



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

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**MAKİNE ÖĞRENME YÖNTEMLERİ İLE SEDİMENT TAŞINIMI
TAHMINİ VE PERFORMANSLARININ KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

Bahar Ezgi BIYIKLI

DANIŞMAN

Prof. Dr. Mehmet Ali HINIS

AKSARAY, 2025

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 222303403 numaralı Yüksek Lisans öğrencisi Bahar Ezgi BIYIKLI tarafından hazırlanan “**MAKİNE ÖĞRENME YÖNTEMLERİ İLE SEDİMENT TAŞINIMI TAHMİNİ VE PERFORMANSLARININ KARŞILAŞTIRILMASI**” 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: Doç. Dr. Sertaç ORUÇ

Ankara Yıldırım Beyazıt Üniversitesi

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

Üye: Doç. Dr. Mustafa Şahin DOĞAN

Aksaray Üniversitesi

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

Tez Savunma Tarihi: 13/06/2025

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

.....

Prof. Dr. Fazliye KARABÖRK

Fen Bilimleri Enstitüsü Müdürü

DOĞRULUK BEYANI

Yüksek lisans tezi olarak sunduğum bu çalışmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, çalışmamda kullandığım verilerin orijinalliğini ve her türlü intihalden uzak olduğunu beyan ederim.

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

İmza

Bahar Ezgi BIYIKLI

TEŐEKKÖR

Lisans eęitimimden bu yana bilgi ve tecrübeleriyle bana yol gösteren deęerli danışmanım Prof. Dr. Mehmet Ali HİNİS'a teşekkürlerimi sunarım.

Tüm eęitim hayatım boyunca her zaman bana destek olan aileme teşekkürlerimi sunarım.

Bahar Ezgi BIYIKLI
AKSARAY, 2025

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
ÖZET.....	iii
ABSTRACT	iv
ŞEKİLLER DİZİNİ	v
ÇİZELGELER DİZİNİ	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	4
3. MALZEME VE YÖNTEM	11
3.1 Çalışma Alanı ve Veri	11
3.2 Yöntemler	17
3.2.1 Destek Vektör Makinesi (DVM)	17
3.2.2 Rastgele Orman(RO)	20
3.2.3 Gauss Süreç Regresyonu (GPR).....	22
3.2.4 Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS).....	23
3.2.4.1 ANFIS mimarisi.....	24
3.2.5 Dalgacık dönüşümü	26
3.2.6 Model performans başarı ölçütleri.....	28
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	30
4.1 Dalgacık Dönüşümü Öncesi Modellerin Değerlendirilmesi	30
4.2 Dalgacık Dönüşümü Sonrası Modellerin Değerlendirilmesi	44
4.3 Tartışma.....	62
5. SONUÇ VE ÖNERİLER.....	64
KAYNAKLAR	67
ÖZGEÇMİŞ.....	72

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENME YÖNTEMLERİ İLE SEDİMENT TAŞINIMI TAHMİNİ VE PERFORMANSLARININ KARŞILAŞTIRILMASI

Bahar Ezgi BIYIKLI

**Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Mehmet Ali HINIS

ÖZET

Askıda sediment yükünün doğru bir şekilde hesaplanması su kaynakları yönetimi, taşkın kontrolü ve baraj gibi su yapılarının tasarım ve işletilmesinde oldukça önemlidir. Pek çok farklı parametreye bağlı olan askıda sediment yükünün tahmini için bu çalışmada Sacramento Nehri'nde bulunan 11447650 numaralı USGS istasyonundan elde edilen 1966-1973 yıllarına ait günlük askıda sediment konsantrasyonu, akım debisi ve su sıcaklığı verileri kullanılmıştır. Bu çalışmada askıda sediment konsantrasyonu, akım debisi ve su sıcaklığı parametrelerinin farklı zamanlara ait gecikme değerleri kullanılarak pek çok kombinasyon araştırılmış ve bunlar arasından seçilen 15 farklı model sunulmuştur. Oluşturulan modeller literatürde sıklıkla tercih edilen dört adet makine öğrenmesi yöntemleri ile: ANFIS, Destek Vektör Makinesi, Rastgele Orman ve Gauss Süreç Regresyonu yöntemleri ile ve tahminlerdeki hassasiyeti artırabilmek için ayrıca dalgacık dönüşümü uygulanarak test edilmiştir. Hem dalgacık dönüşümü öncesi hem de dalgacık dönüşümü sonrasında model performansları karşılaştırılmıştır. Günlük askıda sediment konsantrasyonu tahmininde ANFIS, Destek Vektör Makinesi, Rastgele Orman ve Gauss Süreç Regresyonu yöntemleri hem dalgacık dönüşümü öncesinde hem de dalgacık dönüşümü sonrasında oldukça iyi performans verdikleri görülmüştür. En iyi sonucu veren model ise dalgacık dönüşümü sonrası W-ANFIS M02 modeli olmuştur (Korelasyon: 0.98, NS: 0.97, KGE: 0.97, PI:0.07, RMSE: 0.17).

Anahtar Kelimeler: Askıda sediment, ANFIS, Destek Vektör Makinesi, GPR, Dalgacık dönüşümü.

Haziran, 2025; 72 sayfa

M.Sc. THESIS

SEDIMENT TRANSPORT FORECASTING WITH MACHINE LEARNING METHODS AND COMPARISON OF THEIR PERFORMANCES

Bahar Ezgi Bıyıklı

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

Supervisor: Prof. Dr. Mehmet Ali HINIS

ABSTRACT

The management of water resources, flood control, and the construction and maintenance of water structures like dams all depend heavily on the precise computation of the suspended sediment load. Stream flow, water temperature, and daily suspended sediment concentration data from USGS station number 11447650 in the Sacramento River for 1966–1973 were utilized in this work to estimate the suspended sediment load, which is dependent on numerous factors. Fifteen distinct models were provided in this study, which used lag values from various intervals to examine various combinations of suspended particle concentration, stream flow, and water temperature parameters. Four machine learning techniques that are often used in the literature—ANFIS, Support Vector Machine, Random Forest, and Gaussian Process Regression—as well as the wavelet transform to improve estimate precision were used to assess the built models. Model performances were compared both before and after wavelet transform. In the estimation of daily suspended sediment concentration, ANFIS, Support Vector Machine, Random Forest and Gaussian Process Regression methods were found to perform quite well both before and after wavelet transformation. The model that gave the best result was the W-ANFIS M02 model after wavelet transformation (Correlation: 0.98, NS: 0.97, KGE: 0.97, PI: 0.07, RMSE: 0.17).

Keywords: Suspended sediment, ANFIS, Support Vector Machine, GPR, Wavelet transformation.

June, 2025; 72 pages

ŞEKİLLER DİZİNİ

Şekil 1.1.	Sediment yükünün kaynağına, taşınma şekline göre sınıflandırılması ve su derinliğine göre durumu (Erkek ve Ağralıoğlu, 2020).	1
Şekil 1.2.	Çalışmada takip edilen yöntemler ve akış şeması.	3
Şekil 3.1.	Sacramento Nehri ve çalışma yapılan istasyonun konumu.	11
Şekil 3.2.	Sacramento Nehri'nin 1966-1973 yıllarına ait günlük askıda sediment konsantrasyonu değerleri.	12
Şekil 3.3.	Sacramento Nehri'nin 1966-1973 yıllarına ait günlük akım debisi değerleri.	12
Şekil 3.4.	Sacramento Nehri'nin 1966-1973 yıllarına ait günlük sıcaklık değerleri	13
Şekil 3.5.	Çalışmada kullanılan sediment verisinin dalgacık ayrıştırılmış hali.	16
Şekil 3.6.	Çalışmada kullanılan akım verisinin dalgacık ayrıştırılmış hali.	16
Şekil 3.7.	Çalışmada kullanılan sıcaklık verisinin dalgacık ayrıştırılmış hali.	16
Şekil 3.8.	Destek Vektör Makinesi ile iki sınıfın ayrılması (Widodo ve Yang,2007).	17
Şekil 3.9.	Rastgele Orman yapısının şematik gösterimi.	21
Şekil 3.10.	Bulanık çıkarım sistemi.	23
Şekil 3.11.	ANFIS mimarisi.	24
Şekil 3.12.	Fourier ve Dalgacık analizlerinin frekans-zaman ölçeğinde gösterimi (URL-2).	26
Şekil 3.13.	Fourier ve Dalgacık dönüşümleri ile sinyalin ayrıştırılmasının karşılaştırılması (URL-2).	27
Şekil 3.14.	Dalgacık dönüşümünün seviyeli ayrışma yapısının şematik gösterimi (URL-3).	28
Şekil 4.1.	DVM-Lineer yönteminin model performans sonuçları.	32
Şekil 4.2.	DVM-Polinom model performans sonuçları.	34
Şekil 4.3.	DVM-Gauss model performans sonuçları.	36
Şekil 4.4.	RO model performans sonuçları.	37
Şekil 4.5.	Gauss Süreç Regresyonu yönteminin model performans sonuçları.	39
Şekil 4.6.	ANFIS model performans sonuçları.	41
Şekil 4.7.	Dalgacık dönüşümü öncesindeki en başarılı modellerin Violin grafiği.	42
Şekil 4.8.	Dalgacık dönüşümü öncesindeki en başarılı modellerin Taylor grafiği.	43
Şekil 4.9.	Dalgacık dönüşümü öncesindeki en başarılı modellerin hatalarının Kutu grafiği.	43
Şekil 4.10.	W-DVM-Lineer yönteminin model performans sonuçları.	45
Şekil 4.11.	W-DVM-Polinom model performans sonuçları.	46
Şekil 4.12.	W-DVM-Gauss model performans sonuçları.	47
Şekil 4.13.	W-RO model performans sonuçları.	49
Şekil 4.14.	W-GPR yönteminin model performans sonuçları.	50
Şekil 4.15.	W-ANFIS model performans sonuçları.	52
Şekil 4.16.	Dalgacık dönüşümü sonrasındaki en başarılı modellerin Violin grafiği gösterimi.	53
Şekil 4.17.	Dalgacık dönüşümü sonrasındaki en başarılı modellerin Taylor grafiği gösterimi.	54
Şekil 4.18.	Dalgacık dönüşümü sonrasındaki en başarılı modellerin hatalarının Kutu grafiği gösterimi.	55
Şekil 4.19.	Dalgacık dönüşümü öncesi tespit edilen en iyi modellerin Bland-Altman grafikleri.	57

Şekil 4.20. Dalgacık dönüşümü sonrası tespit edilen en iyi modellerin Bland-Altman grafikleri.	58
Şekil 4.21. Dalgacık dönüşümü öncesindeki başarılı olan modeller.	59
Şekil 4.22. Dalgacık dönüşümü sonrasındaki başarılı olan modeller.	60
Şekil 4.23. Dalgacık dönüşümü öncesinde başarılı olan modellerin dalgacık dönüşümü öncesindeki ve sonrasındaki durumları.	61
Şekil 4.24. Dalgacık dönüşümü sonrasında başarılı olan modellerin dalgacık dönüşümü öncesindeki ve sonrasındaki durumları.	61
Şekil 4.25. Katı madde anahtar eğrisi ile W-ANFIS M02 modelinin karşılaştırılması.	62



ÇİZELGELER DİZİNİ


Çizelge 3.1.	Kullanılan verilerin temel istatistiksel özetleri.....	13
Çizelge 3.2.	Çalışmada kullanılan modeller.....	15
Çizelge 3.3.	Çekirdek fonksiyonlarının formülleri.....	19
Çizelge 3.4.	Nash-Sutcliffe verimlilik katsayısı (Moriasi vd., 2007).....	29
Çizelge 4.1.	DVM-Lineer model performans sonuçları.....	31
Çizelge 4.2.	DVM-Polinom model performans sonuçları.....	33
Çizelge 4.3.	DVM-Gauss model performans sonuçları.....	35
Çizelge 4.4.	RO model performans sonuçları.....	38
Çizelge 4.5.	GPR model performans sonuçları.....	39
Çizelge 4.6.	ANFIS model performans sonuçları.....	40
Çizelge 4.7.	W-DVM_Lineer model performans sonuçları.....	44
Çizelge 4.8.	W-DVM_Polinom model performans sonuçları.....	45
Çizelge 4.9.	W-DVM_Gauss model performans sonuçları.....	47
Çizelge 4.10.	W-RO model performans sonuçları.....	48
Çizelge 4.11.	W-GPR model performans sonuçları.....	50
Çizelge 4.12.	W-ANFIS model performans sonuçları.....	51

SİMGELER VE KISALTMALAR

ANFIS	Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi
ANN/YSA	Yapay Sinir Ağları
ARIMA	Otoregresif hareketli ortalama
ÇLR	Çoklu Lineer Regresyon
DVM/SVM	Destek Vektör Makinesi
Db45	Daubechies 45
FFNN	İleri Beslemeli Sinir Ağları
Fr	Froude Sayısı
GBO	Gradyan Tabanlı Optimize Edici
GPR	Gauss Süreç Regresyonu
GRNN	Genelleştirilmiş Yapay Sinir Ağı
GWO	Gri Kurt Optimizasyonu
KGE	Kling-Gupta Verimlilik Katsayısı
KMAE	Katı Madde Anahtar Eğrisi
KNN	k-En Yakın Komşular
LSTM	Uzun Kısa Süreli Bellek
M	Model
MAE	Ortalama Mutlak Hata
MATLAB	Matris Laboratuvarı
MLP	Çok Katmanlı Algılayıcı
MLR	Çoklu Lineer Regresyon
NSE/NS	Nash-Sutcliffe Verimlilik Katsayısı
PI	Performans İndisi
PSO	Parçacık Sürü Optimizasyon
R	Korelasyon Katsayısı
Re	Reynolds Sayısı
REPTree	Azaltılmış Hata Budama Ağacı
RMSE	Karekök Ortalama Karesel Hata
RO	Rastgele Orman
SPEI	Standartlaştırılmış Yağış Evapotranspirasyon
SPI	Standart Yağış İndeksi
SSTA	Deniz Yüzeyi Sıcaklığı Bozuklukları
USGS	United States Geological Survey
XGB	Aşırı Gradyan Artırma

1. GİRİŞ

Su yapılarının tasarımı ve işletiminde erozyon ve sediment parametrelerinin önemli bir alanı vardır. Erozyon, doğa veya insan etkinliklerine bağlı olarak toprağın su ve rüzgarla aşınması olayıdır. Erozyon sonucu aşınan toprağın akarsu ile taşınması sediment oluşum sürecini başlatır. Sediment, akarsudaki askıda taşınan ve su hızı azaldığında çökecek maddelerin hepsine verilen isimdir (Cöntürk, 1968). Akarsuların taşıdığı katı maddeler kaynağına göre yatak malzemesi ve yıkanmış malzeme olarak ikiye ayrılır. Hareketli bir tabanı oluşturan malzeme yatak malzemesi olarak adlandırılır. Yatak malzemesinden daha ince olan ve çoğunluğu havza erozyonundan gelen malzeme ise yıkanmış malzeme olarak adlandırılır (Erkek ve Ağırlioğlu, 2020). Akarsudaki katı maddeler taşınma şekline göre askı maddesi ve sürüntü maddesi olarak ikiye ayrılır. Suyun içinde askı halinde hareket eden maddeler askı maddesi olarak adlandırılırken, akarsu yatağında yuvarlanarak, kayarak ya da tabanda sıçrayarak hareket eden maddeler sürüntü maddesi olarak adlandırılır (Erkek ve Ağırlioğlu, 2020).



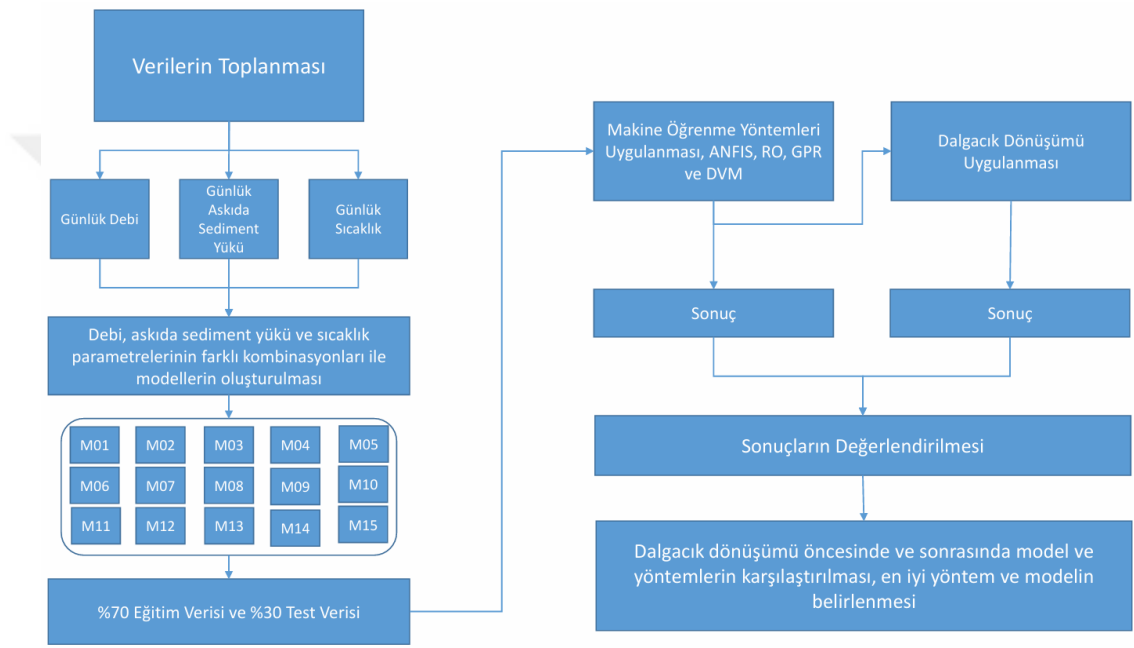
Şekil 1.1. Sediment yükünün kaynağına, taşınma şekline göre sınıflandırılması ve su derinliğine göre durumu (Erkek ve Ağırlioğlu, 2020).

Sediment kaynakları yüzey aşınması ve akarsu yatağı aşınması olarak ikiye ayrılır. Yüzey aşındırması; zeminin aşındırılabilmesi, bitki örtüsüne, akarsu ağının yoğunluğuna, yağış şiddetine ve insan etkinliklerine bağlıdır. Akarsu yatağındaki aşındırma ise akarsu tabanına ve kıyılara gelen su enerjisi ve zeminin direncine bağlıdır (Gürer ve Günyaktı, 2020). Sediment taşınımını etkileyen değişkenlerin bu kadar fazla olması taşınan sediment miktarının hesabını zorlaştırmakta ve hassasiyetini azaltmaktadır.

Sediment yükünün doğru bir şekilde hesaplanması su kaynaklarının uzun vadeli ve verimli kullanılması için oldukça önemlidir. Sediment yükü baraj gibi su yapılarının verimlilik ve ekonomik ömürlerini etkiler. Barajlardaki ölü hacimler sediment depolamak için ayrılmasına rağmen sediment sadece bu kısmı değil aktif hacmi de doldurmaktadır. Aktif hacim barajların işletilmesinde önemli bir faktördür. Sedimentin bunu etkilemesi barajın planlanan ekonomik ömründe gereken verimin sağlanamamasına yol açmaktadır (Latifoğlu, 2003). Ayrıca bu durum içme suyu temini, hidroelektrik üretimi ve sulama gibi faaliyetlerin veriminin düşmesine neden olmaktadır. Akarsu yataklarının şekillenmesinde de sediment taşınımı etkilidir. Akarsuda yetersiz sediment taşınımı olursa tabanda oyuklar oluşabilirken, aşırı sediment birikimi ise akarsunun tabanını yükseltir ve bu durum su seviyesinin yükselmesine ve taşkın taşıma kapasitesinin azalmasına ve taşkınlara neden olur. Bu sebeple sediment yükünün doğru tahmini su kaynakları yönetimi ve taşkın kontrolü için gereklidir.

Son yıllarda gelişen teknoloji ile birlikte lineer ve lineer olmayan parametrelere bağlı birçok problemin çözümünde yapay zeka araçları kullanılmaktadır. Bu çalışmada günlük askıda sediment konsantrasyonunun tahmini için son yıllarda geliştirilmiş ve yaygın kullanıma sahip olan ANFIS, Rastgele Orman, Gauss Süreç Regresyonu, Destek Vektör Makinesi gibi makine öğrenmesi yöntemleri ve ayrıca tahminlerdeki hassasiyeti artırabilmek için dalgacık dönüşümü kullanıldı. Çıktı parametresinde $t + 1$ zamanına ait askıda sediment konsantrasyonu kullanırken, girdi parametresinde $t + 1$, t , $t - 1$ ve $t - 2$ zamanlarına ait askıda sediment konsantrasyonu, debi ve sıcaklık parametrelerinin farklı kombinasyonları oluşturuldu. Günlük askıda sediment konsantrasyonunu tahmin eden en iyi modeli belirleyebilmek için girdi parametreleri arasında farklı model kombinasyonları, farklı makine öğrenme yöntemleri ile hem

dalgacık dönüşümü öncesinde hem de dalgacık dönüşümü sonrasında kullanılmıştır. Böylece askıda sediment konsantrasyonunu tahmin etmekte en iyi olan model ve en iyi olan makine öğrenmesi algoritması tespit edilmeye çalışılmıştır. Çalışmanın sonucunda makine öğrenmesi yöntemlerinin askıda sediment konsantrasyonunun tahmininde performansları karşılaştırılmış, birbirlerine göre avantaj ve dezavantajları belirlenerek yorumlanmış ve hibrit makine öğrenme yöntemlerinin oldukça başarılı sonuçlar verebileceği gözlemlenmiştir. Çalışmada takip edilen yöntemler ve akış şeması Şekil 1.2’de verilmiştir.



Şekil 1.2. Çalışmada takip edilen yöntemler ve akış şeması.

2. KAYNAK ÖZETLERİ

Bu bölümde günlük sediment miktarının tahmin edilmesi ve su kaynaklarının başlıca ilgilendiği alanlarda makine öğrenmesi yöntemleri ile yapılan çalışmaların özetleri verilmiştir.

Dogan (2005) Aşağı Sakarya Nehrinde yaptığı çalışmada askıda katı madde miktarının tahmini için YSA, Mamdani Bulanık Mantık yöntemi, Sugeno Bulanık Mantık yöntemi ve ANFIS yöntemlerini kullanmıştır. Çalışmada girdi parametresi olarak debi kullanılmıştır. Çalışmanın sonucunda ANFIS yönteminin diğer yöntemlere göre daha iyi performans gösterdiği görülmüştür.

Fırat (2007) Büyük Menderes havzasının dört ayrı akarsu kolunda günlük akarsu akışı ve taşınan katı madde miktarının tahmin edilmesi için yağış, debi ve askıda katı madde parametreleri ile modeller oluşturmuştur. ANFIS ve YSA yöntemlerini kullanmıştır. Yapılan çalışma sonucunda ANFIS yönteminin en iyi sonucu verdiğini belirtmiştir.

Bacanli vd. (2009) Orta Anadolu bölgesinde bulunan 10 yağış ölçüm istasyonundan alınan aylık ortalama yağış verileri ile Standart Yağış Endeksi (SPI) değerlerini kullanarak modeller oluşturmuştur. Yapılan çalışma sonucunda ANFIS, Çoklu Lineer Regresyon (MLR), İleri Beslemeli Sinir Ağları (FFNN) yöntemleri karşılaştırılmış ve en iyi sonucu veren yöntemin ANFIS yöntemi olduğu belirtilmiştir.

Azamathulla vd. (2010) Malezya’da yer alan Muda Nehri, Langat Nehri ve Kurau Nehri olmak üzere 3 nehirdeki sediment yükünü tahmin etmek için toplam sediment yükünü etkileyen debi, akım hızı, kanal genişliği, derinlik, hidrolik çap, yatak eğimi parametreleri ile Destek Vektör Makinesi (DVM) yöntemi kullanılmıştır. Çalışmada Destek Vektör Makinesi yönteminin geleneksel yöntemlere göre üstün bir performans gösterdiği belirtilmiştir.

Chiang ve Tsai (2011) Tayvan’da bulunan Kaoping Nehrinde askıda katı madde yükünü tahmin etmek için DVM, ANN, güç regresyon modeli ve doğrusal regresyon modeli kullanmıştır. ANN ve DVM yöntemleri için debi parametresinin gecikmiş zamanları kullanılmıştır. Çalışmada en iyi performansı gösteren yöntemin DVM olduğu belirtilmiştir.

Talebizadeh ve Moridnejad (2011) İran'ın kuzeybatısındaki Urmia Gölü'ndeki göl seviyesi dalgalanmalarının tahmini için ANN ve ANFIS modelleri geliştirdi. Yapılan çalışmada debi, yağış ve buharlaşma parametrelerini kullanmıştır. Çalışmanın sonucunda ise ANFIS modelinin ANN modellerine göre hem daha doğru hem de daha az belirsizliğe sahip olduğu görülmüştür.

Moosavi vd. (2013) İran'ın Mashhad ovasında yaptıkları çalışmada yeraltı suyu seviyesinin tahmini için veri setlerinde toplam yağış, aylık ortalama buharlaşma, aylık ortalama yeraltı suyu seviyesi, aylık ortalama debi kullanmıştır. Su seviyesinin tahmini için Wavelet-ANN, Wavelet-ANFIS, ANN ve ANFIS yöntemleri kullanılmıştır. Wavelet-ANFIS modelinin en iyi performansı gösterdiği görülmüştür.

Hipni vd. (2013) Malezya'da bulunan Klang rezervuarından alınan baraj su seviyesi ve yağış verileri ile Destek Vektör Makinesi ve ANFIS yöntemlerini kullanarak günlük baraj su seviyesinin tahmininde kullanılmıştır. Yapılan çalışmanın sonucunda Destek Vektör Makinesi yönteminin ANFIS'e göre daha iyi performans sergilediği belirtilmiştir.

He vd. (2014) Çin'de yer alan Pailugou Havzası'nda günlük nehir akışını tahmin etmek için girdi parametresinde debinin geciktirilmiş zaman adımlarını içeren kombinasyonlar ile ANFIS, Yapay Sinir Ağları, Destek Vektör Makinesi yöntemlerini kullanmıştır. Çalışmada tüm yöntemlerin iyi sonuç verdiği belirtilmiştir.

Haji vd. (2014) Amerika Birleşik Devletleri'nde bulunan Iowa Nehri'ndeki günlük askıda sediment yükünü tahmin etmek için girdi parametrelerinde debi ve askıda sedimentin geciktirilmiş zaman adımlarını içeren modeller oluşturmuştur. Bu çalışma da Destek Vektör Makinesi ve dalgacık dönüşümlü Destek Vektör Makinesi (W-DVM) yöntemleri kullanılmıştır. Çalışma sonucunda W-DVM yönteminin daha iyi performans verdiği belirtilmiştir.

Olyaie vd. (2015) Flathead Nehri ve Santa Clara Nehri'ndeki istasyonlardan alınan verilerle askıda sediment miktarının tahmini için askıda sediment yükü ve debi parametrelerini kullanarak modeller oluşturmuştur. Çalışmada katı madde anahtar eğrisi (KMAE) gibi geleneksel yöntemin yanı sıra ANFIS, ANN ve W-ANN

kullanmıştır. Yapılan çalışma sonucunda en başarılı performans sırasıyla W-ANN, ANFIS, ANN, KMAE şeklinde olduğu görülmüştür.

Gong vd. (2016) Amerika Birleşik Devletleri'nin Florida Eyaleti'nde bulunan Okeechobee Gölü yakınında bulunan iki kuyu için aylık yeraltı suyu seviyelerini tahmin etmek için yağış, sıcaklık, geçmiş yeraltı suyu seviyesi ve göl seviyesi parametreleri ile modeller oluşturmuştur. Oluşturulan modeller ile aylık yeraltı suyu seviyelerinin tahmini için ANFIS, DVM, ANN yöntemleri kullanılmıştır. Çalışma sonucunda ANFIS ve DVM yöntemlerinin ANN yönteminden daha iyi performans gösterdiği belirtilmiştir.

Nguyen vd. (2017) Vietnam'ın Khanhhoa bölgesinde yaptıkları çalışmada kuraklık tahmini için ANFIS yöntemini kullandı. Standartlaştırılmış Yağış Endeksi (SPI) ve Standartlaştırılmış Yağış Evapotranspirasyon (SPEI) için 15 ANFIS tahmin modeli oluşturuldu ve girdi değişkeni olarak deniz yüzeyi sıcaklığı bozuklukları (SSTA) kullanıldı. Çalışmada kuraklık tahmini için SSTA girdi değişkeni kullanan ANFIS tahmin modellerinin yüksek doğruluk ve güvenilirlik sağladığını belirtilmiştir.

Himanshu vd. (2017) Hindistan'da bulunan Marol ve Muneru havzalarından 1972-2011 yıllarında gözlemlenen günlük askıda sediment yükü, debi ve yağış verilerini girdi parametresi, çıktı parametresi olarak askıda sediment yükünü kullanarak farklı zaman serileri içeren modeller oluşturmuştur. Oluşturulan bu modeller ile günlük askıda sediment yükünü tahmin etmek için DVM ve W-DVM (dalgalı dönüşümlü destek vektör makinesi) yöntemleri kullanılmıştır. Çalışmanın sonucunda W-DVM yönteminin geleneksel destek vektör makinesi yönteminden daha iyi performans gösterdiği belirtilmiştir.

Buyukyildiz ve Kumcu (2017) Çoruh Nehri Havzası'nda yapılan çalışmada günlük askıda sediment yükünü tahmini için debi ve askıda sediment parametreleri ile modeller oluşturmuştur. Oluşturulan modeller ile günlük askıda sediment yükünün tahmini için ANFIS, DVM ve ANN yöntemleri kullanılmıştır. Çalışma sonucunda en başarılı performansı ϵ -SVR yönteminin verdiği belirtilmiştir.

Altunkaynak ve Başakın (2018) Amerika'daki Columbia Nehri'nde ölçülmüş olan günlük akım verilerini kullanarak zaman serisi oluşturmuş ve ileriye yönelik akım

tahmini yapmıştır. Çalışmada, yapay sinir ağları (YSA), otoregresif hareketli ortalama (ARIMA) ve ANFIS yöntemlerini karşılaştırıldı ve en başarılı tahmin yönteminin ANFIS olduğu görülmüştür.

Yıldırım vd. (2019) Samsun’da yaptıkları çalışmada nem, rüzgar hızı, ortalama sıcaklık, global güneşlenme ve yağış verilerini kullanarak modeller oluşturdu ve günlük buharlaşma tahmini yapmak için yapay sinir ağları (YSA) ve ANFIS yöntemlerini kullandı. Model performansını değerlendirmek için ortalama karesel belirleme hatası katsayısı (R^2), kök ortalama kare hatası (RMSE) ve ortalama mutlak hata (MAE) kullandı. Sonuç olarak YSA ve ANFIS modellerini karşılaştırdıklarında ANFIS’in daha iyi sonuç verdiğini gözlemlendi.

Al-Mukhtar (2019) Dicle Nehri’nde yaptığı çalışmada askıda sediment yükünü modellemek ve tahmin etmek için Rastgele Orman, Destek Vektör Makinesi, Yapay Sinir Ağları yöntemlerini kullanmıştır. Yapılan çalışmada 1962-1981 ve 2000-2010 yıllarında gözlemlenen günlük debi girdi verisi olarak yer alırken, askıda sediment konsantrasyonu çıktı verisinde yer almıştır ve günlük debi verileri ile aylık askıda sediment yükünün tahmin edilmesi için farklı zaman serileri içeren modeller oluşturulmuştur. Çalışmanın sonucunda ise en iyi performansı Rastgele Orman yönteminin verdiği belirtilmiştir.

Dalkiliç ve Hashimi (2020) Büyük Menderes Nehri’nde günlük akış tahmini için debi, yağış, ortalama sıcaklık, bağıl nem verilerini kullanarak modeller oluşturdu ve ANFIS, ANN, dalgacık dönüşümü ve ANN’nin birleşimiyle oluşan WNN yöntemlerini kullandı. Yapılan çalışma sonucunda sırasıyla en iyi sonucu WNN, ANFIS ve ANN vermiştir.

Roushangar ve Shahnazi (2020) Amerika Birleşik Devletleri’nin Idaho Eyaleti’ndeki çakıl ağırlıklı 19 farklı nehir ve dereden elde edilen verilerle yaptıkları çalışmada sediment taşınımı oranının tahmini için iki ayrı senaryo oluşturmuş ve Gauss Süreci Regresyonu ve Destek Vektör Makinesi kullanmıştır. Birinci senaryoda yalnızca akım koşullarına dayalı parametreler girdi verilerinde kullanılmıştır. Bu parametreler; Froude sayısı (Fr), Reynolds sayısı (Re), ortalama akım derinliğinin kanal genişliğine oranı (y/B), ortalama akım hızı ile kesme hızı oranı (V/U_*) ve yatak eğimi (S_0)’dir. İkinci senaryoda ise hem akım hem sediment özelliklerini dikkate alan parametreler

kullanılmıştır. Bu parametreler; Froude sayısı (Fr), ortalama akım hızı ile kesme hızı oranı (V/U_*), kanal pürüzlülüğünü gösteren hidrolik yarıçap ile ortanca tanecik çapının oranı (R_h/d_{50}), parçacık hareketliliği (θ), boyutsuz tanecik çapı (D_*), taşınım aşaması parametresi (T), akım gücünü ifade eden $V^3/g.y.\omega_s$ kullanılmıştır. Çalışmada Froude sayısının başarılı olan modellerde ortak parametre olduğu görülmüştür. Ayrıca ampirik formüllere göre hem Gauss Süreç Regresyonu hem de Destek Vektör Makinesi yöntemlerinin daha iyi sonuç verdiği belirtilmiştir. Gauss Süreç Regresyonu yöntemi en iyi performans gösteren yöntem olmuştur.

Acar ve Saplıoğlu (2020) Fırat Havzası'nda sediment konsantrasyonu tahmini için girdi parametrelerinde yağış, debi, sıcaklık kullanmıştır. Bu çalışmada ANFIS ve Yapay Sinir Ağları yöntemleri kullanılmıştır. Çalışmanın sonucunda yapay sinir ağları regresyon katsayısı bakımından en başarılı sonucu verirken, ortalama yüzde hatası bakımından ANFIS ve YSA'nın birbirine yakın sonuçları olduğu belirtilmiştir.

Üneş vd. (2020) Amerika Birleşik Devletleri'nde bulunan Missouri Nehri'ndeki günlük sediment miktarının tahmini için Destek Vektör Makinesi ve Genelleştirilmiş Yapay Sinir Ağı (GRNN) yöntemleri günlük debi, yağış, sıcaklık ve askıda sediment konsantrasyonu parametrelerini kullanmıştır. Yapılan çalışmada Destek Vektör Makinesi ve Genelleştirilmiş Yapay Sinir Ağı (GRNN) yöntemlerinin birbirine yakın ve iyi sonuç verdiği belirtilmiştir.

Terzi ve Baykal (2021) Eğirdir Gölü'ndeki yaptıkları çalışmada buharlaşma tahmini için hava sıcaklığı, su sıcaklığı, rüzgar hızı, nisbi nem, radyasyon, basınç, güneşlenme süresi parametrelerini kullanarak ANFIS, Çoklu Lineer Regresyon (ÇLR) ve dalgacık dönüşümü yöntemlerini kullanarak modeller geliştirmiştir. ANFIS ve ÇLR yöntemleri dalgacık dönüşümü ile kullanıldığında performanslarının daha iyi olduğu ve en iyi tahmin sonucunu ise dalgacık dönüşümlü W-ANFIS modelinin verdiği belirtilmiştir.

Sihag vd. (2021) Hindistan'da bulunan Baitarani Nehri havzasının Champua ölçüm alanından günlük debi, sediment konsantrasyonu ve akarsu yüksekliği parametreleri ile çeşitli modeller oluşturmuştur. Oluşturulan bu modeller ile sediment konsantrasyonunun tahmini için M5P ağacı ve Rastgele Orman yöntemleri kullanılmıştır. Çalışmanın sonucunda Rastgele Orman yönteminin M5P ağacı yöntemine göre daha iyi performans gösterdiği belirtilmiştir.

Band vd. (2021) İran’da bulunan Semnan Ovası’nda yeraltı suyu seviyesinin aylık tahmini için minimum hava sıcaklığı, minimum bağıl nem, yağış ve yeraltı suyu seviyesi parametreleri ile birlikte Gauss Süreç Regresyonu (GPR), Destek Vektör Regresyonu (DVR) ve bunların dalgacık dönüşümü ile kombinasyonları olan W-GPR ve W-DVR yöntemlerini kullanmıştır. Çalışmanın sonucunda en iyi performansı dalgacık dönüşümü kullanan yöntemlerin gösterdiği belirtilmiştir.

Bajirao vd. (2021) Hindistan’da bulunan Koyna Nehri havzasında günlük askıda sediment konsantrasyonunun tahmini için girdi parametrelerinde günlük debi, yağış ve askıda sediment konsantrasyonu ile modeller oluşturmuştur. Çalışmada ANFIS, Yapay Sinir Ağları (ANN) ve bunların dalgacık dönüşümü ile birleşiminden oluşan W-ANN ve W-ANFIS yöntemleri kullanılmıştır. Kullanılan dalgacık türleri Haar, Coiflets ve Daubechies olmak üzere üç ana dalgacık kullanılmıştır. Çalışmanın sonucunda en iyi performansı coiflets dalgacık içeren W-ANFIS yönteminin verdiği belirtilmiştir.

AlDahoul vd. (2022) Malezya’da bulunan Johor Nehri’ndeki askıda sediment yükünün sınıflandırmak için Aşırı Gradyan Artırma (XGB), Rastgele Orman, Destek Vektör Makinesi, k-En Yakın Komşular (KNN), Çok Katmanlı Algılayıcı (MLP) Sinir Ağı yöntemlerini kullanmıştır. Çalışmada debi ve sediment yükü girdi değişkenleri olarak kullanılmıştır. En iyi yöntemin XGB yöntemi olduğu belirtilmiştir.

Allawi vd. (2023) Malezya’da bulunan Johor Nehri’nde günlük askıda sediment tahmini için girdi parametresinde debi ve askıda sediment yükü kullanarak modeller oluşturmuştur. Çalışmada Çok Katmanlı Algılayıcı (MLP) Sinir Ağı, Destek Vektör Regresyonu, Rastgele Orman ve Uzun Kısa Süreli Bellek (LSTM) yöntemleri kullanılmıştır. En iyi performansı veren yöntemin LSTM olduğu belirtilmiştir.

Demir vd. (2023) Kızılırmak Nehri’nde yaptıkları çalışmada günlük ortalama debi ve günlük toplam yağış değerlerini kullanarak model oluşturdu ve günlük ortalama debi tahmin edilmesi için ANFIS yöntemini kullandı. Model performansları, ortalama karesel belirleme hatası katsayısı (R^2) ve kök ortalama kare hatası (RMSE) ile değerlendirildi. Sonuç olarak ANFIS’in başarılı bir tahmin ortaya koyduğu belirtilmiştir.

Sattari vd. (2024) İran'ın Alamut Nehri'nde bulunan Bagh-e Kalayeh hidrometrik istasyonundan elde edilen askıda sediment yükü, debi ve yağış verileri askıda sediment yükünün tahmini için kullanılmıştır. Çalışmada Gauss Süreç Regresyonu, Destek Vektör Regresyonu, M5P ağacı, Rastgele Orman, Çok Katmanlı Algılayıcı (MLP), ekstra ağaçlar, çoklu arama, Azaltılmış Hata Budama Ağacı (REPTree) ve Rastgele Ağaç yöntemleri kullanılmıştır. En iyi performansı Destek Vektör Regresyonu yönteminin gösterdiği belirtilmiştir.


Adnan vd. (2025) Çin'de bulunan Bailong Nehri Havzası'nda yaptıkları çalışmada günlük askıda sediment yükünü tahmin etmek için girdi parametrelerinde debi ve askıda sediment yükünün farklı kombinasyonları ile modeller oluşturmuştur. Çalışmada ANFIS ve ANFIS'e 3 farklı optimizasyon algoritması entegre edilmesi ile oluşturulan yöntemler kullanılmıştır. Bu çalışmada Gradyan Tabanlı Optimize Edici (GBO), Gri Kurt Optimizasyonu (GWO) ve Parçacık Sürü Optimizasyonu (PSO) ANFIS'e entegre edilmiştir. En iyi sonucu veren yöntemin ANFIS-GBO olduğu belirtilmiştir.

Devi vd. (2025) Hindistan'da bulunan Beas Nehri kıyısı boyunca toplanan 270 adet sondaj noktasından alınan zemin örneklerinden elde edilen veriler kullanılarak hidrolik iletkenlik değeri K 'nın tahmini için ANFIS, Yapay Sinir Ağları (ANN), Rastgele Orman (RO) ve Gauss Süreç Regresyonu yöntemleri kullanılmıştır. Girdi parametrelerinde tanecik boyutu parametreleri olan d_{10} , d_{50} , üniformluk katsayısı C_u ve porozite kullanılmıştır. Çalışmanın sonucunda Gauss Süreç Regresyonu ve Rastgele Orman yöntemlerinin ANFIS ve ANN yöntemlerinden daha iyi sonuç verdiği gözlemlenmiştir. En iyi sonucu veren yöntemin Gauss Süreç Regresyonu olduğu belirtilmiştir.

3. MALZEME VE YÖNTEM


3.1 Çalışma Alanı ve Veri

Bu çalışmada, Sacramento Nehrinde bulunan 11447650 numaralı USGS istasyonundan alınan 1966-1973 yıllarına ait 2626 adet günlük akım debisi, askıda sediment yükü (SSL) ve sıcaklık verileri kullanılmıştır. Çalışma alanında vadi tabanı düz ve taşkın tehlikesi olduğundan seddeler yapılmıştır. Bu seddelerin ekonomik ömrü önemli olduğundan sediment hesabı önemlidir. Bu çalışmada, askıda sediment yükünü tahmin etmek için akım verisi (Q), sıcaklık (T) ve askıda sediment konsantrasyonu (Qs) kullanılmıştır. Bu verilerin farklı zamanlara ait gecikmeleri ile kombinasyonlar oluşturularak 15 farklı model kurulmuştur. Bu girdi verileri sayesinde günlük SSL değerleri tahmin edilmiştir. Çalışmada kullanılan 11447650 numaralı USGS istasyonu Amerika Birleşik Devletleri'nde Kaliforniya'nın en büyük nehri olan Sacramento Nehri üzerinde bulunmaktadır (Şekil 3.1). Sacramento Nehri Klamath Dağları'ndan doğar ve Sacramento-San Joaquin Nehri Deltası ve San Francisco Körfezi'ne ulaşmadan önce 640 km güneye akar. Havzanın genişliği 69.000 km²'dir (URL-1).




Şekil 3.1. Sacramento Nehri ve çalışma yapılan istasyonun konumu.


USGS istasyonundan alınan günlük akım debisi, sıcaklık ve askıda taşınan sediment konsantrasyonu Şekil 3.2, Şekil 3.3 ve Şekil 3.4'te verilmiştir. Çalışmada verilerin %70'i eğitim aşamasında kullanılırken, %30'u test aşamasında kullanılmıştır. Kullanılan verilerin temel istatistiksel özetleri Çizelge 3.1' de verilmiştir.



Şekil 3.2. Sacramento Nehri'nin 1966-1973 yıllarına ait günlük askıda sediment konsantrasyonu değerleri.



Şekil 3.3. Sacramento Nehri'nin 1966-1973 yıllarına ait günlük akım debisi değerleri.



Şekil 3.4. Sacramento Nehri'nin 1966-1973 yıllarına ait günlük sıcaklık değerleri.

Çizelge 3.1. Kullanılan verilerin temel istatistiksel özetleri.

		Ortalama	Standart Sapma	Çarpıklık	Minimum	Maksimum
Bütün Veri Seti	$Q_s(\text{mg/l})$	69.59	60.43	2.94	11.00	576.00
	$Q (\text{m}^3/\text{s})$	753.00	520.52	1.56	229.80	2694.16
	$T(^{\circ}\text{C})$	14.72	4.92	0.05	4.60	24.20
Eğitim Verisi	$Q_s(\text{mg/l})$	73.05	62.31	2.82	11.00	576.00
	$Q (\text{m}^3/\text{s})$	767.08	551.67	1.39	229.80	2694.16
	$T(^{\circ}\text{C})$	14.73	4.89	0.05	6.00	23.50
Test Verisi	$Q_s(\text{mg/l})$	61.56	55.01	3.30	15.00	445.00
	$Q (\text{m}^3/\text{s})$	720.53	437.98	2.16	277.34	2623.41
	$T(^{\circ}\text{C})$	14.70	5.01	0.07	4.60	24.20

Bu çalışma için oluşturulan 15 model Çizelge 3.2’de verilmiştir. Çizelge 3.2’de $t + 1$ gözlenen akı ve tahmin verisi zamanını, t ; 1 günlük, $t - 1$; 2 günlük, $t - 2$; 3 günlük geçmişe yönelik ötelenmiş zamanı göstermektedir. Askıda sediment konsantrasyonuna etki eden pek çok parametre olduğundan bu çalışmada kullanılan girdi parametrelerinin çeşitli kombinasyonları kullanılarak modeller oluşturulmuştur. Oluşturulan modellerin yapısı hakkında aşağıda bilgi verilmiştir.


Günlük askıda sediment konsantrasyon miktarının tahmin edilmesi için oluşturulan modellerde, çıktı parametresinde $t + 1$ zamanındaki askıda sediment konsantrasyonu yer alırken, girdi parametrelerinde $t + 1$, t , $t - 1$, $t - 2$ zamanlarına ait askıda sediment konsantrasyonu, debi ve sıcaklık parametrelerinin çeşitli kombinasyonları kullanılarak pek çok modeller oluşturulmuştur. Bu modeller arasından seçilen 15 model bu çalışmada sunulmuştur. M01, M02 ve M03 modellerinin girdi parametrelerinde yalnızca askıda sediment konsantrasyonu yer aldı. M06 modelinde girdi parametresinde yalnızca debi yer alırken M11 modelinde yalnızca sıcaklık parametresi yer aldı. M04, M05, M07 girdi parametrelerinde hem askıda sediment konsantrasyonu hem de debi kullanılmıştır. M08, M09 modellerinde girdi parametresinde debi ve sıcaklık kullanıldı. M12 ve M14 modellerinin girdi parametresi askıda sediment konsantrasyonu ve sıcaklık parametreleri kullanıldı. M10, M13 ve M15 modellerinin girdi parametrelerinde askıda sediment konsantrasyonu, debi ve sıcaklık parametreleri yer almaktadır. Bu 15 model ile günlük askıda sediment konsantrasyonunun tahmin edilmesi için ANFIS, RO, GPR, DVM yöntemleri ve bu yöntemlerin dalgacık dönüşümü ile birleşiminden oluşan W-ANFIS, W-RO, W-GPR, W-DVM yöntemleri kullanılmıştır. Ayrıca Destek Vektör Makinesinin 3 farklı çekirdek fonksiyonu kullanılmıştır. Bunlar; lineer, polinom ve gauss çekirdek fonksiyonlarıdır.

Çizelge 3.2’de görülen db45 dalgacık fonksiyonu Daubechies dalgacık ailesine ait bir dalgacık fonksiyonudur. Daubechies dalgacıkları, sinyalin hem zamanla değişen yapısını hem de frekans bileşenlerini birlikte analiz etme imkânı sunar. Bu özelliği sebebi ile sinyalin hem genel yapısını hem de ayrıntılarını hassas bir şekilde ortaya koyabilmek için Daubechies ailesine ait db45 dalgacığı bu çalışmada tercih edilmiştir.


Çizelge 3.2. Çalışmada kullanılan modeller.

	Girdi Parametresi	Çıktı Parametresi	Dalgacık Fonksiyonu
M01	Q_{S_t}	$Q_{S_{t+1}}$	db45
M02	$Q_{S_t} Q_{S_{t-1}}$	$Q_{S_{t+1}}$	db45
M03	$Q_{S_t} Q_{S_{t-1}} Q_{S_{t-2}}$	$Q_{S_{t+1}}$	db45
M04	$Q_{S_t} Q_t$	$Q_{S_{t+1}}$	db45
M05	$Q_t Q_{t-1} Q_{S_t} Q_{S_{t-1}}$	$Q_{S_{t+1}}$	db45
M06	Q_{t+1}	$Q_{S_{t+1}}$	db45
M07	$Q_{t+1} Q_t Q_{S_t}$	$Q_{S_{t+1}}$	db45
M08	$T_{t+1} Q_{t+1}$	$Q_{S_{t+1}}$	db45
M09	$T_{t+1} T_t Q_{t+1} Q_t$	$Q_{S_{t+1}}$	db45
M10	$T_{t+1} T_t Q_{t+1} Q_t Q_{S_t}$	$Q_{S_{t+1}}$	db45
M11	T_{t+1}	$Q_{S_{t+1}}$	db45
M12	$T_{t+1} T_t Q_{S_t}$	$Q_{S_{t+1}}$	db45
M13	$T_t T_{t-1} Q_t Q_{t-1} Q_{S_t} Q_{S_{t-1}}$	$Q_{S_{t+1}}$	db45
M14	$T_t T_{t-1} Q_{S_t} Q_{S_{t-1}}$	$Q_{S_{t+1}}$	db45
M15	$T_t Q_t Q_{S_t}$	$Q_{S_{t+1}}$	db45


Çalışmada kullanılan günlük askıda sediment verisine, günlük akım verisine ve günlük sıcaklık verisine db45 dalgacığı kullanılarak 5 seviyeli dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümü sonrası oluşan yaklaşık ve detay bileşenlerine (D) ait sinyal görünümleri Şekil 3.5, Şekil 3.6 ve Şekil 3.7’de yer almaktadır. Şekillerde yer alan orijinal ifadesi, orijinal sinyali göstermektedir. Orijinal sinyal, yaklaşık bileşen ile detay bileşenlerinin (D5, D4, D3, D2, D1) toplamından oluşmaktadır.



Şekil 3.5. Çalışmada kullanılan sediment verisinin dalgacık ayrıştırılmış hali.



Şekil 3.6. Çalışmada kullanılan akım verisinin dalgacık ayrıştırılmış hali.




Şekil 3.7. Çalışmada kullanılan sıcaklık verisinin dalgacık ayrıştırılmış hali.

3.2 Yöntemler

3.2.1 Destek Vektör Makinesi (DVM)

Destek vektör makinesi hem sınıflandırma hem de regresyon problemlerine uygulanabilen, temelinde istatistiksel öğrenme teorisi bulunan bir makine öğrenme yöntemidir (Shmilovici, 2010). Destek vektör makinelerinin amacı marjini maksimize ederek verileri sınıflara ayıran en iyi karar sınırı olan hiperdüzlemin bulunmasıdır. Hiperdüzlem oluşturulurken verilerin genel dağılımı göz önünde bulundurulmaz, yalnızca marjine en yakın olan veri noktalarına göre oluşturulur. Marjini tanımlayan bu noktalar destek vektörleri olarak adlandırılır. Şekil 3.8’de Destek Vektör Makinesinin sınıf ayrımı görülmektedir. Siyah kareler ve beyaz daireler farklı iki sınıfı göstermektedir. Gri kareler ve daireler destek vektörünü göstermektedir.



Şekil 3.8. Destek Vektör Makinesi ile iki sınıfın ayrılması (Widodo ve Yang, 2007).

M örnek sayısına sahip, pozitif ve negatif olmak üzere iki sınıfa ayrılacak bir sınıfın gösterimi verilmiştir (Widodo ve Yang, 2007):

$$f(x) = w^T x + b = 0 \quad (3.1)$$

Denklem (3.1)'de x , girdi verisidir, w ağırlık vektörüdür ve b skalerdir. Denklem (3.2)'de gösterilen $f(x)$ karar fonksiyonudur. Karar fonksiyonu hem hiperdüzlemi oluşturur hem de verileri sınıflandırır. y_i sınıf etiketidir. $y_i = 1$ pozitif sınıfı gösterirken, $y_i = -1$ negatif sınıfı gösterir.

$$\begin{aligned} f(x_i) = 1 \text{ ise } y_i &= 1 \\ f(x_i) = -1 \text{ ise } y_i &= -1 \end{aligned} \quad (3.2)$$

Tam Denklem (3.3)'te gösterilmiştir:

$$y_i f(x_i) = y_i (w^T x_i + b) \geq 1 \quad \text{için } i = 1, 2, \dots, M \quad (3.3)$$

Destek vektör makinelerinde amaç en uygun hiperdüzlemi bulmaktır. Bu amaçla Denklem (3.5)'teki koşullar sağlanarak Denklem (3.4)'teki optimizasyon problemi çözülür.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^M \xi_i \quad (3.4)$$

$$\begin{cases} y_i (w^T x_i + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \end{cases} \quad \begin{matrix} i = 1, \dots, M \\ i = 1, \dots, M \end{matrix} \quad (3.5)$$

ξ_i gevşek değişken, C ise ceza parametresidir. Gevşek değişken ξ_i marjinin yanlış tarafında yer alan bir veri noktasının karar sınırına olan hata miktarını ölçer.

Daha sonra Lagrange çarpanı α_i kullanılır ve Kuhn-Tucker koşulu ile problem Lagrange ikili problemine dönüştürülmesiyle Denklem (3.6) oluşturulur.

$$\min L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^M \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^M \alpha_i \quad (3.6)$$

Denklem (3.6)'nın minimumunun bulunması için Denklem (3.7)'de w ve b türevleri alınarak 0'a eşitlenir.

$$\frac{\partial L}{\partial w} = 0, \quad \frac{\partial L}{\partial b} = 0 \quad (3.7)$$

$$w = \sum_{i=1}^M \alpha_i y_i x_i, \quad \sum_{i=1}^M \alpha_i y_i = 0 \quad (3.8)$$

Denklem (3.8), Denklem (3.6)'da yerine konularak Denklem (3.9)'daki optimizasyon problemi elde edilir. Denklem (3.9)'u maksimize etmek için Denklem (3.10)'daki koşullar sağlanmalıdır.

$$\text{maks } L(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=0}^M \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (3.9)$$

$$\alpha_i \geq 0, \quad i = 1, \dots, M, \quad \sum_{i=1}^M \alpha_i y_i = 0 \quad (3.10)$$

Denklem (3.9)'u çözerek α_i katsayıları elde edilir. Elde edilen α_i katsayıları ile karar fonksiyonu Denklem (3.11) yazılır.

$$f(x) = \text{sign}\left(\sum_{i,j=1}^M \alpha_i y_i (x_i x_j) + b\right) \quad (3.11)$$

Verilerin doğrusal olarak ayıramadığı durumlarda çekirdek fonksiyonları kullanılabilir. Bu durumda n boyutlu girdi vektörü x , l boyutlu özellik uzayına taşımak için doğrusal olmayan $\phi(x) = (\phi_1(x), \dots, \phi_l(x))$ vektörü kullanılır ve karar fonksiyonu Denklem (3.12) oluşturulur.

$$f(x) = \text{sign}\left(\sum_{i,j=1}^M \alpha_i y_i \left(\phi^T(x_i) \cdot \phi(x_j)\right) + b\right) \quad (3.12)$$

Çekirdek fonksiyonu $K(x_i, x_j) = \left(\phi^T(x_i) \cdot \phi(x_j)\right)$ olarak ifade edilir ve Denklem (3.12)'de yerine yazılarak son karar fonksiyonu Denklem (3.13)'ü elde ederiz. Çekirdek fonksiyonlarının formülleri Çizelge 3.3'te gösterilmiştir.

$$f(x) = \text{sign}\left(\sum_{i,j=1}^M \alpha_i y_i K(x_i, x_j) + b\right) \quad (3.13)$$

Çizelge 3.3. Çekirdek fonksiyonlarının formülleri.

Kernel	$K(x, x_j)$
Linear	$x^T \cdot x_j$
Polynomial	$(\gamma x^T x_j + r)^d, \gamma > 0$
Gaussian RBF	$\exp\left(-\ x - x_j\ ^2 / 2\gamma^2\right)$

3.2.2 Rastgele Orman (RO)

Rastgele orman yöntemi tahminde etkili bir araçtır ve hem regresyon hem de sınıflandırma problemlerinde kullanılabilir. Bu yöntemde her bir ağacın büyümesi için her düğümde bölünecek girdi ya da girdi kombinasyonları rastgele seçilir. Bu rastgele özellik seçimine ek olarak torbalama (bagging) kullanılır. Torbalama kullanımı rastgele özellik ile kullanıldığında doğruluğu artırdığı görülmüştür. Ayrıca güç ve korelasyon tahminleri vermek için kullanılır (Breiman, 2001). Orijinal eğitim setinden her yeni eğitim seti yedeklenir. Yeni eğitim setinde rastgele özellik seçimi kullanılarak bir ağaç büyütülür, ağaç maksimum uzunluğa kadar büyütülür ve budanmaz (Breiman, 2001).

Her düğümde yapılan bölünmelerin amacı, veriyi mümkün olduğunca homojen sınıflara ayırmaktır. Bu homojenliğin ölçülmesi ve en iyi bölünmenin bulunması için Gini İndeksi kullanılır. Gini İndeksi değerinin az olması sınıf homojenliğinin yüksek olduğu anlamına gelir. Rastgele bir durum seçilip, bunun bir C_i sınıfına ait olduğu belirtilerek, belirli bir eğitim seti T için Gini İndeksi Denklem (3.14)'te verilmiştir (Pal, 2005):


$$\sum \sum_{j \neq i} (f(C_i, T)/|T|)(f(C_j, T)/|T|) \quad (3.14)$$

Burada, $f(C_i, T)/|T|$ seçilen durumun C_i sınıfına ait olma durumudur.

Rastgele orman yönteminde birden fazla karar ağacı kullanılır. Karar ağaçlarında düğümlerdeki en iyi bölünme aranırken tüm özelliklere bakılır, rastgele ormanda ise en iyi bölünme için rastgele seçilmiş bir alt özellik kümesi kullanılır. Rastgele orman yönteminde her bölünmede rastgele seçilen girdi değişkenlerinin sayısı (m_{try}) ve ağaç sayısı (n_{tree}) kullanıcı tarafından tanımlanır. Rastgele orman algoritması birden fazla karar ağacının bir araya gelmesiyle oluşur. Eğitim verilerinden aynı boyutlu olacak şekilde rastgele ve tekrar eden verilerle alt kümeler oluşturulur. Oluşturulan bu alt kümeler bootstrap örnekleri olarak adlandırılır. Bootstrap örneklerinde veriler rastgele ve tekrar seçimle oluşturulurken, bazı veriler hiç seçilmeyebilir. Bootstrap örnekleri karar ağaçlarının eğitilmesini sağlar. Bu nedenle her karar ağacı birbirinden farklıdır. Ayrıca bootstrap örneklerinin oluşumu sırasında hiç seçilmeyen verilerin oluşturduğu bir grup vardır. Bu seçilmeyen veriler, torba dışı (out-of-bag) verileri olarak

adlandırılır. Bu torba dışı veriler eğitim verilerinin 1/3'lük bölümünü oluşturur. Her ağaç eğitim esnasında torba dışı verileri tahmin eder. Bu ağaçlardaki torba dışı veri tahminleri toplanır ve bu modelin ortalama başarısını gösterir. Böylece, torba dışı veriler modelin kendi içinde denetlenmesini sağlar. Bu sayede test için ek bir veriye ihtiyaç duyulmaz.

Karar ağaçlarındaki düğümlerde her bölünme esnasında rastgele özellikler seçilir. Seçilecek rastgele özelliklerin sayısını kullanıcı belirler. Her karar ağacı birbirinden farklı olduğu için bölünmeler sırasında sorulan sorularda farklıdır. Bu soruları rastgele orman algoritması belirli özelliklerin arasından en iyi ayrımı yapacak soruyu kendisi belirler. Bu süreç yapraklara kadar devam eder. Karar ağaçları tamamlandıktan sonra tahmin aşamasına geçilir. Tahmin aşamasında her karar ağacına aynı veriler gönderilir ve tahmin etmesi beklenir. Eğer bu tahmin bir regresyon problemi için kullanılacaksa tahminlerin ortalaması alınır, sınıflandırma problemlerinde ise çoğunluk oylamasına göre karar verilir. Şekil 3.9'da Rastgele Orman yapısının şematik gösterimi verilmiştir.



Şekil 3.9. Rastgele Orman yapısının şematik gösterimi.

3.2.3 Gauss Süreç Regresyonu (GPR)

Bir gauss süreci herhangi bir sonlu sayıda ortak gauss dağılımlarına sahip rastgele değişkenlerden oluşan bir yapıdır (Rasmussen, 2004). Bu rastgele değişkenler girdi noktalarına karşılık gelen çıktı değerleridir. Çıktı değerleri sabit bir değeri göstermez, belirli bir değer etrafındaki bir olasılık dağılımını tanımlar. Bu yönüyle Gauss sürecindeki olasılık dağılımları yalnızca tahmin etmekle kalmaz, aynı zamanda tahminin belirsizliğini ve güven aralığını da gösterir. Bu özellik, tahminler ile birlikte belirsizlik bilgisini de kapsayan Gauss Süreç Regresyonu (GPR)'nin temelini oluşturur. Gauss Süreç Regresyonu, sınıflandırma problemlerini ve doğrusal olmayan regresyon problemlerini çözmek için kullanılabilen parametrik olmayan bir Bayes modelidir (Lin vd., 2019). GPR'de ortalama fonksiyon, kovaryans fonksiyonu ve gözlem gürültüsü olmak üzere 3 temel unsur bulunur. Matematiksel olarak Denklem (3.15) ile (3.20) arasındaki ifadelerle açıklanmaktadır (Bekçioğulları vd., 2021):

$$m(x) = E(f(x)) \quad (3.15)$$

$$k(x, x') = E(f(x) - m(x))(f(x') - m(x')) \quad (3.16)$$

Rastgele değişken $f(x)$ ile gösterilirken, $m(x)$ ortalama fonksiyon ve $k(x, x')$ kovaryans fonksiyonudur. $f(x)$ fonksiyonu Denklem (3.17)'de tanımlanmıştır:

$$f(x) = GP(m(x), k(x, x')) \quad (3.17)$$

Ortalama fonksiyon değeri sıfır olarak kabul edilir. Girdi ve amaç vektörü arasındaki bağıntı Denklem (3.18)'de gösterilmiştir:

$$y_i = f(x_i) + \varepsilon \quad (3.18)$$

Burada ε : Gözlem gürültüsüdür. Kovaryans matrisi Denklem (3.20)'de gösterilmiştir:


$$k_{i,j} = k(x_i, x_j) \quad (3.19)$$

$$k = \begin{bmatrix} k(x_1, x_1) & \cdots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \cdots & k(x_n, x_n) \end{bmatrix} \quad (3.20)$$

3.2.4 Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)

Jang (1993) tarafından geliştirilen Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi anlamına gelen ANFIS, adından da anlaşılacağı üzere uyarlanabilir ağ ve bulanık çıkarım sisteminin birleşmesi ile oluşur. Uyarlanabilir ağ, her düğümün gelen sinyaller üzerinde belirli bir görevinin olduğu ve bu düğümle ilgili bir dizi parametreyi gerçekleştirdiği çok katmanlı ileri beslemeli bir ağıdır. Bulanık çıkarım sistemi Şekil 3.10'da gösterilmiştir ve beş fonksiyonel bölümden oluşur:

- Kural Tabanı: Bir takım eğer- o halde kurallarını içerir.
- Veri Tabanı: Bulanık kurallarda kullanılan bulanık kümelerin üyelik fonksiyonlarını tanımlar.
- Karar Verme Birimi: Kurallar üzerinde çıkarım işlemlerini gerçekleştirir.
- Bulanıklaştırma Arayüzü: Net girdileri dilsel değerler ile eşleşme derecelerine dönüştürür.
- Durulaştırma Arayüzü: Çıkarımın bulanık sonuçlarını net bir çıktıya dönüştürür.




Şekil 3.10. Bulanık çıkarım sistemi.

3.2.4.1 ANFIS mimarisi

Şekil 3.11’de ANFIS mimarisi gösterilmiştir. Bulanık çıkarım sisteminde girdi verileri x ve y olarak gösterilmiştir. Kural tabanı olarak Sugeno ve Takagi’nin iki bulanık eğer-o halde kuralını içermektedir.

Kural 1: Eğer x A_1 ve y B_1 ise, $f_1 = p_1x + q_1y + r_1$,

Kural 2: Eğer x A_2 ve y B_2 ise, $f_2 = p_2x + q_2y + r_2$,



Şekil 3.11. ANFIS mimarisi.

Katman 1: Bu katmandaki her i düğümü, kare düğümdür.

$$O_i^1 = \mu_{A_i}(x) \quad (3.21)$$

x ise i düğümünün girdisidir. A_i düğüm işlevinin dilsel etiketidir. Denklem (3.21)'de gösterilen O_i^1 , A_i 'nin üyelik fonksiyonudur. Genellikle $\mu_{A_i}(x)$ 'in minimum 0'a maksimum 1'e eşit olacağı şekilde çan şeklinde olması seçilir. Denklem (3.22) ve Denklem (3.23)'te örnekleri verilmiştir.

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (3.22)$$

$$\mu_{A_i}(x) = \exp \left\{ - \left(\frac{x - c_i}{a_i} \right)^2 \right\} \quad (3.23)$$

$\{a_i, b_i, c_i\}$ parametre kümesini oluşturur. Parametrelerin değerleri değiştikçe çan şeklindeki fonksiyonlar da değişir bu da dilsel etiket A_i üzerinde çeşitli üyelik fonksiyon biçimleri gösterir. Katman 1’de bulunan parametreler öncül parametreler olarak isimlendirilir.

Katman 2: Bu katmandaki her düğüm 2 etiketli bir daire düğümü olmak ile birlikte gelen sinyalleri çoğaltır ve ürünü dışarı gönderir. Bu katmanda gerçekleşen işlem Denklem (3.24)’te gösterilmiştir.

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), i = 1, 2 \quad (3.24)$$

Bir kuralın ateşleme gücünü her düğüm çıkışı temsil eder.

Katman 3: Bu katmandaki düğümler, N etiketli daire düğümleridir. Düğüm i’nin, i. kuralının ateşleme gücünün tüm kuralların ateşleme güçlerinin toplamına oranını hesaplar. Bu oran Denklem (3.25)’te ifade edilir.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2 \quad (3.25)$$

Bu katmanın çıktıları normalleştirilmiş ateşleme güçleri olarak isimlendirilir.

Katman 4: Bu katmandaki her i düğümü kare düğümdür.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i(p_i x + q_i y + r_i) \quad (3.26)$$

$\{p_i, q_i, r_i\}$ parametre kümesidir, $\bar{w}_i$ ise katman 3’ün çıktısıdır. f_i girdi değişkenlerine bağlı olarak tanımlanan doğrusal fonksiyondur. Kuralın sisteme olan katkısını belirlemek için normalleştirilmiş ateşleme gücü ile doğrusal fonksiyon çarpılır. Bu işlem Denklem (3.26)’da gösterilmiştir. Bu katmandaki parametreler, ardışık parametreler olarak isimlendirilir.


Katman 5: Bu katmandaki tek düğüm olan $\sum$ etiketli daire düğüm, Katman 4’te elde edilen ağırlıklı çıktıların toplamı genel çıktıyı oluşturur. Bu hesaplama Denklem (3.27)’de gösterilir.

$$O_i^5 = \text{Genel çıktı} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (3.27)$$


3.2.5 Dalgacık dönüşümü

Dalgacık dönüşümü sinyalin zaman ve frekans bileşenlerini aynı andan incelemek için kullanılan yöntemdir. Veriyi farklı frekans bileşenlerine ayırdıktan sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel fonksiyonları dalgacıklar olarak adlandırılır (Partal, 2007). Bir veriyi farklı frekans bileşenlerine ayırmak için yaygın olarak kullanılan dönüşümler: Fourier ve Dalgacık dönüşümleridir. Fourier ve Dalgacık dönüşümleri arasındaki farklar Şekil 3.12 ve 3.13'te verilmiştir.

Fourier analizi ile dalgacık analizinin frekans-zaman ölçeğinde gösterimi Şekil 3.12'de verilmiştir. Fourier analizinde sinyalin tüm frekans bileşenleri sabit zaman çözünürlüğü ile incelendiğinden dolayı sinyalin zaman içinde ne zaman değiştiğini belirlemek sınırlıdır. Dalgacık analizinde ise zaman ve frekans çözünürlüğü sabit değildir. İncelenen frekansa bağlı olarak çözünürlük değişir. Yüksek frekanslı bileşenler kısa zaman aralıklarında analiz edilirken, düşük frekanslı bileşenler daha uzun zaman dilimlerinde analiz edilir. Böylece sinyaldeki ani değişiklikleri net bir şekilde gözlemlemek mümkündür.



Şekil 3.12. Fourier ve Dalgacık analizlerinin frekans-zaman ölçeğinde gösterimi (URL-2).




Şekil 3.13. Fourier ve Dalgacık dönüşümleri ile sinyalin ayrıştırılmasının karşılaştırılması (URL-2).

Bir sinyalin Fourier ve dalgacık dönüşümleri ile analiz edilmesindeki fark Şekil 3.13’te verilmiştir. Fourier dönüşümünde, sinyal farklı frekanslardaki sinüzoidlerin toplanması ile elde edilir. Fourier dönüşümünde sinyalin frekans içeriğini belirlemekte başarılı olsa da, bu bileşenlerin hangi anda gerçekleştiği belirlenemez. Dalgacık dönüşümünde ise sinyal, farklı ölçek ve zaman konumlarında yer alan dalgacıklar ile gösterilir; bu sayede hem frekans bileşenleri hem de bu bileşenlerin zaman içindeki konumları birlikte analiz edilir. Bu yönüyle dalgacık dönüşümü zamana duyarlı sinyallerin analizinde etkili sonuç verir.

Bir dalgacık fonksiyonundan, herhangi bir işlevsel biçimi değiştirmeden onu zamansal olarak kaydırarak veya ölçeklendirerek birçok farklı dalgacık oluşturulabilir (Daubechies, 1988). Dalgacık fonksiyonunun kaydırılması, zaman boyunca farklı frekansların durumlarının görülmesini sağlarken; dalgacık fonksiyonunun ötelenmesi ana dalgacık fonksiyonunun frekansını değiştirir (Maity ve Suman, 2019). Ana dalgacık orijinal dalgacık fonksiyonuna verilen isimdir, ondan türetilen diğer fonksiyonlara yavru dalgacık adı verilir. Denklem (3.28)’de verilen bir ana dalgacık $\Psi(t)$ için, yavru dalgacık fonksiyonları($\Psi_{a,b}(t)$)şu şekilde elde edilir:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (3.28)$$

Burada a , ölçekleme parametresidir. Sırasıyla b ve t , kaydırma parametresi ve zaman adımıdır. Kaydırma parametresi ana dalgacığın zamana göre kaydırılmasını sağlarken; ölçekleme parametresi ana dalgacığın frekansının değiştirilmesini sağlar. Ölçekleme parametresinde düşük ölçek ayrıntılı görünüm sağlarken, yüksek ölçek ayrıntılı olmayan görünüm sağlar. Ölçekleme, zaman serisindeki farklı frekans aralıklarındaki bilgileri görebilmek için önemlidir.



Şekil 3.14. Dalgacık dönüşümünün seviyeli ayrışma yapısının şematik gösterimi (URL-3).

Dalgacık dönüşümünde sinyalin yaklaşık ve detay bileşenlerine ayrışması Şekil 3.14'te gösterilmiştir. İlk başta sinyal, genel yapıyı gösteren yaklaşık bileşen ve ayrıntıları gösteren detay bileşenlerine ayrılır. Daha sonra yaklaşık bileşen tekrar dalgacık dönüşümüne girer ve yeniden detay ve yaklaşık bileşenlerine ayrılır. Böylece sinyal kademeli bir şekilde daha küçük bileşenlerine ayrılmış olur.

3.2.6 Model performans başarı ölçütleri

MATLAB programı kullanılarak geliştirilen modeller; korelasyon (R), Nash-Sutcliffe verimlilik katsayısı (NSE), Kling-Gupta verimlilik katsayısı (KGE), performans indisi (PI), karekök ortalama karesel hata ($RMSE$) istatistiksel değerlendirme kriterleri kullanılarak, model performansları değerlendirilmiştir. R , NSE ve KGE değerlendirme kriterleri için en iyi değer 1'e yakın olurken; PI ve $RMSE$ için en iyi değer 0'a yakın olan değerdir. Çizelge 3.4'te Nash-Sutcliffe verimlilik katsayısının değerlerine göre performans derecesi gösterilmiştir. Bahsedilen istatistiksel değerlendirme kriterlerinin hesaplanması Denklem (3.29) ile (3.35) arasında gösterilmiştir.

$$R = \frac{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{1(Göz)}) \times (X_{i(Hesap)} - \bar{X}_{1(Hesap)})}{\sqrt{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{1(Göz)})^2} \times \sqrt{\sum_{i=1}^N (X_{i(Hesap)} - \bar{X}_{1(Hesap)})^2}} \quad (3.29)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (X_{i(Göz)} - X_{i(Hesap)})^2}{\sum_{i=1}^N (X_{i(Göz)} - \bar{X}_{1(Göz)})^2} \quad (3.30)$$

$$PI = \frac{\frac{RMSE}{\bar{X}_{1(Göz)}}}{1+r} \quad (3.31)$$

$$RMSE = \left[\frac{1}{N} \times \sum_{i=1}^N (X_{i(Göz)} - X_{i(Hesap)})^2 \right]^{1/2} \quad (3.32)$$

$$KGE = 1 - [(R - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2]^{1/2} \quad (3.33)$$

$$\alpha = \frac{\sigma_{Hesap}}{\sigma_{Göz}} \quad (3.34)$$

$$\beta = \frac{\bar{X}_{1(Hesap)}}{\bar{X}_{1(Göz)}} \quad (3.35)$$

Çizelge 3.4. Nash-Sutcliffe verimlilik katsayısı (Moriasi vd., 2007).

Performans Derecesi	NSE
Çok İyi	$0.75 < NSE \leq 1.00$
İyi	$0.65 < NSE \leq 0.75$
Yeterli	$0.50 < NSE \leq 0.65$
Kötü	$NSE \leq 0.50$

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu çalışmada Sacramento Nehri'ndeki 11447650 numaralı USGS istasyonundan 1966-1973 yıllarında elde edilen günlük askıda sediment konsantrasyonu, günlük akım debisi ve su sıcaklığı verileri kullanılmıştır. Günlük askıda sediment yükünün tahmin edilmesi amacıyla $t + 1$, t , $t - 1$, $t - 2$ zamanlarına ait akım debisi, askıda sediment konsantrasyonu, su sıcaklığı parametreleri farklı kombinasyonlar ile girdi parametresinde kullanılırken, $t + 1$ anındaki askıda sediment konsantrasyonunun çıktı parametresinde kullanıldığı 15 model oluşturulmuştur. Oluşturulan 15 model ile günlük askıda sediment yükünün tahmin edilmesi için ANFIS, Destek Vektör Makinesi (DVM), Gauss Sürec Regresyonu (GPR) ve Rastgele Orman (RO) yöntemleri kullanılmıştır. Destek Vektör Makinesi yönteminde Gauss, Lineer ve Polinom olmak üzere 3 farklı çekirdek fonksiyonu kullanılmıştır. Ayrıca tahminlerdeki hassasiyeti artırabilmek için dalgacık dönüşümü uygulanmıştır. Bu bölümde modellerin ve yöntemlerin hem dalgacık dönüşümü öncesi hem de dalgacık dönüşümü sonrasında performansları karşılaştırılmıştır. Yöntemlerin ve modellerin performanslarının karşılaştırılmasında Korelasyon, RMSE gibi istatistiksel ölçüt değerleri kullanılmıştır. Ayrıca elde edilen bulgular tablolar ve grafiklerle (Violin, Taylor, Kutu) gösterilmiş ve yorumlanmıştır.


4.1 Dalgacık Dönüşümü Öncesi Modellerin Değerlendirilmesi

DVM-Lineer fonksiyonunda dalgacık dönüşümü öncesinde M02, M03, M05, M07, M10, M13 ve M14 modellerinin başarılı olduğu görülmüştür. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri bahsedilen tüm modellerde birbirine yakın sonuç verdiği gözlemlenmiştir. Sonuçlar yakın olmasına rağmen en iyi sonucu veren model 3 günlük geciktirilen askıda sediment konsantrasyonunun ($Q_{S_t} Q_{S_{t-1}} Q_{S_{t-2}}$) yer aldığı M03 (Korelasyon: 0.88, NS: 0.77, KGE: 0.80, PI:0.22, RMSE: 0.46) olmuştur. En zayıf performansı gösteren model T_{t+1} girdi parametresini kullanan M11 (Korelasyon: 0.33, NS: 0.09, KGE: 0.12, PI:0.63, RMSE: 0.95) modelidir. İyi sonuç vermeyen diğer bir model ise girdi parametresinde Q_{t+1} kullanan M06 modeli (Korelasyon: 0.57, NS: 0.31, KGE: 0.32, PI:0.46, RMSE: 0.82) olmuştur. M08 ve M09 modelleri girdi parametrelerinde debi ve sıcaklık parametrelerini kullanmışlardır ve her iki modelin de sonuçları M06'ya yakındır.

Genel olarak bakıldığında girdi parametrelerinde askıda sediment konsantrasyonu kullanan modellerin başarılı olduğu görülmüştür. Modellerin performans sonuçları Şekil 4.1’de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.1’de verilmiştir.

Çizelge 4.1. DVM-Lineer model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
DVM_Lineer	M01	0.874	0.763	0.821	0.232	0.486	0.884	0.779	0.825	0.214	0.470
	M02	0.879	0.771	0.823	0.228	0.478	0.886	0.783	0.825	0.212	0.466
	M03	0.884	0.780	0.810	0.223	0.469	0.890	0.788	0.815	0.209	0.460
	M04	0.875	0.762	0.783	0.233	0.488	0.884	0.776	0.793	0.215	0.473
	M05	0.883	0.776	0.790	0.225	0.473	0.889	0.784	0.798	0.211	0.465
	M06	0.572	0.318	0.329	0.470	0.825	0.649	0.377	0.401	0.410	0.789
	M07	0.880	0.771	0.790	0.228	0.478	0.890	0.787	0.804	0.209	0.461
	M08	0.580	0.327	0.335	0.464	0.820	0.659	0.391	0.409	0.403	0.780
	M09	0.578	0.326	0.339	0.465	0.821	0.654	0.387	0.412	0.405	0.782
	M10	0.880	0.771	0.787	0.228	0.479	0.890	0.786	0.801	0.209	0.462
	M11	0.331	0.096	0.121	0.639	0.950	0.494	0.213	0.186	0.508	0.887
	M12	0.875	0.765	0.817	0.231	0.484	0.885	0.781	0.822	0.213	0.468
	M13	0.882	0.775	0.797	0.225	0.474	0.888	0.784	0.805	0.211	0.464
	M14	0.880	0.774	0.822	0.226	0.475	0.888	0.785	0.824	0.210	0.464
	M15	0.874	0.761	0.779	0.233	0.489	0.884	0.775	0.790	0.215	0.474




Şekil 4.1. DVM-Linear yönteminin model performans sonuçları.

DVM-Polinom fonksiyonunda dalgacık dönüşümü öncesinde M02, M03, M05, M10, M13, M14 modellerinin başarılı olduğu görülmüştür. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri bahsedilen tüm modellerde birbirine yakın sonuç verdiği gözlemlenmiştir. Sonuçlar yakın olmasına rağmen en iyi sonucu girdi parametresinde $T_t T_{t-1} Q_t Q_{t-1} Q_{S_t} Q_{S_{t-1}}$ kullanılan M13 modeli (Korelasyon: 0.91, NS: 0.83, KGE: 0.84, PI: 0.19, RMSE: 0.40) göstermiştir. M13 modeline girdi parametrelerinde oldukça benzer olan M10 modeli ($T_{t+1} T_t Q_{t+1} Q_t Q_{S_t}$) en iyi ikinci modeldir (Korelasyon: 0.90, NS: 0.82, KGE: 0.83, PI: 0.19, RMSE: 0.41). En zayıf performansa sahip olan model ise M11 (Korelasyon: 0.25, NS:-0.06, KGE: 0.14, PI: 0.73, RMSE: 1.02) modeli olmuştur. İyi sonuç vermeyen diğer modeller ise DVM-Linear’de olduğu gibi M06, M08 ve M09 modelleri olmuştur. Genel olarak bakıldığında debi, sediment konsantrasyonu ve sıcaklık parametrelerinin birlikte kullanıldığı modellerin başarılı olduğu

gözlemlenmiştir. Girdi parametrelerinde askıda sediment konsantrasyonu kullanılmasının tüm modellerin performansını yüksek ölçüde iyileştirdiği gözlemlenmiştir. Model performans sonuçları Şekil 4.2’de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.2’de verilmiştir.

Çizelge 4.2. DVM-Polinom model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
DVM_Polinom	M01	0.882	0.771	0.779	0.227	0.478	0.892	0.784	0.772	0.210	0.464
	M02	0.903	0.815	0.853	0.202	0.430	0.910	0.824	0.836	0.188	0.419
	M03	0.907	0.820	0.840	0.199	0.423	0.912	0.827	0.831	0.186	0.415
	M04	0.881	0.768	0.765	0.229	0.482	0.891	0.780	0.763	0.212	0.469
	M05	0.906	0.818	0.825	0.200	0.426	0.913	0.827	0.822	0.186	0.416
	M06	0.602	0.345	0.336	0.452	0.809	0.668	0.396	0.408	0.399	0.777
	M07	0.896	0.798	0.798	0.212	0.449	0.916	0.832	0.819	0.183	0.410
	M08	0.663	0.422	0.422	0.409	0.760	0.724	0.480	0.478	0.358	0.721
	M09	0.684	0.466	0.547	0.388	0.730	0.805	0.624	0.625	0.291	0.613
	M10	0.910	0.825	0.832	0.196	0.418	0.929	0.857	0.845	0.168	0.378
	M11	0.251	-0.061	0.144	0.736	1.029	0.501	0.235	0.269	0.499	0.874
	M12	0.883	0.772	0.772	0.227	0.478	0.892	0.785	0.777	0.210	0.463
	M13	0.914	0.833	0.842	0.191	0.409	0.917	0.838	0.847	0.180	0.403
	M14	0.907	0.820	0.846	0.199	0.424	0.914	0.832	0.846	0.183	0.409
	M15	0.881	0.769	0.768	0.228	0.480	0.891	0.781	0.764	0.212	0.468



Şekil 4.2. DVM-Polinom model performans sonuçları.


DVM-Gauss fonksiyonunda dalgacık dönüşümü öncesinde M02, M03, M05, M07 ve M14 modellerinin başarılı olduğu gözlemlenmiştir. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri bahsedilen tüm modellerde birbirine yakın sonuç verdiği gözlemlenmiştir. Sonuçlar yakın olmasına rağmen en iyi sonucu girdi parametresinde Q_{t+1} Q_t Q_{S_t} kullanan M07 modeli (Korelasyon: 0.91, NS: 0.83, KGE: 0.80, PI: 0.19, RMSE: 0.40) göstermiştir. İkinci iyi model ise girdi parametresinde Q_{S_t} $Q_{S_{t-1}}$ kullanan M02 modelidir (Korelasyon: 0.90, NS: 0.81, KGE: 0.81, PI: 0.20, RMSE: 0.42). En zayıf performans veren modelin M11 olduğu görülmüştür (Korelasyon: 0.35, NS: 0.10, KGE: 0.17, PI: 0.62, RMSE: 0.94). Diğer iyi performans vermeyen modeller ise sırasıyla M06, M08 ve M09 modelleridir. M06 modeli girdi parametresinde yalnızca Q_{t+1} kullanır. M08 ise girdi parametresi olarak T_{t+1} Q_{t+1} kullanır. Sonuçlara baktığımızda M08 modelinin M06 modeline göre daha iyi performansa sahip olduğunu görürüz. Bu da sıcaklık

parametresinin eklenmesinin sonuca olumlu yönde etki ettiğini göstermiştir. M09 modelinde girdi parametresi olarak T_{t+1} T_t Q_{t+1} Q_t kullanır. M09 modelinin M08'e göre performansının daha iyi olduğu gözlemlenmiştir. Bu da daha fazla debi ve sıcaklık zaman adımlarının eklenmesinin sonuca olumlu yönde etki ettiğini göstermektedir. Genel olarak baktığımızda ise girdi parametresinde askıda sediment konsantrasyonu olan modellerin çok daha iyi performans sergilediği görülmektedir. Modellerin performans sonuçları Şekil 4.3'de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.3'de verilmiştir.

Çizelge 4.3. DVM-Gauss model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
DVM_Gauss	M01	0.882	0.772	0.781	0.227	0.478	0.891	0.783	0.770	0.211	0.466
	M02	0.907	0.817	0.811	0.201	0.428	0.911	0.818	0.794	0.191	0.427
	M03	0.899	0.803	0.802	0.209	0.444	0.912	0.817	0.778	0.192	0.428
	M04	0.887	0.780	0.779	0.222	0.469	0.893	0.783	0.759	0.211	0.466
	M05	0.899	0.801	0.784	0.210	0.446	0.910	0.809	0.764	0.196	0.437
	M06	0.583	0.336	0.407	0.460	0.814	0.698	0.445	0.458	0.376	0.745
	M07	0.917	0.832	0.804	0.191	0.410	0.925	0.841	0.796	0.178	0.399
	M08	0.661	0.429	0.461	0.407	0.755	0.742	0.506	0.501	0.345	0.703
	M09	0.707	0.487	0.559	0.375	0.716	0.835	0.657	0.616	0.273	0.586
	M10	0.903	0.795	0.743	0.213	0.453	0.919	0.822	0.758	0.188	0.422
	M11	0.352	0.106	0.172	0.626	0.945	0.543	0.263	0.277	0.476	0.858
	M12	0.878	0.761	0.752	0.233	0.489	0.890	0.775	0.747	0.215	0.474
	M13	0.885	0.765	0.724	0.230	0.485	0.906	0.794	0.734	0.204	0.453
	M14	0.903	0.802	0.771	0.209	0.445	0.912	0.811	0.760	0.195	0.435
	M15	0.881	0.770	0.769	0.228	0.479	0.894	0.782	0.750	0.211	0.467


DVM yöntemi kullanılarak elde edilen sonuçlarda en iyi sonuç veren modeller; DVM-Linear M03 modeli (Korelasyon: 0.88, NS: 0.77, KGE: 0.80, PI:0.22, RMSE: 0.46), DVM- Polinom M13 modeli (Korelasyon: 0.91, NS: 0.83, KGE: 0.84, PI: 0.19, RMSE: 0.40), DVM-Gauss M07 modeli (Korelasyon: 0.91, NS: 0.83, KGE: 0.80, PI: 0.19, RMSE: 0.40) olduğu görülmektedir. Bu üç model istatistiksel kriterlere göre kıyaslandığında DVM-Polinom M13 modeli ile DVM-Gauss M07 modelinin birbirine yakın performans sergilediği ve DVM-Linear M03 modelinden daha iyi olduğu görülmektedir.



Şekil 4.3. DVM-Gauss model performans sonuçları.

Rastgele Orman yönteminde dalgacık dönüşümü öncesinde kurulan model sonuçları incelendiğinde; M02, M05 ve M14 modellerinin başarılı olduğu gözlemlenmiştir. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri bahsedilen tüm modellerde birbirine yakın sonuç verdiği gözlemlenmiştir. Sonuçlar yakın olmasına rağmen en iyi sonucu girdi parametresinde $Q_{S_t} Q_{S_{t-1}}$ kullanan M02 modeli olmuştur (Korelasyon: 0.89, NS: 0.80, KGE: 0.86, PI: 0.20, RMSE: 0.43). M02, M05 ve M14 modellerine baktığımızda tüm modeller ortak girdi parametresi $Q_{S_t} Q_{S_{t-1}}$ olduğu gözlemlenmiştir. Ayrıca bu girdi parametresi M03 ve M13 modellerinde de kullanılmıştır. Ancak M03 modelinde bu girdi parametresine ek olarak $Q_{S_{t-2}}$ parametresi bulunmaktadır. M03 modeli başarılı modellerden olsa da M02 modeli ile kıyaslandığında ek parametrenin olumlu bir etki göstermediği gözlemlenmiştir. M13 de başarılı modeller arasında yer alır. Ancak DVM-Polinom fonksiyonunda debi ve sıcaklık parametrelerinin eklenmesi sonuca olumlu yönde

katkıda bulunurken, Rastgele Orman yönteminde bu parametrelerin sonuca olan etkisinin daha az olduğu gözlemlendi. En zayıf performansı gösteren model ise M11 modeli olduğu gözlemlenmiştir (Korelasyon: 0.28, NS: -0.25, KGE: 0.24, PI: 0.78, RMSE: 1.12). Rastgele Orman yöntemi dalgacık dönüşümü öncesi model performans sonuçları Şekil 4.4’de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.4’te verilmiştir.



Şekil 4.4. RO model performans sonuçları.


Çizelge 4.4. RO model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
Rastgele Orman (RO)	M01	0.855	0.728	0.829	0.251	0.521	0.914	0.835	0.871	0.182	0.406
	M02	0.899	0.809	0.862	0.206	0.437	0.935	0.872	0.869	0.158	0.358
	M03	0.887	0.786	0.837	0.219	0.462	0.933	0.866	0.847	0.162	0.366
	M04	0.869	0.752	0.815	0.238	0.498	0.932	0.867	0.874	0.162	0.365
	M05	0.900	0.807	0.846	0.207	0.439	0.946	0.892	0.880	0.144	0.328
	M06	0.526	0.181	0.421	0.530	0.904	0.789	0.621	0.673	0.295	0.616
	M07	0.894	0.788	0.794	0.218	0.461	0.955	0.906	0.874	0.134	0.306
	M08	0.626	0.304	0.521	0.459	0.834	0.849	0.715	0.723	0.247	0.534
	M09	0.664	0.356	0.553	0.431	0.802	0.917	0.827	0.783	0.186	0.416
	M10	0.884	0.769	0.800	0.228	0.481	0.953	0.904	0.880	0.135	0.309
	M11	0.283	-0.257	0.241	0.781	1.120	0.601	0.362	0.432	0.427	0.799
	M12	0.835	0.694	0.761	0.270	0.553	0.921	0.840	0.817	0.178	0.399
	M13	0.889	0.780	0.796	0.222	0.469	0.945	0.889	0.867	0.147	0.333
	M14	0.899	0.806	0.857	0.207	0.440	0.945	0.891	0.882	0.145	0.330
	M15	0.858	0.722	0.759	0.254	0.527	0.933	0.867	0.854	0.161	0.364

Gauss Süreç Regresyonu (GPR) yönteminde dalgacık dönüşümü öncesinde kurulan modellerin sonuçları değerlendirildiğinde; M05, M07, M10, M13 ve M14 modellerinin en başarılı modeller olduğu gözlemlenmiştir. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri bahsedilen tüm modellerde birbirine yakın sonuç verdiği gözlemlenmiştir. Sonuçlar yakın olmasına rağmen en iyi sonucu girdi parametresinde Q_t Q_{t-1} Q_{S_t} $Q_{S_{t-1}}$ kullanan M05 modeli göstermiştir (Korelasyon: 0.90, NS: 0.81, KGE: 0.86, PI: 0.20, RMSE: 0.43). M05 modelinin performansına en yakın olan M07 modeli olduğu görülmüştür (Korelasyon: 0.90, NS: 0.80, KGE: 0.83, PI: 0.20, RMSE: 0.43). M07 girdi parametresinde Q_{t+1} Q_t Q_{S_t} kullanılmıştır. M05 ve M07 modellerinin her ikisinde de girdi parametresi olarak askıda sediment konsantrasyonu ve debi yer almaktadır. Gauss Süreç Regresyonu yönteminde başarılı olan modellere bakıldığında debi parametresinin sonuçlara olumlu yönde etki ettiği gözlemlenmiştir. En zayıf performansı gösteren model ise diğer yöntemlerde olduğu gibi M11 modeli olmuştur (Korelasyon: 0.30, NS: -0.13, KGE: 0.22, PI: 0.73, RMSE: 1.06). Ayrıntılı olarak Model performans sonuçları Şekil 4.5'te ve Çizelge 4.5'te verilmiştir.

Çizelge 4.5. GPR model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
Gauss Süreç Regresyonu (GPR)	M01	0.849	0.719	0.811	0.256	0.530	0.930	0.864	0.893	0.164	0.369
	M02	0.873	0.762	0.832	0.233	0.488	0.961	0.924	0.936	0.120	0.275
	M03	0.842	0.707	0.802	0.263	0.541	0.984	0.968	0.966	0.077	0.178
	M04	0.824	0.678	0.768	0.278	0.567	0.949	0.900	0.914	0.139	0.316
	M05	0.903	0.812	0.867	0.204	0.433	0.974	0.948	0.949	0.099	0.228
	M06	0.591	0.274	0.453	0.479	0.851	0.712	0.507	0.588	0.351	0.702
	M07	0.901	0.810	0.833	0.205	0.436	0.994	0.988	0.985	0.048	0.111
	M08	0.658	0.390	0.514	0.421	0.780	0.747	0.559	0.637	0.325	0.664
	M09	0.705	0.451	0.612	0.389	0.740	0.941	0.884	0.891	0.150	0.341
	M10	0.900	0.808	0.826	0.206	0.438	0.995	0.989	0.986	0.044	0.103
	M11	0.300	-0.138	0.223	0.734	1.066	0.586	0.343	0.401	0.438	0.810
	M12	0.825	0.674	0.798	0.280	0.570	0.955	0.912	0.921	0.130	0.296
	M13	0.899	0.804	0.854	0.209	0.443	0.978	0.957	0.955	0.090	0.208
	M14	0.888	0.787	0.851	0.218	0.461	0.969	0.938	0.945	0.108	0.248
	M15	0.819	0.667	0.759	0.284	0.576	0.958	0.918	0.926	0.125	0.286




Şekil 4.5. Gauss Süreç Regresyonu yönteminin model performans sonuçları.

ANFIS yönteminde dalgacık dönüşümü öncesinde kurulan modellerin performansları değerlendirildiğinde; M02, M03, M05, M07, M10, M13, M14 modellerinin başarılı

olduğu gözlemlenmiştir. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri bahsedilen tüm modellerde birbirine yakın sonuç verdiği gözlemlenmiştir. Sonuçlar yakın olmasına rağmen en iyi sonucu girdi parametresinde $Q_{S_t}Q_{S_{t-1}}Q_{S_{t-2}}$ kullanan M03 modeli göstermiştir (Korelasyon: 0.89, NS: 0.80, KGE: 0.84, PI: 0.20, RMSE:0.43). M02 modelinin performansı M03'e yakındır. İki modelin girdi parametreleri arasında M03 modelinde bu girdi parametresine ek olarak $Q_{S_{t-2}}$ parametresi bulunmaktadır. ANFIS yönteminde bu parametrenin bulunması performansa olumlu yönde katkı sağladığı görülmektedir. Ayrıca girdi parametrelerinde debi ve askıda sediment konsantrasyonunun birlikte bulunduğu model M05, girdi parametrelerinde sıcaklık ve askıda sediment konsantrasyonu bulunan M14 modelinden daha başarılı olduğu gözlemlenmiştir. Genel olarak bakıldığında girdi parametrelerinde askıda sediment konsantrasyonu olan modellerin başarılı olduğu gözlemlendi. Ayrıca girdi parametrelerinde askıda sediment konsantrasyonu ve debinin birlikte kullanıldığı modeller, askıda sediment konsantrasyonu ve sıcaklık kullanılan yöntemlerden daha başarılı olduğu gözlemlenmiştir. Diğer yöntemlerde de olduğu gibi en zayıf performans gösteren modelin M11 modeli olduğu gözlemlenmiştir (Korelasyon: 0.33, NS: 0.007, KGE: 0.18, PI: 0.66, RMSE: 0.99). Modellerin performans sonuçları Şekil 4.6'da verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.6'da verilmiştir.


Çizelge 4.6. ANFIS model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
ANFIS	M01	0.874	0.764	0.828	0.232	0.486	0.884	0.781	0.836	0.212	0.467
	M02	0.890	0.792	0.844	0.216	0.456	0.890	0.792	0.844	0.206	0.456
	M03	0.899	0.807	0.846	0.207	0.439	0.894	0.800	0.851	0.202	0.447
	M04	0.875	0.765	0.824	0.231	0.484	0.885	0.783	0.837	0.212	0.466
	M05	0.897	0.803	0.836	0.209	0.444	0.895	0.800	0.851	0.202	0.447
	M06	0.572	0.307	0.389	0.474	0.832	0.649	0.421	0.503	0.395	0.761
	M07	0.897	0.802	0.835	0.210	0.445	0.913	0.833	0.876	0.183	0.409
	M08	0.576	0.306	0.404	0.473	0.832	0.664	0.440	0.524	0.385	0.748
	M09	0.635	0.372	0.518	0.433	0.792	0.759	0.577	0.660	0.317	0.651
	M10	0.896	0.801	0.834	0.210	0.446	0.914	0.836	0.879	0.181	0.405
	M11	0.331	0.007	0.186	0.669	0.996	0.494	0.244	0.285	0.498	0.869
	M12	0.875	0.765	0.823	0.231	0.484	0.887	0.786	0.840	0.210	0.462
	M13	0.897	0.803	0.836	0.209	0.444	0.897	0.805	0.854	0.199	0.442
	M14	0.893	0.795	0.841	0.214	0.452	0.894	0.799	0.850	0.203	0.448
	M15	0.876	0.766	0.823	0.231	0.483	0.887	0.786	0.840	0.210	0.462



Şekil 4.6. ANFIS model performans sonuçları.


Dalgacık dönüşümü öncesi kurulan modellerin performansları incelendiğinde en iyi sonuç veren modellerin: DVM için: M03_Lineer, M13_Polinom, M10_Polinom, M07_Gauss, M02_Gauss; Rastgele Orman algoritması için: M02_RO; GPR için: M05_GPR ve M07_GPR; ve ANFIS için: M03_ANFIS oldukları görülmektedir. Bu modellerin kendi içlerindeki karşılaştırılması amacıyla Keman (Violin) ve Taylor grafikleri ve hataların gösterimi için Kutu grafikleri kullanılmıştır.




Şekil 4.7. Dalgacık dönüşümü öncesindeki en başarılı modellerin Violin grafiği.

Dalgacık dönüşümü öncesinde en iyi modellerin performanslarını kıyaslamak için Violin grafiği kullanılmıştır. Violin grafiği, verinin yoğunluğunu ve dağılımını gösterir. Grafikte geniş görünen bölgeler verinin en yoğun olduğu bölgelerdir. Orta kısımda bulunan kutu grafiği ise merkezi dağılımı ve medyanı gösterir. Bir modelin başarısı gözlem verisinin dağılımını benzerliği ile ölçülür. Şekil 4.7’de en başarılı modellerin yer aldığı Violin grafiğinde en başarılı modelin M03L (DVM-Lineer) olduğu görülmektedir. M03L hem merkezde hem de uç bölgelerde başarılı tahmin verdiği gözlemlenmiştir. Ayrıca gözlem verisinin dağılımına en çok benzeyen modeldir. M03-ANFIS modeli ise diğer iyi model olduğu gözlemlenmiştir. M03-ANFIS merkezde ve uçlardaki yoğunluğuyla gözlem verisinin dağılımına benzemektedir.

Taylor grafiğinde modeller kıyaslanırken standart sapma, korelasyon ve hata değerlerine göre modeller sıralanır. Violin grafiğinde en başarılı model M03L (DVM-Lineer) iken Şekil 4.8’de verilen Taylor grafiğinde M03L en başarılı model değildir. Bunun nedeni korelasyon değerinin diğer modellerden düşük olmasıdır. Taylor grafiğine göre en başarılı model M05-GPR modelidir. Diğer başarılı modeller sırasıyla M07-GPR ve M03-ANFIS modelleridir.



Şekil 4.8. Dalgacık dönüşümü öncesindeki en başarılı modellerin Taylor grafiği.



Şekil 4.9. Dalgacık dönüşümü öncesindeki en başarılı modellerin hatalarının Kutu grafiği.


Şekil 4.9’da verilen Kutu grafiği verilerin ortalaması, yayılımı ve uç değerlerini yani verilerin genel dağılımını gösterir. Kutu grafiğine bakıldığında dalgacık dönüşümü öncesindeki başarılı modellerin ekstrem değerleri çok iyi yakalayamadığını göstermektedir. En başarılı modellerin grafiğine bakıldığında medyanın sifra yakın olması ve kutusunun dar olmasının yanında genel olarak dengeli olduğu görülen M07-GPR modelinin en başarılı model olduğu görülmektedir.

4.2 Dalgacık Dönüşümü Sonrası Modellerin Değerlendirilmesi

Dalgacık dönüşümünde db45 dalgacığı kullanılarak 5 seviyeli dalgacık dönüşümü uygulanmıştır. W-DVM-Linear fonksiyonunda M02, M03, M05, M13 ve M14 modellerinin başarılı olduğu gözlemlenmiştir. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri bahsedilen tüm modellerde birbirine yakın sonuç verdiği gözlemlenmiştir. Başarılı modellerin performansları birbirine yakın olmasına rağmen en iyi performans gösteren M03 modeli olmuştur (Korelasyon: 0.98, NS: 0.96, KGE: 0.93, PI: 0.07, RMSE: 0.17). Dalgacık öncesi DVM-Linear ile karşılaştırdığımızda girdi parametrelerinde yalnızca debi ya da sıcaklık içeren modellerin performanslarında etkin bir değişim olmadığı gözlemlenmiştir. Girdi parametrelerinde askıda sediment konsantrasyonu içeren modellerde ise performanslarında etkin bir iyileşme olduğu gözlemlenmiştir. Bu yöntemdeki başarılı modellerin girdi parametrelerinde ortak olarak Q_{S_t} $Q_{S_{t-1}}$ ’in ortak parametre olduğu görülmüştür. Modellerin performans sonuçları Şekil 4.10’da verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.7’de verilmiştir.

Çizelge 4.7. W-DVM_Lineer model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
W-DVM_Lineer	M01	0.910	0.823	0.819	0.197	0.421	0.928	0.856	0.844	0.168	0.379
	M02	0.982	0.960	0.913	0.090	0.199	0.984	0.965	0.932	0.081	0.187
	M03	0.986	0.969	0.932	0.080	0.177	0.988	0.975	0.950	0.068	0.158
	M04	0.914	0.828	0.809	0.193	0.414	0.934	0.865	0.838	0.163	0.368
	M05	0.982	0.960	0.913	0.090	0.200	0.984	0.966	0.936	0.079	0.184
	M06	0.571	0.316	0.330	0.471	0.826	0.651	0.376	0.399	0.409	0.790
	M07	0.928	0.856	0.838	0.176	0.379	0.949	0.896	0.873	0.142	0.323
	M08	0.583	0.329	0.339	0.463	0.819	0.664	0.393	0.408	0.401	0.779
	M09	0.609	0.361	0.375	0.444	0.799	0.709	0.454	0.456	0.370	0.739
	M10	0.928	0.856	0.834	0.176	0.380	0.950	0.897	0.872	0.141	0.321
	M11	0.340	0.099	0.138	0.633	0.949	0.506	0.227	0.204	0.500	0.879
	M12	0.910	0.822	0.813	0.197	0.421	0.928	0.856	0.840	0.169	0.380
	M13	0.982	0.960	0.914	0.091	0.201	0.984	0.967	0.938	0.079	0.183
	M14	0.982	0.960	0.913	0.090	0.199	0.984	0.965	0.933	0.080	0.186
	M15	0.914	0.829	0.811	0.193	0.413	0.934	0.865	0.841	0.163	0.367




Şekil 4.10. W-DVM-Linear yönteminin model performans sonuçları.

Çizelge 4.8.W-DVM_Polinom model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
W-DVM_Polinom	M01	0.894	0.796	0.879	0.213	0.451	0.942	0.886	0.887	0.149	0.338
	M02	0.925	0.814	0.853	0.200	0.431	0.997	0.995	0.995	0.032	0.074
	M03	0.889	0.674	0.746	0.270	0.571	0.998	0.997	0.997	0.024	0.056
	M04	0.568	-0.326	0.428	0.657	1.151	0.992	0.984	0.986	0.055	0.127
	M05	0.613	-2.565	-0.383	1.047	1.887	0.999	0.997	0.998	0.023	0.055
	M06	0.620	0.294	0.603	0.464	0.839	0.763	0.564	0.600	0.320	0.660
	M07	0.563	-1.343	0.043	0.876	1.530	0.997	0.994	0.994	0.034	0.080
	M08	0.248	-1.832	0.019	1.206	1.682	0.900	0.805	0.818	0.199	0.441
	M09	0.233	-6.227	-0.902	1.949	2.687	0.995	0.991	0.990	0.041	0.095
	M10	0.583	-2.730	-0.399	1.091	1.930	0.998	0.996	0.998	0.026	0.061
	M11	0.116	-0.590	0.081	1.011	1.260	0.532	0.269	0.315	0.478	0.855
	M12	0.562	-1.444	0.009	0.895	1.562	0.995	0.990	0.993	0.043	0.100
	M13	0.702	-0.814	0.104	0.708	1.346	0.998	0.997	0.996	0.025	0.058
	M14	0.708	-0.280	0.339	0.592	1.131	0.998	0.997	0.998	0.025	0.058
	M15	0.541	-2.468	-0.287	1.081	1.861	0.998	0.995	0.996	0.030	0.069

W-DVM-Polinom fonksiyonunda M01 ve M02 modellerinin diğer modellere göre daha iyi performans sergilediği gözlemlenmiştir. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri kıyaslandığında M02 modelinin en başarılı model olduğu gözlemlenmiştir (Korelasyon: 0.92, NS: 0.81, KGE: 0.85, PI: 0.20, RMSE: 0.43). DVM-Polinom ile kıyaslandığında M01 ve M02 modelleri dışındaki tüm modellerin performanslarında düşüş olduğu gözlemlenmiştir. Modellerin performans sonuçları Şekil 4.11’de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.8’de verilmiştir.




Şekil 4.11. W-DVM-Polinom model performans sonuçları.

W-DVM-Gauss fonksiyonu ile elde edilen sonuçlarda, diğer yöntemler ile kıyaslandığında model performansları çok yüksek olmamıştır. DVM-Gauss fonksiyonu ile kıyaslandığında tüm modellerin performanslarında düşüş olduğu gözlemlenmiştir. Yalnızca debi parametresi kullanan M06 modelinin performansında değişiklik gözlemlenmemiştir. Ancak girdi parametrelerinde debi ve sıcaklık

parametresi bulunan M08 ve M09 modellerinin performansı dalgacık dönüşümü öncesindeki performans ile kıyaslandığında düşüş olduğu gözlemlenmiştir. Bu da girdi parametresinde sıcaklık parametresinin kullanılmasının bu yöntemde model performansını kötüleştirdiğini göstermektedir. Modellerin performans sonuçları Şekil 4.12’de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.9’da verilmiştir.

Çizelge 4.9.W-DVM_Gauss model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
W-DVM_Gauss	M01	0.705	0.490	0.521	0.375	0.714	0.886	0.732	0.644	0.235	0.518
	M02	0.610	0.371	0.424	0.441	0.793	0.867	0.686	0.597	0.257	0.560
	M03	0.555	0.306	0.357	0.479	0.832	0.857	0.660	0.569	0.269	0.583
	M04	0.568	0.317	0.370	0.471	0.826	0.863	0.675	0.586	0.262	0.570
	M05	0.477	0.219	0.241	0.535	0.883	0.847	0.633	0.540	0.281	0.606
	M06	0.609	0.364	0.421	0.443	0.797	0.860	0.682	0.608	0.259	0.564
	M07	0.517	0.260	0.303	0.507	0.860	0.854	0.654	0.564	0.272	0.588
	M08	0.328	0.080	-0.033	0.646	0.959	0.826	0.578	0.487	0.305	0.650
	M09	0.163	0.013	-0.256	0.764	0.993	0.805	0.510	0.420	0.332	0.700
	M10	0.138	0.010	-0.281	0.782	0.994	0.804	0.501	0.409	0.335	0.706
	M11	0.174	-0.021	-0.022	0.770	1.010	0.767	0.512	0.459	0.338	0.698
	M12	0.204	0.028	-0.203	0.732	0.985	0.802	0.514	0.428	0.331	0.697
	M13	0.121	0.007	-0.300	0.795	0.996	0.803	0.496	0.404	0.337	0.710
	M14	0.173	0.020	-0.237	0.755	0.990	0.805	0.505	0.415	0.334	0.703
	M15	0.285	0.058	-0.092	0.675	0.970	0.820	0.553	0.459	0.315	0.669




Şekil 4.12. W-DVM-Gauss model performans sonuçları.

Genel olarak bakıldığında DVM yöntemi ile yapılan tahminlerde dalgacık dönüşümü öncesi modellerde iyi sonuçlar elde edildiği görülmüştür. Sonuçların iyileştirilmesi için uygulanan dalgacık dönüşümü sonrasında destek vektör makineleri içerisinde en iyi sonucu veren yöntemin W-DVM-Lineer olduğu bulunmuştur.

Dalgacık dönüşümü sonrası kullanılan Rastgele Orman (W-RO) yönteminde M01 (Korelasyon: 0.87, NS: 0.76, KGE: 0.76, PI: 0.23, RMSE: 0.48) ve M02 (Korelasyon: 0.88, NS: 0.76, KGE: 0.73, PI: 0.23, RMSE: 0.48) modellerinin diğer modellere göre daha iyi sonuç verdiği gözlemlenmiştir. RO yöntemi ile kıyaslandığında M01 modelinin dalgacık dönüşümü sonrası performansında iyileşme gösterdiği gözlemlenmiştir. Ancak M02 modelinin performansının dalgacık dönüşümü öncesinde daha iyi olduğu gözlemlenmiştir. Ayrıca W-RO yönteminde M06 ve M08 modellerinin de performansları dalgacık öncesi performanslarına göre daha iyi olduğu gözlemlenmiştir. Diğer modellerin performanslarında düşüş gözlemlenmiştir. Modellerin performans sonuçları Şekil 4.13’de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.10’da verilmiştir.

Çizelge 4.10. W-RO model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
W-Rastgele Orman (W-RO)	M01	0.878	0.764	0.768	0.231	0.485	0.965	0.923	0.871	0.121	0.277
	M02	0.881	0.763	0.739	0.232	0.487	0.974	0.942	0.885	0.104	0.240
	M03	0.875	0.754	0.737	0.237	0.496	0.978	0.950	0.893	0.097	0.223
	M04	0.852	0.708	0.692	0.261	0.540	0.968	0.928	0.870	0.117	0.269
	M05	0.839	0.689	0.678	0.271	0.557	0.976	0.944	0.886	0.102	0.236
	M06	0.710	0.465	0.574	0.383	0.731	0.917	0.819	0.756	0.190	0.425
	M07	0.836	0.683	0.675	0.274	0.563	0.970	0.932	0.873	0.113	0.260
	M08	0.679	0.431	0.519	0.402	0.754	0.943	0.867	0.790	0.160	0.364
	M09	0.638	0.371	0.498	0.433	0.792	0.954	0.890	0.810	0.145	0.331
	M10	0.812	0.639	0.627	0.297	0.601	0.973	0.939	0.880	0.107	0.247
	M11	0.287	0.025	0.098	0.686	0.987	0.892	0.686	0.548	0.254	0.560
	M12	0.851	0.706	0.679	0.262	0.542	0.972	0.936	0.877	0.110	0.253
	M13	0.826	0.665	0.654	0.283	0.578	0.977	0.946	0.884	0.100	0.232
	M14	0.857	0.721	0.700	0.255	0.528	0.976	0.945	0.885	0.102	0.234
	M15	0.831	0.670	0.648	0.280	0.574	0.970	0.932	0.873	0.113	0.260




Şekil 4.13. W-RO model performans sonuçları.

Dalgacık dönüşümü sonrası kullanılan GPR (W-GPR) yönteminde en başarılı modellerin M02, M03 ve M14 modelleri olduğu gözlemlenmiştir. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri kıyaslandığında en başarılı modelin M03 olduğu (Korelasyon: 0.97, NS: 0.95, KGE: 0.97, PI: 0.09, RMSE: 0.20) gözlemlenmiştir. GPR ile kıyasladığında girdi parametresinde yalnızca Q_{S_t} kullanılan modellerin performanslarında düşüş olduğu gözlemlenirken, girdi parametresinde $Q_{S_t} Q_{S_{t-1}}$ kullanılan tüm modellerin performanslarında artış olduğu gözlemlenmiştir. GPR ve W-GPR yöntemlerinin en başarılı model performans sonuçları kıyaslandığında en iyi sonucu veren yöntemin W-GPR yöntemi olduğu gözlemlenmiştir. Modellerin performans sonuçları Şekil 4.14’de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.11’de verilmiştir.

Çizelge 4.11. W-GPR model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
W-Gauss Süreç Regresyonu (W-GPR)	M01	0.812	0.650	0.792	0.292	0.591	0.996	0.991	0.991	0.040	0.093
	M02	0.970	0.940	0.966	0.111	0.244	0.999	0.997	0.997	0.022	0.052
	M03	0.980	0.960	0.978	0.091	0.201	0.999	0.998	0.998	0.019	0.044
	M04	0.790	0.579	0.784	0.324	0.648	0.998	0.996	0.994	0.028	0.065
	M05	0.924	0.837	0.905	0.187	0.403	0.999	0.999	0.998	0.017	0.039
	M06	0.600	0.096	0.503	0.531	0.950	0.987	0.973	0.966	0.071	0.164
	M07	0.829	0.624	0.793	0.300	0.613	0.998	0.996	0.995	0.028	0.065
	M08	0.602	0.101	0.501	0.529	0.947	0.989	0.978	0.971	0.064	0.150
	M09	0.672	0.245	0.545	0.465	0.868	0.990	0.979	0.975	0.062	0.144
	M10	0.828	0.624	0.792	0.300	0.613	0.998	0.996	0.995	0.028	0.065
	M11	0.142	-0.251	0.059	0.876	1.118	0.975	0.943	0.883	0.104	0.239
	M12	0.815	0.656	0.794	0.289	0.586	0.996	0.992	0.992	0.038	0.088
	M13	0.923	0.837	0.906	0.188	0.404	0.999	0.999	0.998	0.016	0.038
	M14	0.971	0.941	0.964	0.111	0.243	0.999	0.997	0.997	0.022	0.051
	M15	0.789	0.579	0.782	0.324	0.649	0.998	0.996	0.994	0.028	0.065



Şekil 4.14. W-GPR yönteminin model performans sonuçları.

Dalgacık dönüşümü sonrası kullanılan ANFIS (W-ANFIS) yönteminde en başarılı modeller M01 ve M02 modelleri olduğu gözlemlenmiştir. Başarı performansını değerlendirmede kullanılan Korelasyon, NSE, KGE, PI ve RMSE değerleri kıyaslandığında en başarılı modelin M02 olduğu gözlemlenmiştir (Korelasyon: 0.98, NS: 0.97, KGE: 0.97, PI: 0.07, RMSE: 0.17). ANFIS yönteminde en başarılı model M03, dalgacık dönüşümü sonrasında performansında düşüş olduğu gözlemlenmiştir. M03 modeli girdi parametresinde M02'nin girdi parametrelerine ek olarak Q_{St-2} parametresi bulunmaktaydı. Dalgacık dönüşümü sonrasında fazladan geciktirilmiş sediment parametresinin kullanılmasının model performansına olumsuz etki ettiği görülmüştür. Ayrıca geciktirilmiş debi parametresinin birden fazla kullanıldığı modellerde dalgacık dönüşümü sonrasında performanslarında düşüş olduğu gözlemlenmiştir. Modellerin performans sonuçları Şekil 4.15’de verilmiştir. Ayrıntılı model performans sonuçları Çizelge 4.12’de verilmiştir.


Çizelge 4.12. W-ANFIS model performans sonuçları.

Yöntem	Modeller	TEST					EĞİTİM				
		Korelasyon	NS	KGE	PI	RMSE	Korelasyon	NS	KGE	PI	RMSE
W-ANFIS	M01	0.909	0.827	0.873	0.195	0.416	0.929	0.863	0.899	0.164	0.370
	M02	0.985	0.971	0.974	0.077	0.170	0.986	0.972	0.976	0.072	0.168
	M03	0.867	0.644	0.761	0.286	0.596	0.898	0.777	0.873	0.213	0.472
	M04	0.872	0.745	0.870	0.241	0.505	0.907	0.820	0.901	0.191	0.425
	M05	0.845	0.541	0.693	0.328	0.677	0.841	0.590	0.751	0.298	0.640
	M06	0.598	0.336	0.433	0.456	0.814	0.665	0.441	0.536	0.384	0.747
	M07	0.846	0.641	0.800	0.290	0.598	0.860	0.694	0.837	0.255	0.553
	M08	0.622	0.351	0.492	0.444	0.805	0.678	0.458	0.572	0.376	0.736
	M09	0.613	0.246	0.556	0.481	0.868	0.736	0.521	0.707	0.341	0.692
	M10	0.792	0.427	0.675	0.377	0.756	0.850	0.652	0.806	0.273	0.589
	M11	0.338	0.006	0.199	0.666	0.996	0.509	0.259	0.306	0.488	0.861
	M12	0.872	0.755	0.860	0.237	0.495	0.918	0.843	0.893	0.177	0.396
	M13	0.793	0.305	0.576	0.416	0.833	0.829	0.526	0.709	0.322	0.688
	M14	0.885	0.716	0.812	0.253	0.533	0.927	0.851	0.923	0.171	0.385
	M15	0.868	0.735	0.866	0.246	0.514	0.908	0.820	0.904	0.190	0.424




Şekil 4.15. W-ANFIS model performans sonuçları.

Dalgacık dönüşümü sonrası kurulan modellerin performansları incelendiğinde en iyi sonuç veren modellerin: DVM için: M02_Lineer, M02_Polinom, M03_Lineer, M05_Lineer, M14_Lineer; GPR için: M02_GPR, M03_GPR, M14_GPR; ve ANFIS için: M01_ANFIS, M02_ANFIS oldukları görülmektedir. Bu modellerin kendi içlerindeki performansları ve karşılaştırılması amacıyla Keman (Violin) ve Taylor grafikleri ve hataların gösterimi için Kutu grafikleri kullanılmıştır.



Şekil 4.16. Dalgacık dönüşümü sonrasındaki en başarılı modellerin Violin grafiği gösterimi.


Dalgacık dönüşümü sonrasında en iyi modelleri kıyaslamak için Violin grafiği kullanılarak sonuç Şekil 4.16’da verilmiştir. Gözlem verisinin dağılımına en çok benzeyen modeller W-ANFIS M02 ve M03Lw(W-DVM-Lineer) modelleri olduğu gözlemlenmiştir. İki modelinde merkezdeki yoğunluğu ve uç noktadaki tahminleri gözlem verisi ile uyumludur. Ancak W-ANFIS M02 modeli gözlem dağılımı ile oldukça uyumlu olsa da, gözlem dağılımının alt sınırının altında tahmin yaptığı gözlemlenmiştir. Bu nedenle M03Lw(W-DVM-Lineer) modeli Violin grafiğinde en başarılı model olarak görülse de maksimum değerlerin (pik değerlerin) tahmininde bu modelin W-ANFIS M02 modeli kadar iyi olmadığı görülmüştür. Dolayısıyla minimum değer olarak W-ANFIS M02 negatif değer tahmin etmesine karşılık, pik değerleri tahmin etmedeki başarısından dolayı en iyi model olarak W-ANFIS M02 kabul edilmiştir. Bu durum Şekil 4.17’de verilen Taylor grafiğinde daha açık olarak görülmektedir.



Şekil 4.17. Dalgacık dönüşümü sonrasındaki en başarılı modellerin Taylor grafiği gösterimi.

Şekil 4.17’de verilen Taylor grafiğine göre dalgacık dönüşümü sonrasında en başarılı model; standart sapma, RMSE ve korelasyon ilişkisi açısından gözlem değerine en yakın olan W-ANFIS M02 olduğu görülmüştür. W-ANFIS M02 modeli en yüksek korelasyon katsayısını ve en düşük hata değerini göstermiştir. Ayrıca W-ANFIS M02 ve M03Lw(W-DVM-Linear) modellerinin performans kriterlerine bakıldığında; W-ANFIS M02 dalgacık öncesi PI: 0.21; NSE: 0.79 ve dalgacık dönüşümü sonrası PI: 0.07, NSE: 0.97 iken M03Lw(W-DVM-Linear) modeli dalgacık öncesi PI: 0.22, NSE: 0.78 ve dalgacık dönüşümü sonrası PI: 0.08, NSE: 0.96 olarak bulunmuştur.

M03Lw(W-DVM-Linear) modeli Violin grafiğinde en iyi dağılıma sahip model olmasına rağmen Taylor grafiğinde W-ANFIS M02 modelinin gerisinde kalmış ve performans grafiği açısından da en iyi ikinci model olmuştur.




Şekil 4.18. Dalgacık dönüşümü sonrasındaki en başarılı modellerin hatalarının Kutu grafiği gösterimi.


Şekil 4.18’de verilen dalgacık dönüşümü sonrasındaki en başarılı modellerin Kutu grafiği incelendiğinde tüm modellerin kutularının dar olduğu görülmektedir bu da modellerin tutarlı tahmin yaptığını gösterir. Aykırı değerler kıyaslandığında en başarılı olan modellerin M03Lw(W-DVM-Lineer) ve W-ANFIS M02 modeli olduğu görülmektedir. Ayrıca her iki modelin de ekstrem değerleri iyi tahmin edebildiği görülmektedir. İki model birbirine yakın olmasına rağmen W-ANFIS M02 modeli daha dengelidir. Bu nedenle Kutu grafiğine göre en iyi modelin W-ANFIS M02 modeli olduğu görülmektedir.

Modellerin hatalarının analizinde bir başka yöntem olarak Bland-Altman grafikleri kullanılmıştır. Fark grafikleri olarak da bilinen Bland-Altman (BA) grafikleri, iki farklı ölçümü karşılaştırmak ve iki veri kümesi arasındaki uyumu değerlendirmek için kullanılan güçlü bir grafiksel araçtır (Bland ve Altman, 1999). BA grafikleri iki yöntem arasındaki uyumun ve herhangi bir sistematik önyargının veya rastgele hatanın görselleştirilmesine olanak tanır. Bu çalışmada BA grafiği, gözlem değerleri ile tahmin edilen model değerleri arasındaki farkların sapmasının ve farkların %95 güven aralığını karşılaştırmak için kullanılmıştır. BA grafik analizinde, y eksenini gözlem değerleri ile model değerleri arasındaki farkı yani gözlem ile model arasındaki hata miktarını ve x eksenini ise gözlem ile model sonuçlarının aritmetik ortalamasını çizerek yapılan model tahminin görsel bir temsilini sağlar. Aynı zamanda farkların ortalaması ve bu farkların normal dağıldığını varsayarak %95 güven aralığı (farkların standart

sapmasının 1.96 katının ortalamasının üstünde ve altında kalan bölge) grafikte gösterilmiştir. Dalgacık dönüşümü öncesi tespit edilen en iyi modellerin Bland-Altman sonuçları Şekil 4.19’da ve dalgacık dönüşümü sonrası tespit edilen en iyi modellerin Bland-Altman sonuçları Şekil 4.20’de verilmiştir. Dalgacık dönüşümü öncesi BA grafikleri incelendiğinde hataların çoğunlukla %95 güven aralığı içerisinde kaldığı gözlenmekle birlikte en yüksek ve en düşük hataların +200 ile -100 arasında saçıldığı görülmektedir. Bu durum dalgacık dönüşümü öncesi seçilen en iyi modellerin ortak noktasının gözlem değerlerindeki pik değerleri yakalamakta çok başarılı olamadıklarını göstermektedir. Dalgacık sonrası en iyi modellerin BA grafikleri incelendiğinde ise bu model sonuçlarının büyük çoğunluğunun hataların %95 güven aralığı içerisinde kaldığını, en düşük pik değerleri tahmindeki hataların saçılımı olarak ise en başarılı modellerin +50 ile -50 değerleri arasında kalan W-ANFIS M02 ve M03Lw(W-DVM-Lineer) olduğu görülmüştür.




Şekil 4.19. Dalgacık dönüşümü öncesi tespit edilen en iyi modellerin Bland-Altman grafikleri.




Şekil 4.20. Dalgacık dönüşümü sonrası tespit edilen en iyi modellerin Bland-Altman grafikleri.

Dalgacık dönüşümü öncesindeki ve dalgacık dönüşümü sonrasındaki performanslarıyla öne çıkan modeller Şekil 4.21’de ve Şekil 4.22’de verilmiştir. Dalgacık dönüşümü öncesinde başarılı olan modellerde gözlem değerleriyle alt değerlerde uyum iyi görünürken, yüksek değerlerde gözlem değerini pek yakalayamadığı görülmektedir. Modelleri tek tek incelediğimizde DVM-Lineer M03 modelinin alt değerlerde gözlem değerlerini diğer modellere göre daha iyi yakaladığı görülürken, yüksek değerlerde gözlem değerlerine iyi uyum sağlayamadığı görülmüştür. Diğer yandan DVM-Polinom az farklarla olsa da alt değerleri yakalamakta DVM-Lineer’e göre daha zayıf kaldığı görülürken, üst değerleri yakalamakta daha iyi olduğu gözlemlenmiştir. GPR M05 modeli alt değerleri yakalamakta bazı sapmalar olsa da, bazı yüksek değerleri yakalayabildiği görülmüştür. GPR M07 modelinde ise alt değerleri yakalamakta GPR M05 modeline göre daha iyi olduğu görülürken, yüksek değerleri yakalamakta GPR M05 modeli daha iyidir.




Şekil 4.21. Dalgacık dönüşümü öncesindeki başarılı olan modeller.




Şekil 4.22. Dalgacık dönüşümü sonrasındaki başarılı olan modeller.

Dalgacık dönüşümü sonrasındaki başarılı olan modellerde alt değerlerde gözlem değeri ile uyumu fazla iken, yüksek değerleri de yakalamakta iyi oldukları gözlemlenmektedir. W-GPR M03 modeli alt değerlerde gözlem değeri ile uyumluyken pik değerlerde gözlem değerini geçen tahmin yaptığı gözlemlenmiştir. W-DVM-Linear M03 modeli ile kıyaslandığında W-DVM-Linear M03 modelinin alt değerlerde gözlem değeri ile daha uyumlu olduğu görülmektedir. Ayrıca DVM-Linear M03 modelinin dalgacık dönüşümü öncesi ve dalgacık dönüşümü sonrası performansları kıyaslandığında gözlem değerlerini yakalamakta daha başarılı olduğu ve modelin performansının yüksek oranda iyileştiği görülmüştür. W-ANFIS M02 modelinin gözlem değerlerini yakalamakta iyi performans verdiği ve sapmaların son derece az


olduğu görülmektedir. Genel olarak bakıldığında dalgacık dönüşümü uygulanmasının model performansını yüksek oranda iyileştirdiği ve modellerin yüksek doğrulukla tahmin verebildikleri gözlemlenmiştir. Şekil 4.23 ve Şekil 4.24'te başarılı modellerin dalgacık dönüşümü öncesi ve sonrasındaki durumları gösterilmiştir.



Şekil 4.23. Dalgacık dönüşümü öncesinde başarılı olan modellerin dalgacık dönüşümü öncesindeki ve sonrasındaki durumları.



Şekil 4.24. Dalgacık dönüşümü sonrasında başarılı olan modellerin dalgacık dönüşümü öncesindeki ve sonrasındaki durumları.



Şekil 4.25. Katı madde anahtar eğrisi ile W-ANFIS M02 modelinin karşılaştırılması.

4.3 Tartışma

Dalgacık dönüşümü öncesinde ve dalgacık dönüşümü sonrasındaki modellerin performansları kıyaslandığında düşük RMSE değeri (0.17) ile yüksek korelasyon değerine (0.98) sahip olan W-ANFIS M02 modelinin en başarılı model olduğu ve günlük sediment yükü tahmininde güçlü bir performans sergilediği görülmüştür. Ayrıca Şekil 4.25'te geleneksel olarak kullanılan katı madde anahtar eğrisi ile W-ANFIS M02 modeli verilmiştir. W-ANFIS M02 modelinin katı madde anahtar eğrisinden daha iyi sonuç verdiği görülmektedir. Sediment yükünün tahmininde kaynak özetlerinde çeşitli çalışmalar yer almaktadır. Yapılan bu çalışmalarda sonuçlar karşılaştırıldığında aşağıdaki sonuçlara ulaşılmıştır:

Üneş vd. (2020) Missouri Nehri'ndeki günlük sediment miktarının tahmini için debi, yağış, sıcaklık ve askıda sediment konsantrasyonu parametrelerini kullanmıştır. Çalışmada Destek Vektör Makinesi ve Genelleştirilmiş Yapay Sinir Ağı (GRNN) yöntemlerini kullanılmıştır. Destek Vektör Makinesi yönteminin iyi bir korelasyon değerine (0.90) sahip olduğu ve RMSE değerinin 55.61 olduğu görülmüştür. Bajirao vd. (2021) Hindistan'da bulunan Koyna Nehri havzasında günlük askıda sediment konsantrasyonunun tahmini için girdi parametrelerinde debi, yağış ve askıda sediment konsantrasyonu kullanarak modeller oluşturmuştur. Çalışmada ANFIS, Yapay Sinir Ağları (ANN) ve bu yöntemlerin dalgacık dönüşümü ile birleşiminden oluşan W-ANN ve W-ANFIS yöntemleri kullanılmıştır. En iyi performansı veren modelin coiflets dalgacığını içeren W-ANFIS yöntemi olduğu belirtilmiştir (Korelasyon: 0.87, RMSE:0.060). Sihag vd.(2021) Hindistan'da bulunan Baitarani Nehri havzasında

sediment konsantrasyonunun tahmini için debi, sediment konsantrasyonu ve akarsu yüksekliği parametreleri ile çeşitli modeller oluşturmuştur. Çalışmada M5P ağacı ve Rastgele Orman yöntemleri kullanılmıştır. Rastgele Orman yöntemi kullanılan modelin en iyi performansı gösterdiği belirtilmiştir (Korelasyon:0.81, RMSE:18.15).

Yapılan çalışmalara bakıldığında askıda sediment yükünün tahmini için makine öğrenme yöntemlerinin iyi sonuç verdiği görülmektedir. Bahsedilen çalışmalar karşılaştırıldığında dalgacık dönüşümü kullanılmasının modelin performansını güçlendirdiği ve tahmin doğruluğunu artıran etkili bir yöntem olduğu gözlemlenmiştir.



5. SONUÇ VE ÖNERİLER

Yapılan bu çalışmada günlük askıda sediment yükünün tahmin edilmesi için literatürde en çok kullanılan makine öğrenmesi metotlarından ANFIS, DVM, RO, GPR yöntemlerini kullanarak sediment yüküne etki eden parametrelerin farklı kombinasyonları ile modeller oluşturulmuş ve en iyi model ve yöntem tespit edilmeye çalışılmıştır. Modelleri oluştururken $t+1$ zamanına ait askıda sediment konsantrasyonu çıktı parametresi olarak kullanılmış olup, girdi parametresi olarak askıda sediment konsantrasyonu, debi ve sıcaklık parametrelerinin $t + 1$, t , $t - 1$ ve $t - 2$ zamanlarına ait ile farklı kombinasyonları kullanılmıştır. En iyi modellerin tespiti için denenen pek çok kombinasyon arasından çeşitli durumları temsil eden 15 farklı model seçilmiştir.

Bu çalışmada makine öğrenmesi yöntemleri olarak kullanılan Destek Vektör Makinesi (DVM), ANFIS, Rastgele Orman (RO) ve Gauss Süreç Regresyonu (GPR) yöntemlerinin tahmin hassasiyetini artırmak için dalgacık dönüşüm yöntemi de modellere ilave edilmiştir. Destek Vektör Makinesi Polinom, Gauss ve Lineer olmak üzere 3 farklı çekirdek fonksiyonu ile kullanılmıştır. Çalışmada önce bu yöntemler ile oluşturulan modellerin dalgacık dönüşümü öncesi performansları karşılaştırılmıştır. Dalgacık dönüşümü öncesinde her yöntemde en zayıf performansı yalnızca sıcaklık parametresinin kullanıldığı M11 modeli göstermiştir. Böylece bu çalışmada yalnızca su sıcaklığı bilgisinin günlük sediment miktarını tahmin etmede yetersiz olduğu görülmüştür. Tüm modellerde diğer bir iyi performans göstermeyen model ise yalnızca akım debisini kullanan M06 modeli olduğu görülmüştür. Yapılan çalışmada yalnızca su sıcaklığı ya da debi bilgisinin askıda sediment konsantrasyonu tahmininde yeterli olmadığı sonucuna varılmıştır. Diğer yandan en başarılı modellerin girdi parametresi olarak askıda sediment konsantrasyonunun geciktirilmiş değerlerinin kullanıldığı modeller olduğu görülmüştür. Dalgacık dönüşümü öncesinde her yöntemde başarılı olan modeller M05 ve M14 modelleri olduğu gözlemlenmiştir. Bu modellere baktığımızda ortak yönlerinin girdi parametrelerinde aynı geciktirilmiş zaman adımlarını kullandıkları görülmüştür. Dalgacık dönüşümü öncesinde ANFIS, GPR, RO ve DVM yöntemlerinin çekirdek fonksiyonlarının hepsinde başarılı modeller olduğu gözlemlenmiştir. Bu modeller Violin grafiğinde kıyaslandığında gözlem dağılımına en yakın modellerin yöntemleri arasında Destek Vektör Makinesi (Polinom ve Lineer) ve ANFIS yöntemlerinin öne çıktığı gözlemlenmiştir.

Dalgacık dönüşümü sonrası kurulan modellerin performanslarına bakıldığında dalgacık dönüşümünün genel olarak modellerin çoğunluğunda performansı artırdığı görülmüştür. Bu çalışmada dalgacık dönüşümü için sadece db45 dalgacığı tercih edilmiş ve 5 seviyeli dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümü sonrasında Destek Vektör Makinelerinin lineer fonksiyonundaki modellerin performanslarında artış gözlemlenirken, polinom ve Gauss fonksiyonlarında modellerin performanslarında düşüş olduğu gözlemlenmiştir. Ayrıca DVM polinom ve Gauss çekirdek fonksiyonlarının model performans başarı ölçütlerindeki değerlerde eğitim ve test veri setleri arasındaki fark oldukça fazla olduğu sonucuna varılmıştır. Rastgele Orman yönteminde ise dalgacık dönüşümü sonrasında modellerin performanslarında belirgin bir iyileşme görülmemiş aksine model performanslarında düşüş gözlemlenmiştir. Gauss Süreç Regresyonunda dalgacık dönüşümü sonrasında bazı modellerin performansında W-DVM-Lineer fonksiyonunda olduğu gibi etkin bir artış gözlemlenmiştir. W-ANFIS yönteminde de dalgacık dönüşümü sonrasında performansında etkin bir artış olan model vardır. Hataların Bland-Altman grafikleri, hataların Kutu grafikleri, modellerin Keman ve Taylor grafikleri kıyaslandığında dalgacık dönüşümü sonrası en iyi modelin W-ANFIS yöntemi olduğu görülmüştür.

Sonuç olarak dalgacık dönüşümü sonrasında en iyi performansı veren yöntemlerin W-ANFIS, W-DVM-Lineer ve W-GPR olduğu tespit edilmiştir. Yapılan çalışmada günlük askıda sediment miktarını en çok etkileyen girdi parametresinin askıda sediment konsantrasyonu olduğu gözlemlenmiştir. Ayrıca $t + 1$ zamanındaki askıda sediment konsantrasyonunun tahmininde t ve $t - 1$ zamanlarındaki askıda sediment konsantrasyonunu kullanan modellerin hem dalgacık dönüşümü öncesi hem de dalgacık dönüşümü sonrasında en başarılı modeller arasında yer aldığı gözlemlenmiştir. Günlük sediment miktarının tahmini için Destek Vektör Makinesi, ANFIS ve Gauss Süreç Regresyonu yöntemlerinin dalgacık dönüşümü öncesi ve sonrasında da başarılı performans sergilediği gözlemlenmiştir.

Yapılan çalışmada askıda sediment yükünün tahmin edilmesi amacıyla bazı hidrolojik parametrelerin farklı zamanlara ait gecikme değerlerinin kombinasyonları kullanılarak 15 farklı model oluşturulmuştur. Çalışmada ANFIS, Destek Vektör Makinesi, Rastgele Orman ve Gauss Süreç Regresyonu yöntemleri kullanılmıştır. Daha sonra bu yöntemler ile birlikte dalgacık dönüşümü uygulanmasının modellerin performansına

olan etkisi incelenmiştir. Elde edilen sonuçlar askıda sediment yükü tahmininde makine öğrenmesi temelli yaklaşımların başarılı sonuç verdiğini ve dalgacık dönüşümü uygulanmasının model performanslarını iyileştirdiğini göstermiştir. Sediment yükünün doğru tahmin edilmesi su kaynakları yönetimi, taşkın kontrolü, baraj gibi su yapılarının tasarımı ve işletilmesinde kritik öneme sahiptir. Bu çalışma baraj gibi su yapılarının tasarımı ve işletilmesinde, havza planlanmasında ve akarsu yataklarının taşkın kapasitesini belirlemek için çalışan uzmanlar ve karar vericiler ile sediment taşınımı üzerine çalışmalar yapan araştırmacılar için yardımcı nitelikte olabilir.

Gelecekte yapılacak olan çalışmalarda, hidrolojik parametre çeşitlerinin artırılması ve farklı makine öğrenme yöntemlerinin kullanılmasıyla modellerin geliştirilmesi ve daha iyi tahmin sonuçları elde edilmesi mümkündür. Çalışmada kurulan modellerin farklı havzalara uygulanmasıyla geçerliliği kontrol edilebilir.

KAYNAKLAR

- Acar, R. ve Saplıoğlu, K., 2020. Akarsulardaki sediment taşınımının yapay sinir ağıları ve ANFIS yöntemleri kullanılarak tespiti, Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 9, 1, 437–450.
- Adnan, R.M., Wang, M., Masood, A., Kisi, O., Shahid, S. ve Zounemat-Kermani, M., 2025. Applications of advanced optimized neuro fuzzy models for enhancing daily suspended sediment load prediction, Computer Modeling in Engineering and Sciences, 143, 1, 1249–1272.
- AlDahoul, N., Ahmed, A.N., Allawi, M.F., Sherif, M., Sefelnasr, A., Chau, K. ve El-Shafie, A., 2022. A comparison of machine learning models for suspended sediment load classification, Engineering Applications of Computational Fluid Mechanics, 16, 1, 1211–1232.
- Allawi, M.F., Sulaiman, S.O., Sayl, K.N., Sherif, M. ve El-Shafie, A., 2023. Suspended sediment load prediction modelling based on artificial intelligence methods: The tropical region as a case study, Heliyon, 9, 8, e18506.
- Al-Mukhtar, M., 2019. Random forest, support vector machine, and neural networks to modelling suspended sediment in Tigris River-Baghdad, Environmental Monitoring And Assessment, 191, 11.
- Altunkaynak, A. ve Başakın, E.E., 2018. Zaman serileri kullanılarak nehir akım tahmini ve farklı yöntemlerle karşılaştırılması, Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 11, 1, 92–101.
- Azamathulla, H.M., Ghani, A.A., Chang, C.K., Hasan, Z.A. ve Zakaria, N.A., 2010. Machine learning approach to predict sediment load - a case study, Clean - Soil, Air, Water, 38, 10, 969–976.
- Bacanli, U.G., Firat, M. ve Dikbas, F., 2009. Adaptive Neuro-Fuzzy inference system for drought forecasting, Stochastic Environmental Research And Risk Assessment, 23, 8, 1143–1154.
- Bajirao, T.S., Kumar, P., Kumar, M., Elbeltagi, A. ve Kuriqi, A., 2021. Superiority of hybrid soft computing models in daily suspended sediment estimation in highly dynamic rivers. Sustainability (Switzerland), 13, 2, 1–29.
- Band, S.S., Heggy, E., Bateni, S.M., Karami, H., Rabiee, M., Samadianfard, S., Chau, K.W. ve Mosavi, A., 2021. Groundwater level prediction in arid areas using wavelet analysis and Gaussian process regression, Engineering Applications Of Computational Fluid Mechanics, 15, 1, 1147–1158.
- Bekçioğulları, F.M., Dikici, B., Açıkgöz, H. ve Keçecioğlu, F.Ö., 2021. Güneş Enerjisinin Kısa-Dönem Tahmininde Farklı Makine Öğrenme Yöntemlerinin Karşılaştırılması, Emo Bilimsel Dergi, 11, 22, 37–45.

- Bland, J.M., ve Altman, D.G., 1999. Measuring agreement in method comparison studies. *Statistical Methods in Medical Research*, 8, 135–160.
- Breiman, L., 2001. Random forests, *Machine Learning*, 45, 5–32, Kluwer Academic Publishers, Netherlands.
- Buyukyildiz, M. ve Kumcu, S.Y., 2017. An estimation of the suspended sediment load using adaptive network based fuzzy inference system, support vector machine and artificial neural network models, *Water Resources Management*, 31, 4, 1343–1359.
- Chiang, J.L. ve Tsai, Y.S., 2011. Suspended sediment load estimate using support vector machines in Kaoping river basin, 2011 International Conference On Consumer Electronics, Communications And Networks, Cecnet 2011 - Proceedings, 1750–1753.
- Cöntürk, H., 1968. Erozyon Ve Sediment Etütlerinin Planlanmasına Doğru. İnşaat Mühendisleri Odası 4. Teknik Kongresi, Konu: 1, Rapor: 13, Ankara, Yeni Desen Matbaası.
- Dalkılıç, H.Y. ve Hashimi, S.A., 2020. Prediction of daily streamflow using artificial neural networks (ANNs), wavelet neural networks (WNNs), and adaptive neuro-fuzzy inference system (ANFIS) models, *Water Science And Technology: Water Supply*, 20, 4, 1396–1408.
- Daubechies, I., 1988. Orthonormal bases of compactly supported wavelets. *Communications On Pure And Applied Mathematics*, 41, 7, 909–996.
- Demir, H.N., Korkmaz, M.S. ve Arıman, S., 2023. Akım gözlem istasyonlarında anfis yöntemi ile günlük ortalama debi tahmini: Kızılırmak örneği, *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13, 4, 2565–2582.
- Devi, A., Chandel, A. ve Shankar, V., 2025. Modelling hydraulic conductivity of porous media using machine learning techniques, *Journal Of Hydroinformatics*, 27, 3, 381–405.
- Dogan, E., 2005. Suspended sediment load estimation in lower sakarya river by using artificial neural networks, fuzzy logic and neuro-fuzzy models, *Electronic Letters On Science & Engineering*, 1, 1, 22–32.
- Erkek C. ve Ağralıoğlu N., 2020. Su Kaynakları Mühendisliği, Dokuzuncu Baskı, Beta Basım Yayın Dağıtım A. Ş. İstanbul.
- Firat, M., 2007. Sinirsel bulanık mantık yaklaşımı ile havza modellemesi, Doktora Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Gong, Y., Zhang, Y., Lan, S. ve Wang, H., 2016. A comparative study of artificial neural networks, support vector machines and adaptive neuro fuzzy inference system for forecasting groundwater levels near lake Okeechobee, Florida. *Water Resources Management*, 30, 1, 375–391.

- Gürer, İ. ve Günyaktı, A., 2020. Uygulamalı Mühendislik Hidrolojisi. Nobel Akademik Yayıncılık, Ankara.
- Haji, M.S., Mirbagheri, S.A., Javid, A.H., Khezri, M. ve Najafpour, G.D., 2014. Suspended sediment modelling by SVM and wavelet, *Gradjevinar*, 66, 3, 211–223.
- He, Z., Wen, X., Liu, H. ve Du, J., 2014. A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region, *Journal Of Hydrology*, 509, 379–386.
- Himanshu, S.K., Pandey, A. ve Yadav, B., 2017. Ensemble wavelet-support vector machine approach for prediction of suspended sediment load using hydrometeorological data, *Journal Of Hydrologic Engineering*, 22, 7, 1–14.
- Hipni, A., El-shafie, A., Najah, A., Karim, O.A., Hussain, A. ve Mukhlisin, M., 2013. Daily forecasting of dam water levels: comparing a support vector machine (SVM) model with adaptive neuro fuzzy inference system (ANFIS), *Water Resources Management*, 27, 10, 3803–3823.
- Jang, J. R., 1993. ANFIS : adaptive-network-based fuzzy inference system, 23,3. *Ieee Transactions On Systems, Man, And Cybernetics*.
- Latifoğlu, L., 2003. Barajlarda ölü hacim hesabı ve yamula barajı örneği, Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri.
- Lin, C., Li, T., Chen, S., Liu, X., Lin, C. ve Liang, S., 2019. Gaussian process regression-based forecasting model of dam deformation, *Neural Computing And Applications*, 31, 12, 8503–8518.
- Maity, R. ve Suman, M., 2019. Predictability of hydrological systems using the wavelet transformation: application to drought prediction, *Springer Water*.
- Moosavi, V., Vafakhah, M., Shirmohammadi, B. ve Behnia, N., 2013. A wavelet-ANFIS hybrid model for groundwater level forecasting for different prediction periods, *Water Resources Management*, 27, 5, 1301–1321.
- Moriasi, D., Arnold J., Van Liew M., Bingner R., Harmel, R.D. ve Veith T., 2007. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations, *Transactions of the ASABE*, 50, 3, 885–900.
- Nguyen, V.H., Li, Q.F. ve Nguyen, L.B., 2017. Drought forecasting using ANFIS- a case study in drought prone area of Vietnam, *Paddy And Water Environment*, 15, 3, 605–616.
- Olyaie, E., Banejad, H., Chau, K.W. ve Melesse, A.M., 2015. A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: a case study in United States, *Environmental Monitoring And Assessment*, 187, 4.

- Pal, M., 2005. Random forest classifier for remote sensing classification, *International Journal Of Remote Sensing*, 26, 1, 217–222.
- Partal, T., 2007 Türkiye yağış miktarlarının yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Rasmussen, C.E., 2004. Gaussian Processes in machine learning, *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 3176, 63–71.
- Roushangar, K. ve Shahnazi, S., 2020. Prediction of sediment transport rates in gravel-bed rivers using Gaussian process regression, *Journal Of Hydroinformatics*, 22, 2, 249–262.
- Sattari, M.T., Apaydin, H. ve Milweski, A., 2024. Kernel-based versus tree-based data-driven models: on applying suspended sediment load estimation, *Water*, 16, 2973.
- Shmilovici, A., 2010. Support Vector Machines, pp. 231–247 in: Maimon O. ve Rokach L. (Editör), *Data Mining and Knowledge Discovery Handbook*, Springer, Boston, MA .
- Sihag, P., Sadikhani, M.R., Vambol, V., Vambol, S., Prabhakar, A.K. ve Sharma, N., 2021. Comparative study for deriving stage-discharge–sediment concentration relationships using soft computing techniques, *Journal Of Achievements In Materials And Manufacturing Engineering*, 104, 2, 57–76.
- Talebizadeh, M. ve Moridnejad, A., 2011. Uncertainty analysis for the forecast of lake level fluctuations using ensembles of ANN and ANFIS models, *Expert Systems With Applications*, 38, 4, 4126–4135.
- Terzi Ö. ve Baykal T., 2021. Dalgacık dönüşüm tekniği ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi ile eğirdir gölü buharlaşma tahmini, *Düzce Üniversitesi Bilim Ve Teknoloji Dergisi*, 9, 4, 1408–1419.
- Üneş, F., Karaeminoğulları, A.B. ve Taşar, B., 2020. Forecasting of river sediment amount using machine model, *International Journal Of Environment, Agriculture And Biotechnology*, 5, 1, 9–15.
- Widodo, A. ve Yang B.S., 2007. Support vector machine in machine condition monitoring and fault diagnosis, *Mechanical Systems And Signal Processing*, 21, 6, 2560–2574.
- Yıldırım, D., Cemek, B. ve Küçüktopçu, E., 2019. Bulanık yapay sinir ağları ve çok katmanlı yapay sinir ağları ile günlük buharlaşma tahmini, *Toprak Su Dergisi*, 24–31.
- URL-1 < https://en.wikipedia.org/wiki/Sacramento_River >, Erişim tarihi: 25.05.2025.

URL-2<<https://onurbagdat.medium.com/dalgacik-d%C3%B6n%C3%BC%C5%9F%C3%BCm%C3%BC-wavelet-transform-fe45524700fb>>, Erişim tarihi: 25.05.2025.

URL-3 < https://en.wikipedia.org/wiki/Discrete_wavelet_transform >, Erişim tarihi: 25.05.2025.



ÖZGEÇMİŞ

Adı ve Soyadı : Bahar Ezgi BIYIKLI

EĞİTİM BİLGİLERİ

Lisans : Aksaray Üniversitesi, Mühendislik Fakültesi İnşaat
Mühendisliği Bölümü, 2016-2021

Yüksek Lisans : Aksaray Üniversitesi, Fen Bilimleri Enstitüsü İnşaat
Mühendisliği Anabilim Dalı, 2022-2025

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Kongrelerde Sunulan Makaleler

1. Hınıs, M.A. ve Bıyıklı, B.E., 2025. Dalgacık dönüşümü ve ANFIS ile günlük sediment yükü modellenmesi, 5th International Symposium of Scientific Research and Innovative Studies (ISSRIS'25)