



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**GÜNLÜK AKARSU AKIMLARININ FARKLI MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Ulviye ZİYA

DANIŞMAN

Prof. Dr. Mehmet Ali HİNİS

AKSARAY, 2024

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 222303702 numaralı Yüksek Lisans öğrencisi Ulviye ZİYA tarafından hazırlanan “GÜNLÜK AKARSU AKIMLARININ FARKLI MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİNİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Mehmet Ali HINIS

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Dr. Öğr. Üyesi Ömer BİLHAN

Nevşehir Hacı Bektaş Veli Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Dr. Öğr. Üyesi Mustafa Şahin DOĞAN

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Tez Savunma Tarihi: 26/06/2024

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Prof.Dr. Mehmet Ali HINIS
Fen Bilimleri Enstitüsü Müdürü

DOĐRULUK BEYANI

Yüksek lisans tezi olarak sunduĐum bu çalıřmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı düřecek bir yol ve yardıma bařvurmaksızın yazdıĐımı, yararlandıĐım eserlerin kaynakçada gösterilenlerden olduĐunu, çalıřmamda kullandıĐım verilerin orijinalliĐini ve her türlü intihalden uzak olduĐunu beyan ederim.

Enstitü tarafından belli bir zamana baĐlı olmaksızın, tezimle ilgili yaptıĐım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacaĐımı bildiririm.

Ulviye ZİYA

TEŐEKKÜR

Tezimin hazırlanmasında büyük katkıları sunan, çalışmalarımı yönlendiren, bilgi, tecrübe ve zamanını hiçbir zaman esirgemeyen kıymetli hocam ve tez danışmanın Prof. Dr. Mehmet Ali HİNİS hocama sonsuz teşekkürlerimi sunarım.

Eğitimimin her aşamasında maddi manevi desteklerini esirgemeyen babam İlyas KARABAĞ, eşim Hüseyin ZİYA ve oğlum Yekta Yusuf ZİYA sonsuz teşekkürlerimi sunarım.

Ulviye ZİYA

AKSARAY, 2024

İÇİNDEKİLER

| | |
|---|-----|
| TEŞEKKÜR | i |
| İÇİNDEKİLER | ii |
| ÖZET..... | iii |
| ABSTRACT | iv |
| ŞEKİLLER DİZİNİ | v |
| ÇİZELGELER DİZİNİ | vi |
| SİMGELER VE KISALTMALAR | vii |
| 1. GİRİŞ | 1 |
| 1.1. Genel Bilgiler | 1 |
| 1.2. Çalışmanın Amacı ve Kapsamı | 3 |
| 2. LİTERATÜR ÖZETİ | 4 |
| 3. MATERYAL VE YÖNTEMLER..... | 12 |
| 3.1. Çalışma Alanı | 12 |
| 3.2. Yöntemler | 16 |
| 3.2.1. Destek vektörleri makinesi (DVM) | 16 |
| 3.2.2. Gauss süreci regresyon analizi (GPR) | 20 |
| 3.2.3. Karar ağaçları..... | 21 |
| 3.2.4. Rastgele orman (Random forest) yöntemi | 22 |
| 3.2.5. Yapay sinir ağları (YSA/ANN) | 23 |
| 3.2.6. Dalgacık dönüşümü | 25 |
| 3.2.7. Model performans başarı ölçütleri..... | 27 |
| 4. BULGULAR | 29 |
| 5. SONUÇLAR ve ÖNERİLER | 58 |
| KAYNAKLAR | 60 |
| ÖZGEÇMİŞ..... | 65 |

YÜKSEK LİSANS TEZİ

GÜNLÜK AKARSU AKIMLARININ FARKLI MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİNİ

Ulviye ZİYA

Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Mehmet Ali HİNİS

ÖZET

Günlük akarsu akımlarının tahmini su yapılarının işletilmesi, kontrolü ve yönetimi için oldukça önemlidir. Pek çok parametreye bağlı değişkenlik gösteren bir hidrolojik parametre olan akım değerlerinin kısa süreli değerlerinin tahmini zor bir konudur. Günlük, haftalık gibi kısa süreli akış tahminleri, bir havzadaki belirli bir rezervuarın ileriye yönelik akışını tahmin etmek için kullanılır. Bu tahminler, mevcut su kaynaklarının optimum kullanımı için rezervuar depolamasının aktif olarak düzenlenmesini gerektiren hidroelektrik güç planlaması ve taşkın azaltılması gibi durumları planlamak için kullanılır. Bu sebeple akarsu yapılarının yönetiminde gerek rezervuarda ne kadar su biriktirileceği veya bırakılacağı belirlenmesinde gerekse üretilecek enerji miktarının belirlenmesinde kısa süreli akım tahminlerine ihtiyaç duyulmaktadır. Bu sebeple en uygun tahmin yapılabilmesi su yapıları yönetiminde hayati öneme sahiptir. Bu çalışma kapsamında kısa süreli akım tahminlerinde kullanılan pek çok makine öğrenmesi yöntemleri arasından seçilmiş olan Gauss Süreci Regresyon Analizi (GPR), Destek Vektör Makinesi (DVM), Karar Ağaçları (KA), Rastgele Orman (RO) ve Yapay Sinir Ağları (YSA/ANN) yöntemlerinden en uygun olanı araştırılmıştır. Daha sonra bu yöntemlerin sonuçlarının iyileştirilmesi için Dalgacık Dönüşümü metodu kullanılmış ve aynı yöntemlerin Dalgacık Dönüşümünden sonraki modelleri hesaplanmıştır. Dalgacık dönüşümü öncesi ve sonrası oluşturulan yöntem ve modellerin sonuçları çeşitli istatistiksel kriterler ile karşılaştırılmıştır. En iyi model dalgacık dönüşümü sonrası Destek Vektörleri Makinesi yöntemlerinden Lineer fonksiyonu kerneli ile oluşturulan M04 modeli (R:0.998131, NSE:0.99624, KGE:0.99282, PI:0.03940, RMSE:0.30386, MAPE:0.05553) olarak bulunmuştur.

Anahtar Kelimeler : Günlük Akarsu Akımı, Hidrolojik modelleme, Makine Öğrenmesi Yöntemleri, Dalgacık Dönüşümü.

Haziran, 2024; 65 sayfa

M.Sc. THESIS

**FORECASTING OF DAILY STREAM FLOW USING VARIOUS
MACHINE LEARNING METHODS**

Ulviye ZİYA

**Aksaray University
Graduate of Natural and Applied Sciences
Department of Civil Engineering**

Supervisor: Prof. Dr. Mehmet Ali HINIS

ABSTRACT

Estimation of daily stream flows is very important for the operation, control and management of water structures. Predicting short-term values of streamflow, which is a hydrological parameter that varies depending on many parameters, is a difficult issue. Short-term flow forecasts, such as daily, weekly, etc., are used to estimate the forward flow of a particular reservoir in a basin. These forecasts are used to plan situations such as hydroelectric power planning and flood mitigation, which require active regulation of reservoir storage for optimal use of available water resources. For this reason, short-term flow forecasts are needed in the management of river structures, both in determining how much water will be accumulated or left in the reservoir and in determining the amount of energy to be produced. For this purpose, making the most appropriate prediction is of vital importance in the management of water structures. Within the scope of this study, Gaussian Process Regression Analysis (GPR), Support Vector Machine (SVM), Decision Trees (KA), Random Forest (RO) and Artificial Neural Networks (ANN) were chosen among many machine learning methods used in short-term flow forecasts.) the most appropriate method was determined. Later, in order to improve the results of the methods used in the studies, the Wavelet Transform method was used and the models of the same methods after the Wavelet Transform were calculated. The results of the methods and models created before and after the wavelet transformation were compared with various statistical criteria. The best model was found to be the M04 model (R:0.998131, NSE:0.99624, KGE:0.99282, PI:0.03940, RMSE:0.30386, MAPE:0.05553), which was created with the Linear function kernel from the Support Vector Machine methods after the wavelet transform.

Key Words: Daily Stream Flow, Hydrologic modelling, Machine Learning Methods, Wavelet Transform.

June, 2024; 65 pages

ŞEKİLLER DİZİNİ

| | |
|--|----|
| Şekil 3.1. Büyükdere Çayının Coğrafi Konumu..... | 12 |
| Şekil 3.2. Büyükdere Nehri Günlük Akım değerleri | 13 |
| Şekil 3.3. Çalışmada kullanılan günlük akım verilerinin Daubicies 45 (db45) dalgacık dönüşümü ile ayrıştırılmış serileri | 15 |
| Şekil 3.4. (A) İki sınıflı veriyi ayıran bir alt düzlem, (B) en iyi alt düzlem ve sınırları | 18 |
| Şekil 3.5. Veri çakışması olmayan doğrusal olmayan bir DVM (Kecman, 2004) | 19 |
| Şekil 3.6. Doğrusal olarak sınıflandırılmayan durumlarda kernel fonksiyonlarının etkisi (Fletcher, 2009)..... | 19 |
| Şekil 3.7. Model 4'ün yapay sinir ağının mimarisi..... | 24 |
| Şekil 3.8. Model 4'ün saklı katmandaki en uygun Nöron sayısının belirlenmesi | 25 |
| Şekil 4.1. Dalgacık Dönüşümü öncesi test verilerinin çeşitli istatistiksel kriterlere göre performansları | 37 |
| Şekil 4.2. Dalgacık Dönüşümü öncesi eğitim verilerinin çeşitli istatistiksel kriterlere göre performansları | 38 |
| Şekil 4.3. Dalgacık Dönüşümü sonrası test verilerinin çeşitli istatistiksel kriterlere göre performansları | 43 |
| Şekil 4.4. Dalgacık Dönüşümü sonrası eğitim verilerinin çeşitli istatistiksel kriterlere göre performansları | 44 |
| Şekil 4.5. Yapay sinir ağları ANN metoduyla test verilerinin çeşitli istatistiksel kriterlere göre performansları | 45 |
| Şekil 4.6. Yapay sinir ağları ANN metoduyla eğitim verilerinin çeşitli istatistiksel kriterlere göre performansları | 46 |
| Şekil 4.7. Dalgacık dönüşümü öncesi ve dalgacık dönüşümü sonrası test veri seti için en iyi modellerin saçılma grafiklerinin karşılaştırılması. | 47 |
| Şekil 4.8. Dalgacık dönüşümü öncesi ve dalgacık dönüşümü sonrası test veri seti için en iyi modellerin saçılma grafiklerinin karşılaştırılması. | 48 |
| Şekil 4.9. Dalgacık dönüşümü öncesi GA M02 ve RF M02 model karşılaştırılması | 49 |
| Şekil 4.10. GPR metodunda gözlenmiş veri ile dalgacık dönüşümü sonrası WM03 ve WM04 model karşılaştırılması..... | 50 |
| Şekil 4.11. En iyi modellerden olan WDVM_Lineer M04 ve WANN M04 model karşılaştırılması | 51 |
| Şekil 4.12. Modellere ait Violin (Keman) grafikleri..... | 52 |
| Şekil 4.13. Modellere ait Taylor grafiği..... | 53 |

ÇİZELGELER DİZİNİ

| | |
|---|----|
| Çizelge 3.1. Verilen temel istatistik değerleri..... | 13 |
| Çizelge 3.2. Çalışmada kullanılan modeller | 14 |
| Çizelge 3.3. Çalışmada kullanılan saklı katman sayıları | 25 |
| Çizelge 3.4. Nash-Sutcliffe Verimlilik Katsayısı (Nash & Sutcliffe, 1970)..... | 28 |
| Çizelge 4.1. Dalgacık Dönüşümü öncesi Lineer ve Polinom test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri..... | 33 |
| Çizelge 4.2. Dalgacık Dönüşümü öncesi Gauss ve RO'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri..... | 34 |
| Çizelge 4.3. Dalgacık Dönüşümü öncesi GPR ve KA'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri..... | 35 |
| Çizelge 4.4. Dalgacık Dönüşümü öncesi ANN'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri | 36 |
| Çizelge 4.5. Dalgacık Dönüşümü sonrası Lineer ve Polinom ile hesaplanmış test ve eğitim süreçlerinde akım verilerinin tahmin edilen değerleri | 39 |
| Çizelge 4.6. Dalgacık Dönüşümü sonrası Gauss ve RO'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri..... | 40 |
| Çizelge 4.7. Dalgacık Dönüşümü sonrası GPR ve KA'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri..... | 41 |
| Çizelge 4.8. Dalgacık Dönüşümü sonrası ANN'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri | 42 |
| Çizelge 4.9. NSE kriterine göre en iyi modellerin sıralaması..... | 54 |
| Çizelge 4.10. KGE kriterine göre en iyi modellerin sıralaması..... | 55 |
| Çizelge 4.11. En iyi modellerin Dalgacık Dönüşümü sonrasında iyileşme yüzdeleri..... | 57 |

SİMGELER VE KISALTMALAR

| | |
|----------------|---|
| DSİ | Devlet Su İşleri |
| DMİ | Devlet Meteoroloji İşleri |
| GPR | Gauss Süreci Regresyon |
| DVM/SVM | Destek Vektörleri Makinesi |
| KA | Karar Ağaçları |
| RO | Rasgele Orman |
| YSA/ANN | Yapay Sinir Ağları |
| ÇK-YSA | Çok Katmanlı Yapay Sinir Ağları |
| RBFNN | Radyal Tabanlı Yapay Sinir Ağları |
| MLP | Çok Katmanlı Algılayıcı |
| MATLAB | Matris Laboratuvarı |
| AGİ | Akım Gözlem İstasyonu |
| DÖ | Derin Öğrenme |
| SPEI | Yağış Buharlaştırma-Terleme İndeksi |
| ELM | Ekstrem öğrenme makinesi |
| ENN | Elman Sinir Ağı |
| ANFIS | Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi |
| ÇDR | Çoklu Doğrusal Regresyon |
| RMSE | Ortalama Karesel Hatanın Karekökü |
| MAE | Ortalama Mutlak Hata |
| NSE | Nash Sutcliffe Verimlilik Katsayısı |
| KGE | Kling-Gupta Verimlilik Katsayısı |
| PI | Performans İndisi |
| R | Korelasyon Katsayısı |
| WI | Willmatt İndeksi |
| M | Model |
| DB45 | Daubechies 45 |
| DB2 | Daubechies 2 |

1. GİRİŞ

1.1. Genel Bilgiler

Su kaynakları mühendisliği plan ve projelendirme çalışmalarında kullanılan en önemli veriler arasında akarsu akımları, yeraltı su seviyeleri, yağış, akış, sızma ve buharlaşma verileri sayılabilir. Bu verilerin sağlıklı şekilde elde edilmesi, eksik olan verilerin tamamlanması ve geleceğe yönelik tahmin yapılması planlamanın sağlıklı yapılabilmesi için önemli aşamalardır. Taşkın ve kurak zamanlar ve bu zamanlardaki akım tahminleri büyük ve küçük hidrolik yapıların tasarımında ve yönetiminde önemlidir. Uzun ve kısa süreli akımların tahmin edilmesi planlama açısından uzun ve kısa süreli planlamaların kolaylaştırılmasına ve su yapılarının tasarımının daha doğru yapılabilmesine ışık tutacaktır.

Büyük debi, yüksek su seviyesi ve büyük hızlar ile karakterize edilen taşkın değerinin bilinmesi hidrolik yapılar için önemlidir. Aynı zamanda su yapılarının yönetilmesi esnasında gelecekte meydana gelecek olan büyük akım değerlerinin önceden kestirilmesi halinde depolama hacminin önceden tahmin edilip gerekli hazırlıkların yapılması için yeterli zaman kazanmak mümkündür. Özellikle baraj, bağlama ve su kuvveti tesislerinde taşkın debilerinin bilinmesi büyük önem taşır (Erkek ve Ağırlioğlu, 1993). Hidrolik yapıların tasarımında akışların gelecekteki olası değerleri kullanılmaktadır. Rastgele değişken olan yağışlar sonucu oluşan akışların gelecekteki değerlerini önceden tam olarak kestirmek mümkün olamamakla beraber bu değişkenin gelecekteki durumu yapay sinir ağları ve türevleri olan çeşitli makine öğrenmesi yöntemleri ile yaklaşık olarak belirlenebilmektedir. Hidrolik yapıların tasarım ve işletilmesinde, debi tahminlerinde ve havzalarda yerleşke kurmaktan taşkın tahliyesine kadar uzanan ilgi alanlarında tahmin modelleri kullanmak zorunlu hale gelmiştir.

Günlük akarsu akımlarının tahmini su yapılarının işletilmesi, kontrolü ve yönetimi için oldukça önemlidir. Kısa süreli akım değerlerinin tahmini birçok parametreye bağlı olarak ve değişkenlik gösteren zor bir konudur. Akış tahmin modellerinin doğruluğu ve hassasiyeti, su kaynakları yönetimi kararları üzerinde doğrudan etkiye sahiptir. Su kaynakları yöneticilerine ve politika yapıcılara daha iyi ve bilinçli karar vermede yardımcı olmak için çeşitli istatistiksel ve kavramsal akış tahmin modelleri geliştirilmiştir (Beven, 2012).

Regresyona dayalı modeller de dahil olmak üzere istatistiksel teknikler aşırı derecede basittir ve analizden önce değişkenler arasında işlevsel bir biçimle sınırlıdır. Kavramsal hidrolojik modeller, bir havzadaki akarsu akışını daha iyi simüle edebilir çünkü matematiksel formülasyon yoluyla hidrolojik döngünün çeşitli süreçlerini hesaba katarlar. Ancak son yıllarda geliştirilen çeşitli makine öğrenmesi yöntemleri ile daha uygun sonuçlar almak mümkün olmaktadır. Yapay zeka yöntemleri ve makine öğrenmesi yöntemleri; yüksek boyutlu verilerin daha düşük boyutlara indirgenmesi, kümeleme ve sınıflandırma analizleri gibi çok değişkenli veri incelenmesinde kullanılan istatistiksel yöntemlere alternatif olarak son yıllarda tercih edilmektedir (Liu ve Weisberg, 2005). Akım verilerinin tahmin edilmesinde kullanılan yöntemler arasında yapay sinir ağlarına ilave olarak uzman sistemler ve son yıllarda giderek popülerlik kazanan makine öğrenmesi yöntemleri sayılabilir. Uygulama zaman serilerinin tahmininde uzun süreler için (aylık, yıllık) daha iyi netice alınırken aynı başarı kısa süreler için (günlük, saatlik) gösterilememektedir.

Günlük akarsu akımı tahmininde son yıllarda kullanılan baskın yaklaşım, makine öğrenimi ve regresyon algoritmalarının uygulanmasıdır. Doğrusal modellerin (çoğunlukla zaman serisi modelleri) aylık ve yıllık olan daha büyük zaman ölçeklerinde daha rekabetçi olduğu bulunmuştur (Papacharalampous vd, 2018). Regresyon algoritmaları, belirli bir zamandaki bağımlı değişken akışını bir dizi seçilmiş öngörücü değişkenin (örneğin, geçmiş akım değerleri, geçmiş yağış değerleri ve geçmiş sıcaklık değerleri) fonksiyonu olarak modeller; son iki tür bilgi topluca "dışsal tahmin değişkenleri" olarak adlandırılır. Makine öğrenimi durumunda, bu işlev algoritmik bir yaklaşımla doğrudan verilerden öğrenilir. Günlük akım tahminine yönelik mevcut yaklaşımların çoğunlukla tek bir makine öğrenimi algoritmasının uygulanmasına dayanmaktadır.

Mevcut çalışmanın sonuçları, hidrolojik uygulamalarda günlük akım tahmini için kullanılabileceği gibi zaman serisi modellerinin görece performansının anlaşılmasını da geliştirecek sonuçlar içermektedir. Bu çalışmanın sonuçlarının hidrolojik modelleme çalışmalarına, farklı makine öğrenimi yöntemlerinin performanslarının karşılaştırılmasına ve günlük akarsu akım modellemesinin modellenmesinde karar vericilere bir yol gösterici olması amaçlanmıştır.

1.2. Çalışmanın Amacı ve Kapsamı

Bir rezervuar yönetiminin planlanmasında günlük, haftalık gibi kısa süreli akışlar kullanılmakta ve bu akışların hassas bir şekilde tahmin edilmesi önemlidir. Bu tahminler, mevcut su kaynaklarının optimum kullanımı için rezervuar depolamasının aktif olarak düzenlenmesini gerektiren hidroelektrik güç planlaması ve taşkın azaltmayı planlamak için kullanılır. Bu sebeple gerek akarsu yapılarının yönetiminde, rezervuarda ne kadar su biriktirileceği veya bırakılacağı belirlenmesinde gerekse üretilecek enerji miktarının belirlenmesinde kısa süreli akım tahminlerine ihtiyaç duyulmaktadır. Bu sebeple kısa sürede meydana gelebilecek olan akım değerinin bilinmesi elzemdir ve bunun için en uygun akım değerinin tahmini su yapılarının yönetiminde hayati öneme sahiptir. Bu tez çalışmasında kısa süreli akım tahminlerinde son yıllarda geliştirilmiş olan makine öğrenmesi yöntemleri arasında literatürde kullanımları en çok tercih edilenler arasında bulunan beş (5) adet yöntem seçilmiş ve akım tahminlerinde olan performansları incelenmiştir.

Gauss Süreci Regresyon Analizi (GPR), Destek Vektör Makinesi (DVM), Karar Ağaçları (KA), Rastgele Orman (RO) ve Yapay Sinir Ağları (YSA/ANN) yöntemleri kullanılarak bunlar arasında en uygun tahmin veren yöntem belirlenmiştir. En uygun yöntemin sonuçlarının iyileştirilmesi için daha sonra Dalgacık Dönüşümü metodu kullanılmıştır. Dalgacık dönüşümü ile veriler çoklu çözünürlüklü analizden geçirilerek seçilmiş yöntemlerin Dalgacık Dönüşümünden sonraki tahmin değerleri de karşılaştırılmıştır. Böylece kısa süreli akım tahminlerinde literatürde sıklıkla kullanılan seçilmiş yöntemlerin sonuçlarının iyileştirilmesi hedeflenmiştir.

Bu çalışmada akarsu akımlarının kısa süreli gerçek zamanlı tahminlerinin seçilmiş bazı makine öğrenmesi yöntemleri ile kullanılabilirliği araştırılmış ve tahmin sonuçlarının iyileştirilmesi için dalgacık dönüşümü kullanılmıştır. Günlük akarsu verilerinin kısa süreli tahminleri için seçilmiş yöntemlerle modeller geliştirilmiş; baraj, bağlama gibi su yapılarının yönetilmesinde yardımcı olmak amacıyla en uygun tahmin yöntemi ve modeli tespit edilerek sunulmuştur.

2. LİTERATÜR ÖZETİ

Günlük akarsu akım verileri tahmini konusunda daha önce yapılmış olan çalışmalar irdelenmiş ve bazı çalışmalar özet halinde aşağıda sunulmuştur.

Son yıllarda çeşitli yapay zeka tekniklerinin kuraklık tahminlerindeki kullanımına değinen Mokhtarzad vd. (2017), ANN, ANFIS ve DVM yöntemleri ile Bojnourd bölgesinde bir çalışma yapmışlardır. Bu çalışmada 1984 – 2012 yılları arasında yağış verisini kullanarak Normalleştirilmiş Yağış İndisi (SPI) ile kuraklık analizi yapmış ve SPI'ı 3 aylık zaman periyodunda modellemiştir. Mohamadi, vd. (2020) ANFIS, MLP, Radyal Tabanlı Yapay Sinir Ağları (RBFNN) ve DVM algoritmalarından yararlanarak kuraklık modellemesi yapmış ve su kaynaklarının etkili yönetilmesinde son derece önemli olduğunu göstermiştir.

Choubin vd. (2016) aylık ortalama yağış verisini kullanarak Kuraklık analizi yapmış ve analiz için veri madenciliğinde yer alan Çok Katmanlı Algılayıcı (MLP), ANFIS ve Karar Ağaçları (KA) yöntemlerinden yararlanarak MLP ile yapılan analizlerin diğerlerinden daha iyi olduğu sonucuna ulaşmıştır. Ghorbani vd. (2019) akarsu akımı tahmininde çeşitli yöntemleri karşılaştırdığı çalışmasında MLP'nin diğer modellere göre daha iyi tahmin ettiğini bulmuştur.

Deo vd. (2017) üç farklı algoritmayla Çoklu Uyarlanabilir Regresyon Eğriler (MARS), En küçük kareler Destek Vektör Makineleri (LSSVM) ve M5 Karar ağaçlarını çalışarak kuraklık analizleri yapmışlardır. Faizollahzadeh ardabili vd. (2019) Rastgele Orman yönteminin hidrolojik modellemede etkin bir biçimde kullanılabileceğini göstermişlerdir.

Citakoglu ve Coşkun (2022) 1960-2020 yıllar arası yağış verileri ile DWT, EMD ve VMD ön işleme tekniklerinin beş farklı makine öğrenimi yöntemine (ANFIS, ANN, SVMR, KNN, GPR) dahil edilmesiyle on beş hibrit model oluşturmuşlardır. Ayrıca ön işleme gerek kalmadan beş adet bağımsız model oluşturmuşlardır. Performans kriterlerine göre VMD ön işleme tekniği, DWT ve EMD ön işleme tekniklerinden daha iyi sonuç verdiğini bulmuşlardır.

Çubukçu vd. (2022) Mersin Lamas Nehri aylık ortalama akım verileri kullanılarak Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM) ve Derin Öğrenme (DÖ)

yöntemleri kullanılarak akım modellemesi yapmışlar ve sonuçları karşılaştırmışlardır. KOKH, OMH, NSE, OMBH ve R^2 kriterlerine göre sonuçları değerlendirdiğinde, Derin Öğrenme metodu ile oluşturulan modellerin sonuçlarının birbirine yakın ve en iyi sonuçları verdiğini görmüştür.

Soh. vd. (2018) Malezya'nın Langat nehir havzasında standartlaştırılmış yağış buharlaşma-terleme indeksinin (SPEI) tahmini için yapay zeka modellerini uygulamışlardır. SPEI'yi tahmin edebilmek için WAANN ve WANFIS olarak iki ayrı model oluşturularak dalgacık dönüşümü kullanılmıştır. WAANN modelinin WANFIS modelinden daha iyi sonuç verdiği gözlemlenmiştir. WANFIS modelinde WAANN modeline göre girdi verilerinin eğitim girdi aralığının dışında olduğu durumlarda tahmin doğruluğunun azaldığı saptanmıştır.

Yesilyurt vd. (2023) Fırat Dicle havzasındaki akım verilerinden yararlanarak beş farklı yöntem kullanarak tahminde bulunmuşlardır. Bu yöntemlerden (ANFIS, ELM, ENN, SVM, GPR) en yüksek tahmin sonucunu veren ELM yöntemi çıkmıştır. Performans sıralamasının ise sırasıyla ELM, GPR, ENN, SVM ve ANFIS olduğu görülmüştür. Bu sonuçlar ELM, GPR ve ENN'nin ANFIS ve SVM gibi geleneksel yapay zeka teknikleriyle karşılaştırıldığında çok daha iyi sonuçlar verdiğini bulmuştur.

Yürük vd. (2019), BİST'te işlem gören imalat sanayi sektöründeki 140 işletmenin 2008-2016 yılları arasındaki verilerini örnek olarak kullanarak firma başarısızlığını tahmin etmeyi amaçlamış ve bunu için Yapay Sinir Ağları, Destek Vektör Makineleri ve Ensemble Öğrenme Modelleri yöntemlerini kullanmıştır. Ensemble Öğrenme Modeli en iyi sonucu verirken Yapay Sinir Ağları ise Destek Vektörleri Makinesine göre daha iyi sonuç vermiştir.

Pham vd. (2020) Vietnam'ın Hoa Binh eyaletindeki günlük yağış verilerini kullanarak yapmış oldukları çalışmada çeşitli yapay zeka yöntemleri kullanarak modelleri geliştirmeyi ve karşılaştırmayı hedeflemişlerdir. Çalışmalarında maksimum sıcaklık, minimum sıcaklık, rüzgar hızı, bağıl nem ve güneş ışınımı gibi meteorolojik değişken parametreleri toplamış ve modellerde girdi parametresi olarak, günlük yağış miktarı ise çıktı parametresi olarak kullanmışlardır. Yapay Sinir Ağları (ANN) ve Destek Vektör Makineleri (DVM) ile çalışılan modellerden DVM'nin daha iyi sonuç verdiğini görülmüştür.

Golob vd. (1998), Yapay Sinir Ağları metodu kullanarak akım tahmini yapmışlardır. Bunun için Soca Nehri'ne (Slovenya) ait akım ve yağış verileri ile modeller oluşturulmuş ve kurulan modellerin iyi sonuçlar verdiğini göstermişlerdir.

Turhan (2012), MATLAB programı kullanarak Seyhan Havzasında Yağış-Akış modellemesi yapmıştır. İleri Beslemeli Geriye Yayılmalı Yapay Sinir Ağı (İBGYSA) ve Çoklu Doğrusal Regresyon (ÇDR) yöntemleri birbirleriyle karşılaştırılmış ve performanslara bakıldığında İBGYSA yönteminin ÇDR yöntemine göre daha iyi sonuçlar verdiğini bulmuştur.

Achite vd. (2022) çalışmalarında Kuzey Cezayir'deki Wadi Ouahrane havzasının ortalama aylık yağış verileri kullanılarak ANN, ANFIS, DVM ve DT yöntemleri ile en iyi modeli oluşturup kuraklık tahmininde bulunmuşlardır. Oluşturulan modellerinin performansı, RMSE, MAE, NSE ve Korelasyon dahil olmak üzere çeşitli değerlendirme kriterleri kullanılmış ve DVM yönteminin diğer yöntemlere göre daha iyi sonuç verdiğini göstermişlerdir.

Ahmadi vd. (2021) İran'da bulunan Tahran ve Dezful adlı iki hava durumu istasyonunda üç farklı zaman ölçeği seçerek modeller oluşturmuştur. Hibrit modellerin geliştirilmesinde altı ana dalgacık fonksiyonu (yani Haar, Daubechies (db2, db4), Coifflet, Symlet ve Fejer-Korovkin) kullanılmıştır. Modellerin performansı, ortalama karesel hataların karekökü (RMSE), ortalama mutlak hata (MAE), Willmott indeksi (WI) ve Nash Sutcliffe verimliliği (NSE) aracılığıyla değerlendirilmiş ve Coifflet ana dalgacığının en iyi performans gösteren dalgacık olduğu tespit edilmiştir.

Albostan vd. (2015), Günlük Akarsu Akımlarının Kaotik Analizinde Dalgacık Yaklaşımının Uygulaması çalışmasında Devlet Su İşleri Genel Müdürlüğü'ne ait Çoruh Havzası 2304 numaralı istasyona ait 33 yıllık günlük akım verileri üzerinde kaotik analiz yapılmış ve dalgacık analizi yapılarak ayrılan bilgi içermeyen gürültü parçasının faz uzayı oluşumunda ve öngörülebilirlikte etkisini araştırmışlardır. Çalışmalarında elde edilen sonuçların, su kaynaklarının öngörülmesi konusunda literatüre katkı sağlayacağı ve bilimsel anlamda da doğal seriler üzerinde kaotik analiz konusunda örnek teşkil edeceğini göstermişlerdir.

Yabar vd. (2020), Dalgacık Dönüşümlü Yapay Sinir Ağlarıyla Günlük Akım Serilerinin Tahmini çalışmasında, Bitlis deresine ait 2008-2011 yıllarındaki günlük akım verilerini kullanmışlardır. Çalışmada Yapay Sinir Ağı metodunu kullanarak model oluşturmuş sonra Dalgacık Dönüşümü ile ayırtmışlardır. Sonucunda hesaplanan tahmin modellerini gerçek veriler ile kıyaslamışlardır. Modellerde hem YSA hem de dalgacık dönüşümlü YSA (WYSA) iyi sonuçlar vermiş ancak Dalgacık Dönüşümünden sonraki Yapay Sinir Ağı Metodunun daha iyi sonuç verdiğini ortaya koymuşlardır. Hidrolojik süreçlerin tahmininde dalgacık dönüşümlü YSA modellerin oldukça başarılı sonuçlar verdiğini ileriye dönük tahmin modellerinde sıklıkla kullanabileceğini belirtmişlerdir.

Demir vd. (2023) Kızılırmak Akım Gözlem İstasyonlarından alınan iki farklı AGİ için günlük ortalama debi ve günlük toplam yağış değerleri kullanarak ANFIS Yöntemi debi tahmininde bulunmuşlardır. ANFIS modelinin akarsulardaki günlük ortalama debi tahminini yapmak için kullanılabilecek bir yöntem olduğunu ve başarılı sonuçlar elde edilebileceğini öne sürmüşlerdir.

Küçük ve Ağralıoğlu (2006), yaptıkları çalışmada dalgacık dönüşüm tekniği kullanılarak hidrolojik akım serilerinin modellenmişlerdir. Tekniğin analiz gücü ve çok çözünürlüklü analiz yardımıyla serinin değişik periyottaki bileşenlerinin elde edilmesi, modellemede yüksek bir başarı elde edilebilmesini sağladığını ortaya koymuşlardır. Birbirine yakın akım ölçüm istasyonları arasında oluşturulacak bir modelde sözü edilen periyodik bileşenlerden önemli olanları, diğer tüm istasyonlar içinde önemli olacaktır. Dolayısıyla bölgenin iklimsel davranışını en iyi temsil eden bileşen veya bileşenler arasında oluşturulan modeller, bir istasyon ölçümleri kullanılarak diğer istasyondaki veriyi tahmin etmek için kullanılmış ve başarılı sonuçlar elde edilmiştir. Su kaynakları alanında, dalgacık dönüşümü tekniği kullanımının çok daha yararlı olabileceği yapılan çalışma ile ortaya konulmuştur.

Türkben vd. (2019) DSİ tarafından işletilen D21A001 numaralı Karasu Karagöze akım gözlem istasyonuna ait günlük akım verileri kullanılarak ileri beslemeli geri yayımlı yapay sinir ağı modeli (İBGYYSA) geliştirilip Karasu' daki akımların tahmininin yapılması amaçlamışlardır. YSA modelinin eğitimi için Levenberg-Marquardt ve Bayesian Regularization algoritmaları kullanılmış ve YSA ile gerçekleştirilen senaryoların başarılı olduğu gözlenmiştir. Ayrıca 1 Ekim 1999 – 30

Eylül 2015 tarihleri arasındaki Levenberg-Marquardt algoritması ve Bayesian Regularization algoritması ile uygulanan YSA modelinin tahmin ettiği akım değerleri ve ölçülmüş akım verilerinin oldukça uyumlu olduğunu göstermişlerdir. Sonuç olarak, üretilen senaryolar ve kullanılan eğitim algoritmaları çerçevesinde ileri beslemeli geri yayımlı YSA modeli akarsudaki akımın tahmininde kullanılabileceği bulunmuştur.

Dursun vd. (2009) Fırat Havzasında bulunan Göynük Çayı üzerindeki Akım gözlem istasyonlarında 2178 nolu Akım gözlem istasyonunun eksik akım verilerini tamamlanması amacıyla korelasyon analizi ve YSA metodu kullanılarak modeller oluşturulmuştur. YSA metoduyla yapılan çalışma gerçeğe daha yakın sonuçlar verdiğini ortaya koymuşlardır.

Okkan ve Mollamahmutoğlu (2010) Gediz havzasında yer alan Yiğitler Çayına ait günlük akımların modellenmesi için kullanılabilecek bir yapay sinir ağı modeli (YSA) hazırlamışlardır. Hazırlanan YSA modeli çoklu doğrusal regresyon modeli ile karşılaştırılmış, model performansları, Yiğitler Çayına ait ölçülmüş günlük akım değerleri ile sınıanmıştır. Analiz sonucu, yapay sinir ağı algoritması performansı regresyon modeline göre daha başarılı bulunmuştur. Sonuç olarak yapay sinir ağları ile hazırlanan akım modellerinin akarsu havzalarının doğrusal olmayan yağış akış ilişkilerini başarıyla modelleyebildiği, kavramsal ve fiziksel tabanlı modellere kıyasla yoğun verilere ve kalibrasyon işlemlerine gerek kalmaksızın hızlı bir modelleme imkanı tanıdığı görülmektedir.

Terzi vd. (2012) Göksu Nehri'nde bulunan Karahacılı (1714), Kırkkavak (1719) ve Hamam (1720) akım gözlem istasyonlarından alınan 1990–2010 yılları arasında bulunan günlük akım değerleri kullanarak YSA modelleri geliştirmişlerdir. Geliştirilen modellerin performansları değerlendirilirken, belirleme katsayısı ve ortalama mutlak hata değerlerini kullanmışlar ve YSA yönteminin akım tahmininde kullanılabilir olduğunu ortaya koymuşlardır.

Ak (2021) yılındaki çalışmasında ABD Worcester şehrindeki Stilwater nehrinin verilerini kullanarak akım tahmini yapmıştır. Çalışmasında Destek Vektörleri Makinesi (DVM), Bulanık Mantık (Sugeno ve Mamdani) ve Çoklu Lineer Regresyon (ÇLR) yöntemlerini kullanmıştır. Oluşturulan modellerde günlük 1095 yağış, akış ve sıcaklık verileri girdi olarak kullanılmış ve DVM'nin diğerlerine göre daha iyi sonuç

verdiği gözlemlenmiştir. Korelasyon katsayısı, ortalama mutlak hata, kareler hataların ortalamasının karekökü kriterlerinin sonuçları değerlendirilmiştir.

Karaeminoğulları (2020) Nebraska eyaleti Omaha istasyonundan ölçülen nehir debisi, hava sıcaklığı, yağış gibi hidrometeorolojik parametreler kullanılarak katı madde miktarını çeşitli metotlar kullanarak tahmin etmiştir. Katı madde anahtar eğrisi (KMAE), Destek Vektörleri Makinesi ve genelleştirilmiş regresyon yapay sinir ağı (GRYSA) metotlarını kullanmıştır. Kullandığı metotlar arasında DVM'nin diğer metotlara göre daha iyi sonuç verdiği görülmüştür.

Zhoua vd. (2016), Destek Vektörleri Makinesi yöntemini kullanarak Çin'deki Three Gorges Rezervuarında Bazimen toprak kaymasını öngörmek için modeller oluşturmuşlardır. Yağış değerlerini, rezervuarın değişme aralığını ve önceki dönem toprak kaymalarını kullanarak, yöntemle ölçülen değerleri kıyaslamışlar ve Destek Vektörleri Makinesi yönteminin gerçeğe yakın sonuçlar verdiğini belirtmişlerdir.

Allawi vd. (2019) çalışmalarında, üç zaman artış serisini (günlük, haftalık ve aylık) dikkate alarak buharlaşma oranını tahmin etmişlerdir. Çalışmalarında Malezya, Johor Nehri'ndeki Layang Rezervuarı'ndaki tropikal bir alan için buharlaşma oranını tahmin etmede radyal taban fonksiyonlu yapay sinir ağı (YSA-RTF) ve destek vektör makinesi (DVM) yöntemlerini kullanmışlardır. Çalışmanın sonucunda DVM modelinin YSA modelinden daha iyi sonuç verdiğini ortaya koymuşlardır.

Aldori (2018) çalışmasında günlük akım verileri kullanarak çeşitli hibrit modeller oluşturmuştur. Oluşturulan hibrit modeller de Yapay Sinir Ağları (ANN), Destek Vektörleri Makinesi (DVM) ve uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) yöntemleri kullanılmıştır. Modellerin performansını artırmak için ön işlem olarak Dalgacık Dönüşümü kullanılmıştır. Çalışmasında Seyhan havzasındaki 17 istasyondan 1987-1994 yılları arasında alınan veriler kullanılmıştır. Sonucunda ise ANN'nin ANFIS ve DVM'ye göre daha iyi performansa sahip olduğu gösterilmiştir.

Elbeltagi vd. (2023) çalışmalarında Hindistan'ın Rajasthan eyaletindeki farklı kuraklık endekslerini değerlendirmek için Standart Yağış Endeksi (SPI) kullanmışlardır. Bölgedeki 2 farklı meteoroloji istasyonundan elde ettikleri 2000-2019 yılları arasındaki aylık toplam yağış verisiyle kuraklık indislerini hesaplamışlardır. Rasgele

Orman (RO), Rastgele Ağaç (RA) ve Gaus Süreci Regresyon (GPR) yöntemlerini kullanmışlardır. MAE, RMSE, RAE, RRSE ve Korelasyon kriterlerini esas alarak Rasgele Orman metodunun daha iyi sonuç verdiğini belirtmişlerdir.

Salim vd. (2023) yaptıkları çalışmada Cezayir havzasındaki kuraklık tahmini için 1936-2008 yılları arasında Algerois havasının aylık yağış verisini kullanmışlardır. SYİ hesapladıktan sonra YSA yöntemiyle kuraklık modelleri oluşturmuşlardır. Sonra verilere dalgacık dönüşümünde kullanılan Haar, Daubechies, Symlets, Coiflets ve Meyer fonksiyonlar uygulanmış ve dönüştürülmüş verilerle oluşturulan modeller test edilmiştir. Elde ettikleri sonucu NSE ve RMSE'den kriterleri sonucuna göre değerlendirerek Meyer fonksiyonunun diğer dalgacık fonksiyonlarına göre daha iyi sonuç verdiğini belirtmişlerdir. Ayrıca dalgacık dönüşümü sonuçlarının modelleri iyileştirdiğini ifade etmişlerdir.

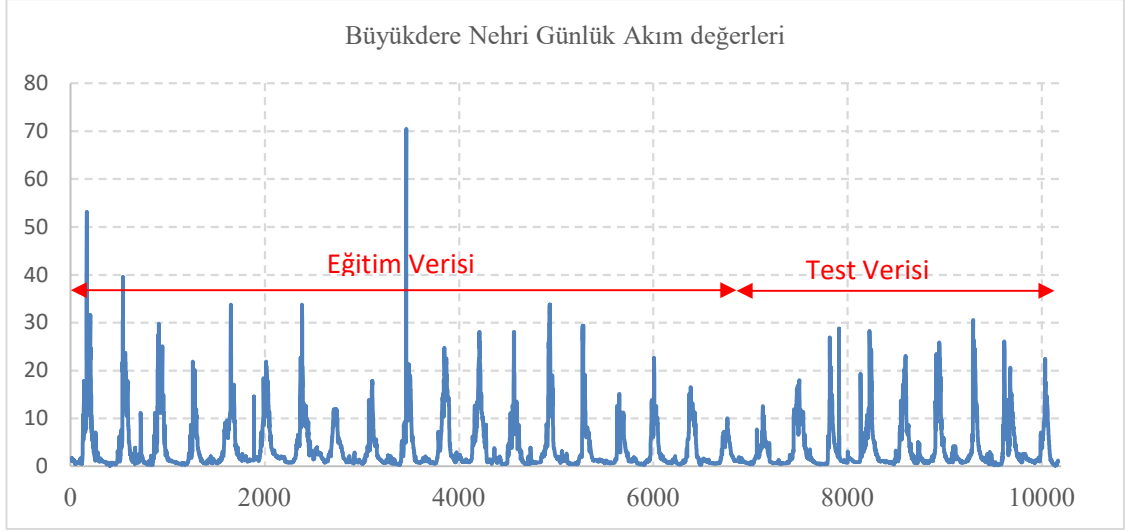
Hinge vd. (2022) Dalgacık Dönüşümü metodunu kullanarak MLR ve YSA yöntemleriyle kuraklık tahmini yapmışlardır. Rajasthan isyasyonlarından 1901 ve 2015 yılları arasındaki aylık yağış verisini kullanmışlardır. Dalgacık Dönüşümünün modelleri iyileştirdiğini öne süren Hinge vd. (2022), MLR'nin daha iyi sonuç verdiğini ortaya koymuşlardır.

Sharma vd. (2023), çalışmalarında makine öğrenmesi yöntemlerinden Destek Vektör Makineleri (SVM), Rastgele Orman (RF), Uzun Kısa Süreli Bellek (LSTM) ve Çok Değişkenli Uyarlamalı Regresyon Eğrileri (MARS) kullanarak modelleri test etmişlerdir. 1951-2018 yılları arasında Suvarna, Aghanashini ve Kunderu nehirlerindeki akış, yağış ve sıcaklık verilerini kullanmışlardır. Çalışmanın sonucunda RO günlük akım için daha iyi performans gösterirken, MARS Suvarna nehri aylık akım değerlerinde daha iyi sonuç verdiğini NSE gibi kriterlerle ortaya koymuşlardır.

Difi vd. (2022) Cezayir Cheliff havzasında bulunan üç hidrometrik istasyondan alınan 1983-1995 yılları arası aylık yağış verilerini çalışmalarında kullanmışlardır. Yöntem olarak MLP, aşırı öğrenme makinesi (ELM) ve metasezgisel yarasa algoritması (Bat-ELM), destek vektör regresyonu (DVR), Gauss süreci regresyonu (GPR), çok katmanlı algılayıcı sinir ağı (MLPNN) ve genelleştirilmiş regresyon sinir ağı (GRNN) gibi metotlar kullanılarak en uygun model araştırılmıştır. Korelasyon ve NSE kriterlere göre Bat-ELM algoritmasının diğer bütün modellere göre daha iyi sonuçlar verdiğini tespit etmişlerdir.

Zhang vd. (2022) Kadın ve erkek öğrenciler için ayrı ayrı paylaşımli duş odaları sağlayan Capital Normal Üniversitesi'nde (Pekin, Çin) yürütölen bir çalışmayı sunmuşlardır. Çalışmalarında duş binalarındaki kısa vadeli banyo suyu tüketimini tahmin etmek için banyo suyu tüketim verileri, duş musluğu kontrol cihazları aracılığıyla gerçek zamanlı olarak kullanmışlardır. Otoresif entegre hareketli ortalama (ARIMA), rastgele orman (RO), uzun kısa vadeli bellek (LSTM) ve sinirsel temel genişleme analizi zaman serisi tahmin modellerini kullanarak günlük ve saatlik banyo suyu talebini tahmin edip karşılaştırmışlardır. Oluşturulan modellerin performansını ortalama mutlak hata, ortalama mutlak yüzde hata, ortalama karesel hataların karekökü ve belirleme katsayısı kriterlerini kullanarak değerlendirmişler ve Makine öğrenmesi yöntemlerinin istatistiksel yöntemlerden daha iyi performans gösterdiğini ortaya koymuşlardır.





Şekil 3.2. Büyükdere Nehri Günlük Akım değerleri.

Çizelge 3.1. Verilen temel istatistik değerleri.

| | Tüm Veri | Eğitim Verisi | Test Verisi |
|-----------|----------|---------------|-------------|
| Ortalama | 3.851 | 3.848 | 3.860 |
| St.Sapma | 5.144 | 5.222 | 4.957 |
| CV | 1.336 | 1.357 | 1.284 |
| Çarpıklık | 2.577 | 2.735 | 2.138 |
| Maks | 70.476 | 70.476 | 30.610 |
| Min | 0.118 | 0.118 | 0.183 |

Çalışmada kullanılan veriler Denklem (3.1)'e göre normalleştirme işlemine tabii tutulmuştur.


$$Z_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (3.1)$$

Bu çalışmada oluşturulan modeller Çizelge 3.2.'de verilmiştir. Çizelgede verilen; t gözlenen t zamanındaki akımı; t-1: 1 günlük gecikmeyi, t-2; 2 günlük gecikmeyi, t-i; i günlük gecikmeyi ve modeldeki giriş sıralamasını temsil etmektedir.

Çizelge 3.2. Çalışmada kullanılan modeller.

| Modeller | Girdi | Çıktı | Dalgacık Fonksiyonu |
|----------|-------------------------------|-------|---------------------|
| M01 | Q_{t-1} | Q_t | db45 |
| M02 | Q_{t-1}, Q_{t-2} | Q_t | db45 |
| M03 | $Q_{t-1}, Q_{t-2}, Q_{t-3}$ | Q_t | db45 |
| M04 | $Q_{t-1}, Q_{t-2}, Q_{t-5}$ | Q_t | db45 |
| M05 | $Q_{t-1}, Q_{t-2}, Q_{t-6}$ | Q_t | db45 |
| M06 | $Q_{t-1}, Q_{t-2}, Q_{t-11}$ | Q_t | db45 |
| M07 | $Q_{t-1}, Q_{t-2}, Q_{t-30}$ | Q_t | db45 |
| M08 | $Q_{t-1}, Q_{t-2}, Q_{t-60}$ | Q_t | db45 |
| M09 | $Q_{t-1}, Q_{t-2}, Q_{t-365}$ | Q_t | db45 |
| M10 | Q_{t-1}, Q_{t-2} | Q_t | haar |
| M11 | Q_{t-1}, Q_{t-2} | Q_t | db4 |

Dalgacık dönüşümünde Daubechies dalgacık fonksiyonu kullanılmıştır. Daubechies dalgacık fonksiyonunun yüksek salımlı doğası, gözlem verisindeki sinyal bileşenlerinin hassas şekilde yakalamasını mümkün kılabilen ve bu sebeple Daubechies dalgacık ailesi (db) literatürde kullanılmakta ve tavsiye edilmektedir (Zajam vd., 2019; Çatar, 2021). Bu çalışmada Daubechies 45 (db45) dalgacık fonksiyonu ile 5 seviye dalgacık dönüşümü kullanılmıştır. Ayrıca Model 10 haar dalgacık fonksiyonu Model 11 de ise 'db4' dalgacık fonksiyonu kullanılarak Model 02 ile karşılaştırılmıştır. Çalışmada kullanılan günlük akım verileri ve 5 seviyede db45 dalgacık dönüşümü sonucu elde edilen yaklaşık ve detaylı serileri Şekil 3.3'de verilmiştir. Şekil 3.3'te A: Yaklaşık sinyal ve D: Detay sinyallerini temsil eden veriler olup, 5.ci seviyede sinyal ayrıştırması ile orijinal sinyal (S) $S=D5+A5+A4+A3+A2+A1$ şeklinde sinyallere ayrılmaktadır



Şekil 3.3. Çalışmada kullanılan günlük akım verilerinin Daubechies 45 (db45) dalgacık dönüşümü ile ayrıştırılmış serileri.

3.2. Yöntemler

3.2.1. Destek vektörleri makinesi (DVM)

DVM modelleri başlangıçta doğrusal olarak ayrılabilir nesne sınıflarının sınıflandırılması için geliştirilmiştir. DVM'nin çalışma prensibi iki sınıfı birbirinden ayırabilen en uygun karar fonksiyonun tahmin edilmesidir. İki ayrı sınıftan doğrusal olarak ayrılabilen nesnelere oluşan iki boyutlu bir düzlemde bunları mükemmel şekilde ayıran bir sınıflandırıcı bulmak amaçlanmıştır. Bu nesnelere sınıflandırmak için DVM, maksimum marj üreten bir hiperdüzlem bulmaya çalışır (Vapnik, 1995). Bu hiperdüzlem ile DVM, her sınıfın en yakın veri noktası arasındaki mesafeyi maksimuma çıkarır. Her iki sınıfın hiperdüzlemlerinin üzerine düşen nesnelere destek vektörleri olarak adlandırılır. Destek vektörleri en önemli eğitim noktalarıdır. Destek vektörleri hiperdüzlemi tanımlar ve karar yüzeyinin optimum konumunun belirlenmesinde doğrudan etkiye sahiptir (Raghavendra ve Deka, 2014). Gerçek zamanlı problemlerde, verileri uzayda bölen, ayırıcı bir hiperdüzlemi tam olarak belirlemek mümkün değildir ve ayrıca bazı durumlarda eğri bir karar sınırı elde edilebilir. Dolayısıyla SVM, ayrılamayan sınıflar için bir sınıflandırıcı olarak da kullanılabilir. Bu gibi durumlarda, orijinal girdi uzayı, özellik fonksiyonları adı verilen doğrusal olmayan fonksiyonlar kullanılarak her zaman daha yüksek boyutlu bir özellik uzayına (Hilbert uzayı) eşlenebilir. Özellik uzayı yüksek boyutlu olmasına rağmen, hiperdüzlemin sınıflandırılması için doğrudan özellik fonksiyonlarını kullanmak pratikte mümkün değildir. Bu gibi durumlarda, özellik fonksiyonları tarafından oluşturulan doğrusal olmayan haritalandırma, çekirdek (kernel) adı verilen özel doğrusal olmayan fonksiyonlar kullanılarak yapılabilir.

Çekirdek fonksiyonlarının seçimi daha iyi bir genelleme yapılmasını sağlar. Çekirdek fonksiyonu kullanılarak DVM'lerde doğrusal olmayan sınırlar oluşturulabilir ve böylece problem daha iyi tanımlanıp çözülebilir. Bu amaçla kullanılacak oldukça fazla sayıda çekirdek vardır. Bunlar arasında doğrusal, polinom, gauss fonksiyonları sayılabilir. Doğrusal olmayan çekirdekler (nonlinear kernel) sayesinde, DVM'ye karmaşık ayırıcı hiperdüzlemleri modelleme yeteneği verir.

DVM veri seti üzerinde ortalama hata karesini minimize ederek türetilen ampirik risk minimizasyonu prensibinden ziyade, istatistiksel öğrenme teorisindeki yapısal risk

minimizasyonu niteliğinde çalışmasıdır. Gerçek dünyada karşımıza çıkan problemlerin çoğu doğrusal olarak ayırabilen verilere sahip değildir. Bu durumda giriş verileri klasik yöntemle çözülmeyebilir. Böyle problemlerde ise doğrusal olmayan sınıflandırma yöntemi kullanılmaktadır (Cristianini ve Shawe-Taylor, 2000).

Hidrolojik analizlerde pek çok parametre doğrusal olmama eğilimindedir. Bu sebeple doğrusal olmayan problemleri çözmek amacıyla girdi değişkenlerini daha yüksek boyutlu bir özellik uzayına dönüştürmek için doğrusal olmayan bir eşleme fonksiyonunun tanıtılmasıdır. Bu nedenle bu çalışmada akış tahmini için doğrusal olmayan destek vektör regresyonunu uygulanmıştır.

Drucker ve arkadaşları (1997) tarafından önerilen destek vektör regresyonu (DVR) regresyon için kullanılan bir Destek vektör makinesi modelidir. DVR, yüksek boyutlu bir özellik uzayında doğrusal fonksiyonun bir hipotez uzayını kullanır ve yapısal risk minimizasyonu ilkesine göre eğitilir (Wu vd., 2019). DVR’de karar fonksiyonu Denklem (3.2) gibi yazılabilir:

$$f(x)=w \cdot \phi(x)+b \quad (3.2)$$

Burada $f(x)$: regresyon fonksiyonu, x : girdi vektörü, w ve b fonksiyonun parametreleridir. $\phi(x)$ ise doğrusal olmayan haritalandırma fonksiyonudur. Amaç optimum değerlerin bulunmasıdır. Bu amaca Denklem (3.3)’deki gibi optimizasyon denkleminin çözülmesi ile ulaşılabilir.


$$\min_{w,b,\xi,\xi^*} \frac{1}{2} w^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3.3)$$

Denklem (3.4) ve Denklem (3.5) şartlarını sağlamalıdır:

$$y_i - (w \cdot \phi(x_i) + b) \leq \varepsilon + \xi_i \quad (3.4)$$

$$(w \cdot \phi(x_i) + b) - y_i \leq \varepsilon + \xi_i^* \quad (3.5)$$

$\xi_i, \xi_i^* \geq 0, i=1, \dots, n$ burada ξ_i ve ξ_i^* esnek değişkenler, C : sabit ceza katsayısı, ε : marjin değeridir. Denklem 3.4’te sağ taraf modelin genelleştirilmesini, sol taraf ise ampirik riski temsil etmektedir. Bu iki değer minimumda tutulması ile DVR çözüme ulaşmaktadır.



Şekil 3.4. (A) İki sınıflı veriyi ayıran bir alt düzlem, (B) en iyi alt düzlem ve sınırları.

Doğrusal olmayan DVR, Denklem (3.6) ve Denklem (3.7)'de belirtildiği gibi Lagranj çarpanları ile gösterilebilir.

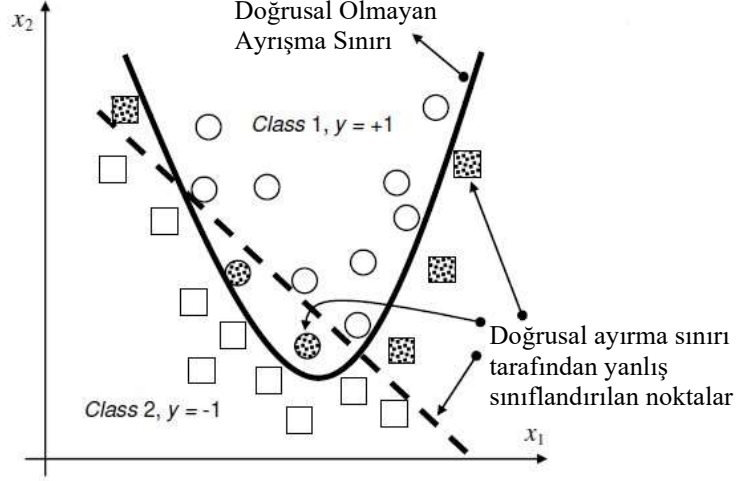
$$\min_{a,a^*} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (a_i - a_i^*)(a_j - a_j^*)K + \varepsilon \sum_{i=1}^n (a_i + a_i^*) - \sum_{i=1}^n y_i(a_i - a_i^*) \quad (3.6)$$

$$\sum_{i=1}^n y_i(a_i - a_i^*) = 0 \quad (3.7)$$

$0 \leq a_i, a_i^* \leq C, i=1, \dots, n$; a_i ve a_i^* : Lagranj çarpanları; K: Kernel fonksiyonudur. Kernel fonksiyonu Denklem (3.8) de verilmiştir.


$$K=K(i,j)=\phi(x_i)T\phi(x_j)K=K(i,j)=\phi(x_i)T\phi(x_j) \quad (3.8)$$

Şekil 3.5 de verilen basit bir doğrusal olmayan destek vektörleri makinasıdır. Gerçek bir ayırma ikinci dereceden bir eğridir. Doğrusal olmayan ayırma çizgisi (düz), doğrusal ne (kesikli) ve doğrusal ayırma çizgisi tarafından yanlış sınıflandırılan veri noktaları (dokulu eğitim veri noktaları) gösterilir. 4 adet yanlış sınıflandırılmış negatif veri ve 2 adet yanlış sınıflandırılmış pozitif veri bulunmaktadır. (Kecman, 2004)



Şekil 3.5. Veri çakışması olmayan doğrusal olmayan bir DVM (Kecman, 2004).

Doğrusal olarak ayrılamayan durumlarda yapılan bu boyut değişikliğini sağlayan haritalama fonksiyonunun bilinmemesi ve yüksek boyutlarda işlem yapmanın zor olması nedeniyle çekirdek düzenlemesi (kernel trick) denilen düzenlemeler yapılır. Böylelikle dönüştürülmüş uzaydaki haritalama fonksiyonu yerine, doğrudan girdi uzayındaki verilerin kullanımı sağlayan çekirdek fonksiyonları işleme dâhil edilmiş olur. Literatürde çok sayıda çekirdek fonksiyonu olmakla birlikte; en sık kullanılanları doğrusal fonksiyon, polinomiyal fonksiyon, sigmoid fonksiyon ve radyal tabanlı fonksiyonlardır (Aydoğan Culha, 2015).



Şekil 3.6. Doğrusal olarak sınıflandırılmayan durumlarda Kernel fonksiyonlarının etkisi (Fletcher, 2009).

Yaygın olarak kullanılan Kernel fonksiyonları;

Doğrusal Kernel Denklem (3.9)'da verilmiştir:

$$K(i,j)=x_i \cdot x_j \quad (3.9)$$

Gauss Kernel Denklem (3.10)'da verilmiştir:

$$K(i,j)=\exp(-\gamma|x_i-x_j|^2) \quad (3.10)$$

Polinom Kernel Denklem (3.11)'de verilmiştir:

$$K(i,j)=(\gamma(x_i \cdot x_j)+r)^d \quad (3.11)$$

Burada; γ : Yapısal parametre; d: polinom derecesi; r: kalıntı terimidir.

3.2.2. Gauss süreci regresyon analizi (GPR)

Gauss süreç regresyon (GSR) modelleri çok değişkenli dağılımlı rasgele değişkenlerin sınırlı bir koleksiyonuna sahip parametrik olmayan çekirdek tabanlı olasılık modelleridir. Her doğrusal kombinasyon eşit dağılmıştır. Gaussian süreçleri, Carl Friedrich Gauss'un ismini almıştır çünkü Gauss dağılımının çok değişkenli normal dağılımların sonsuz boyutlu bir genellemesi olduğu kavramına dayanmaktadır. Gauss süreçleri istatistiksel modelleme, çoklu hedef değerlere regresyon ve haritalamanın daha yüksek boyutlarda analiz edilmesinde kullanılır (Zhang vd., 2018).

Gauss süreçleri, veri modellemesi için esnek bir parametrik olmayan araç sağlayan stokastik süreçlerin bir ailesidir. En temel ayarda, bir Gauss süreci, sınırlı bir gözlem kümesine dayanan gizli bir işlevi modellemektedir. Gauss süreci, çok değişkenli bir Gauss dağılımının sonsuz sayıda boyuta uzatılması olarak görülebilir, burada herhangi bir sonlu boyut kombinasyonu, ortalama ve kovaryans fonksiyonlarını tamamen belirten çok değişkenli bir Gauss dağılımına neden olur. Ortalama ve kovaryans fonksiyonunun seçimi (aynı zamanda çekirdek olarak da bilinir), ilgilenilen gizli fonksiyona düzgünlük varsayımları uygular ve ilgili gözlem verisi noktaları arasındaki, X öklid mesafenin bir fonksiyonu olarak Y çıktı gözlemleri arasındaki korelasyonu belirler (Fairbrother vd., 2018).

Sonuçları oluşturan temel işlevin, tamamen bir ortalama işlev, $m(x)$ ve bir kovaryans işlevi, $k(x,x')$ tarafından belirtilen stokastik bir süreç olan bir Gauss Süreci olduğu varsayımına dayanır. Gauss Sürecinin ortalama işlevi, girdi değişkenlerini çıktı değişkenlerine eşleyen herhangi bir işlev olabilirken kovaryans işlevi, işlevin düzgünlüğünü ve benzerliğini kodlar (Mohd Aris vd., 2019).

Bir dizi giriş-çıkış çifti $(x_1,y_1), (x_2,y_2), \dots, (x_n,y_n)$ verildiğinde, verinin olasılığı Denklem (3.12)'de verilmiştir:

$$P(y|X, \theta) = N(y|0, K + \sigma^2 I_n) \quad (3.12)$$

burada X girdi değişkenlerinin matrisidir, Θ hiperparametrelerin bir vektörüdür, K , $k(x_i,x_j)$ öğelerini içeren kovaryans matrisidir, σ^2 gürültü varyansıdır (Mohd Aris vd., 2019).

GPR'nin amacı ise Denklem (3.13) de verilen $f(x)$ fonksiyonunu bulmaktır ki; bu fonksiyon y 'nin x üzerindeki dağılımıdır (Mohd Aris vd., 2019).

$$P(f|X, y, \theta) = N(f|m(x), K) \quad (3.13)$$

burada $m(x)$, ortalama işlev ve K , kovaryans işlevidir. Modelin hiperparametreleri, verilerin marjinal olasılığını maksimize ederek tahmin edilebilir (Mohd Aris vd., 2019).

3.2.3. Karar ağaçları

Karar Ağaçları; sınıflandırma ve regresyonun kapsayıcı hedefi tahminde kullanılmak üzere bir modelin oluşturulmasıdır. Bir sınıflandırma veya regresyon probleminde, eğitim kayıtları bize verilmektedir. Her bir kayıt çok sayıda nitelikten oluşmaktadır. Tanım kümesi sayısal olan özniteliklere sayısal nitelikler, tanım kümesi sayısal olmayan niteliklere ise kategorik nitelikler denir. Bağımlı nitelik adı verilen bir tane seçkin nitelik mevcuttur. Kalan diğer nitelikler belirleyici nitelik olarak adlandırılır; bunlar ya sayısal ya da kategorik olabilirler. Eğer bağımlı nitelik kategorik ise problem bir sınıflandırma problemi olarak belirtilir ve bağımlı nitelik sınıf etiketi olarak adlandırılır. Eğer bağımlı nitelik sayısal ise, problem regresyon problemi olarak adlandırılır (Kuzey, 2012).

Karar ağacı oluşturmak iki adımda gerçekleştirilir. İlk adımda model ağacın ağacı ayıran veri tanımları açılır. M5 modelin kriter ayrımları için alt düğümlerde verilerin standart sapması indirilmesi maksimuma ulaştırılır ve her adımda alt düğüm oluşturulur. Daha fazla indirgenemeyen standart sapmaya ulaşıldığı zaman alt düğümlerin ayrılmasına devam edilmez. Denklem (3.14) ve Denklem (3.15) de verilen SDR her düğümdeki standart sapma azaltımı, T ilgili düğüm veri girişi, SD ise standart sapmayı oluşturmaktadır.

$$SDR = SD(T) - \sum_{i=1}^n \left(\frac{T_i}{T}\right) SD(T_i) \quad (3.14)$$

$$SD = \sqrt{\frac{1}{n} \left[\sum_{i=1}^n Y_i^2 - \frac{1}{n} \left(\sum_{i=1}^n Y_i \right)^2 \right]} \quad (3.15)$$

3.2.4. Rastgele orman (Random forest) yöntemi

Topluluk öğrenme yöntemi olan RF algoritması, sınıflandırma veya regresyon işlemi esnasında birden fazla karar ağacı üreterek sınıflandırma değerini yükseltmeyi hedefleyen bir algoritmadır. Bireysel olarak oluşturulan karar ağaçları bir araya gelerek karar ormanı oluşturur. Buradaki karar ağaçları bağlı olduğu veri setinden rastgele seçilmiş birer alt kümedir. Breiman (1996) tarafından geliştirilen Rastgele Orman (RF) algoritması, Bagging yöntemi ve Kim Ho tarafından geliştirilen Random Subspace yöntemlerinin birleşimidir. RF yöntemi bilinen makine öğrenme yöntemleri içerisinde eşsiz bir tahmin geçerliliği ve model yorumlanabilirliği sağlar. Rastgele örnekleme ve topluluk yöntemlerindeki tekniklerin iyileştirilmiş özelliklerini içermesi nedeniyle RF yöntemi daha iyi genellemeler sunar ve geçerli tahminlerde bulunur.

RF algoritmasını başlatmak için kullanıcı tarafından 2 parametre tanımlanmalıdır. Bu parametreler, en iyi bölünmeyi belirlemek için her bir düğümde kullanılan değişkenlerin sayısı (m) ve geliştirilecek ağaçların sayısı N'dir. İlk olarak eğitim veri setinin 2/3'ünden önyükleme örnekleri oluşturulur. Outof-bag (OOB) verisi olarak da adlandırılan, eğitim veri setinin 1/3'lük geri kalan kısmı hataları test etmek için kullanılır. Sonra her bir önyüklemeli örnekten budama olmadan ağaç geliştirilir. Her bir düğümde m değişkenleri tüm değişkenler arasından rastgele olarak seçilir ve bu değişkenler arasından en iyi dal belirlenir. Yeterli öngörü gücü ile yeterli miktarda düşük korelasyon sağlayan değişken sayısının seçimi son derece önemlidir. Breiman

(2002)'e göre toplam M adet değişken sayısının kare köküne eşit alınan m değişken sayısı genel olarak optimum sonuca en yakın sonucu verir. RF ağaç üretmek için CART (Classification and Regression Tree) algoritmasını kullanır. Her bir düğüm de dallar CART algoritmasının kriterine (örn. GINI indeksi) göre oluşturulur. GINI indeksi sınıf homojenliğini ölçer ve Denklem (3.16) ile ifade edilebilir.

$$\sum \sum_{j \neq i} = (f(C_i, T)/|T|)(f(C_i, T)/|T|) \quad (3.16)$$


Burada T eğitim veri setini, C_i rastgele seçilen verinin ait olduğu sınıfı, C_i ve $f(C_i, T)/|T|$, seçilen örneğin C_i sınıfına ait olma olasılığını göstermektedir (Pal, 2005).

3.2.5. Yapay sinir ağları (YSA/ANN)

Yapay sinir ağları, insan sinir sisteminin merkezi olan beynin en küçük işlem birimi olan sinir hücrelerini taklit ederek, bilgisayarların insana öğrenme yeteneği kazandırmasını sağlar. Yapay sinir ağlar yapay zekâ kavramını öğrenme ve yardımcı olma yeteneğine sahiptir. Yapay sinir ağları kendisine sunulan giriş parametreleri ile kendi kendini eğiterek genelleme yapar ve bu genellemeyi takiben sunulan giriş parametrelerine karşı bir çıkış parametresi üretir (Çitakoğlu ve Coşkun, 2021).

Yapay sinir ağlar paralel hesaplama sistemleri olmaları nedeniyle insan beynindeki nöronlarla karşılaştırılabilir. Aktivasyon (transfer) fonksiyonu, ağırlıklar ve düğümler bunları tanımlayan üç unsurdur. Doğrusal, lojistik ve teğet aktivasyon fonksiyonları mühendislik uygulamalarında yaygındır. Bir çıktı elde etmek için her nöron, her girdiyi bağlantı ağırlığıyla çarpar, ürünleri toplar ve ardından toplamı bir transfer fonksiyonu aracılığıyla aktarır. Transfer fonksiyonu genellikle diferansiyellenebilir, sürekli büyüyen S şeklinde bir eğri olan sigmoid bir fonksiyondur. Çıkış fonksiyonunun (y_i) 0 ila 1 aralığı vardır, ancak girişler sonsuz bir değer aralığına sahip olabilir. Bir katmandaki j 'inci nörondan gelen y_i , eşik fonksiyonu kullanılarak Denklem (3.17) gibi hesaplanır:

$$Y_i = f\left(\sum w_{ji} \cdot x_i\right) = \frac{1}{1 + e^{-\left(\sum w_{ji} \cdot x_i\right)}} \quad (3.17)$$



Şekil 3.8. Model 4'ün saklı katmandaki en uygun Nöron sayısının belirlenmesi.

Çizelge 3.3. Çalışmada kullanılan saklı katman sayıları.

| Model No | ANN Model yapısı | WANN Model yapısı |
|----------|------------------|-------------------|
| M01 | 1-68-1 | 1-99-1 |
| M02 | 2-86-1 | 2-52-1 |
| M03 | 3-85-1 | 3-97-1 |
| M04 | 3-63-1 | 3-55-1 |
| M05 | 3-54-1 | 3-45-1 |
| M06 | 3-52-1 | 3-41-1 |
| M07 | 3-43-1 | 3-38-1 |
| M08 | 3-57-1 | 3-52-1 |
| M09 | 3-98-1 | 3-92-1 |
| M10 | 2-48-1 | 2-41-1 |
| M11 | 2-94-1 | 2-87-1 |

Örnek olarak; bu tez çalışmasında yapılan analizlerde yek saklı katman kullanılmış ve en iyi sonucu veren model olan Model 4'ün gizli katmandaki Nöron sayısı 63 olarak bulunmuştur (Şekil 3.8). ANN ve WANN yöntemlerinde kullanılan model yapıları girdi-saklı katman sayıları-çıkı olarak Çizelge 3.3'te verilmiştir.

3.2.6. Dalgacık dönüşümü

Dalgacık dönüşümü (wavelet transformation), gözlemsel elde edilen büyük veri kümelerinden (tarihsel kayıtlar, zaman serileri vb.) potansiyel olarak yararlı bilgi veya

bilginin çıkarılmasında uygulanmaktadır. Sınıflandırma veya tahmin sorunlarını çözmek için kullanılabilen dalgacık dönüşümü, bir sinyalin zaman-frekans alanındaki davranışı hakkında bilgi sağlayabilen çoklu çözünürlüklü bir analizdir (Saraiva vd., 2021). Dalgacık dönüşümünün istatistik analizlere göre bir avantajı, sinyali ayırtmak için tek bir pencere tekniği yerine farklı pencere boyutları analizini gerçekleştirmesidir. Dalgacık dönüşümü ile veriler ayrıştırıldığında hem zaman boyutunda hem frekans boyutunda veri değişimi tespit edilebilmektedir.

Hidrolojik zaman serisi modellemede dalgacık dönüşümünün uygulamalarında hidrolojik serilerin çok-zamanlı ölçeklerinin belirlenmesi ve anlaşılması, mevsimselliklerin ve eğilimlerin tanımlanması ve veri gürültüsünün giderilmesinde kullanılabilir. Bu nedenle, dalgacık dönüşümünün durağan olmayan sinyalleri farklı zamansal ölçeklerde (seviyelerde) alt sinyallere ayırma yeteneği, hidrolojik süreçlerin daha iyi yorumlanmasında yardımcı olmaktadır (Nurani, 2014). Dalgacık dönüşümü, sinyali sırasıyla düşük ve yüksek çözünürlüklü bileşenlere ayırmak için dar ve geniş pencere analizini kullanır. İkinci avantaj ise hidro-meteorolojik zaman serilerinin çoğunlukla durağan olmaması nedeniyle bu serilerde dalgacık dönüşümünün istatistik analizinden daha başarılı bir araç olarak değerlendirilmesidir (Partal ve Kisi 2007). Dalgacık dönüşümü avantajlarından biri de düşük frekanslar için geniş, yüksek frekanslar için dar olacak şekilde değişen pencere boyutlarının olmasıdır. Böylece, bütün frekans aralıklarında uygun değer zaman-frekans çözünürlüğü sağlanabilmektedir (Ersöz ve Özşen, 2011).

Dalgacık dönüşümünde kullanılan ana dalgacık fonksiyonu ölçek parametresi ve konum parametresine bağlı olarak Denklem 3.18'de verilmiştir.

$$\Psi_{a,b}(t) = |a|^{-1/2} \Psi\left(\frac{t-a}{b}\right) \quad (3.18)$$

Burada, a ve b ölçek parametresi, t zamandır. Dalgacık fonksiyonu $\Psi(t)$ ana fonksiyonunun “a” kadar ölçeklendirilip “b” kadar zaman ekseninde ötelenmesi ile elde edilir (Başakın, 2019).

3.2.7. Model performans başarı ölçütleri

Geliştirilen modellerin performansı çeşitli istatistiksel değerlendirme kriterleri kullanılarak değerlendirilmiştir. Bu çalışmada Korelasyon, Nash-Sutcliffe verimlilik katsayısı (NSE), Kling-Gupta verimlilik katsayısı (KGE), Performans İndisi (PI), Karekök ortalama karesel hata (RMSE) ve Ortalama mutlak yüzde hata (MAPE) kriterleri kullanılmıştır. R, NSE ve KGE kriterleri için mükemmel değer 1'e yakın olan değerler olurken, PI, RMSE ve MAPE kriterleri için mükemmel değer 0'a yakın değerlerdir. Bu değerlerden uzaklaşılması mükemmellikten uzaklaşıldığını göstermektedir. NSE kriteri değerlendirilmesi Çizelge 3.4'te verilmiştir. Kullanılan değerlerden Korelasyon (R) formülü Denklem (3.19)'da, Nash-Sutcliffe verimlilik katsayısı (NSE) Denklem (3.20)'de, Performans İndisi (PI) Denklem (3.21)'de, Karekök ortalama karesel hata (RMSE) Denklem (3.22)'de, Ortalama mutlak yüzde hata (MAPE) değerinin denklemi Denklem (3.23)'de ve Kling-Gupta verimlilik katsayısı (KGE) Denklem (3.24), Denklem (3.25) ve Denklem (3.26) formülleri ile hesabı yapılmaktadır. Bu çalışmada yapılan analizler MATLAB 2022 ortamında yapılmıştır.

$$R = \frac{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{i(Göz)}) \times (X_{i(Hesap)} - \bar{X}_{i(Hesap)})}{\sqrt{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{i(Göz)})^2} \times \sqrt{\sum_{i=1}^N (X_{i(Hesap)} - \bar{X}_{i(Hesap)})^2}} \quad (3.19)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (X_{i(Göz)} - X_{i(Hesap)})^2}{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{i(Göz)})^2} \quad (3.20)$$

$$PI = \frac{\frac{RMSE}{\bar{X}_{i(Göz)}}}{1+r} \quad (3.21)$$

$$RMSE = \left[\frac{1}{N} \times \sum_{i=1}^N (X_{i(Göz)} - X_{i(Hesap)})^2 \right]^{1/2} \quad (3.22)$$

$$MAPE = \frac{1}{N} \times \sum_{i=1}^N \frac{|X_{i(Göz)} - X_{i(Hesap)}|}{|X_{i(Göz)}|} \quad (3.23)$$

$$KGE = 1 - [(R - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2]^{1/2} \quad (3.24)$$

$$\alpha = \frac{\sigma_{Hesap}}{\sigma_{Göz}} \quad (3.25)$$

$$\beta = \frac{\bar{X}_{i(Hesap)}}{\bar{X}_{i(Göz)}} \quad (3.26)$$

Çizelge 3.4. Nash-Sutcliffe Verimlilik Katsayısı (Nash & Sutcliffe, 1970).

| <u>Performans Değerlendirmesi</u> | <u>NSE</u> |
|--|------------------------|
| Çok iyi | $0.75 < NSE \leq 1.00$ |
| İyi | $0.65 < NSE \leq 0.75$ |
| Yeterli | $0.5 < NSE \leq 0.65$ |
| Kötü | $NSE \leq 0.50$ |

4. BULGULAR

Bu çalışma kapsamında baraj ve bağlama gibi önemli su yapılarının yönetilmesinde önemli yer alan günlük akarsu akımlarının modellenmesi ve akım değerlerinin ileriye yönelik tahmin edilmesinde yardımcı olacak bir model ortaya koymak amaçlanmıştır. Modeller oluşturularak bir gün sonrası akım değerleri çeşitli girdi senaryolarına göre tahmin edilmeye çalışılmıştır. Bu tez çalışması ile kısa süreli akım tahminlerinde geliştirilmiş olan makine öğrenmesi yöntemlerinden Gauss Süreci Regresyon Analizi (GPR), Destek Vektör Makinesi (DVM), Karar Ağaçları (KA), Rastgele Orman (RO) ve Yapay Sinir Ağları (ANN) kullanılarak en uygun yöntem belirlenmiştir. Kullanılan yöntemlerden Destek vektör makineleri ise üç farklı Kernel yöntemi kullanılarak modellenmiştir. Kullanılan çekirdek fonksiyonları sırasıyla: Doğrusal (lineer) fonksiyon, polinom fonksiyonu ve Gauss fonksiyonudur.

Günlük akım verilerinin farklı zaman gecikmeleri ile oluşturulan ve Çizelge 3.2’de verilen dokuz farklı model ilk önce dalgacık analizi ile ayrıştırılmadan ve daha sonra dalgacık analizi ile ayrıştırılarak incelenmiştir. Elde edilen sonuçlar arasında dalgacık analizi ile dönüştürülmemiş olanlar Çizelge 4.1., Çizelge 4.2., Çizelge 4.3. ve Çizelge 4.4’de verilmiştir. Dalgacık dönüşümü ile elde edilen modellerin sonuçları ise Çizelge 4.5., Çizelge 4.6., Çizelge 4.7. ve Çizelge 4.8’de verilmiştir.

Dalgacık dönüşümü öncesi kurulan model sonuçlarını gösteren Çizelge 4.1., Çizelge 4.2., Çizelge 4.3. ve Çizelge 4.4 incelendiğinde; test serisi için bütün modellerde Korelasyon, NSE, PI ve RMSE kriterlerine göre en iyi sonuçlar Gauss kernel fonksiyonundan elde edilirken, KGE kriterine göre ise en iyi sonuçlar Lineer kernel fonksiyonu ile hesaplanan DVM modellerinden elde edilmiştir. Eğitim serisi sonuçları incelendiğinde Korelasyon, NSE, PI ve RMSE kriterlerine göre en iyi sonuçlar Gauss Süreci Regresyon Analizi (GPR) yönteminden elde edilmiştir yine KGE kriterine göre de Gauss Süreci Regresyon Analizi (GPR) modelinin en iyi model olduğu bulunmuştur.

Dalgacık dönüşümü öncesi eğitim ve test serisi modelleri incelendiğinde; eğitim serisi verileri için bütün modellerde Gauss Süreci Regresyon Analizi (GPR) modelinin Korelasyon, NSE, KGE, PI, RMSE ve MAPE tüm kriterler için en uygun model olduğu görülmüştür. Eğitim veri setinde en uygun model Korelasyon (0.99737), NSE

(0.99475), KGE (0.99531), PI (0.04926), RMSE (0.37857) ve MAPE (0.05800) kriterlerine göre M09 modeli olmuştur. Test veri seti incelendiğinde bu modeller arasında en iyi bulunan model ise; Korelasyon (0.97745), NSE (0.95542), PI (0.13712) ve RMSE (1.04658) kriterlerine göre Gauss tabanlı M02 modeli; KGE (0.97327) göre Gauss Süreci Regresyon Analizi (GPR) M01 modeli; MAPE kriterine göre (0.08124) lineer tabanlı M01 modeli en iyi model olarak bulunmuştur.

Modellerin iyileştirilmesi için dalgacık ayrıştırması dönüşümü uygulanmış ve yeni kurulan modeller incelenmiştir. Dalgacık dönüşümü sonrası kurulan modellerde ise eğitim serisi modellerinde Dalgacık Dönüşümlü Gauss Süreci Regresyon Analizi (WGPR) modellerinin en uygun sonuçları verdiği görülmüştür. Dalgacık Dönüşümlü Gauss Süreci Regresyon Analizi (WGPR) modelleri arasında ise WM03 modeli kriterlerin tamamına göre en uygun model olarak bulunmuştur (R: 0.999939; NSE:0.99988; KGE:0.99988; PI: 0.00747; RMSE:0.05748 ve MAPE:0.02107). Dalgacık dönüşümü sonrası elde edilen modellerin test serisi incelendiğinde kriterlerin tamamına göre DVM fonksiyonlarından Lineer kernel fonksiyonu en iyi sonucu vermiştir. Buna göre Korelasyon (0.998131), NS (0.99624), PI (0.03940) ve RMSE (0.30386) kriterlerine göre WM04 modeli KGE (0.99461) kriterine göre WM03 modeli MAPE (0.04705) kriterine göre WM11 en iyi model olarak bulunmuştur.

Yapay Sinir Ağları (ANN) ile oluşturulan modellerde Dalgacık Dönüşümü ile ayrıştırılmadan önce test serisi incelendiğinde Korelasyon (0.975095), NS (0.95058), KGE (0.97293), PI (0.14453) ve RMS (1.10186) kriterlerine göre M01, MAPE (0.07951) kriterine göre ise M04 en iyi sonucu vermiştir. Eğitim serisinde ise Korelasyon (0.981932), NS (0.96419), PI (0.12960) ve RMSE (0.98836) kriterlerine göre M05 modeli, KGE kriterine göre (0.97930) M09 modeli ve MAPE (0.07426) kriterine göre ise M04 en iyi sonucu veren modeller olmuştur.

Yapay sinir Ağları yöntemi Dalgacık Dönüşümü ile ayrıştırıldıktan sonra ise test serisinde tüm kriterlere göre WM04 en iyi sonucu vermiştir (R:0.997210; NS:0.99442; KGE:0.99552; PI:0.04802; RMSE:0.37019; MAPE:0.04634). Eğitim serisinde ise kriterlerin çoğuna göre WM03 modeli en iyi model bulunurken (R:0.998844; NS:0.99768; PI:0.03270; RMSE:0.25154 ve MAPE:0.03287) KGE kriterine göre WM04 en iyi sonuç olarak bulunmuştur.

Dalgacık dönüşümü öncesi oluşturulan modellerin test serisi kriter grafikleri Şekil 4.1.de, eğitim serisi kriterlerin grafikleri Şekil 4.2’de, dalgacık dönüşümü sonrası elde edilen model sonuçlarının test serisi kriterlerin grafikleri Şekil 4.3.’de ve eğitim serisinin kriter grafikleri de Şekil 4.4.’de verilmiştir.

Yapay sinir ağları kullanılarak oluşturulan modellerin test serisi kriter grafikleri Şekil 4.5.’de, eğitim serisi kriterlerin grafikleri Şekil 4.6.’da verilmiştir.

Model sonuçlarının dalgacık dönüşümü öncesi ve dalgacık dönüşümü sonrası elde edilen model sonuçlarının arasından en iyi modellerin saçılım grafiklerinin karşılaştırılması Şekil 4.7 ve Şekil 4.8’de verilmiştir. Saçılım grafikleri incelendiğinde bütün dalgacık dönüşümü sonrası elde edilen model sonuçlarının dalgacık dönüşümü olmadan elde edilen sonuçlardan daha üstün olduğu görülmektedir. Dalgacık dönüşümü ile elde edilen sonuçlar incelendiğinde Gauss fonksiyonunda diğer modellere göre iyileşme olmadığı görülmüştür. Diğer dalgacık modelleri saçılma grafiklerinin 45^0 ’lik eğime (1:1 çizgisine) oldukça yakın sonuçlar verdiği görülmüştür. Diğer bir anlatımla, dalgacık dönüşümü sonrası kurulan modellerde gözlem değerlerine oldukça yakın sonuçlar elde edilmiştir. Hangi modelin daha iyi performans gösterdiğini belirleyebilmek için Taylor grafiği ve Violin (Keman) grafiği kullanılmıştır. Bütün modellerin Taylor grafiği ile karşılaştırılması Şekil 4.13’de verilmiş olup en uygun bulunan modellerin dağılımlarının karşılaştırılması Violin (Keman) grafiği olarak Şekil 4.12’de verilmiştir.

Daubechies dalgacık fonksiyonu ailesinde db45, db4 ve haar ile yapılan çalışmalar sonucunda, günlük akarsu akımların tahmin edilmesinde db45 dalgacık fonksiyonunun diğerlerine göre daha iyi sonuç verdiği görülmüştür.

Dalgacık dönüşümü öncesi elde edilen en iyi modeller arasında olan Model 2’nin Destek Vektörleri Makinesinden Gauss ve Rastgele Orman (RF) gözlem verisi ile karşılaştırılması Şekil 4.9.’da, dalgacık dönüşümü sonrası elde edilen en iyi modeller olan Gauss Süresi Regresyon Analizi (GPR) metodundan WM03 ve WM04 modellerinin gözlem verisi ile karşılaştırılması ise Şekil 4.10’da verilmiştir. En iyi modellerden olan Dalgacık Dönüşümü sonrası Destek Vektörleri Makinesi fonksiyonlarından Lineer Yönteminin Model 4 ve yine Dalgacık Dönüşümü sonrası Yapay Sinir Ağları yönteminin Model 4 karşılaştırması Şekil 4.11’de verilmiştir.

Dalgacık dönüşümü sonrası elde edilen modeller dalgacık dönüşümsüz modellere göre daha iyi sonuç verdiği tespit edilmiştir. Dalgacık dönüşümü sonrası elde edilen modellerin gösteriminde modellerin başına W harfi eklenmiştir. Örnek olarak: DVMLN-M04: Lineer kernel ile kurulmuş olan Destek vektör makinesi ile hesaplanmış olan M04 modeli; WDVMLN-M04 ise dalgacık dönüşümü sonrası veriler ile kurulmuş olan Destek vektör makinesi ile hesaplanmış olan M04 modelini temsil etmektedir.

Dalgacık dönüşümü sonrası kurulan modellerin üstün olduğu Şekil 4.12.'de dalgacık sonrası elde edilen modellere ait Violin (keman) grafikleri ile de gösterilmiştir. Şekil 4.12. incelendiğinde dalgacık dönüşümü sonrası model sonuçlarının gözlem verisi ile çok yakın aritmetik ortalama ve medyan verisine sahip olduğu; tahmin edilen verilerin dağılımının gözlem verilerinin dağılımına oldukça benzer olduğu; ancak maksimum değer tahmininde hiç birisinin maksimum gözlem değerine ulaşamadığı görülmüştür.

Dalgacık dönüşümü öncesi ve sonrasında Destek Vektörleri Makinelerinden en iyi sonucu veren Lineer fonksiyonunda test aşamasında NSE kriterine göre M04 modelinde %4.9, M03 modelinde %4.8 ve M05 modelinde %4.7 oranında iyileşme görülmüştür. Modellerin detaylı iyileşme yüzdeleri ise Çizelge 4.11'de verilmiştir.

Taylor grafiği (Şekil 4.13.) incelendiğinde dalgacık dönüşümü öncesi kurulan modellerin grafiğin üst kısmında olduğu, dalgacık dönüşümü sonrası kurulan modellerin gözlem değerine daha yakın bir pozisyonda gruplandığı görülmüştür. Büyütülerek daha detaylı incelendiğinde WDVMLN-M04 ve WANN-M04 modellerinin gözlem değerlerine en yakın olduğu ve WDVMLN-M04 modelinin gözlem değerine daha yakın olduğundan daha iyi bir model olduğu görülmüştür. Bu modelleri ise üçüncü sırada en iyi model olarak WANN M03 modeli izlemektedir. Bu modellere ait NSE; KGE; PI; RMSE ve MAPE değerlerine sırasıyla bakıldığında: WDVMLN M04 (0.996; 0.993; 0.039; 0.304 ve 0.056); WANN M04 (0.994; 0.995; 0.048; 0.370 ve 0.047) olarak tespit edilmiştir. Burada KG kriteri haricindeki diğer kriterler birbirleri ile uyumlu olarak modellerin sırasını iyi bir şekilde tespit etmiştir. Dolayısı ile KGE kriterini kullanırken, diğer istatistiksel kriterler ile onaylamak gerekmektedir.

Çizelge 4.1. Dalgacık Dönüşümü öncesi Lineer ve Polinom test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri.

| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|------------|---------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| DVM_Lineer | Model 1 | 0.97446 | 0.94944 | 0.96551 | 0.14623 | 1.11447 | 0.08124 | 0.96914 | 0.93902 | 0.96135 | 0.17022 | 1.28976 | 0.07741 |
| | Model 2 | 0.97466 | 0.94973 | 0.97178 | 0.14581 | 1.11136 | 0.08529 | 0.96952 | 0.93950 | 0.96744 | 0.16951 | 1.28465 | 0.08246 |
| | Model 3 | 0.97462 | 0.94980 | 0.97019 | 0.14571 | 1.11058 | 0.10565 | 0.96944 | 0.93954 | 0.96625 | 0.16946 | 1.28417 | 0.10155 |
| | Model 4 | 0.97452 | 0.94947 | 0.97233 | 0.14619 | 1.11416 | 0.09422 | 0.96938 | 0.93924 | 0.96795 | 0.16989 | 1.28740 | 0.09067 |
| | Model 5 | 0.97467 | 0.94977 | 0.97224 | 0.14575 | 1.11089 | 0.09299 | 0.96952 | 0.93954 | 0.96787 | 0.16945 | 1.28417 | 0.08965 |
| | Model 6 | 0.97465 | 0.94983 | 0.97044 | 0.14566 | 1.11021 | 0.10743 | 0.96948 | 0.93962 | 0.96647 | 0.16934 | 1.28334 | 0.10314 |
| | Model 7 | 0.97467 | 0.94984 | 0.97136 | 0.14564 | 1.11010 | 0.10730 | 0.96950 | 0.93961 | 0.96695 | 0.16936 | 1.28346 | 0.10328 |
| | Model 8 | 0.97470 | 0.94982 | 0.97246 | 0.14567 | 1.11029 | 0.10585 | 0.96956 | 0.93963 | 0.96796 | 0.16933 | 1.28326 | 0.10271 |
| | Model 9 | 0.97480 | 0.95013 | 0.97022 | 0.14521 | 1.10687 | 0.09558 | 0.96973 | 0.94010 | 0.96665 | 0.16865 | 1.27821 | 0.09142 |
| DVM_Poly | Model 1 | 0.97468 | 0.94995 | 0.96170 | 0.14548 | 1.10884 | 0.11258 | 0.97420 | 0.94854 | 0.94516 | 0.15596 | 1.18475 | 0.10687 |
| | Model 2 | 0.96969 | 0.93938 | 0.96237 | 0.16052 | 1.22039 | 0.08406 | 0.97846 | 0.95681 | 0.95120 | 0.14258 | 1.08545 | 0.08385 |
| | Model 3 | 0.96765 | 0.93479 | 0.95029 | 0.16665 | 1.26572 | 0.18944 | 0.97903 | 0.95782 | 0.95015 | 0.14086 | 1.07266 | 0.18191 |
| | Model 4 | 0.96461 | 0.92427 | 0.89816 | 0.17987 | 1.36398 | 0.35950 | 0.97882 | 0.95339 | 0.89968 | 0.14808 | 1.12754 | 0.34839 |
| | Model 5 | 0.96630 | 0.93175 | 0.95312 | 0.17061 | 1.29489 | 0.11739 | 0.97852 | 0.95671 | 0.95050 | 0.14273 | 1.08661 | 0.11678 |
| | Model 6 | 0.96899 | 0.93798 | 0.96052 | 0.16241 | 1.23436 | 0.14926 | 0.97867 | 0.95742 | 0.95429 | 0.14156 | 1.07777 | 0.14312 |
| | Model 7 | 0.96989 | 0.93837 | 0.94788 | 0.16183 | 1.23047 | 0.13438 | 0.97854 | 0.95625 | 0.94174 | 0.14349 | 1.09242 | 0.13449 |
| | Model 8 | 0.97136 | 0.94222 | 0.95513 | 0.15658 | 1.19142 | 0.18018 | 0.97878 | 0.95740 | 0.95044 | 0.14158 | 1.07801 | 0.17516 |
| | Model 9 | 0.97011 | 0.94089 | 0.96610 | 0.15848 | 1.20511 | 0.11885 | 0.97883 | 0.95778 | 0.95507 | 0.14095 | 1.07321 | 0.11048 |

Çizelge 4.2. Dalgacık Dönüşümü öncesi Gauss ve RO'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri.

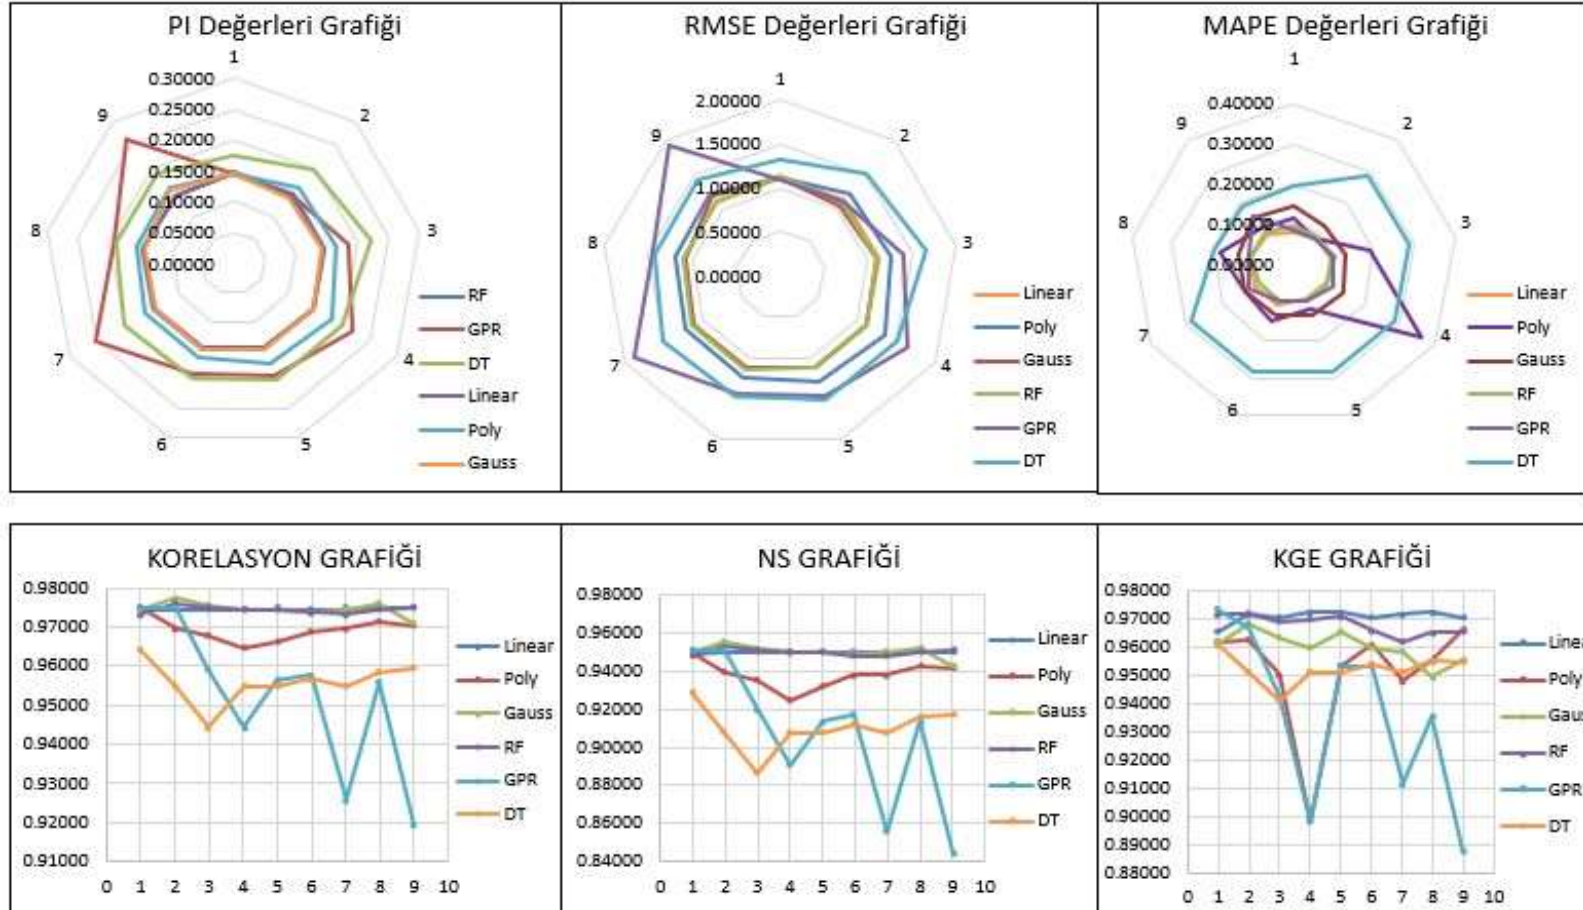
| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|-----------|---------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| DVM_Gauss | Model 1 | 0.97434 | 0.94932 | 0.96111 | 0.14643 | 1.11588 | 0.14334 | 0.97021 | 0.94070 | 0.93798 | 0.16777 | 1.27186 | 0.12889 |
| | Model 2 | 0.97745 | 0.95542 | 0.96778 | 0.13712 | 1.04658 | 0.12458 | 0.97149 | 0.94348 | 0.94579 | 0.16367 | 1.24163 | 0.11069 |
| | Model 3 | 0.97560 | 0.95177 | 0.96287 | 0.14274 | 1.08850 | 0.13219 | 0.97145 | 0.94310 | 0.93956 | 0.16424 | 1.24587 | 0.11469 |
| | Model 4 | 0.97431 | 0.94924 | 0.95948 | 0.14654 | 1.11669 | 0.13946 | 0.97100 | 0.94185 | 0.93279 | 0.16607 | 1.25949 | 0.11834 |
| | Model 5 | 0.97443 | 0.94951 | 0.96523 | 0.14615 | 1.11380 | 0.13465 | 0.97133 | 0.94252 | 0.93389 | 0.16508 | 1.25217 | 0.11428 |
| | Model 6 | 0.97378 | 0.94822 | 0.95943 | 0.14804 | 1.12788 | 0.13171 | 0.97089 | 0.94177 | 0.93487 | 0.16618 | 1.26028 | 0.10991 |
| | Model 7 | 0.97463 | 0.94983 | 0.95831 | 0.14566 | 1.11019 | 0.13348 | 0.96989 | 0.93976 | 0.93236 | 0.16912 | 1.28189 | 0.11333 |
| | Model 8 | 0.97587 | 0.95188 | 0.94938 | 0.14257 | 1.08729 | 0.13275 | 0.96766 | 0.93523 | 0.92666 | 0.17555 | 1.32916 | 0.11238 |
| | Model 9 | 0.97095 | 0.94268 | 0.95530 | 0.15598 | 1.18665 | 0.14880 | 0.96927 | 0.93825 | 0.92737 | 0.17127 | 1.29782 | 0.11756 |
| RO | Model 1 | 0.97345 | 0.94731 | 0.97167 | 0.14936 | 1.13774 | 0.09490 | 0.97614 | 0.95284 | 0.96485 | 0.14916 | 1.13416 | 0.08067 |
| | Model 2 | 0.97595 | 0.95240 | 0.97155 | 0.14178 | 1.08135 | 0.09093 | 0.97969 | 0.95968 | 0.96330 | 0.13767 | 1.04874 | 0.07381 |
| | Model 3 | 0.97506 | 0.95070 | 0.96891 | 0.14436 | 1.10050 | 0.09534 | 0.97951 | 0.95923 | 0.95933 | 0.13845 | 1.05458 | 0.07417 |
| | Model 4 | 0.97447 | 0.94953 | 0.96927 | 0.14611 | 1.11357 | 0.09673 | 0.97992 | 0.95996 | 0.95799 | 0.13717 | 1.04503 | 0.07303 |
| | Model 5 | 0.97464 | 0.94981 | 0.97061 | 0.14569 | 1.11041 | 0.09799 | 0.98028 | 0.96064 | 0.95801 | 0.13598 | 1.03614 | 0.07282 |
| | Model 6 | 0.97367 | 0.94802 | 0.96569 | 0.14834 | 1.13007 | 0.09906 | 0.98038 | 0.96080 | 0.95714 | 0.13569 | 1.03402 | 0.07265 |
| | Model 7 | 0.97332 | 0.94734 | 0.96169 | 0.14933 | 1.13745 | 0.09557 | 0.98043 | 0.96094 | 0.95815 | 0.13545 | 1.03219 | 0.07188 |
| | Model 8 | 0.97446 | 0.94957 | 0.96485 | 0.14605 | 1.11306 | 0.10341 | 0.98077 | 0.96163 | 0.95933 | 0.13423 | 1.02307 | 0.07262 |
| | Model 9 | 0.97505 | 0.95073 | 0.96519 | 0.14432 | 1.10019 | 0.10684 | 0.97943 | 0.95890 | 0.95492 | 0.13902 | 1.05886 | 0.07535 |

Çizelge 4.3. Dalgacık Dönüşümü öncesi GPR ve KA'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri.

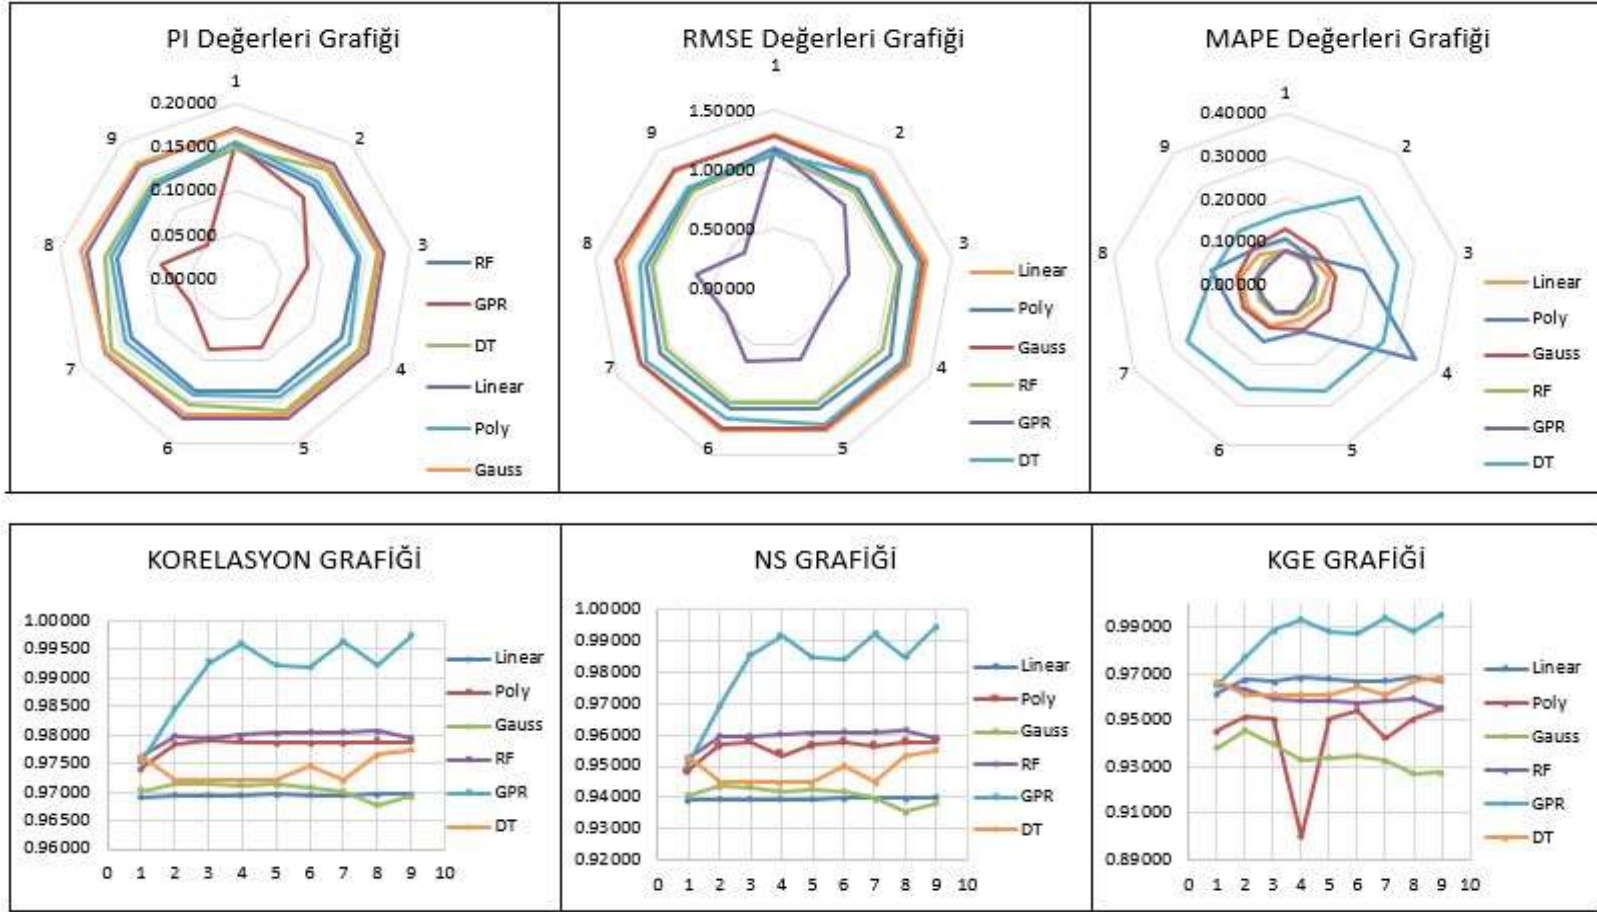
| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|--------|---------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| GPR | Model 1 | 0.97516 | 0.95068 | 0.97327 | 0.14438 | 1.10072 | 0.08561 | 0.97512 | 0.95086 | 0.96467 | 0.15233 | 1.15773 | 0.07987 |
| | Model 2 | 0.97500 | 0.95061 | 0.96689 | 0.14449 | 1.10149 | 0.08465 | 0.98460 | 0.96943 | 0.97709 | 0.11958 | 0.91320 | 0.07705 |
| | Model 3 | 0.95902 | 0.91966 | 0.94227 | 0.18580 | 1.40495 | 0.09858 | 0.99265 | 0.98536 | 0.98839 | 0.08243 | 0.63199 | 0.06865 |
| | Model 4 | 0.94424 | 0.89052 | 0.89806 | 0.21853 | 1.64000 | 0.11557 | 0.99588 | 0.99178 | 0.99333 | 0.06166 | 0.47351 | 0.05970 |
| | Model 5 | 0.95638 | 0.91398 | 0.95300 | 0.19251 | 1.45374 | 0.09900 | 0.99229 | 0.98464 | 0.98809 | 0.08443 | 0.64721 | 0.06819 |
| | Model 6 | 0.95788 | 0.91704 | 0.95310 | 0.18891 | 1.42762 | 0.09728 | 0.99193 | 0.98393 | 0.98711 | 0.08639 | 0.66216 | 0.06980 |
| | Model 7 | 0.92580 | 0.85583 | 0.91145 | 0.25318 | 1.88199 | 0.12573 | 0.99633 | 0.99268 | 0.99389 | 0.05817 | 0.44683 | 0.06073 |
| | Model 8 | 0.95586 | 0.91343 | 0.93504 | 0.19318 | 1.45838 | 0.10788 | 0.99230 | 0.98465 | 0.98771 | 0.08441 | 0.64708 | 0.06884 |
| | Model 9 | 0.91913 | 0.84471 | 0.88783 | 0.26367 | 1.95320 | 0.15605 | 0.99737 | 0.99475 | 0.99531 | 0.04926 | 0.37857 | 0.05800 |
| KA | Model 1 | 0.96401 | 0.92891 | 0.96054 | 0.17433 | 1.32154 | 0.19313 | 0.97626 | 0.95308 | 0.96642 | 0.14878 | 1.13135 | 0.16465 |
| | Model 2 | 0.95457 | 0.90738 | 0.95069 | 0.19994 | 1.50845 | 0.28605 | 0.97210 | 0.94499 | 0.96055 | 0.16143 | 1.22502 | 0.26283 |
| | Model 3 | 0.94437 | 0.88667 | 0.94116 | 0.22234 | 1.66864 | 0.28760 | 0.97210 | 0.94499 | 0.96055 | 0.16143 | 1.22502 | 0.26283 |
| | Model 4 | 0.95457 | 0.90738 | 0.95069 | 0.19994 | 1.50845 | 0.28605 | 0.97210 | 0.94499 | 0.96055 | 0.16143 | 1.22502 | 0.26283 |
| | Model 5 | 0.95457 | 0.90738 | 0.95069 | 0.19994 | 1.50845 | 0.28605 | 0.97210 | 0.94499 | 0.96055 | 0.16143 | 1.22502 | 0.26283 |
| | Model 6 | 0.95670 | 0.91211 | 0.95406 | 0.19456 | 1.46945 | 0.28407 | 0.97453 | 0.94970 | 0.96398 | 0.15417 | 1.17133 | 0.26165 |
| | Model 7 | 0.95457 | 0.90738 | 0.95069 | 0.19994 | 1.50845 | 0.28605 | 0.97210 | 0.94499 | 0.96055 | 0.16143 | 1.22502 | 0.26283 |
| | Model 8 | 0.95854 | 0.91567 | 0.95513 | 0.19040 | 1.43935 | 0.19382 | 0.97645 | 0.95346 | 0.96670 | 0.14816 | 1.12677 | 0.16705 |
| | Model 9 | 0.95945 | 0.91710 | 0.95459 | 0.18869 | 1.42713 | 0.19165 | 0.97739 | 0.95530 | 0.96803 | 0.14513 | 1.10423 | 0.16537 |

Çizelge 4.4. Dalgacık Dönüşümü öncesi ANN'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri.

| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|--------|---------|-----------------|----------------|----------------|----------------|----------------|----------------|-----------------|----------------|----------------|----------------|----------------|----------------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| ANN | Model 1 | 0.975095 | 0.95058 | 0.97293 | 0.14453 | 1.10186 | 0.08365 | 0.979275 | 0.95898 | 0.96997 | 0.13889 | 1.05782 | 0.07763 |
| | Model 2 | 0.959960 | 0.92102 | 0.95530 | 0.18413 | 1.39298 | 0.08420 | 0.981453 | 0.96323 | 0.97655 | 0.13135 | 1.00146 | 0.08011 |
| | Model 3 | 0.949271 | 0.89396 | 0.93805 | 0.21453 | 1.61408 | 0.08860 | 0.980202 | 0.96078 | 0.96953 | 0.13574 | 1.03428 | 0.08038 |
| | Model 4 | 0.970804 | 0.94148 | 0.97071 | 0.15762 | 1.19901 | 0.07951 | 0.980192 | 0.96071 | 0.97648 | 0.13587 | 1.03530 | 0.07426 |
| | Model 5 | 0.960265 | 0.91644 | 0.94609 | 0.18936 | 1.43276 | 0.08538 | 0.981932 | 0.96419 | 0.97387 | 0.12960 | 0.98836 | 0.07658 |
| | Model 6 | 0.972786 | 0.94622 | 0.96768 | 0.15096 | 1.14950 | 0.09035 | 0.981639 | 0.96359 | 0.97663 | 0.13069 | 0.99655 | 0.08456 |
| | Model 7 | 0.971185 | 0.94280 | 0.96978 | 0.15581 | 1.18547 | 0.08278 | 0.980890 | 0.96212 | 0.96914 | 0.13337 | 1.01657 | 0.07856 |
| | Model 8 | 0.939392 | 0.87642 | 0.93649 | 0.23276 | 1.74243 | 0.08693 | 0.981682 | 0.96369 | 0.97395 | 0.13052 | 0.99525 | 0.07842 |
| | Model 9 | 0.961334 | 0.92130 | 0.95837 | 0.18367 | 1.39048 | 0.09300 | 0.979753 | 0.95964 | 0.97930 | 0.13774 | 1.04929 | 0.08048 |



Şekil 4.1. Dalgacık Dönüşümü öncesi test verilerinin çeşitli istatistiksel kriterlere göre performansları.



Şekil 4.2. Dalgacık Dönüşümü öncesi eğitim verilerinin çeşitli istatistiksel kriterlere göre performansları.

Çizelge 4.5. Dalgacık Dönüşümü sonrası Lineer ve Polinom ile hesaplanmış test ve eğitim süreçlerinde akım verilerinin tahmin edilen değerleri.

| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|-------------|----------|-----------------|----------------|----------------|----------------|----------------|----------------|-----------------|----------------|----------------|----------------|----------------|----------------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| WDVM_Lineer | Model 1 | 0.984619 | 0.96934 | 0.96942 | 0.11330 | 0.86791 | 0.07665 | 0.982375 | 0.96490 | 0.96529 | 0.12828 | 0.97852 | 0.07205 |
| | Model 2 | 0.996991 | 0.99398 | 0.99314 | 0.04989 | 0.38455 | 0.05863 | 0.996794 | 0.99359 | 0.99391 | 0.05441 | 0.41802 | 0.04714 |
| | Model 3 | 0.997901 | 0.99580 | 0.99461 | 0.04167 | 0.32134 | 0.05051 | 0.997539 | 0.99508 | 0.99586 | 0.04765 | 0.36626 | 0.04219 |
| | Model 4 | 0.998131 | 0.99624 | 0.99282 | 0.03940 | 0.30386 | 0.05553 | 0.997683 | 0.99535 | 0.99279 | 0.04632 | 0.35605 | 0.04776 |
| | Model 5 | 0.997245 | 0.99448 | 0.99291 | 0.04776 | 0.36822 | 0.06545 | 0.996921 | 0.99384 | 0.99302 | 0.05335 | 0.40991 | 0.05306 |
| | Model 6 | 0.997070 | 0.99412 | 0.99151 | 0.04930 | 0.38003 | 0.07740 | 0.996841 | 0.99367 | 0.99095 | 0.05410 | 0.41569 | 0.06359 |
| | Model 7 | 0.996934 | 0.99383 | 0.98925 | 0.05052 | 0.38942 | 0.08330 | 0.996766 | 0.99349 | 0.98875 | 0.05484 | 0.42136 | 0.07017 |
| | Model 8 | 0.996947 | 0.99389 | 0.99273 | 0.05026 | 0.38744 | 0.06655 | 0.996780 | 0.99356 | 0.99341 | 0.05454 | 0.41902 | 0.05505 |
| | Model 9 | 0.997000 | 0.99400 | 0.99364 | 0.04980 | 0.38388 | 0.05867 | 0.996794 | 0.99360 | 0.99447 | 0.05440 | 0.41795 | 0.04716 |
| | Model 10 | 0.983667 | 0.96752 | 0.98171 | 0.11666 | 0.89323 | 0.05555 | 0.981255 | 0.96265 | 0.98061 | 0.13241 | 1.00943 | 0.05453 |
| | Model 11 | 0.995262 | 0.99053 | 0.98956 | 0.06265 | 0.48246 | 0.04705 | 0.993694 | 0.98741 | 0.98817 | 0.07638 | 0.58598 | 0.04251 |
| WDVM_Poly | Model 1 | 0.922626 | 0.46994 | 0.25339 | 0.48627 | 3.60864 | 2.38061 | 0.768840 | -0.29442 | 0.07846 | 0.87304 | 5.94214 | 2.37491 |
| | Model 2 | 0.968896 | 0.85353 | 0.64574 | 0.24961 | 1.89694 | 1.14845 | 0.941087 | 0.76070 | 0.61343 | 0.34207 | 2.55490 | 1.12564 |
| | Model 3 | 0.951422 | 0.76959 | 0.58946 | 0.31587 | 2.37920 | 1.31611 | 0.960658 | 0.80373 | 0.59440 | 0.30670 | 2.31385 | 1.29881 |
| | Model 4 | 0.891499 | 0.57923 | 0.54326 | 0.44038 | 3.21519 | 1.27831 | 0.902084 | 0.60858 | 0.54528 | 0.44646 | 3.26760 | 1.23535 |
| | Model 5 | 0.855201 | -0.46375 | -0.22034 | 0.83743 | 5.99674 | 3.81317 | 0.901998 | -0.15939 | -0.17668 | 0.76841 | 5.62367 | 3.74252 |
| | Model 6 | 0.955556 | 0.85804 | 0.75630 | 0.24741 | 1.86752 | 0.75419 | 0.984403 | 0.93550 | 0.78193 | 0.17371 | 1.32641 | 0.72655 |
| | Model 7 | 0.954289 | 0.71622 | 0.48223 | 0.35004 | 2.64044 | 1.71693 | 0.944574 | 0.66354 | 0.46039 | 0.40488 | 3.02949 | 1.69208 |
| | Model 8 | 0.965798 | 0.71691 | 0.43406 | 0.34756 | 2.63719 | 1.91342 | 0.962914 | 0.72340 | 0.44252 | 0.36367 | 2.74680 | 1.89551 |
| | Model 9 | 0.872968 | -2.03814 | -1.02348 | 1.19504 | 8.63945 | 6.59328 | 0.867839 | -1.97368 | -1.02831 | 1.25313 | 9.00642 | 6.48270 |
| | Model 10 | 0.746566 | -4.10288 | -1.49088 | 1.66085 | 11.19669 | 7.81521 | 0.860828 | -3.05818 | -1.42823 | 1.46942 | 10.52133 | 7.66313 |
| | Model 11 | 0.130731 | -0.48262 | -0.58275 | 1.38281 | 6.03529 | 0.71358 | 0.030425 | -0.59791 | -0.44242 | 1.66512 | 6.60208 | 0.70942 |

Çizelge 4.6. Dalgacık Dönüşümü sonrası Gauss ve RO'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri.

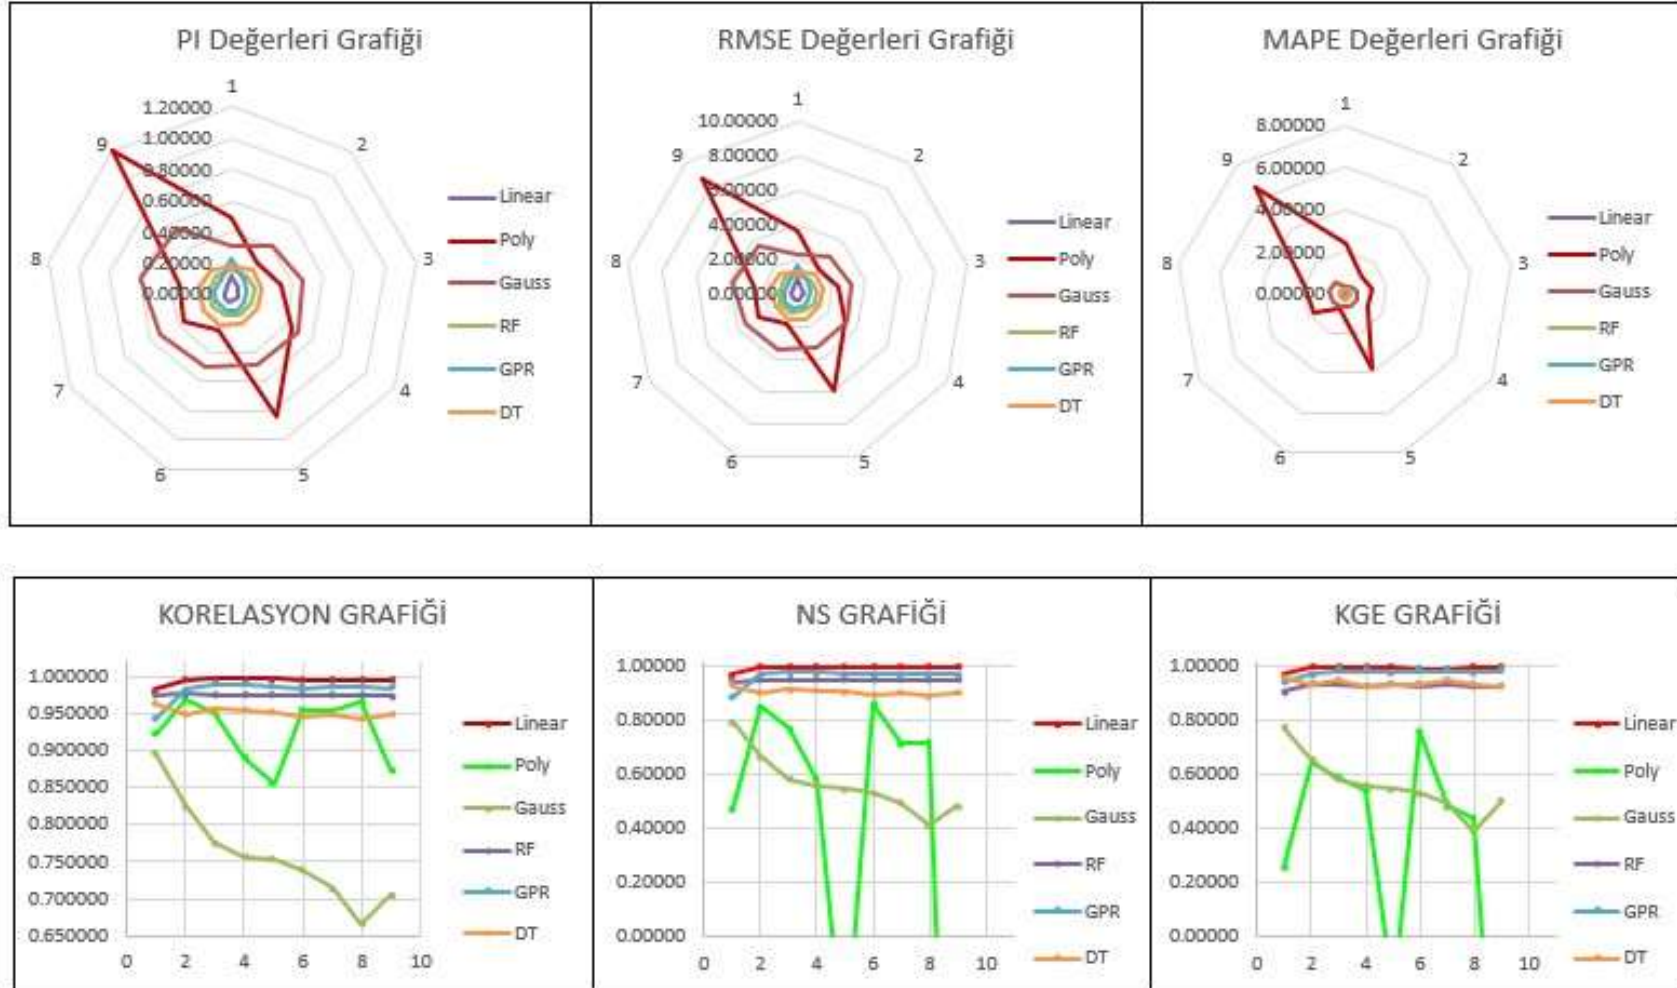
| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|------------|----------|-----------------|----------------|----------------|----------------|----------------|----------------|-----------------|----------------|----------------|----------------|----------------|----------------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| WDVM_Gauss | Model 1 | 0.896305 | 0.79351 | 0.77229 | 0.30772 | 2.25233 | 0.28553 | 0.936703 | 0.85822 | 0.78726 | 0.26389 | 1.96657 | 0.12042 |
| | Model 2 | 0.824956 | 0.66468 | 0.65323 | 0.40746 | 2.87022 | 0.42242 | 0.915023 | 0.79957 | 0.70531 | 0.31731 | 2.33820 | 0.13310 |
| | Model 3 | 0.775573 | 0.58382 | 0.57984 | 0.46656 | 3.19760 | 0.54497 | 0.902658 | 0.76046 | 0.65167 | 0.34916 | 2.55621 | 0.15022 |
| | Model 4 | 0.757082 | 0.55626 | 0.55702 | 0.48683 | 3.30176 | 0.60560 | 0.899136 | 0.74784 | 0.63418 | 0.35890 | 2.62266 | 0.15587 |
| | Model 5 | 0.752912 | 0.54925 | 0.54879 | 0.49183 | 3.32773 | 0.61738 | 0.898131 | 0.74384 | 0.62872 | 0.36192 | 2.64338 | 0.16505 |
| | Model 6 | 0.738482 | 0.52842 | 0.53088 | 0.50724 | 3.40377 | 0.64767 | 0.894781 | 0.73317 | 0.61537 | 0.37004 | 2.69788 | 0.17151 |
| | Model 7 | 0.714186 | 0.49017 | 0.48892 | 0.53489 | 3.53911 | 0.67486 | 0.889239 | 0.71179 | 0.58722 | 0.38570 | 2.80387 | 0.17218 |
| | Model 8 | 0.666302 | 0.40937 | 0.38701 | 0.59226 | 3.80926 | 0.79975 | 0.874172 | 0.66494 | 0.53456 | 0.41921 | 3.02317 | 0.19289 |
| | Model 9 | 0.705681 | 0.48501 | 0.49873 | 0.54027 | 3.55697 | 0.67881 | 0.892203 | 0.72083 | 0.59724 | 0.37901 | 2.75955 | 0.17359 |
| | Model 10 | 0.854977 | 0.71394 | 0.69000 | 0.37025 | 2.65100 | 0.27059 | 0.923960 | 0.82039 | 0.72791 | 0.29899 | 2.21346 | 0.11889 |
| | Model 11 | 0.853732 | 0.71193 | 0.68937 | 0.37180 | 2.66030 | 0.25920 | 0.919765 | 0.81276 | 0.72278 | 0.30594 | 2.26000 | 0.12046 |
| WRO | Model 1 | 0.975018 | 0.94647 | 0.90685 | 0.15043 | 1.14677 | 0.25305 | 0.987630 | 0.97381 | 0.94612 | 0.11052 | 0.84526 | 0.10498 |
| | Model 2 | 0.976625 | 0.95216 | 0.93206 | 0.14209 | 1.08409 | 0.20220 | 0.990027 | 0.97951 | 0.96330 | 0.09763 | 0.74761 | 0.07840 |
| | Model 3 | 0.975365 | 0.94975 | 0.93097 | 0.14572 | 1.11110 | 0.19619 | 0.991154 | 0.98181 | 0.96589 | 0.09195 | 0.70448 | 0.07324 |
| | Model 4 | 0.975878 | 0.95029 | 0.92659 | 0.14490 | 1.10507 | 0.20450 | 0.992029 | 0.98351 | 0.96642 | 0.08749 | 0.67062 | 0.07196 |
| | Model 5 | 0.976349 | 0.95171 | 0.93273 | 0.14278 | 1.08920 | 0.20459 | 0.991701 | 0.98288 | 0.96630 | 0.08917 | 0.68341 | 0.07183 |
| | Model 6 | 0.975567 | 0.94985 | 0.92790 | 0.14556 | 1.11000 | 0.20870 | 0.991071 | 0.98166 | 0.96609 | 0.09233 | 0.70737 | 0.07261 |
| | Model 7 | 0.974809 | 0.94861 | 0.92963 | 0.14741 | 1.12361 | 0.21373 | 0.990587 | 0.98055 | 0.96266 | 0.09510 | 0.72841 | 0.07229 |
| | Model 8 | 0.975992 | 0.95041 | 0.92566 | 0.14471 | 1.10374 | 0.21661 | 0.990636 | 0.98066 | 0.96294 | 0.09483 | 0.72638 | 0.07390 |
| | Model 9 | 0.974390 | 0.94728 | 0.92353 | 0.14934 | 1.13808 | 0.21916 | 0.990759 | 0.98096 | 0.96415 | 0.09408 | 0.72069 | 0.07348 |
| | Model 10 | 0.967253 | 0.93287 | 0.90909 | 0.16913 | 1.28423 | 0.15884 | 0.985508 | 0.97072 | 0.96025 | 0.11698 | 0.89370 | 0.06732 |
| | Model 11 | 0.973293 | 0.94630 | 0.93591 | 0.15080 | 1.14856 | 0.15429 | 0.989718 | 0.97880 | 0.96105 | 0.09933 | 0.76051 | 0.06766 |

Çizelge 4.7. Dalgacık Dönüşümü sonrası GPR ve KA'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri.

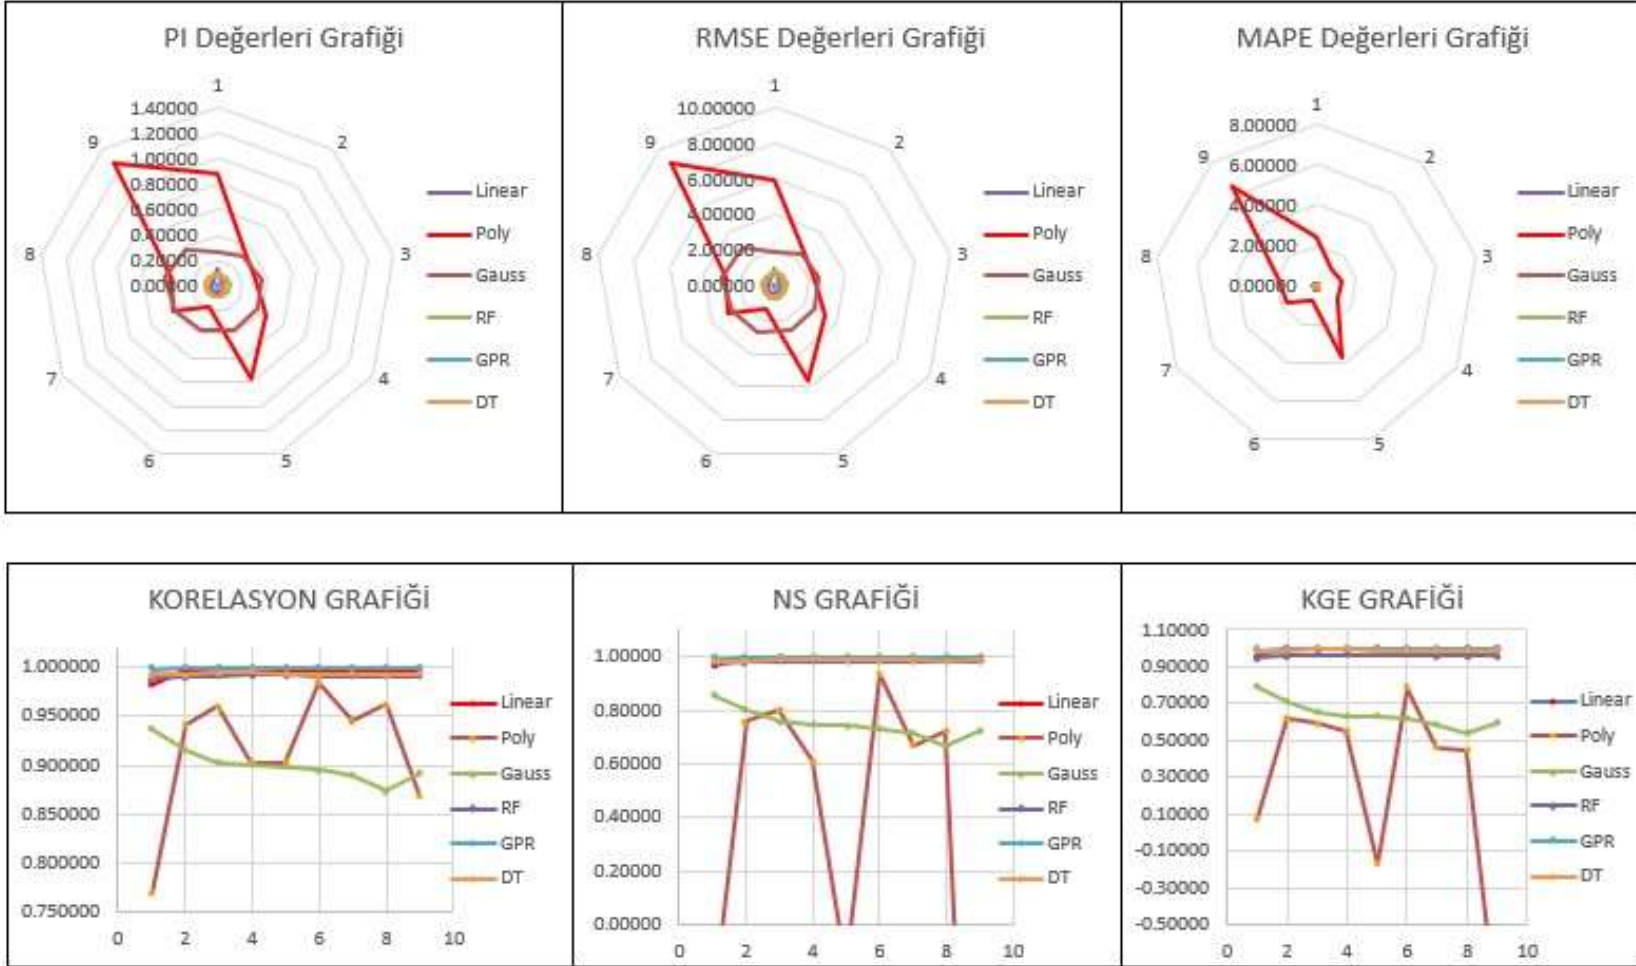
| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|--------|----------|-----------------|----------------|----------------|----------------|----------------|----------------|-----------------|----------------|----------------|----------------|----------------|----------------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| WGPR | Model 1 | 0.943447 | 0.88672 | 0.94099 | 0.22239 | 1.66827 | 0.17552 | 0.999655 | 0.99931 | 0.99929 | 0.01783 | 0.13719 | 0.04404 |
| | Model 2 | 0.984623 | 0.96945 | 0.97379 | 0.11310 | 0.86638 | 0.08961 | 0.999913 | 0.99983 | 0.99982 | 0.00897 | 0.06903 | 0.02643 |
| | Model 3 | 0.990227 | 0.98053 | 0.98305 | 0.09003 | 0.69159 | 0.06577 | 0.999939 | 0.99988 | 0.99988 | 0.00747 | 0.05748 | 0.02107 |
| | Model 4 | 0.989625 | 0.97935 | 0.98430 | 0.09274 | 0.71222 | 0.05896 | 0.999935 | 0.99987 | 0.99987 | 0.00774 | 0.05956 | 0.02168 |
| | Model 5 | 0.985777 | 0.97175 | 0.98046 | 0.10868 | 0.83302 | 0.07438 | 0.999934 | 0.99987 | 0.99986 | 0.00779 | 0.05994 | 0.02390 |
| | Model 6 | 0.984841 | 0.96969 | 0.98368 | 0.11264 | 0.86294 | 0.07734 | 0.999923 | 0.99985 | 0.99984 | 0.00841 | 0.06475 | 0.02562 |
| | Model 7 | 0.985709 | 0.97113 | 0.98325 | 0.10987 | 0.84213 | 0.07565 | 0.999912 | 0.99982 | 0.99981 | 0.00898 | 0.06909 | 0.02656 |
| | Model 8 | 0.985766 | 0.97102 | 0.98102 | 0.11008 | 0.84377 | 0.07890 | 0.999892 | 0.99978 | 0.99975 | 0.00996 | 0.07663 | 0.02661 |
| | Model 9 | 0.984987 | 0.96998 | 0.98429 | 0.11209 | 0.85880 | 0.08382 | 0.999918 | 0.99984 | 0.99982 | 0.00870 | 0.06694 | 0.02717 |
| | Model 10 | 0.966732 | 0.93361 | 0.92796 | 0.16823 | 1.27711 | 0.09937 | 0.999092 | 0.99819 | 0.99849 | 0.02892 | 0.22247 | 0.03839 |
| | Model 11 | 0.971967 | 0.94458 | 0.95134 | 0.15330 | 1.16687 | 0.07477 | 0.999905 | 0.99981 | 0.99980 | 0.00935 | 0.07192 | 0.02490 |
| WKA | Model 1 | 0.963370 | 0.92788 | 0.95684 | 0.17564 | 1.33108 | 0.22585 | 0.991794 | 0.98365 | 0.98839 | 0.08712 | 0.66773 | 0.06752 |
| | Model 2 | 0.949437 | 0.90134 | 0.93054 | 0.20690 | 1.55685 | 0.24694 | 0.992288 | 0.98464 | 0.98909 | 0.08445 | 0.64739 | 0.06531 |
| | Model 3 | 0.956274 | 0.91418 | 0.94852 | 0.19230 | 1.45203 | 0.24266 | 0.994879 | 0.98978 | 0.99276 | 0.06877 | 0.52788 | 0.06418 |
| | Model 4 | 0.954702 | 0.91112 | 0.92652 | 0.19585 | 1.47771 | 0.23848 | 0.995456 | 0.99093 | 0.99357 | 0.06477 | 0.49735 | 0.06142 |
| | Model 5 | 0.951690 | 0.90556 | 0.93193 | 0.20220 | 1.52324 | 0.25252 | 0.993188 | 0.98642 | 0.99037 | 0.07935 | 0.60856 | 0.06079 |
| | Model 6 | 0.945840 | 0.89401 | 0.93312 | 0.21485 | 1.61366 | 0.26300 | 0.992854 | 0.98576 | 0.98989 | 0.08128 | 0.62327 | 0.06213 |
| | Model 7 | 0.950235 | 0.90178 | 0.94733 | 0.20636 | 1.55341 | 0.25326 | 0.993019 | 0.98609 | 0.99013 | 0.08033 | 0.61604 | 0.06159 |
| | Model 8 | 0.943701 | 0.89016 | 0.93058 | 0.21895 | 1.64270 | 0.25291 | 0.992612 | 0.98528 | 0.98955 | 0.08265 | 0.63370 | 0.06105 |
| | Model 9 | 0.950119 | 0.90237 | 0.92116 | 0.20575 | 1.54871 | 0.25674 | 0.993035 | 0.98612 | 0.99015 | 0.08024 | 0.61535 | 0.06304 |
| | Model 10 | 0.908536 | 0.81995 | 0.90463 | 0.28550 | 2.10319 | 0.23212 | 0.992952 | 0.98595 | 0.99003 | 0.08072 | 0.61897 | 0.06090 |
| | Model 11 | 0.945694 | 0.88966 | 0.94358 | 0.21923 | 1.64643 | 0.18947 | 0.994241 | 0.98852 | 0.99186 | 0.07294 | 0.55972 | 0.05833 |

Çizelge 4.8. Dalgacık Dönüşümü sonrası ANN'nin test ve eğitim sürelerinde akım verilerinin tahmin edilen performans değerleri.

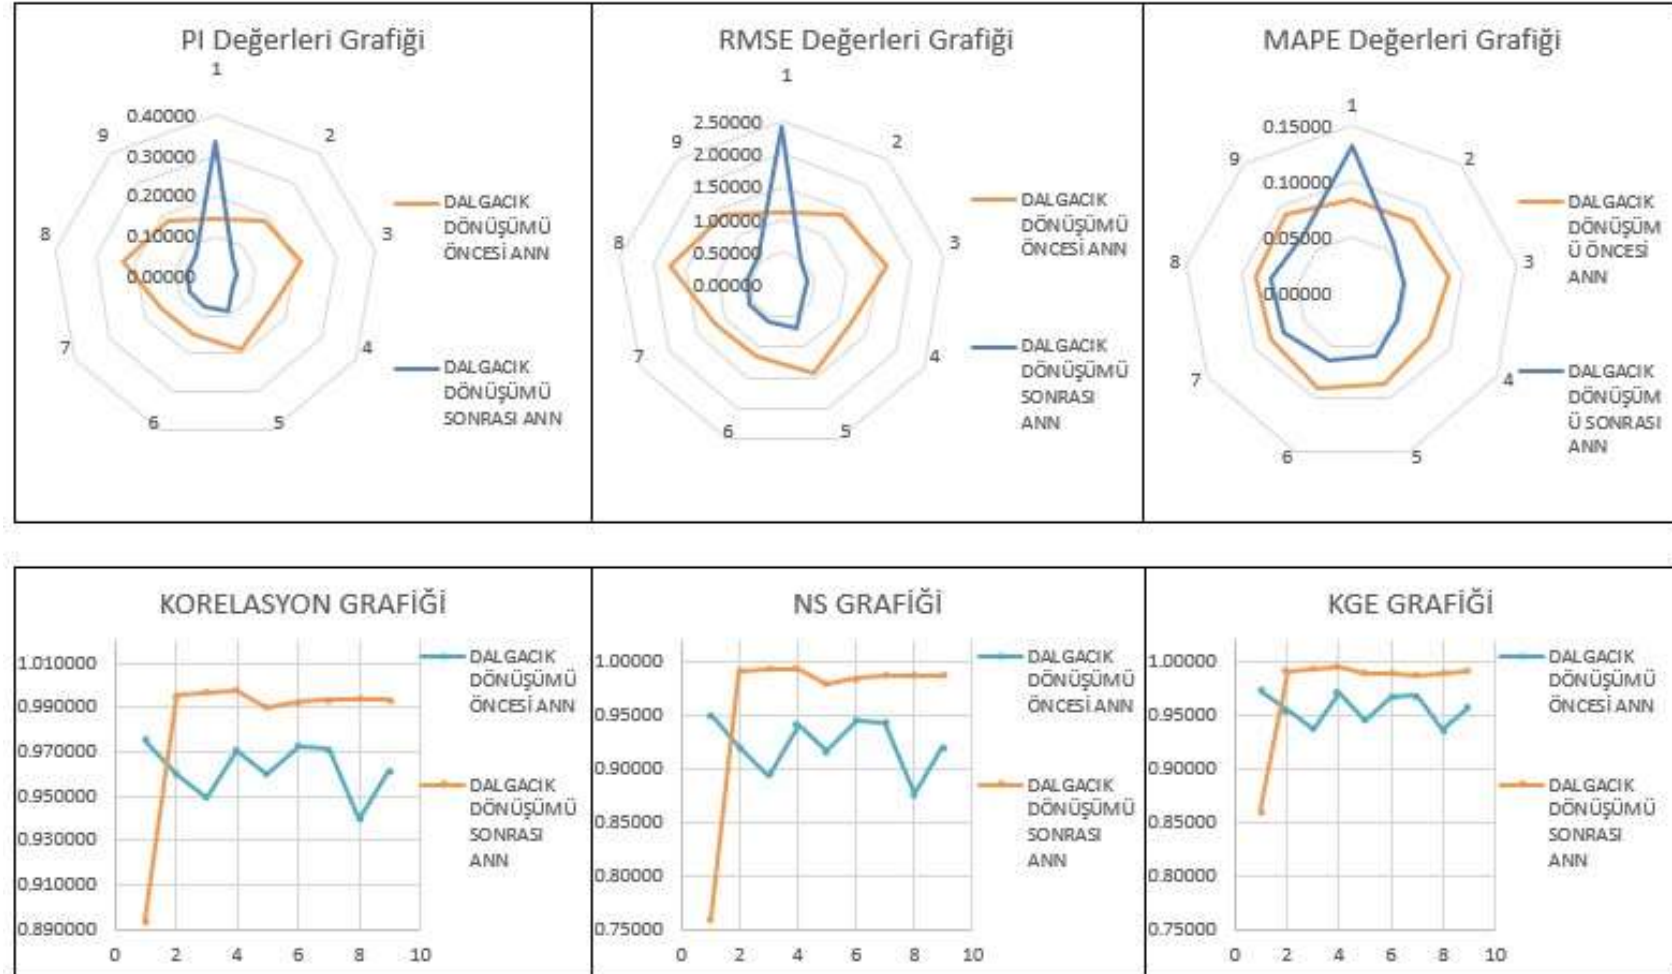
| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|--------|---------|-----------------|----------------|----------------|----------------|----------------|----------------|-----------------|----------------|----------------|----------------|----------------|----------------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| WANN | Model 1 | 0.892785 | 0.75884 | 0.86091 | 0.33316 | 2.43406 | 0.13147 | 0.981090 | 0.96217 | 0.97966 | 0.13327 | 1.01590 | 0.07697 |
| | Model 2 | 0.995571 | 0.99116 | 0.99204 | 0.06051 | 0.46609 | 0.05838 | 0.998670 | 0.99734 | 0.99687 | 0.03503 | 0.26939 | 0.04240 |
| | Model 3 | 0.996735 | 0.99340 | 0.99326 | 0.05225 | 0.40273 | 0.04700 | 0.998844 | 0.99768 | 0.99794 | 0.03270 | 0.25154 | 0.03287 |
| | Model 4 | 0.997210 | 0.99442 | 0.99552 | 0.04802 | 0.37019 | 0.04634 | 0.998735 | 0.99747 | 0.99837 | 0.03418 | 0.26284 | 0.03361 |
| | Model 5 | 0.990138 | 0.98018 | 0.98914 | 0.09083 | 0.69772 | 0.05997 | 0.994394 | 0.98872 | 0.99292 | 0.07227 | 0.55464 | 0.03664 |
| | Model 6 | 0.992503 | 0.98487 | 0.99010 | 0.07927 | 0.60966 | 0.06337 | 0.995856 | 0.99163 | 0.99304 | 0.06220 | 0.47769 | 0.03862 |
| | Model 7 | 0.993405 | 0.98683 | 0.98784 | 0.07394 | 0.56892 | 0.07102 | 0.997781 | 0.99554 | 0.99496 | 0.04536 | 0.34866 | 0.04314 |
| | Model 8 | 0.994082 | 0.98805 | 0.99014 | 0.07039 | 0.54179 | 0.07296 | 0.997867 | 0.99570 | 0.99502 | 0.04457 | 0.34263 | 0.04311 |
| | Model 9 | 0.993502 | 0.98704 | 0.99210 | 0.07333 | 0.56427 | 0.06764 | 0.998308 | 0.99661 | 0.99532 | 0.03954 | 0.30400 | 0.04273 |



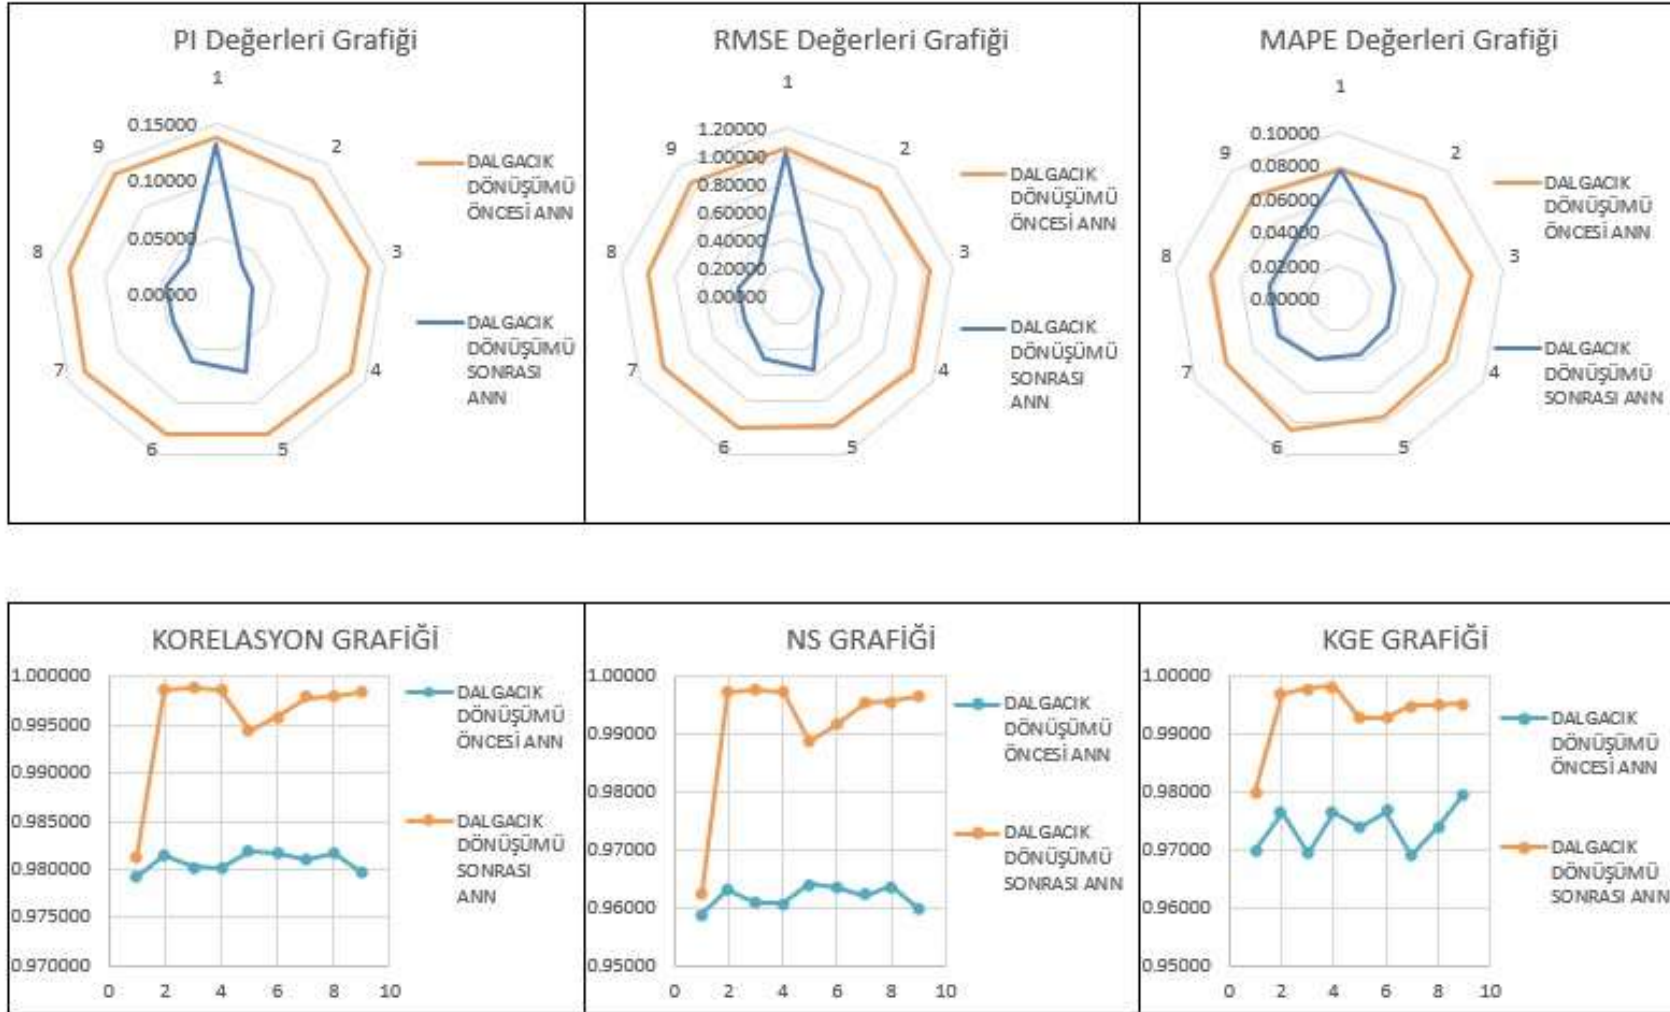
Şekil 4.3. Dalgacık Dönüşümü sonrası test verilerinin çeşitli istatistiksel kriterlere göre performansları.



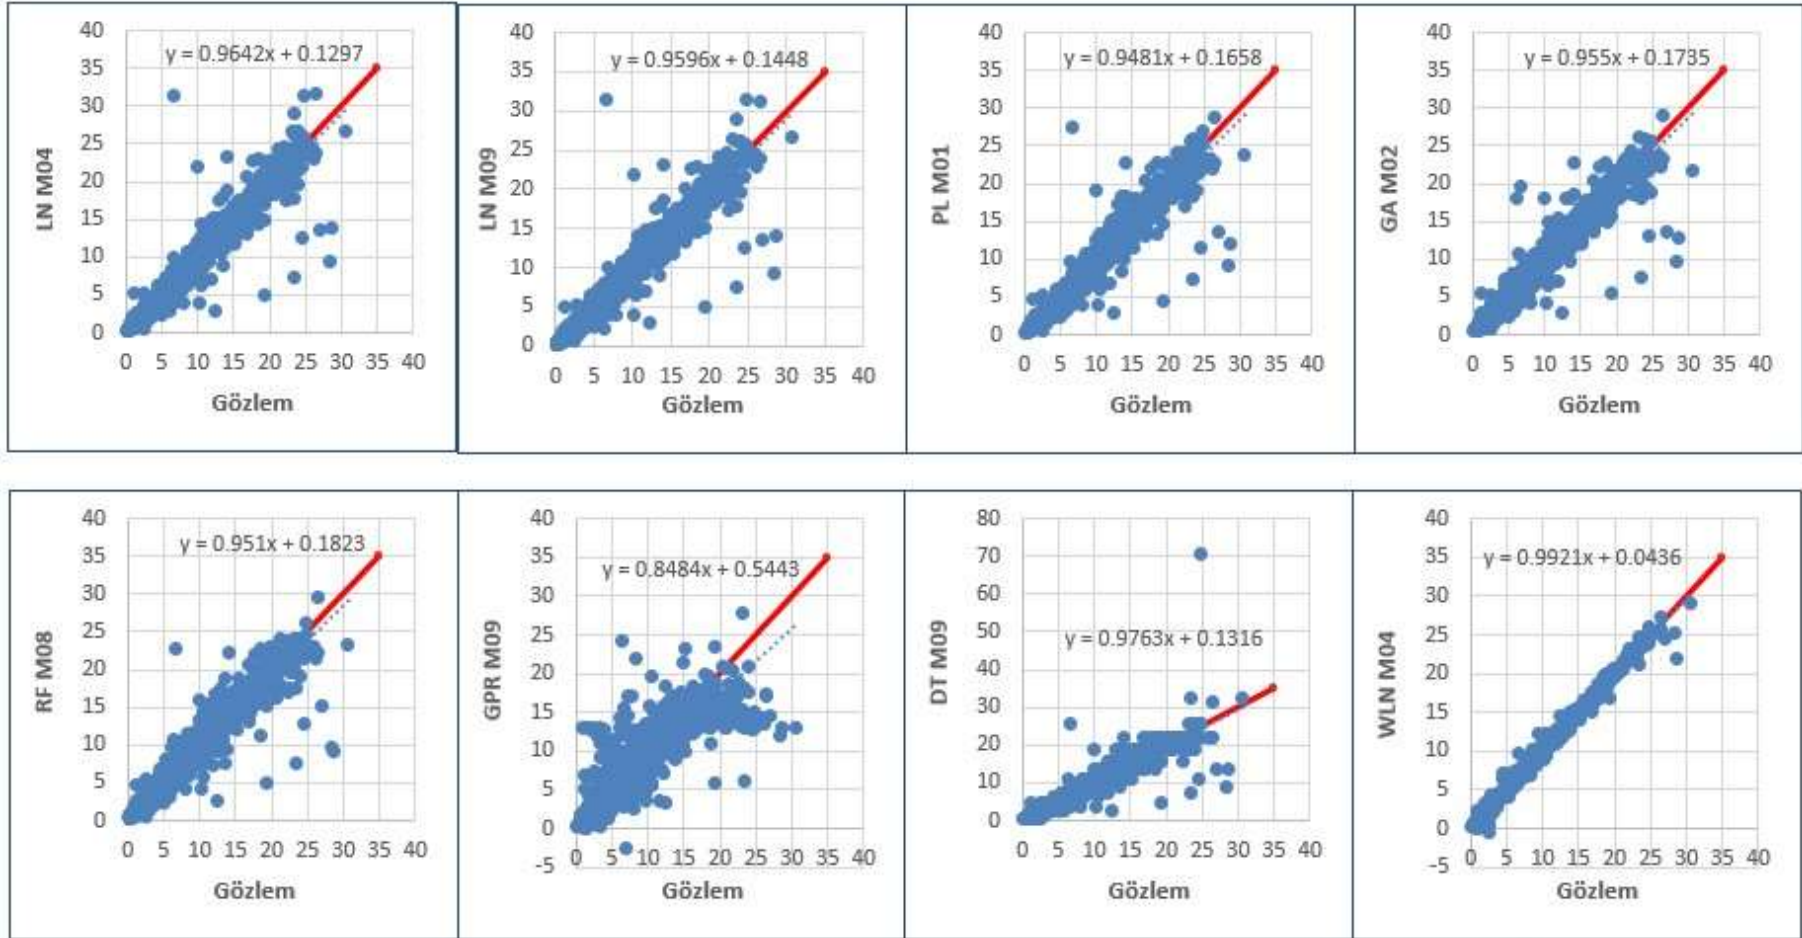
Şekil 4.4. Dalgacık Dönüşümü sonrası eğitim verilerinin çeşitli istatistiksel kriterlere göre performansları.



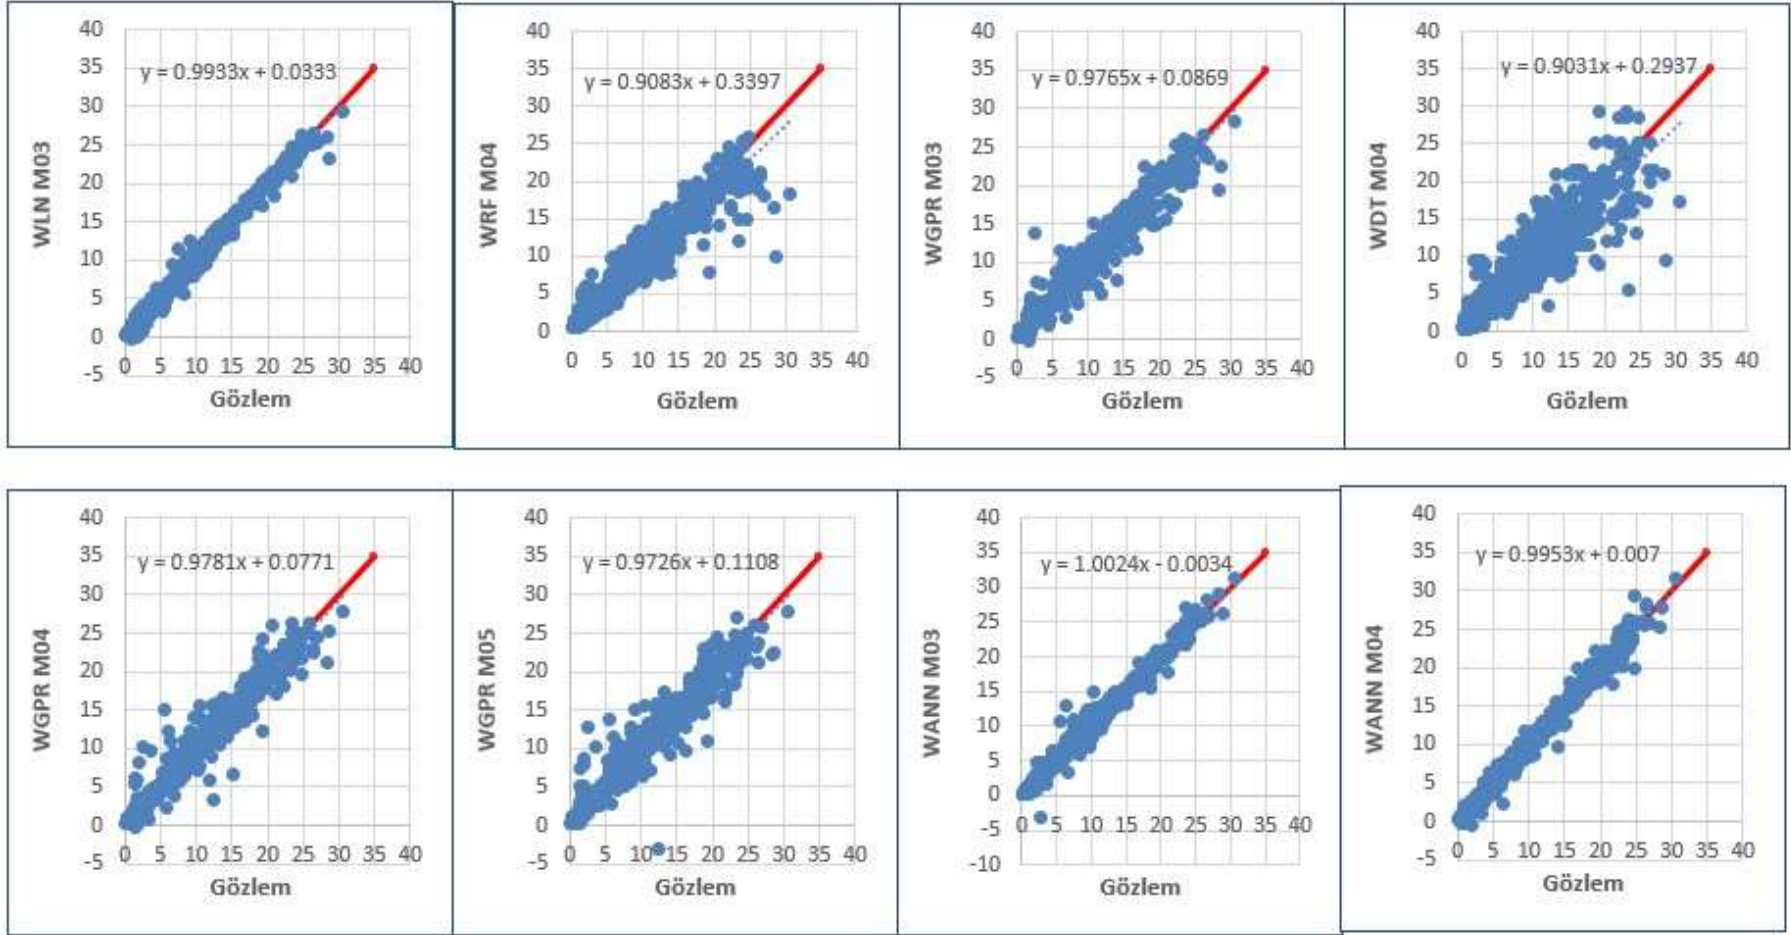
Şekil 4.5. Yapay sinir ağı ANN metoduyla test verilerinin çeşitli istatistiksel kriterlere göre performansları.



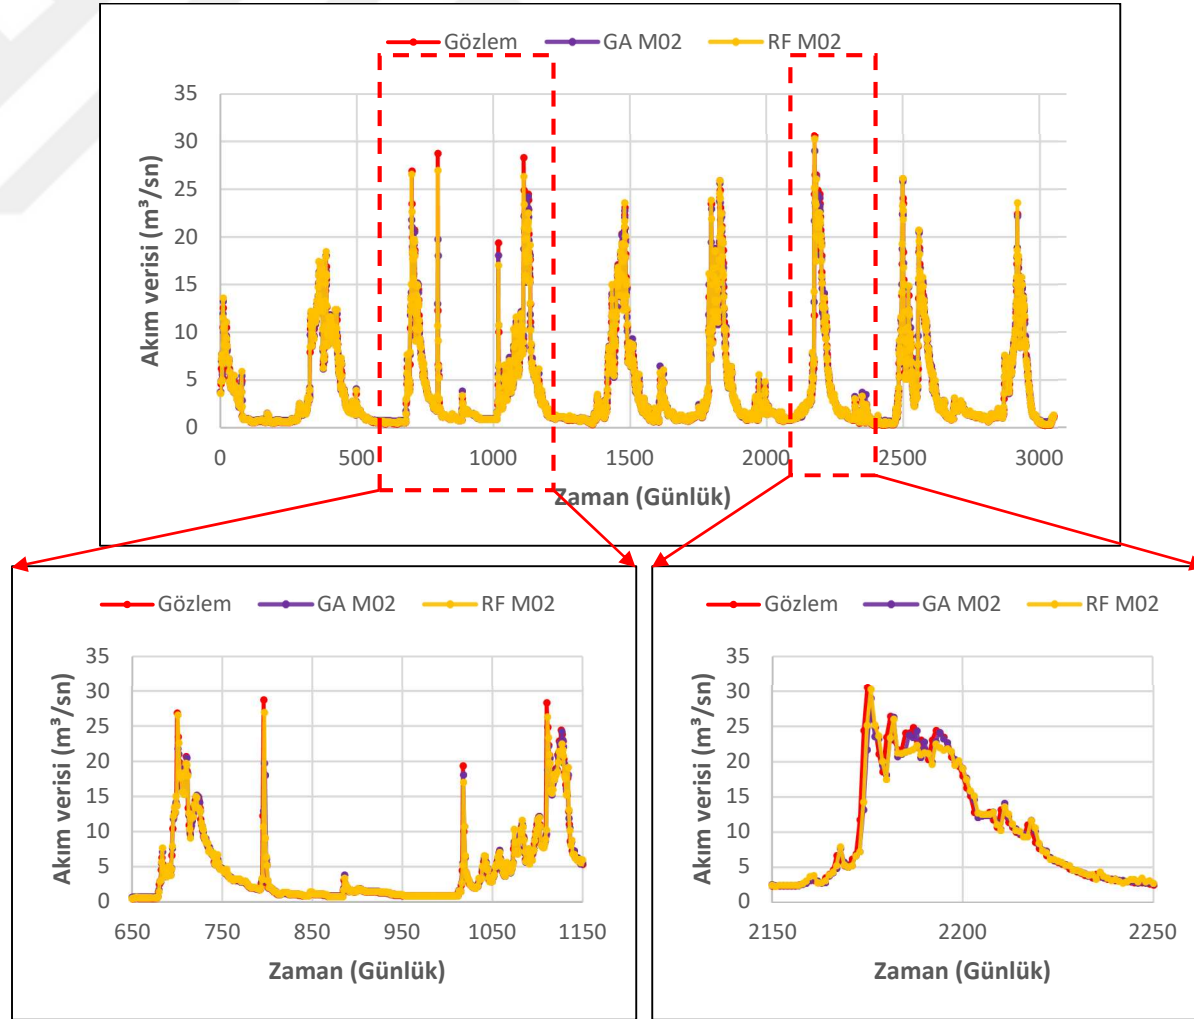
Şekil 4.6. Yapay sinir ağıları ANN metoduyla eğitim verilerinin çeşitli istatistiksel kriterlere göre performansları.



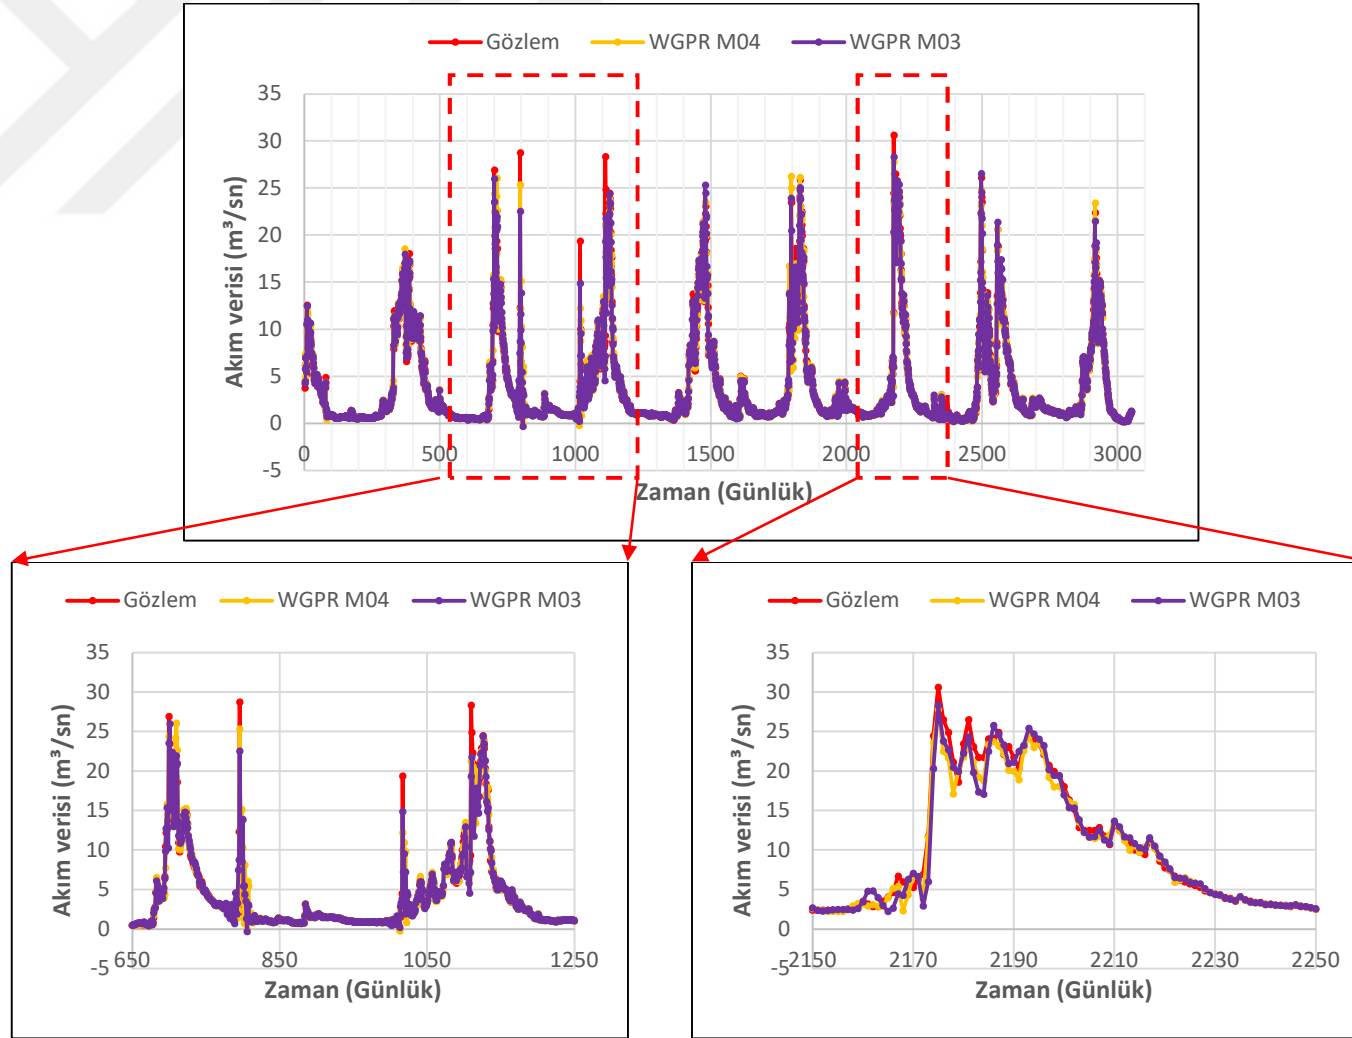
Şekil 4.7. Dalgacık dönüşümü öncesi ve dalgacık dönüşümü sonrası test veri seti için en iyi modellerin saçılma grafiklerinin karşılaştırılması. Kırmızı renk ile verilen çizgi 1:1 (450'lik) simetri çizgisidir.



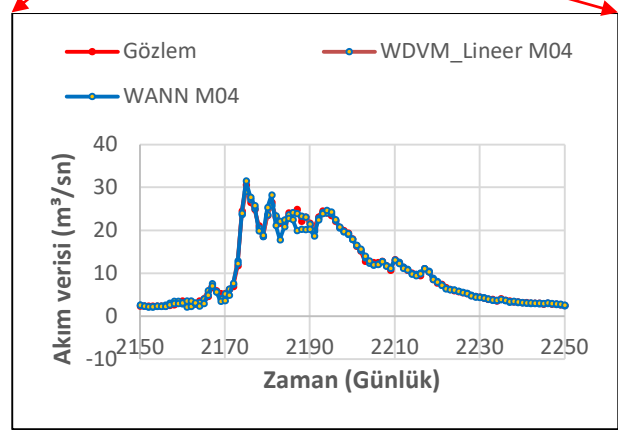


Şekil 4.8. Dalgacık dönüşümü öncesi ve dalgacık dönüşümü sonrası test veri seti için en iyi modellerin saçılma grafiklerinin karşılaştırılması. Kırmızı renk ile verilen çizgi 1:1 (450'lik) simetri çizgisidir.




Şekil 4.9. Dalgacık dönüşümü öncesi GA M02 ve RF M02 model karşılaştırılması.




Şekil 4.10. GPR metodunda gözlenmiş veri ile dalgacık dönüşümü sonrası WM03 ve WM04 model karşılaştırılması.



Şekil 4.11. En iyi modellerden olan WDV_M_Lineer M04 ve WANN M04 model karşılaştırılması.



Şekil 4.12. Modellere ait Violin (Keman) grafikleri.



Şekil 4.13. Modellere ait Taylor grafiği.

Çizelge 4.9. NSE kriterine göre en iyi modellerin sıralaması.

| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|-------------|----------|------------|---------|---------|---------|---------|---------|------------|---------|---------|---------|---------|---------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| WDVM_Lineer | Model 04 | 0.99813 | 0.99624 | 0.99282 | 0.03940 | 0.30386 | 0.05553 | 0.99768 | 0.99535 | 0.99279 | 0.04632 | 0.35605 | 0.04776 |
| WDVM_Lineer | Model 03 | 0.99790 | 0.99580 | 0.99461 | 0.04167 | 0.32134 | 0.05051 | 0.99754 | 0.99508 | 0.99586 | 0.04765 | 0.36626 | 0.04219 |
| WDVM_Lineer | Model 05 | 0.99724 | 0.99448 | 0.99291 | 0.04776 | 0.36822 | 0.06545 | 0.99692 | 0.99384 | 0.99302 | 0.05335 | 0.40991 | 0.05306 |
| WANN | Model 04 | 0.99721 | 0.99442 | 0.99552 | 0.04802 | 0.37019 | 0.04634 | 0.99874 | 0.99747 | 0.99837 | 0.03418 | 0.26284 | 0.03361 |
| WDVM_Lineer | Model 06 | 0.99707 | 0.99412 | 0.99151 | 0.04930 | 0.38003 | 0.07740 | 0.99684 | 0.99367 | 0.99095 | 0.05410 | 0.41569 | 0.06359 |
| WDVM_Lineer | Model 09 | 0.99700 | 0.99400 | 0.99364 | 0.04980 | 0.38388 | 0.05867 | 0.99679 | 0.99360 | 0.99447 | 0.05440 | 0.41795 | 0.04716 |
| WDVM_Lineer | Model 02 | 0.99699 | 0.99398 | 0.99314 | 0.04989 | 0.38455 | 0.05863 | 0.99679 | 0.99359 | 0.99391 | 0.05441 | 0.41802 | 0.04714 |
| WDVM_Lineer | Model 08 | 0.99695 | 0.99389 | 0.99273 | 0.05026 | 0.38744 | 0.06655 | 0.99678 | 0.99356 | 0.99341 | 0.05454 | 0.41902 | 0.05505 |
| WDVM_Lineer | Model 07 | 0.99693 | 0.99383 | 0.98925 | 0.05052 | 0.38942 | 0.08330 | 0.99677 | 0.99349 | 0.98875 | 0.05484 | 0.42136 | 0.07017 |
| WANN | Model 03 | 0.99673 | 0.99340 | 0.99326 | 0.05225 | 0.40273 | 0.04700 | 0.99884 | 0.99768 | 0.99794 | 0.03270 | 0.25154 | 0.03287 |
| WANN | Model 02 | 0.99557 | 0.99116 | 0.99204 | 0.06051 | 0.46609 | 0.05838 | 0.99867 | 0.99734 | 0.99687 | 0.03503 | 0.26939 | 0.04240 |
| WANN | Model 08 | 0.99408 | 0.98805 | 0.99014 | 0.07039 | 0.54179 | 0.07296 | 0.99787 | 0.99570 | 0.99502 | 0.04457 | 0.34263 | 0.04311 |
| WANN | Model 09 | 0.99350 | 0.98704 | 0.99210 | 0.07333 | 0.56427 | 0.06764 | 0.99831 | 0.99661 | 0.99532 | 0.03954 | 0.30400 | 0.04273 |
| WANN | Model 07 | 0.993405 | 0.98683 | 0.98784 | 0.07394 | 0.56892 | 0.07102 | 0.997781 | 0.99554 | 0.99496 | 0.04536 | 0.34866 | 0.04314 |

Çizelge 4.10. KGE kriterine göre en iyi modellerin sıralaması.

| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|-------------|----------|------------|----------------|----------------|----------------|---------|---------|----------------|----------------|----------------|----------------|---------|---------|
| | | KORELASYON | NSE | KGE | PI | RMSE | MAPE | KORELASYON | NSE | KGE | PI | RMSE | MAPE |
| WANN | Model 04 | 0.99721 | 0.99442 | 0.99552 | 0.04802 | 0.37019 | 0.04634 | 0.99874 | 0.99747 | 0.99837 | 0.03418 | 0.26284 | 0.03361 |
| WDVM_Lineer | Model 03 | 0.99790 | 0.99580 | 0.99461 | 0.04167 | 0.32134 | 0.05051 | 0.99754 | 0.99508 | 0.99586 | 0.04765 | 0.36626 | 0.04219 |
| WDVM_Lineer | Model 09 | 0.99700 | 0.99400 | 0.99364 | 0.04980 | 0.38388 | 0.05867 | 0.99679 | 0.99360 | 0.99447 | 0.05440 | 0.41795 | 0.04716 |
| WANN | Model 03 | 0.99673 | 0.99340 | 0.99326 | 0.05225 | 0.40273 | 0.04700 | 0.99884 | 0.99768 | 0.99794 | 0.03270 | 0.25154 | 0.03287 |
| WDVM_Lineer | Model 02 | 0.99699 | 0.99398 | 0.99314 | 0.04989 | 0.38455 | 0.05863 | 0.99679 | 0.99359 | 0.99391 | 0.05441 | 0.41802 | 0.04714 |
| WDVM_Lineer | Model 05 | 0.99724 | 0.99448 | 0.99291 | 0.04776 | 0.36822 | 0.06545 | 0.99692 | 0.99384 | 0.99302 | 0.05335 | 0.40991 | 0.05306 |
| WDVM_Lineer | Model 04 | 0.99813 | 0.99624 | 0.99282 | 0.03940 | 0.30386 | 0.05553 | 0.99768 | 0.99535 | 0.99279 | 0.04632 | 0.35605 | 0.04776 |
| WDVM_Lineer | Model 08 | 0.99695 | 0.99389 | 0.99273 | 0.05026 | 0.38744 | 0.06655 | 0.99678 | 0.99356 | 0.99341 | 0.05454 | 0.41902 | 0.05505 |
| WANN | Model 09 | 0.99350 | 0.98704 | 0.99210 | 0.07333 | 0.56427 | 0.06764 | 0.99831 | 0.99661 | 0.99532 | 0.03954 | 0.30400 | 0.04273 |
| WANN | Model 02 | 0.99557 | 0.99116 | 0.99204 | 0.06051 | 0.46609 | 0.05838 | 0.99867 | 0.99734 | 0.99687 | 0.03503 | 0.26939 | 0.04240 |
| WDVM_Lineer | Model 06 | 0.99707 | 0.99412 | 0.99151 | 0.04930 | 0.38003 | 0.07740 | 0.99684 | 0.99367 | 0.99095 | 0.05410 | 0.41569 | 0.06359 |
| WANN | Model 08 | 0.99408 | 0.98805 | 0.99014 | 0.07039 | 0.54179 | 0.07296 | 0.99787 | 0.99570 | 0.99502 | 0.04457 | 0.34263 | 0.04311 |
| WANN | Model 06 | 0.99250 | 0.98487 | 0.99010 | 0.07927 | 0.60966 | 0.06337 | 0.99586 | 0.99163 | 0.99304 | 0.06220 | 0.47769 | 0.03862 |
| WDVM_Lineer | Model 07 | 0.99693 | 0.99383 | 0.98925 | 0.05052 | 0.38942 | 0.08330 | 0.99677 | 0.99349 | 0.98875 | 0.05484 | 0.42136 | 0.07017 |
| WANN | Model 07 | 0.99341 | 0.98683 | 0.98784 | 0.07394 | 0.56892 | 0.07102 | 0.99778 | 0.99554 | 0.99496 | 0.04536 | 0.34866 | 0.04314 |
| WGPR | Model 03 | 0.99023 | 0.98053 | 0.98305 | 0.09003 | 0.69159 | 0.06577 | 0.99994 | 0.99988 | 0.99988 | 0.00747 | 0.05748 | 0.02107 |

Çizelge 4.9’da verilen NSE kriterine göre; oluşturulan en iyi modeller sıralamasında Dalgacık dönüşümü sonrasında Destek Vektörleri Makinesi fonksiyonlarından olan Lineer yönteminin en iyi model olduğu görülmüştür. Daha sonrasında yine Dalgacık dönüşümü sonrası ayrıştırılan Yapay Sinir Ağları metodu en iyi modelleri vermiştir. Sonuçlar kıyaslandığında Destek Vektör Makinesi-Lineer metodundan en iyi modeli ise Model 4’ten elde edilmiştir.

Çizelge 4.10’da verilen KGE kriterine göre; en iyi modeller sıralamasında Dalgacık Dönüşümü sonrasında Yapay Sinir Ağları yönteminden elde edilmiştir. Yapay Sinir Ağları metoduna göre ise en iyi model Model 4 bulunmuştur.

Çizelge 4.11’de ise Dalgacık Dönüşümü öncesi ve sonrasında elde edilen iyileşme yüzdeleri gösterilmektedir. Test aşamasında en iyi iyileşme Yapay Sinir Ağları metodundan elde edilirken eğitim aşamasında ise Dalgacık Dönüşümü ile ayrıştırıldıktan sonra en iyi iyileşmenin DVM_Lineer Kernel fonksiyonunda olduğu gözlemlenmiştir.

Çizelge 4.11. En iyi modellerin Dalgacık Dönüşümü sonrasında iyileşme yüzdeleri.

| YÖNTEM | MODEL | TEST | | | | | | EĞİTİM | | | | | |
|------------|---------|----------------------|-----------------------|--------------|----------------------|-----------------------|-------------|----------------------|-----------------------|-------------|----------------------|-----------------------|-------------|
| | | DAL. DÖN. ÖNCESİ NSE | DAL. DÖN. SONRASI NSE | İYİLEŞME | DAL. DÖN. ÖNCESİ KGE | DAL. DÖN. SONRASI KGE | İYİLEŞME | DAL. DÖN. ÖNCESİ NSE | DAL. DÖN. SONRASI NSE | İYİLEŞME | DAL. DÖN. ÖNCESİ KGE | DAL. DÖN. SONRASI KGE | İYİLEŞME |
| DVM_Lineer | Model 4 | 0.94947 | 0.99624 | 4.9% | 0.97233 | 0.99282 | 2.1% | 0.93924 | 0.99535 | 6.0% | 0.96795 | 0.99279 | 2.6% |
| DVM_Lineer | Model 3 | 0.9498 | 0.99580 | 4.8% | 0.97019 | 0.99461 | 2.5% | 0.93954 | 0.99508 | 5.9% | 0.96625 | 0.99586 | 3.1% |
| DVM_Lineer | Model 5 | 0.94977 | 0.99448 | 4.7% | 0.97224 | 0.99291 | 2.1% | 0.93954 | 0.99384 | 5.8% | 0.96787 | 0.99302 | 2.6% |
| ANN | Model 4 | 0.94148 | 0.99442 | 5.6% | 0.97071 | 0.99552 | 2.6% | 0.96071 | 0.99747 | 3.8% | 0.97648 | 0.99837 | 2.2% |
| DVM_Lineer | Model 6 | 0.94983 | 0.99412 | 4.7% | 0.97044 | 0.99151 | 2.2% | 0.93962 | 0.99367 | 5.8% | 0.96647 | 0.99095 | 2.5% |
| DVM_Lineer | Model 9 | 0.95013 | 0.99400 | 4.6% | 0.97022 | 0.99364 | 2.4% | 0.94010 | 0.99360 | 5.7% | 0.96665 | 0.99447 | 2.9% |
| DVM_Lineer | Model 2 | 0.94973 | 0.99398 | 4.7% | 0.97178 | 0.99314 | 2.2% | 0.93950 | 0.99359 | 5.8% | 0.96744 | 0.99391 | 2.7% |
| DVM_Lineer | Model 8 | 0.94982 | 0.99389 | 4.6% | 0.97246 | 0.99273 | 2.1% | 0.93963 | 0.99356 | 5.7% | 0.96796 | 0.99341 | 2.6% |
| DVM_Lineer | Model 7 | 0.94984 | 0.99383 | 4.6% | 0.97136 | 0.98925 | 1.8% | 0.93961 | 0.99349 | 5.7% | 0.96695 | 0.98875 | 2.3% |
| ANN | Model 3 | 0.89396 | 0.99340 | 11.1% | 0.93805 | 0.99326 | 5.9% | 0.96078 | 0.99768 | 3.8% | 0.96953 | 0.99794 | 2.9% |
| ANN | Model 2 | 0.92102 | 0.99116 | 7.6% | 0.95530 | 0.99204 | 3.8% | 0.96323 | 0.99734 | 3.5% | 0.97655 | 0.99687 | 2.1% |
| ANN | Model 8 | 0.87642 | 0.98805 | 12.7% | 0.93649 | 0.99014 | 5.7% | 0.96369 | 0.99570 | 3.3% | 0.97395 | 0.99502 | 2.2% |
| ANN | Model 9 | 0.9213 | 0.98704 | 7.1% | 0.95837 | 0.99210 | 3.5% | 0.95964 | 0.99661 | 3.9% | 0.97930 | 0.99532 | 1.6% |
| ANN | Model 7 | 0.9428 | 0.98683 | 4.7% | 0.96978 | 0.98784 | 1.9% | 0.96212 | 0.99554 | 3.5% | 0.96914 | 0.99496 | 2.7% |
| ANN | Model 6 | 0.94622 | 0.98487 | 4.1% | 0.96768 | 0.99010 | 2.3% | 0.96359 | 0.99163 | 2.9% | 0.97663 | 0.99304 | 1.7% |
| GPR | Model 3 | 0.95902 | 0.98053 | 2.2% | 0.94227 | 0.98305 | 4.3% | 0.98536 | 0.99988 | 1.5% | 0.98839 | 0.99988 | 1.2% |

5. SONUÇLAR ve ÖNERİLER

Bu tez çalışmasında günlük akım verilerinin modellenmesi araştırılmıştır. Bu amaçla son yıllarda geliştirilmiş ve literatürde en çok tercih edilen yöntemler arasından seçilmiş olan makine öğrenmesi yöntemlerinden Destek Vektör Makinesi (DVM), Gauss Süreci Regresyon Analizi (GPR), Karar Ağaçları (KA), Rastgele Orman (RO) ve Yapay Sinir Ağları (ANN) kullanılmış ve günlük akım verilerine bağlı modeller geliştirilmiştir. Çalışmanın birinci kısmında bu modellerin seçilmiş makine öğrenmesi yöntemleri ile yapılan analizleri sonucu günlük akımları tahmin eden en iyi modeller araştırılmıştır. Çalışmanın ikinci kısmında ise veriler dalgacık dönüşümü kullanılarak ayrıştırılmış ve elde edilen ayrıştırılmış veriler birinci kısımda elde edilen en iyi model sonuçlarının iyileştirilmesinde kullanılmıştır. Dalgacık ayrıştırmasının model performanslarına oldukça olumlu katkı sağladığı görülmüştür. Günlük akım verilerinin farklı zaman gecikmeleri ile dokuz farklı model oluşturulmuştur. Elde edilen modellerin iyileştirilmesi için dalgacık dönüşümü olarak daubechies 45 (db45) dalgacık fonksiyonu ile 5 seviye dalgacık dönüşümü kullanılmış ve model sonuçlarında yaklaşık %5 oranında iyileşme görülmüştür. Daha detaylı modellerin iyileşme yüzdeleri ise Çizelge 4.11’de verilmiştir.

NSE kriterine göre en iyi modeller Destek Vektörleri Makinesi-Linear fonksiyonundan elde edilmiştir. DVM-Linear fonksiyonu ile araştırılan modeller arasında ise Model 4’ün en iyi sonucu verdiği görülmüştür. Değerlendirme kriteri olarak KGE kullanıldığında Yapay Sinir Ağları metodu ön plana çıkmıştır. Yapay Sinir Ağları metodunda ise yine Model 4 en iyi sonucu vermiştir. NSE kriterinin en iyi model sıralaması Çizelge 4.9’da KGE kriterinin en iyi model sıralaması ise Çizelge 4.10’da verilmiştir. Buna göre araştırılan modeller arasında Model 4 (Q_{t-1} , Q_{t-2} , Q_{t-5})’ün diğer modellerden daha iyi sonuç verdiği gözlemlenmiştir.

Günlük akarsu akım değerlerinin modellenmesinde kullanılan Gauss Süreci Regresyon Analizi (GPR), Destek Vektör Makinesi (DVM) , Karar Ağaçları (KA) ve Rastgele Orman (RO) karşılaştırıldığında en iyi sonuçların Destek Vektörleri Makinesi (Linear fonksiyonu), Yapay Sinir Ağları ve Gauss Süreci Regresyon Analizi fonksiyonlarından elde edildiği görülmüştür. Dalgacık dönüşümü kullanılarak oluşturulan modellerde ise yine aynı yöntemlerin iyi performans gösterdiği gözlemlenmiştir. Destek Vektörleri Makinesi fonksiyonlarından Polinom ve Gauss

yöntemlerinin Dalgacık Dönüşümü ile ayrıştırıldıktan sonra iyileşme olmadığı diğer tüm yöntemlerde ise iyileşme olduğu gözlemlenmiştir.

Günlük akarsu akım modellerinde dalgacık dönüşümünün DVM Lineer fonksiyonunda, Yapay Sinir ağlarında ve Gauss Süreci Regresyon Analizi fonksiyonu ile hesaplanan modellerinde kullanılmasının model performansını artıracığı bu çalışma ile elde edilen en önemli sonuçtur.



KAYNAKLAR

- Achite, M., Jehanzaib, M., Elshaboury, N., & Kim, T. W., 2022. Evaluation of machine learning techniques for hydrological drought modeling: A case study of the Wadi Ouahrane basin in Algeria. *Water*, 14(3), 431.
- Ahmadi, F., Mehdizadeh, S., & Mohammadi, B., 2021. Development of bio-inspired and wavelet-based hybrid models for reconnaissance drought index modeling. *Water Resources Management*, 35(12), 4127-4147.
- Ak, Büşra (2021) Nehirdeki Akış Miktarının Destek Vektörleri Makineleri ve Bulanık Mantık Yöntemleri İle Modellenmesi.
- Aldoori, Sinan Jasim Hadi., 2018. Improving data-driven based streamflow forecasting using wavelet transformation. Diss. Anadolu University (Turkey).
- Allawi, M. F., Binti Othman, F., Afan, H. A., Ahmed, A. N., Hossain, M., Fai, C. M. ve El-Shafie, A., 2019. Reservoir evaporation prediction modeling based on artificial intelligence methods, *Water*, 11(6), 1226.
- Albostan, A., & Önöz, B., 2015. Günlük Akarsu Akımlarının Kaotik Analizinde Dalgacık Yaklaşımının Uygulanması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 30(1).
- Aydoğan Culha, Ü., 2015. Yüksek boyut düşük örneklem genişliği durumunda sınıflama algoritmalarının performanslarının karşılaştırılması. Doktora Tezi Hacettepe Üniversitesi
- Başakın, E., Ekmekcioğlu, Ö., Özger, M., 2019. Makine öğrenmesi yöntemleri ile kuraklık analizi, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 25(8), 985-991.
- Beven, K. J., 2012. Yağış-akış modellemesi: başlangıç . John Wiley & Sons.
- Bishop, Christopher M., 2007. *Pattern Recognition and Machine Learning (Information Science and Statistics)* Springer-Verlag New York Inc.; Newer (Colored) basım
- Breiman, L., 1996. Bagging predictors. *Machine Learning*, 24(2), 123-140.
- Breiman, L., 2002. *Manual on setting up, using, and understanding random forests*. Berkeley: Statistics Department University of California Berkeley.
- Choubin, B., Malekian, A. ve Golshan, M., 2016. Application of several data-driven techniques to predict a standardized precipitation index. *Atmosfera*, 29(2), 121-128.
- Cristianini, N., Shawe-Taylor, J., 2000. *An Introduction to Support Vector Machines and Other Kernel-based Learning methods*, Cambridge University Press.

- Çatar, F.D., 2021. Kısa dönem kuraklık analizi. Yüksek Lisans Tezi, Aksaray Üniversitesi, Fen Bilimleri Enstitüsü, Aksaray.
- Çıtakoğlu, H., & Coşkun, Ö., 2021. Dalgacık Dönüşüm Modelli Yapay Zekâ Teknikleri Kullanılarak Orta Anadolu Bölge İstasyonlarının Yağış Tahmini. Harran Üniversitesi Mühendislik Dergisi, 6(1), 39-54.
- Çıtakoglu, H., & Coşkun, Ö., 2022. Comparison of hybrid machine learning methods for the prediction of short-term meteorological droughts of Sakarya Meteorological Station in Turkey. Environmental Science and Pollution Research, 29(50), 75487-75511.
- Çubukçu, E. A., Demir, V., & Sevimli, M. F., 2022. Estimating streamflow data with machine learning techniques. Gazi Journal of Engineering Sciences, 8(2), 257-272.
- Demir, H. N., Korkmaz, M. S., & Arıman, S., 2023. Akım Gözlem İstasyonlarında ANFIS Yöntemi ile Günlük Ortalama Debi Tahmini: Kızılırmak Örneği. Journal of the Institute of Science and Technology, 13(4), 2565-2582.
- Deo, R. C., Kisi, O. ve Singh, V. P., 2017. Drought forecasting in eastern Australia using multivariate adaptive regression spline, least square support vector machine and M5Tree model. Atmospheric Research, 184, 149-175.
- Difi, S., Elmeddahi, Y., Hebal, A., Singh, V. P., Heddami, S., Kim, S. ve Kisi, O., 2022. Monthly streamflow prediction using hybrid extreme learning machine optimized by bat algorithm: a case study of Cheliff watershed, Algeria. Hydrological Sciences Journal, 1-20.
- Drucker, H., Burges, C.J.C., Kaufman, L., Smola, A., 1997. Advances in Neural Information Processing Systems 28(7):779-784
- Dursun, Ö., & Karabatak, M., 2009. The Estimation Of Missing Flow Records By Correlation And Neural Networks In Fırat Basin. Engineering Sciences, 4(1), 30-40.
- Elbeltagi, A., Pande, C. B., Kumar, M., Tolche, A. D., Singh, S. K., Kumar, A. ve Vishwakarma, D. K., 2023. Prediction of meteorological drought and standardized precipitation index based on the random forest (RF), random tree (RT), and Gaussian process regression (GPR) models. Environmental Science and Pollution Research, 1-20.
- Erkek, C., ve Ağırlioğlu N., 2008. Su Kaynakları Mühendisliği, Beta Yayınevi, İstanbul.
- Ersöz, A., Özşen, S., 2011. Uyku EEG Sinyalinin Yapay Sinir Ağ Modeli İle Sınıflandırılması, Elektrik-Elektronik ve Bilgisayar Sempozyumu, , 298-301, Elazığ.

- Faizollahzadeh ardabili, S., Mosavi, A., Dehghani, M., ve R. Várkonyi-Kóczy, A., 2019. Deep learning and machine learning in hydrological processes climate change and earth systems: A Systematic Review. Preprints. doi: 2019080166
- Fairbrother, J, Nemeth, C., Rischard, M., ve Brea, J., 2018. GaussianProcesses.jl: A Nonparametric Bayes Package for the Julia Language. arXiv preprint arXiv:1812.09064.
- Fletcher, T., 2009. Support vector machines explained. Tutorial paper, 1118, 1-19.
- Ghorbani MA, Deo RC, Karimi V, Kashani MH ve Ghorbani S., 2019. Design and implementation of a hybrid MLP-GSA model with multi-layer perceptron-gravitational search algorithm for monthly lake water level forecasting. Stoch Env Res Risk Assess 33(1):125–147.
- Golob, R., & Stokelj, T., 1998. Real-time scheduling of hydro cascaded system using evolutionary computation. In MELECON'98. 9th Mediterranean Electrotechnical Conference. Proceedings (Cat. No. 98CH36056) (Vol. 2, pp. 983-987). IEEE.
- Haykin, S., 1994. Neural Networks: A Comprehensive Foundation. MacMillan. New York.
- Hinge, G., Piplodiya, J., Sharma, A., Hamouda, M. A. ve Mohamed, M. M., 2022. Evaluation of Hybrid Wavelet Models for Regional Drought Forecasting. Remote Sensing, 14(24), 6381.
- Liu, Y. ve Weisberg, R., 2005. Patterns of ocean current variability on the West Florida Shelf using the self-organizing map, Journal of Geophysical Research, Vol. 110, C06003.
- Karaeminoğulları, A. B., 2020. Nehirlerdeki Katı Madde Miktarının Destek Vektör Makinesi Modeli İle Tahmini
- Kecman, V., 2004. Support vector machines basics. School of Engineering, University of Auckland.
- Kuzey, C., 2012. Veri Madenciliğinde Destek Vektör Makinaları ve Karar Ağaçları Yöntemlerini Kullanarak Bilgi Çalışanlarının Kurum Performansı Üzerine Etkisinin Ölçülmesi ve Bir Uygulama. (Phd). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Küçük, M., & Ağırlioğlu, N., 2006. Dalgacık dönüşüm tekniği kullanılarak hidrolojik akım serilerinin modellenmesi. İtÜdergisi, 5(2).
- Mohamadi, S., Sammen, S. S., Panahi, F., Ehteram, M., Kisi, O., Mosavi, A. ve Al-Ansari, N., 2020. Zoning map for drought prediction using integrated machine learning models with a nomadic people optimization algorithm. Natural Hazards, 104(1), 537-579.

- Mokhtarzad, M., Eskandari, F., Vanjani, N. J., ve Arabasadi, A., 2017. Drought forecasting by ANN, ANFIS, and SVM and comparison of the models. *Environmental Earth Sciences*, 76(21).
- Mohd Aris, M.N.; Daud, H.; Dass, S.C.; Mohd Noh, K.A., 2019. Gaussian Process Methodology for Multi-Frequency Marine Controlled-Source Electromagnetic Profile Estimation in Isotropic Medium. *Processes*, 7, 661.
- Nash, J.E. ve Sutcliffe, J. V., 1970. Kavramsal Modelle Nehir Akışı Tahmini. Bölüm 1—İlkelerin Tartışılması. *Hidroloji Dergisi*, 10, 282-290.
- Okkan, U., & Mollamahmutoğlu, A., 2010. Yiğitler Çayı Günlük Akımlarının Yapay Sinir Ağları Ve Regresyon Analizi İle Modellenmesi. *Journal of Science and Technology of Dumlupınar University(023)*, 33-48.
- Papacharalampous G, Tyrallis H ve Koutsoyiannis D., 2018. Predictability of monthly temperature and precipitation using automatic time series forecasting methods. *Acta Geophys* 66(4):807–831.
- Partal, T., Kişi, Ö. (2007). Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology*, 342: 1-2 199-212.
- Pham, B. T., Le, L. M., Le, T. T., Bui, K. T. T., Le, V. M., Ly, H. B., & Prakash, I., 2020. Development of advanced artificial intelligence models for daily rainfall prediction. *Atmospheric Research*, 237, 104845.
- Raghavendra S.N.,ve Deka, P.C., 2014. Support vector machine applications in the field of hydrology: A review, *Applied Soft Computing*, 19, 372-389.
- Salim, D., Doudja, S.-G., Ahmed, F., Omar, D., Mostafa, D., Oussama, B. ve Mahmoud, H., 2023. Comparative Study of Different Discrete Wavelet Based Neural Network Models for long term Drought Forecasting. *Water Resources Management*, 37(3), 1401-1420.
- Saraiva SV, Carvalho FDO, Santos CAG, Barreto LC, Freire PKDMM, 2021. Daily streamflow forecasting in Sobradinho Reservoir using machine learning models coupled with wavelet transform and bootstrapping. *Appl Soft Comput J* 102:1568–4946.
- Sharma, R. K., Kumar, S., Padmalal, D. ve Roy, A., 2023. Streamflow prediction using machine learning models in selected rivers of Southern India. *International Journal of River Basin Management (just-accepted)*, 1-57.
- Soh, Y. W., Koo, C. H., Huang, Y. F., & Fung, K. F., 2018. Application of artificial intelligence models for the prediction of standardized precipitation evapotranspiration index (SPEI) at Langat River Basin, Malaysia. *Computers and electronics in agriculture*, 144, 164-173.
- Terzi, Ö., & Köse, M., 2012. Flow Forecasting Of Göksu River With Artificial Neural Networks Method. *International Journal of Technological Sciences*, 4(3), 1-7.

- Turhan, E., 2012. Seyhan havzası yağış-akış ilişkisinin yapay sinir ağı yöntemi ile modellenmesi.
- Türkben, A. B., & Okan, M., 2019. Fırat Havzası Karasu Günlük Akımlarının Yapay Sinir Ağları İle Modellenmesi. Muğla Sıtkı Koçman Üniversitesi, 10. Ulusal Hidroloji Kongresi.
- Vapnik, V.N., 1995. The Nature of Statistical Learning Theory, Springer-Verlag, New York.
- Wu J., Liu, H., Wei, G., Song T., Zhang C., ve Zhou H., 2019. Flash Flood Forecasting Using Support Vector Regression Model in a Small Mountainous Catchment, Water 2019, 11(7), 1327.
- Yabar, E., & Aydın, M. C., 2020. Dalgacık Dönüşümlü Yapay Sinir Ağlarıyla Günlük Akım Serilerinin Tahmini. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(2), 943-951.
- Yesilyurt, S. N., Dalkılıç, H. Y., & Samui, P., 2023. Application of Soft Computing Techniques in River Flow Modeling. Sakarya University Journal of Science, 27(3), 634-642.
- Yürük, M. F., & Ekşi, İ. H., 2019. Yapay Zeka Yöntemleri ile İşletmelerin Finansal Başarısızlığının Tahmin Edilmesi: Bist İmalat Sektörü Uygulaması. Mukaddime, 10(1), 393-422.
- Zajam, S., Joshi, T., ve Bhattacharya, B., 2019. Application of wavelet analysis and machine learning on vibration data from gas pipeline for structural health monitoring, Procedia Structural Integrity, 14, 712-719.
- Zhang, N, Xiong, J, Zhong, J, ve Leatham, K., 2018. Gaussian Process Regression Method for Classification for HighDimensional Data with Limited Samples. In 2018 Eighth International Conference on Information Science and Technology (ICIST) (pp. 358-363).
- Zhang G, Hu Y, Yang D, Ma L, Zhang M, Liu X., 2022. Short-term bathwater demand forecasting for shared shower rooms in smart campuses using machine learning methods. Water, 14: 1291.
- Zhoua, C., Yin, K., Caoa, Y., Ahmed, B., 2016. Application of time series analysis and PSO–SVM model in predicting the Bazimen landslide in the Three Gorges Reservoir, China. Engineering Geology, 204, 108-120.

ÖZGEÇMİŞ

Adı ve Soyadı : Ulviye ZİYA

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Aksaray Üniversitesi, Mühendislik Fakültesi İnşaat Mühendisliği Bölümü, 2005-2009

Yüksek Lisans : Aksaray Üniversitesi, Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı, 2022-2024

MESLEKİ DENEYİM

1. Obial Endüstri Ürünleri San. İth. Ihr. A. Ş. (2009)
2. Fernas İnş. A.Ş. – Met-Gün İnş. Taah. Tic. A.Ş.(2010-2014)
3. Özmert İnşaat Beton Maden Nakliye İthalat İhracat Tic. Ve San. A.Ş. (2016-2017)
4. Karayolları Genel Müdürlüğü (2017-devam)

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Kongrelerde Sunulan Makaleler

1. Hınıs, M.A. ve Ziya U., 2024. Hibrit Destek Vektör Makinesi ile Günlük Akarsu Akım Verilerinin Tahmini, II. Bilsel Uluslararası Korykos Bilimsel Araştırmalar ve İnovasyon Kongresi Kongre Kitabı, 181-182.

Uluslararası Hakemli Dergilerde Yayımlanan Makaleler

1. Hınıs, M.A. ve Ziya U., 2024. Günlük Akarsu Akım Verilerinin Destek Vektör Makinesi ve Dalgacık Dönüşümü ile Modellenmesi, Karamanoğlu Mehmetbey Üniversitesi Mühendislik ve Doğa Bilimleri Dergisi.