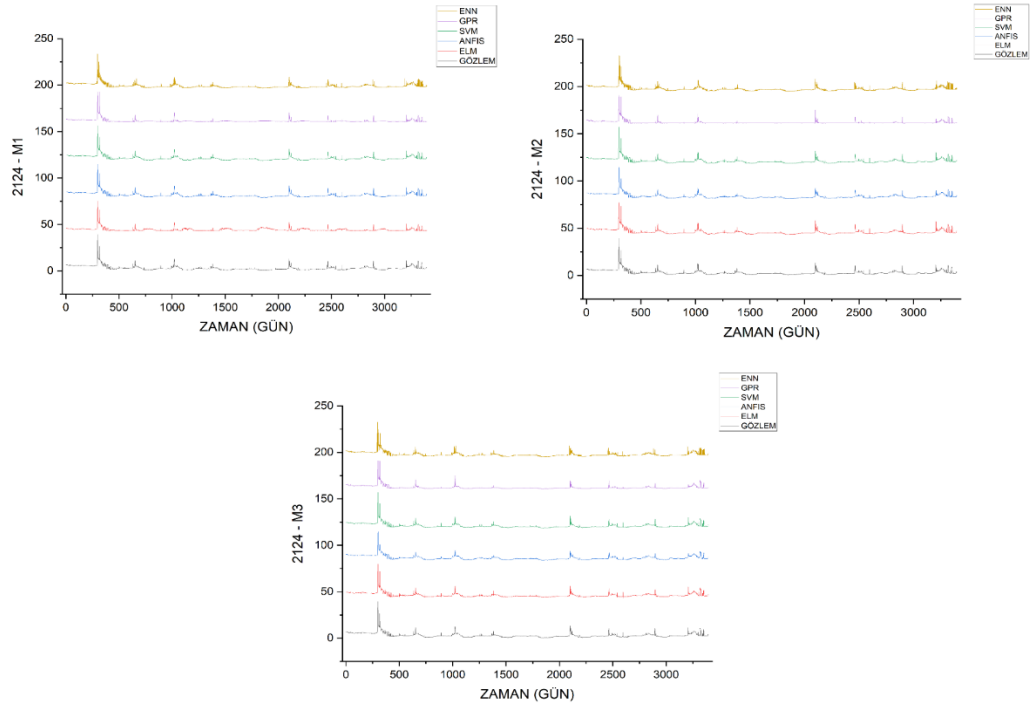


**Ek-4.13.** 2612 numaralı istasyonun Taylor Diyagramı

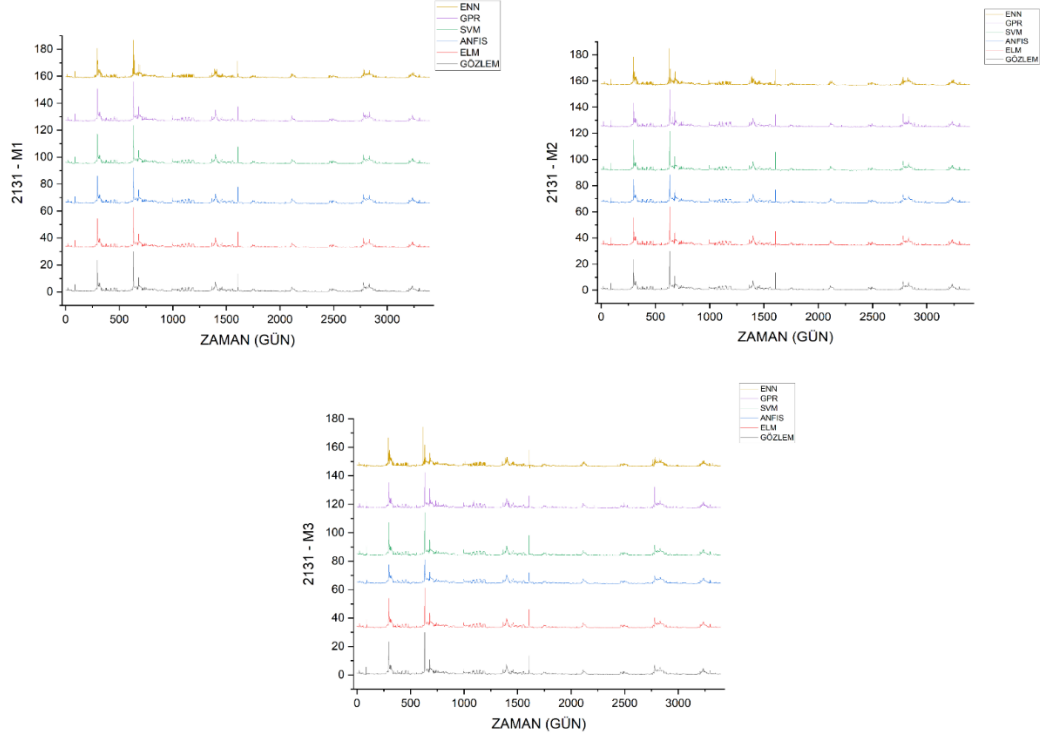
## Ek- 5. İstasyonlara ait zaman serileri



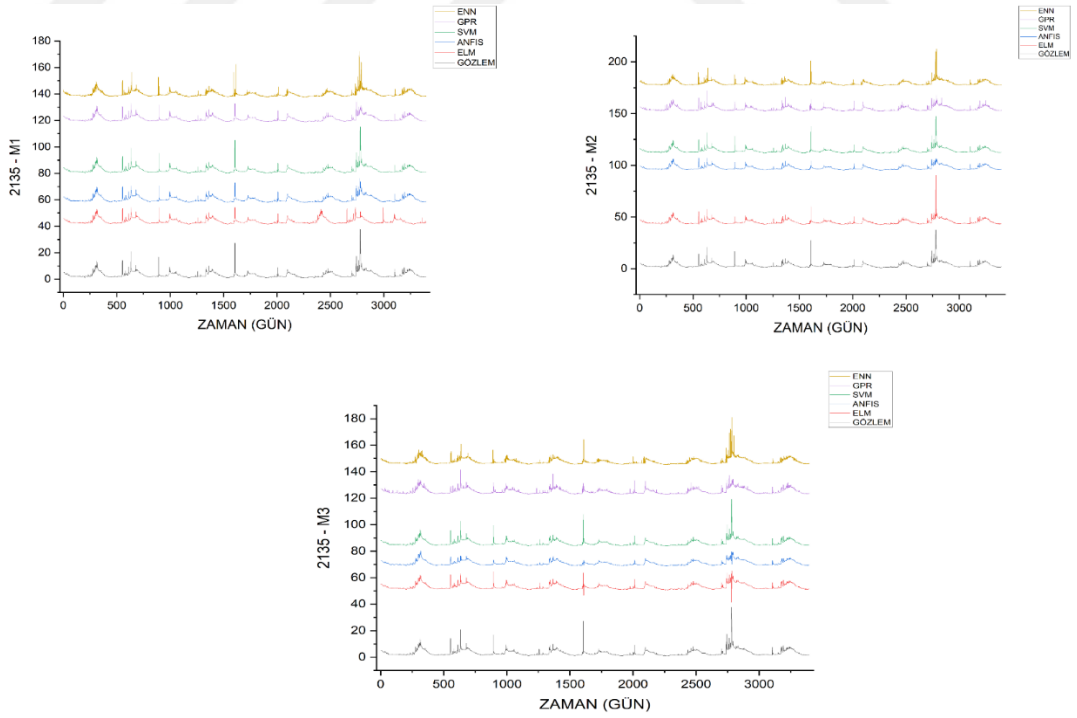
## Ek-5.1. 2122 numaralı istasyonun model çıktılarının zaman serisi



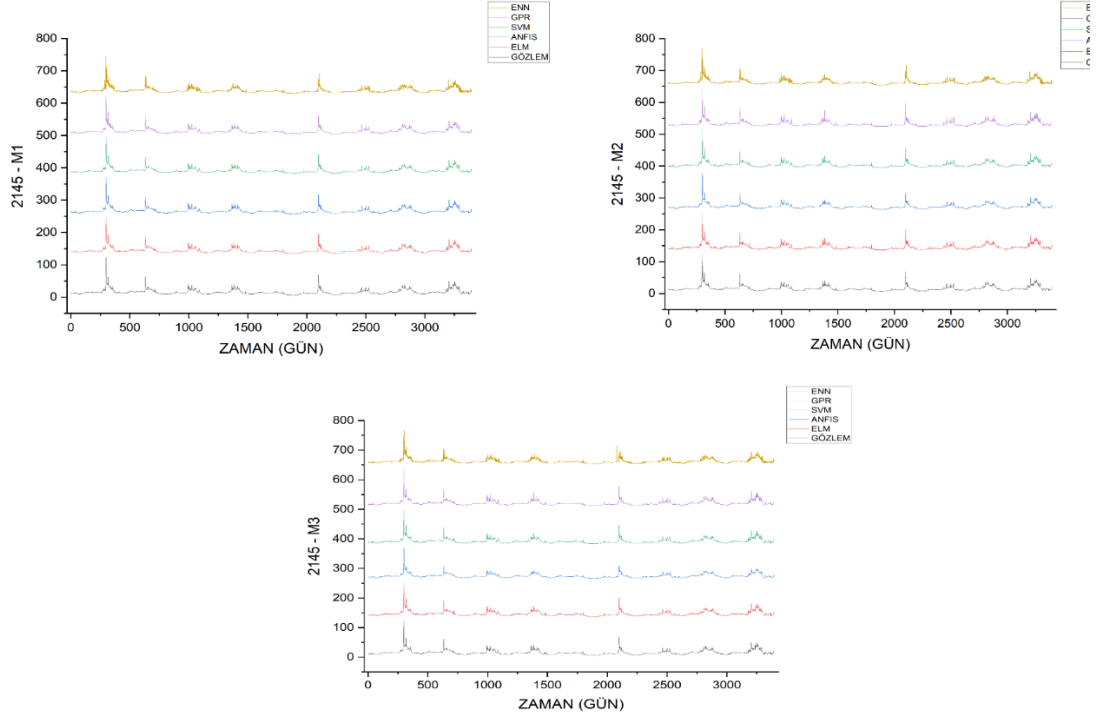
## Ek-5.2. 2124 numaralı istasyonun model çıktılarının zaman serisi



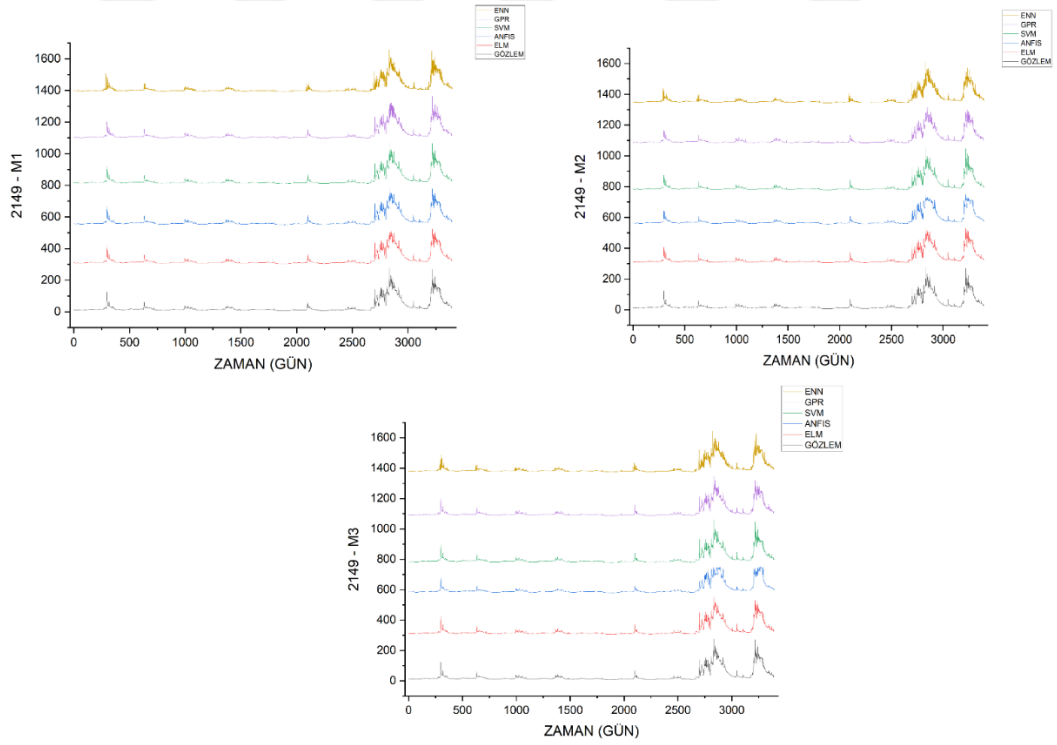
**Ek-5.3.** 2131 numaralı istasyonun model çıktılarının zaman serisi



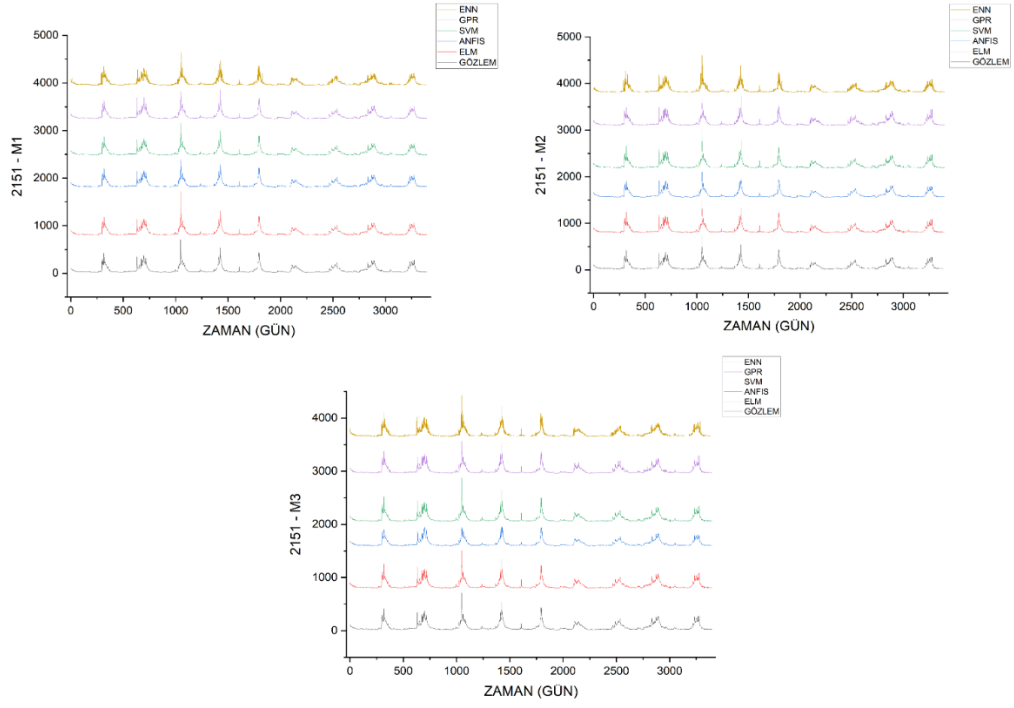
**Ek-5.4.** 2135 numaralı istasyonun model çıktılarının zaman serisi



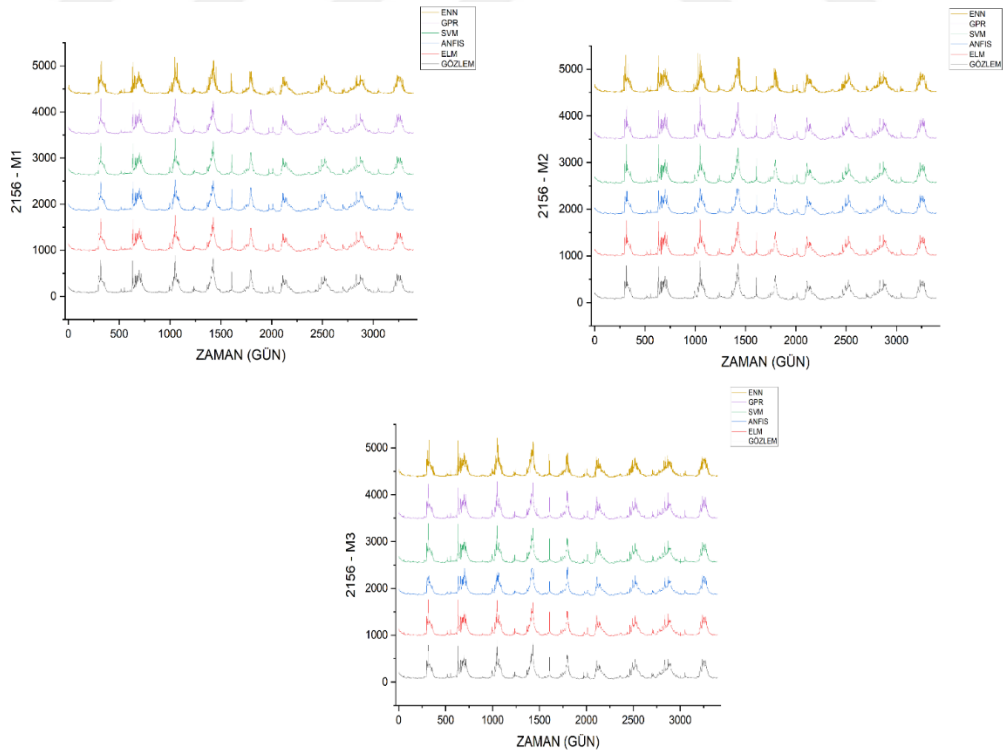
**Ek-5.5.** 2145 numaralı istasyonun model çıktılarının zaman serisi



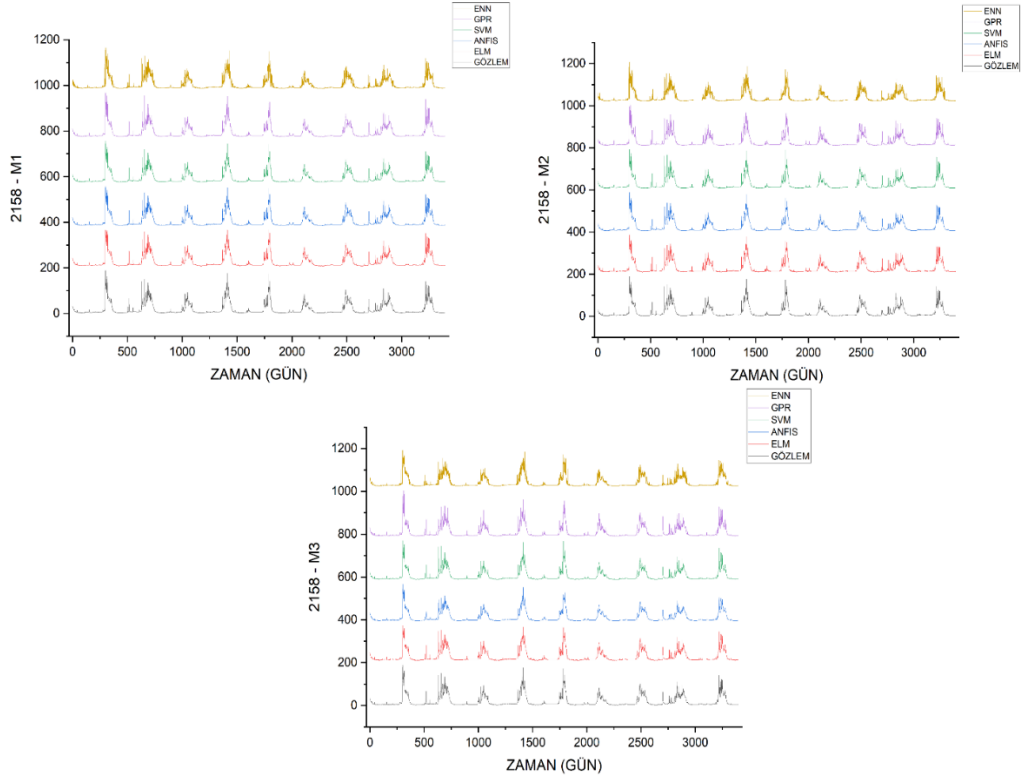
**Ek-5.6.** 2149 numaralı istasyonun model çıktılarının zaman serisi



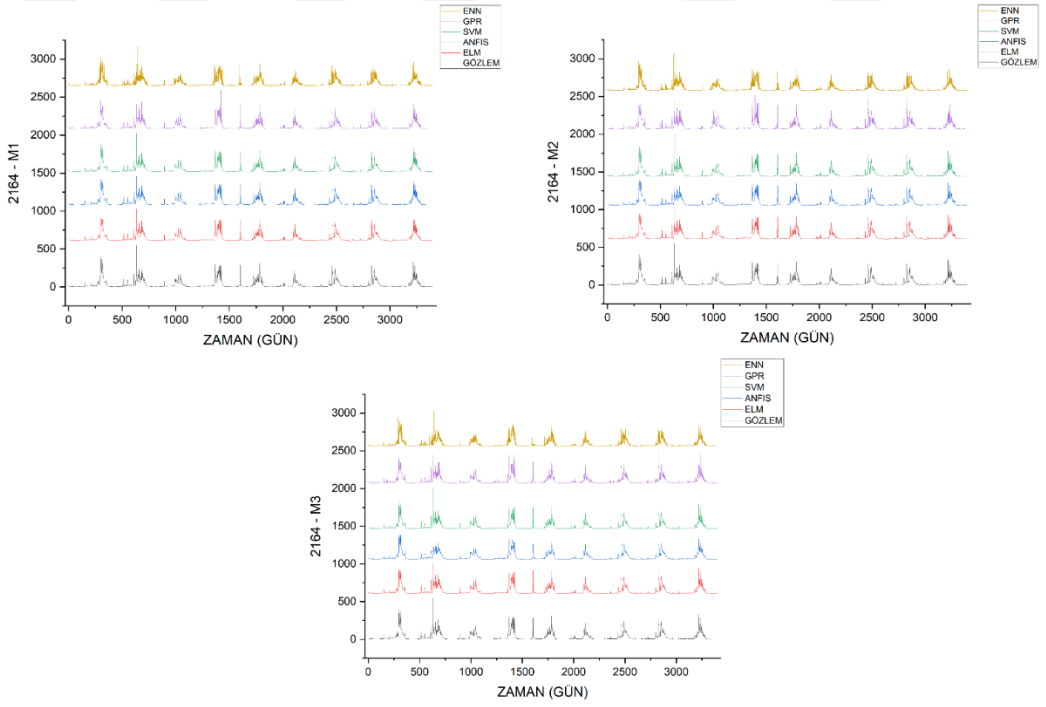
**Ek-5.7.** 2151 numaralı istasyonun model çıktılarının zaman serisi



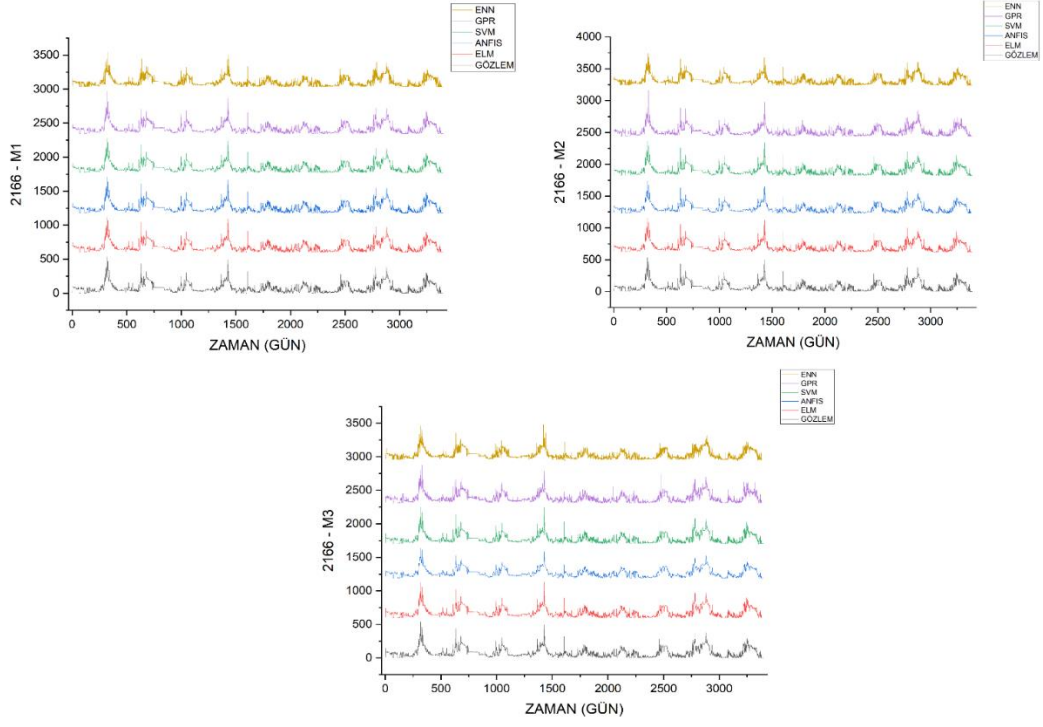
**Ek-5.8.** 2156 numaralı istasyonun model çıktılarının zaman serisi



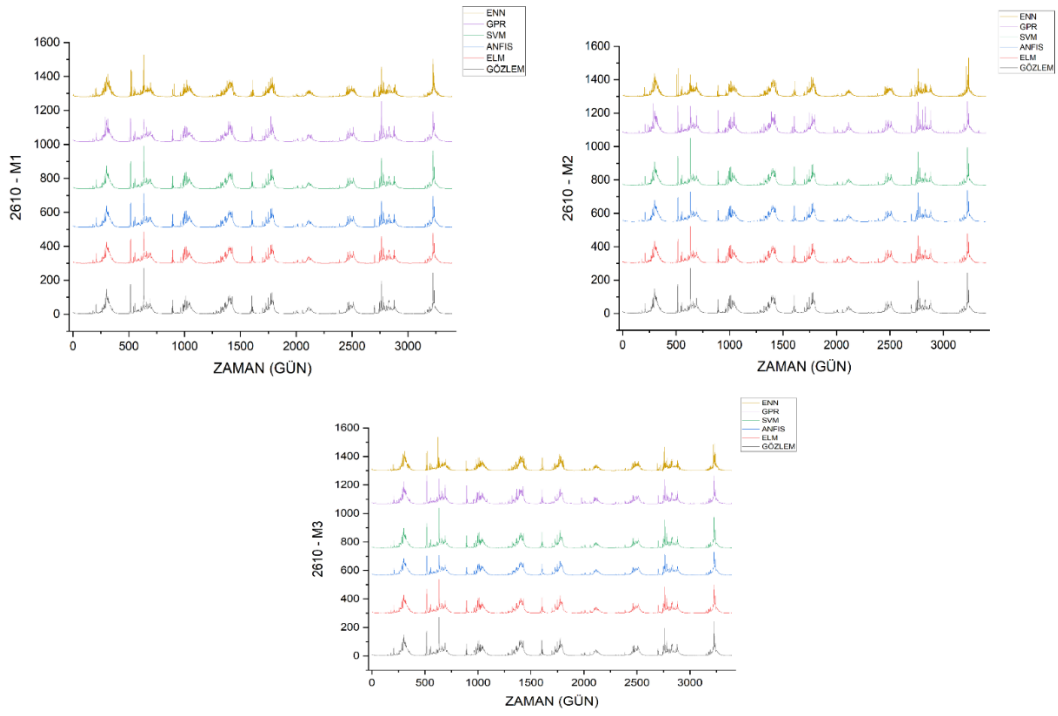
**Ek-5.9.** 2158 numaralı istasyonun model çıktılarının zaman serisi



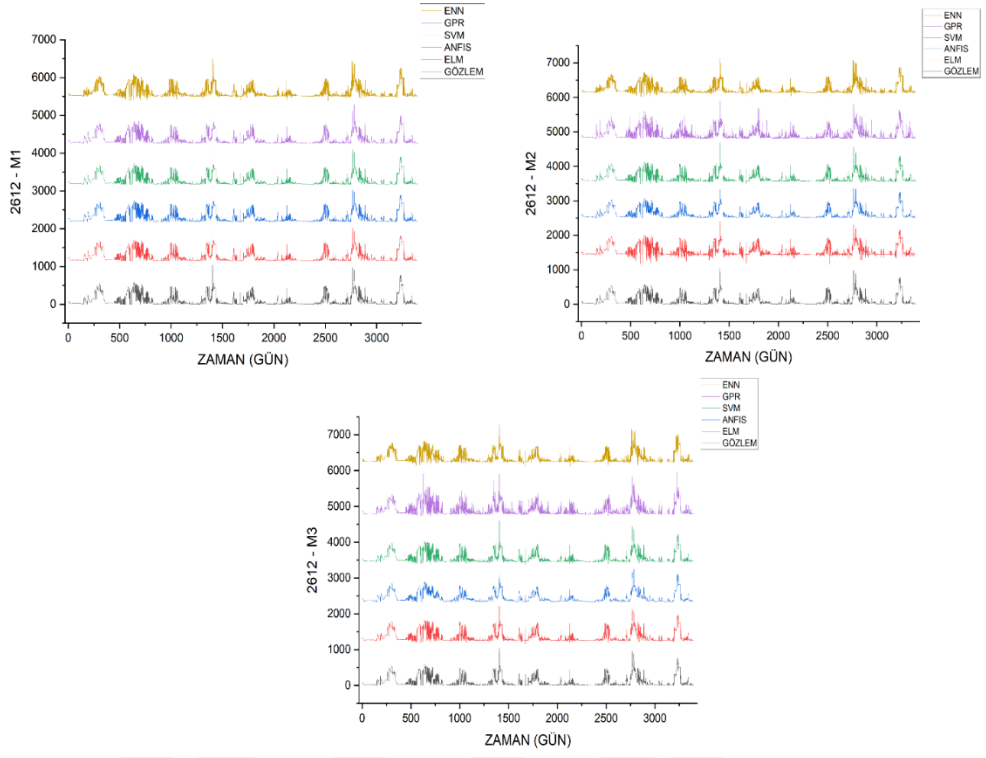
**Ek-5.10.** 2164 numaralı istasyonun model çıktılarının zaman serisi



**Ek-5.11.** 2166 numaralı istasyonun model çıktılarının zaman serisi



**Ek-5.12.** 2610 numaralı istasyonun model çıktılarının zaman serisi



**Ek-5.13.** 2612 numaralı istasyonun model çıktılarının zaman serisi

## **Ek. 6. Tez Çalışması Süresince Yapılan Akademik Çalışmalar**

Hakemli üniversite dergilerinde yayımlanan ulusal makaleler;

Katipoğlu, O.M., Yeşilyurt, S.N., Dalkılıç, H.Y. (2022) “Yeşilirmak Havzasındaki Hidrolojik Kuraklıkların Mann-Kendall Ve Yenilikçi Şen Yöntemi İle Trend Analizi”, *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 12(2),422-442.

Dalkılıç, H.Y., Yeşilyurt, H.Y., Samui, P. (2021) “Random Forest ve K-Nearest Neighbor Yöntemler ile Günlük Akım Modellemesi”, *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14(3), 914-925.

Tanınmış uluslararası yayınevleri tarafından basılmış kitap bölümleri;

Nazimi, N., Ertugay, N. ve Yeşilyurt, S.N. (2022) “Artificial Intelligence Techniques and Application Of Monthly Flow forecast: Fırat River Basin” *International Research in Engineering Sciences*, Eğitim Yayınevi, Konya, 5-26.

Kurt, Z.Ö., Yeşilyurt, S.N, ve Dalkılıç, H.Y, (2022) “Hidrolojik ve Meteorolojik Verilere En Uygun Dağılım Modelinin Belirlenmesi”, *Mühendislik Alanında Uluslararası Çalışmalar IV*, Eğitim Yayınevi, Konya, 81-96.

Katipoğlu, O.M., Yeşilyurt S.N. ve Dalkılıç, H.Y. (2022) “Aylık Maksimum Yağışlara En Uygun Dağılım Modelinin Belirlenmesi”, *Mühendislik Alanında Uluslararası Araştırmalar III*, Eğitim Yayınevi, Konya, 57-74.

Katipoğlu, O.M., Yeşilyurt, S.N. ve Dalkılıç, H.Y. (2021) “Akım Kuraklık İndeksi ve Kesim Seviyesi Metodu İle Yeşilirmak Havzasındaki Hidrolojik Kuraklık Karakteristiklerinin Değerlendirilmesi”, *Mühendislik Alanında Araştırma ve Değerlendirmeler- II*, Gece Kitaplığı, Ankara, 39-62.

Yeşilyurt, H.Y. ve Dalkılıç, H.Y., “İstatistiksel Ölçek İndirgeme Yöntemi Uygulanarak Aylık Toplam Açık Yüzey Buharlaşması Değerlerinin Tahmini: Antalya”, *Mühendislik Alanında Araştırma ve Değerlendirmeler*, Gece Kitaplığı, 195-212.

Dalkılıç, H.Y. ve Yeşilyurt, S.Y. (2021) “Era5 Re-Analiz Verileri İle İstatistiksel Ölçek İndirgeme Yöntemi Uygulanarak Rize İli Aylık Ortalama Sıcaklık Değerlerinin Tahmin Edilmesi”, *Mühendislik ve Mimarlık Bilimleri: Teori, Güncel Araştırmalar ve Yeni Eğilimler/3*, İVPE, Cetinje, 63-78.

Hakemli Kongre / Sempozyum Bildiri Kitaplarında Yer Alan Yayınlar

Yeşilyurt, S.N. ve Dalkılıç, H.Y. (2021) “XgBoost ve Gradient Boost Machine İle Günlük Nehir Akımı Tahmini”, *3 rd International Symposium of Engineering Applications on Civil Engineering and Earth Sciences 2021 (IEACES2021)*, Karabük, 36-45.