

**T.C.**  
**İSTANBUL AYDIN ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**İLERİ VERİ İŞLEM YÖNTEMLERİ İLE SU KAYNAKLARININ**  
**KULLANIMI VE PLANLANMASININ OPTİMİZASYONU**

**DOKTORA TEZİ**

**Uğur AKBULUT**

**Bilgisayar Mühendisliği Anabilim Dalı**  
**Bilgisayar Mühendisliği Programı (Bütünleşik)**

**KASIM, 2023**



**T.C.**  
**İSTANBUL AYDIN ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**İLERİ VERİ İŞLEM YÖNTEMLERİ İLE SU KAYNAKLARININ**  
**KULLANIMI VE PLANLANMASININ OPTİMİZASYONU**

**DOKTORA TEZİ**

**Uğur AKBULUT**  
**(Y1813.615001)**

**Bilgisayar Mühendisliği Anabilim Dalı**  
**Bilgisayar Mühendisliği Programı (Bütünleşik)**

**Tez Danışmanı: Prof. Dr. Zafer ASLAN**

**KASIM, 2023**

## ONAY FORMU

## ONUR SÖZÜ

Doktora tezi olarak sunduđum “İleri Veri İşlem Yöntemleri İle Su Kaynaklarının Kullanımı Ve Planlanmasının Optimizasyonu” konulu tezin proje safhasından sonuçlanmasına kadar olan tüm aşamalarında bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmadan yazıldığını ve yararlanılan eserlerin Kaynakça 'da atıf yapılarak gösterildiğini onurumla beyan ederim.  
(.../.../20...)

Uğur AKBULUT

## ÖNSÖZ

Bu çalışmayı tamamlamam için doktora öğrenimi boyunca bilimsel, moral ve motivasyon olarak benden her zaman sabır ve desteğini esirgemeyen danışman hocam, Sayın Prof. Dr. Zafer ASLAN' a, tez çalışmam süresince tarafıma çözüm yolları sunan olumlu eleştirileriyle tezime katkıda bulunan jüri üyesi hocalarım; Sayın Prof. Dr. Kasım KOÇAK ve Sayın Dr. Öğr. Üyesi Adem ÖZYAVAŞ'a, doktora öğrenimimi tamamladığım İstanbul Aydın Üniversitesi Lisansüstü Eğitim Enstitüsü'nde görevli değerli hocalarıma ve kıymetli çalışanlara, çalışmamda desteklerini esirgemeyen Sayın Dr. Buket KILIÇ ve Sayın Doç. Dr. Mehmet Akif ÇİFCİ'ye, tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen, her zaman yanımda olan sevgili annem Ayşe AKBULUT ve bu çalışmaya başladığıma çok sevinen rahmetli babam Mesut AKBULUT'a, bana olan güven ve desteğini hiçbir zaman esirgemeyen değerli eşim Demet AKBULUT' a, kızım Ayşe Merve AKBULUT ve oğlum Mesut Erdem AKBULUT' a sonsuz teşekkürler.

Kasım, 2023

Uğur AKBULUT

# İLERİ VERİ İŞLEM YÖNTEMLERİ İLE SU KAYNAKLARININ KULLANIMI VE PLANLANMASININ OPTİMİZASYONU

## ÖZET

Suyun tarımsal faaliyetler, ekonomi, sağlık, enerji kaynaklarının kullanımı ve hijyen ile karmaşık bir ilişkisi vardır. İklim değişiklikleri ve artan nüfus göz önüne alındığında önümüzdeki yıllarda su kaynaklarımızda yetersizlik yaşanması muhtemel büyük sorunların başında gelmektedir. Temiz su kaynaklarının korunması ve daha verimli kullanılması, uzun süre temiz ve kullanılabilir kalmasının geliştirilmesi gerekliliği büyük önem taşımaktadır. Mevcut su potansiyelinin ekonomik olarak kullanılması, suyun ve kullanımının verimli hale getirilmesi gerekmektedir. Buradan yola çıkarak mevcut suyun kullanılabilceği miktarın ve gelecekte su potansiyelinin ne kadar değişeceğinin öngörüsü su planlaması için büyük önem taşımaktadır.

İklim değişiklikleri, mevsimsel dalgalanmalar ayrıca nüfus artışı ve birçok nedenle küresel sorunlar artmakta ve su kaynaklarının sürdürülebilir yönetimi önemli ölçüde bir endişe kaynağı haline gelmektedir.

Bu bilimsel tez çalışmasında, Türkiye'deki farklı akarsu havzalarından seçilen nehirlerin akım ortalama hızları tahmin edilmeye çalışılmıştır. Çalışma, günlük ortalama yağış ve günlük ortalama hava sıcaklığı değerleri ile günlük ortalama akış verilerinin kapsamlı bir analizini içerir, gelecekteki su potansiyelini tahmin etme karmaşıklığını çözmeyi amaçlamıştır. Araştırmada doğrusal regresyon (LR ), destek vektörü regresyonu ( SVR ), karar ağacı ( DT ), rastgele orman ( RF ) ve ekstra ağaç regresyonu ( ETR ) olarak kısaltılmıştır. Bu yöntemler, veri kümesi içinde örülen kalıpları deşifre etmek için özenle kullanılmıştır. Sonuçlar su dinamiklerinin bilinçli bir şekilde anlaşılmasını olanaklı kılmıştır. Tahmin doğruluğunu arttırmak için, dalgacık dönüşümü (WT) tekniğinin çok önemli bir rol üstlendiği bir hibrit yaklaşım göz önüne alınmıştır.

Veri setinin sırasıyla yaklaşık %65 eğitim, %15 doğrulama ve %20'si test verisi olarak kullanılmıştır.

Hibrit metodu uygulandığında tahmin başarı oranları yaklaşık olarak %10 oranında artmıştır. Bulgularımız, belirsizliklerin hüküm sürdüğü bir çağda su kaynakları yönetiminin karmaşıklığına yol gösterici çözüm önerisi sunmaktadır. Bu çalışma, ileri matematiksel paradigmların ve makine öğrenimi modellerinin kullanımının vazgeçilmezliğinin altını çizerek, gelecek nesiller için sürdürülebilir su kaynakları yönetiminin temelini güçlendirmektedir. Entegre öğrenme ve yenilikçi tekniklerin birleşiminden yararlanarak, su kaynakları tahmini ve yönetiminin karmaşık dokusunu deşifre etmeye yönelik süreci aydınlatmaya, esnek ve kalıcı bir su dünyasını oluşturmaya çalışılmıştır.

Akış tahmini için Lineer Regresyon (Linear Regression-LR), Destek Vektör Regresyonu (Support Vector Regression-SVR), Karar Ağaçları (Decision Tree-DT), Rasgele Orman (Random Forest- RF) ve Ekstra Ağaçlar Regresyon (Extra Tree Regressor- ETR) yöntemleri uygulanmıştır. Ayrıca, uygulanan modellerin her birinin başarı performansını artırmak amacıyla Dalgacık Dönüşümü (Wavelet Transform- WT) kullanarak hibrit bir yöntem geliştirilmiştir. Karamandere AGİ verileriyle yapılan uygulamada yalın yöntemde en başarılı sonuç LR 97,77 oranıyla sağlanmıştır. Hibrit yöntemde en başarılı sonuç W-ETR 90,99 oranıyla çıkmıştır. İki yöntem arasındaki en fazla başarı artışı ise DT yönteminde %25,6 oranıyla olmuştur. Çaydere AGİ verileriyle yapılan uygulamada yalın yöntemde en başarılı sonuç SVR 60,31 yöntemi ile elde edilmiştir. Hibrit yöntemde en başarılı sonuç W-RF yöntemi 89,12 oranıyla en başarılı yöntemdir. İki yöntem arasındaki en çok başarı artışı ise DT yönteminde 41,54 oranıyla olmuştur. Beşdeğirmen AGİ verileriyle yapılan uygulamada yalın yöntemde ETR 88,09 oranıyla en başarılı yöntem olmuştur. Hibrit yöntemde W-ETR yöntemi 97,73 oranıyla en başarılı yöntemdir. İki yöntem arasındaki en çok başarı artışı ise LR yönteminde 62,48 oranıyla olmuştur. Melekbahçe AGİ verileriyle yapılan uygulamada yalın yöntemde SVR 68,68 oranıyla en başarılı yöntem olmuştur. Hibrit yöntemde W-RF yöntemi 85,24 oranıyla en başarılı yöntemdir. İki yöntem arasındaki en çok başarı artışı ise DT yönteminde 18,36 oranıyla olmuştur. Porsuk Çiftliği AGİ verileriyle yapılan uygulamada yalın yöntemde ETR 67,67 oranıyla en başarılı yöntem olmuştur. Hibrit yöntemde W-ETR yöntemi 91,46



oranıyla en başarılı yöntemdir. İki yöntem arasındaki en çok başarı artışı ise SVR yönteminde 39,77 oranıyla olmuştur. Küçükkuşluk AGİ verileriyle yapılan uygulamada yalın yöntemde ETR 70,8 oranıyla en başarılı yöntem olmuştur. Hibrit yöntemde W-ETR yöntemi 86,39 oranıyla en başarılı yöntemdir. İki yöntem arasındaki en yüksek başarı artışı ise SVR yönteminde 20,82 oranıyla olmuştur.

**Anahtar Kelimeler:** Debi Tahmini, Yağış, Sıcaklık, Dalgacık, Regresyon

# **OPTIMISATION OF WATER RESOURCES USE AND PLANNING WITH ADVANCED DATA PROCESSING METHODS**

## **ABSTRACT**

Water has multifaceted connections with agriculture, the economy, health, energy usage, and sanitation. With climate change and population growth, water scarcity is predicted to become a pressing issue in the near future. Therefore, safeguarding clean water resources and increasing their efficiency and longevity are of paramount importance. Efficient and economic use of existing water resources is imperative. Predicting the amount of water available for use and monitoring changes in water potential are crucial aspects of water planning. Amidst the increasing global challenges arising from population growth and climate change, effective water resource management has become an urgent priority.

This scientific dissertation aims to estimate the mean flow velocities of chosen rivers from diverse river basins in Turkey. The research involves a detailed examination of daily mean flow data, total daily precipitation and the daily mean air temperature values in order to address the intricacies of estimating future water potential. The research adopts a logical approach with causal connections between statements, and all technical terms are explained when introduced. The language is formal and objective, with clear and concise sentences, balanced arguments, precise vocabulary, and grammatical accuracy. The text adheres to standard academic formatting, including citation and footnote style, with titles that are factual and unambiguous. The aim of this research centres on various well-established methodologies, encompassing linear regression (LR), support vector regression (SVR), decision tree (DT), random forest (RF), and extra tree regression (ETR). Our team has meticulously applied these techniques to reveal underlying patterns within the dataset. As a result, we have developed an informed comprehension of water dynamics. To enhance

prediction accuracy, a hybrid approach is utilized wherein the wavelet transform (WT) technique plays a fundamental role. The data was split into three parts for training, checking, and testing, with 65%, 15%, and 20% allocated to each respectively.

When the hybrid method was utilized, the rates of success in predictions rose by about 10%. Our discoveries offer a guiding resolution to the intricacy of water resource administration during an age of uncertainty. This investigation establishes the significance of implementing sophisticated mathematical paradigms and machine learning models, thereby reinforcing the groundwork for sustainable management of water resources in future decades. By combining integrated learning with innovative techniques, this study aims to clarify the process of interpreting the intricate web of water resource forecasting and management. The ultimate goal is to promote the development of a durable and adaptable water infrastructure.

Linear Regression (LR), Support Vector Regression (SVR), Decision Tree (DT), Random Forest (RF) and Extra Tree Regression (ETR) methods were applied for flow prediction. In addition, a hybrid method was developed using Wavelet Transform (WT) to improve the performance of each of the applied models. In the application with Karamandere AGI data, the most successful result was obtained with LR 97.77 in the lean method. In the hybrid method, the most successful result was W-ETR 90.99. The highest success increase between the two methods was 25.6% in the DT method. In the application with Çaydere AGI data, the most successful result was obtained with SVR 60.31 in the lean method. In the hybrid method, the W-RF method is the most successful method with a rate of 89.12. The highest success increase between the two methods was 41.54 in the DT method. In the application with Beşdeğirmen AGI data, ETR was the most successful method with a rate of 88.09 in the lean method. In the hybrid method, W-ETR method is the most successful method with a rate of 97.73. The highest success increase between the two methods was 62.48 in the LR method. In the application with Melekbahçe AGI data, SVR was the most successful method with a rate of 68.68 in the lean method. In the hybrid method, W-RF method is the most successful method with a rate of 85.24. The highest success increase between the two methods was 18.36 in the DT method. In the application made

with the data of Porsuk Farm AGI, ETR was the most successful method with a rate of 67.67 in the lean method. In the hybrid method, W-ETR method is the most successful method with a rate of 91.46. The highest success increase between the two methods was 39.77 in the SVR method. In the application with Küçükkumluk AGI data, ETR was the most successful method with a rate of 70.8 in the lean method. In the hybrid method, W-ETR method is the most successful method with a rate of 86.39. The highest success increase between the two methods was 20.82 in the SVR method.

**Keywords:** River Flow Rate, Precipitation, Temperature, Wavelet, Regression, Machine Learning Methods

# İÇİNDEKİLER

## Sayfa

ONUR SÖZÜ .....	i
ÖNSÖZ.....	ii
ÖZET.....	iii
ABSTRACT .....	vi
İÇİNDEKİLER .....	ix
KISALTMALAR LİSTESİ.....	xii
ÇİZELGELER LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ.....	xv
<b>I. GİRİŞ .....</b>	<b>1</b>
A. Suyun Önemi ve Özellikleri .....	1
B. Dünyada Suyun Durumu ve Kullanım Alanları .....	2
C. Yeryüzünde Su Potansiyeli ve Hidrolojik Döngü .....	3
D. Yağış ve Akarsu oluşumu.....	4
E. Akarsu Tipleri .....	5
F. Akım Ölçümleri ve Verileri.....	5
<b>II. İNCELEME BÖLGELERİ VE YERİ .....</b>	<b>7</b>
A. Giriş .....	7
B. Marmara Havzası- Çatalca- Karamandere.....	7
C. Antalya Havzası – Çaydere Göl Girişi - Gelendost.....	9
D. Sakarya Havzası - Porsuk Çayı.....	10
E. Fırat Havzası Tunceli Munzur Suyu.....	11

<b>III. YÖNTEM.....</b>	<b>13</b>
A. Giriş .....	13
B. Linear Regression(LR) .....	14
C. Destek Vektör Regresyonu (SVR).....	15
D. Karar Ağacı (DT).....	17
E. Rastgele Orman (RF).....	18
F. Ekstra Ağaçlar (ETR) .....	19
G. Dalgacık Dönüşümü (WT) .....	21
<b>IV. ANALİZ-UYGULAMA.....</b>	<b>24</b>
A. Marmara Havzası Çatalca İstıranca Deresi Karamandere İstasyonu.....	24
1. Makine Öğrenme yöntemleriyle Uygulamalar(Karamandere) .....	25
2. Hibrit Model Yöntemi Uygulamaları (Karamandere) .....	25
B. Antalya Havzası Isparta Çaydere Eğirdir Göl girişi İstasyonu.....	30
1. Makine Öğrenme yöntemleriyle Uygulamalar(Çaydere) .....	30
2. Hibrit Model Yöntemi Uygulamaları (Çaydere).....	31
C. Sakarya Havzası -Porsuk Çayı Beşdeğirmen İstasyonu .....	34
1. Makine Öğrenme yöntemleriyle Uygulamalar (Beşdeğirmen).....	35
2. Hibrit Model Yöntemi Uygulamaları (Beşdeğirmen).....	36
D. Fırat Havzası Tunceli Munzur Suyu Melekbahçe .....	39
1. Makine Öğrenme yöntemleriyle Uygulamalar (Melekbahçe).....	40
2. Hibrit Model Yöntemi Uygulamalar.....	41
E. Sakarya Havzası -Porsuk Çayı Porsuk Çiftliği.....	43
1. Makine Öğrenme yöntemleriyle Uygulamalar .....	44
2. Hibrit model yöntemleriyle Uygulamalar .....	45
F. Yukarı Fırat Havzası - Tagar Çayı Küçükkumluk.....	49
1. Makine Öğrenme Yöntemleriyle Uygulamalar (Küçükkumluk).....	49

2. Hibrit Model Yöntemleriyle Uygulamalar (Küçükkumluk) .....	50
<b>V. SONUÇLAR VE ÖNERİLER .....</b>	<b>55</b>
A. Yorumlar ve Öneriler .....	55
<b>VI. KAYNAKÇA .....</b>	<b>60</b>
<b>EKLER.....</b>	<b>70</b>
<b>ÖZGEÇMİŞ.....</b>	<b>81</b>

## KISALTMALAR LİSTESİ

- AGİ** : Akım Gözlem İstasyonu  
**DSİ** : Devlet Su İşleri  
**DT** : Karar Ağacı  
**ETR** : Ekstra Ağaç Regresyonu  
**LR** : Doğrusal Regresyon  
**MGM** : Meteoroloji Genel Müdürlüğü  
**RBF** : Radyal Temel Fonksiyon  
**RF** : Rastgele Orman  
**SVR** : Destek Vektör Regresyonu  
**WT** : Dalgacık Dönüşüm



## ÇİZELGELER LİSTESİ

### Sayfa

Çizelge 1. İstıranca İnceleme Bölgesi konum bilgileri .....	8
Çizelge 2. Çaydere Eğirdir Göl Girişi- Gelendost İnceleme Bölgesi konum bilgileri	9
Çizelge 3. İnceleme Bölgesi konum bilgileri .....	10
Çizelge 4. İnceleme Bölgesi konum bilgileri .....	11
Çizelge 5. Karamandere AGİ veri setine ait istatistik değerleri.....	24
Çizelge 6. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Karamandere)	25
Çizelge 7. Hibrit model eğitim ve test sonuçları (Karamandere).....	26
Çizelge 8. Yalın-Hibrit yöntem karşılaştırılması (Karamandere) .....	28
Çizelge 9. Çaydere Eğirdir Göl girişi AGİ veri setine ait istatistik değerleri.....	30
Çizelge 10. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Çaydere) .....	31
Çizelge 11. Hibrit model eğitim ve test sonuçları (Çaydere).....	32
Çizelge 12. Yalın Hibrit yöntem karşılaştırılması (Çaydere).....	32
Çizelge 13. Beşdeğirmen AGİ veri setine ait istatistik değerleri. ....	34
Çizelge 14. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Beşdeğirmen)	35
Çizelge 15. Hibrit model eğitim ve test sonuçları (Beşdeğirmen) .....	36
Çizelge 16. Yalın-Hibrit yöntem karşılaştırılması (Beşdeğirmen).....	37
Çizelge 17. Melekbahçe AGİ veri setine ait istatistik değerleri. ....	39
Çizelge 18. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Melekbahçe)	40
Çizelge 19. Hibrit model eğitim ve test sonuçları (Melekbahçe).....	41
Çizelge 20. Yalın-Hibrit yöntem karşılaştırılması (Melekbahçe) .....	42
Çizelge 21. Porsuk Çiftliği veri kümesine ait istatistiksel değerler .....	44

Çizelge 22. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Porsuk Çiftliği)	44
Çizelge 23. Hibrit model eğitim ve test sonuçları (Porsuk Çiftliği)	45
Çizelge 24. Yalın-Hibrit yöntem karşılaştırılması (Porsuk Çiftliği)	46
Çizelge 25. Küçükkumluk veri kümesine ait istatistiksel değerler	49
Çizelge 26. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Küçükkumluk)	50
Çizelge 27. Hibrit model eğitim ve test sonuçları karşılaştırılması (Küçükkumluk)	51
Çizelge 28. Yalın Hibrit yöntem karşılaştırılması (Küçükkumluk)	51
Çizelge 29. Debi tahmininde farklı havzalardaki AGİ'ler için en başarılı yöntemler	55
Çizelge 30. Literatürdeki çalışmaların kapsamlı özetleri	58

## ŞEKİLLER LİSTESİ

### Sayfa

Şekil 1.	Şekil 1. Yerküredeki su kaynaklarının dağılımı (usgs.gov, 2023) .....	2
Şekil 2.	Hidrolojik Döngünün Şematik Gösterimi (Tatar, 2019). .....	4
Şekil 3.	Istranca Deresi üzerindeki istasyonların konumu (Saç ve Özuluğ, 2014)8	
Şekil 4.	Eğirdir göl girişi istasyonu konumu .....	10
Şekil 5.	Çalışma alanı (E12A003) akarsu istasyonların konumu .....	11
Şekil 6.	Çalışma alanı (E21A033) akarsu istasyonların konumu .....	12
Şekil 7.	Uygulama Analizi Akış Diyagramı.....	14
Şekil 8.	Destek Vektör Regresyonu Modeli (Kına ve Biçek, 2023) .....	16
Şekil 9.	Karar Ağacı modeli .....	18
Şekil 10.	Rastgele Orman modeli.....	19
Şekil 11.	Ekstra Ağaçlar modeli.....	20
Şekil 12.	Dalgacık dönüşümü.....	21
Şekil 13.	Örnek dalgacık şekilleri ( Öner, v.d. 2017 )......	22
Şekil 14.	Makine öğrenmesi algoritmaları eğitim ve test grafiği (Karamandere)..	25
Şekil 15.	Hibrit model eğitim ve test sonuçları grafiği (Karamandere) .....	26
Şekil 16.	Dalgacık(Wavelet) 1- D Db, Level 3 grafiği (Karamandere) .....	27
Şekil 17.	Dalgacık (Wavelet) Continuous 1-D(Karamandere).....	27
Şekil 18.	. A: Doğrusal Regresyon B: Dalgacık Dönüşümü ve Doğrusal Regresyon (Hibrit) C: Destek Vektör Regresyon(SVR) D: Dalgacık Dönüşümü ve SVR (Hibrit) E: Karar Ağacı F: Dalgacık Dönüşümü ve Karar Ağacı (Hibrit) G: Rastgele Orman I: Dalgacık Transformasyonu ve Rastgele Orman (Hibrit)J: Ekstra Ağaçlar K: Dalgacık Transformasyonu ve Ekstra Ağaçlar (Hibrit) .....	29

Şekil 19. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Çaydere) 31	31
Şekil 20. Hibrit model eğitim ve test sonuçları grafiği (Çaydere) .....	32
Şekil 21. Dalgacık(Wavelet) 1- D Db, Level 3 grafiği (Çaydere).....	33
Şekil 22. Eğirdir Göl Giriş Ortalama Akım Dalgacık(Çaydere) .....	34
Şekil 23. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Beşdeğirmen) .....	35
Şekil 24. Hibrit model eğitim ve test sonuçları grafiği (Beşdeğirmen).....	36
Şekil 25. Ortalama Akım Dalgacık(Wavelet) 1- D Db, Level 3 grafiği. (Beşdeğirmen) .....	38
Şekil 26. Ortalama Akım Dalgacık (Wavelet) Continuous 1-D (Beşdeğirmen) ....	39
Şekil 27. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Melekbahçe).....	40
Şekil 28. Hibrit model eğitim ve test sonuçları grafiği (Melekbahçe) .....	41
Şekil 29. Ortalama Akım Dalgacık(Wavelet) 1- D Db, Level 3 grafiği. (Melekbahçe).....	43
Şekil 30. Ortalama Akım Dalgacık (Wavelet) Continuous 1-D Melekbahçe).....	43
Şekil 31. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Porsuk Çiftliği) 45	45
Şekil 32. Hibrit model eğitim ve test sonuçları grafiği (Porsuk Çiftliği) .....	45
Şekil 33. Günlük Ortalama Akış Dalgacık 1-D Db, Level 3 (Porsuk Çiftliği) .....	47
Şekil 34. Günlük Ortalama Akış, Wavelet Continuous 1-D (Porsuk Çiftliği) .....	47
Şekil 35. Porsuk Çiftliği için Ortalama Akım Hızı Tahmini Dağılım Grafiği a ) Makine Öğrenmesi modelleri b) <i>Dalgacık Dönüşümü</i> ve Makine öğrenmesi modelleri (Hibrit) c ) <i>Doğrusal Regresyon</i> d) <i>Dalgacık Dönüşümü ve Doğrusal Regresyon (Hibrit)</i> e) <i>Destek Vektör Regresyon(SVR)</i> f) <i>Dalgacık Dönüşümü ve SVR (Hibrit)</i> g ) <i>Karar Ağacı</i> h) <i>Dalgacık Dönüşümü ve Karar Ağacı (Hibrit)</i> i ) <i>Rastgele Orman</i> j) <i>Dalgacık Dönüşümü ve Rastgele Orman (Hibrit)</i> k) <i>Ekstra Ağaçlar</i> l) <i>Dalgacık Dönüşümü ve Ekstra Ağaçlar (Hibrit)</i> .....	48

Şekil 36. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Küçükkumluk) .....	50
Şekil 37. Hibrit model eğitim ve test sonuçları (Küçükkumluk).....	51
Şekil 38. Günlük Ortalama Akım Hızı Wavelet Continuous 1-D,( Küçükkumluk)52	
Şekil 39. Günlük Ortalama Akım Hızı Dalgacık 1-D Db, Level 3 (Küçükkumluk)52	
Şekil 40. Küçükkumluk için Ortalama Akım Hızı Tahmini Dağılım Grafiği a ) Makine Öğrenmesi modelleri b) <i>Dalgacık Dönüşümü</i> ve Makine öğrenmesi modelleri (Hibrit) c) <i>Doğrusal Regresyon</i> d) <i>Dalgacık Dönüşümü ve Doğrusal</i> <i>Regresyon (Hibrit)</i> e) <i>Destek Vektör Regresyon(SVR)</i> f) <i>Dalgacık Dönüşümü ve</i> <i>SVR (Hibrit)</i> g) <i>Karar Ağacı</i> h) <i>Dalgacık Dönüşümü ve Karar Ağacı (Hibrit)</i> i) <i>Rastgele Orman</i> j) <i>Dalgacık Dönüşümü ve Rastgele Orman (Hibrit)</i> k) <i>Ekstra Ağaçlar</i> l) <i>Dalgacık Dönüşümü ve Ekstra Ağaçlar (Hibrit)</i> .....	53

## I. GİRİŞ

Dünyamızda karalara şeklini veren su, evrende en çok bulunan ikinci moleküldür. (Alok Jha, 2015). Evrende ilk olarak oluşan hidrojen, en yaygın elementtir. Yaygın olma yoğunluk sıralaması helyum, karbon ve oksijen elementleri ile devam eder. Molekül yoğunluk sıralaması hidrojen molekülü(H<sub>2</sub>), karbon monoksit (CO) ve su (H<sub>2</sub>O) yaşam için gerekli olan moleküllerdir (tubitak.gov.tr, 2022). Evrenin oluşumu sırasında molekül ve atomlar toz parçacıkları halindeydi. Oksijen ve hidrojen atomları toz parçacıklarına tutunarak kimyasal bir reaksiyon neticesinde su molekülü buz haliyle oluştu. Yüzbinlerce yıl neticesinde toz taneleri buzul tabakalara dönüşerek dünyamız ve güneş sistemini oluşturmuştur. Bu oluşumun ilk anlarında sıcaklığın etkisiyle buharlaşan su sonradan oluşan atmosferin etkisiyle yoğunlaşarak binlerce yıl yağmur halinde yeryüzüne düşmüştür. Dünyamızın güneşe olan uzaklığı da okyanus, deniz ve su birikintilerinin oluşmasını olağan kılmıştır (bbc.com, 2023).

### A. Suyun Önemi ve Özellikleri

Su oda sıcaklığında sıvı halde bulunan, iki adet hidrojen ve bir adet oksijenden oluşan, rengi kokusu ve tadı olmayan bir maddedir. Su yeryüzünde üç fiziksel (Katı, Sıvı, Gaz) halde bulunan tek maddedir. (Soytürk, 2014). Katı halini buz veya dolu, sıvı halini su, gaz halini ise bulut veya su buharı olarak görülmektedir. Suyu diğer moleküllerden ayıran bir özellik +4 °C'da en büyük yoğunluğuna ulaşmasıdır. Diğer moleküllerin katı hali yoğunluk farkından dolayı sıvısı içerisinde dibe çökerken su +4 °C yoğunluğundan dolayı buzlar suyun üstünde yüzebilmektedir. (Oğuz, 2015)

Canlılar için gerekli olan su belli oranlarda canlıların kütlelerinde bulunmak zorundadır. Bu oran çoğu canlıda %70 ve üzerindedir. Sulu bitkilerde bu yoğunluk %90 ve fazla oranları bulmaktadır. Bitkilerin en kuru dokusu sayabileceğiniz odun dokusu yaklaşık %60 oranında su barındırmaktadır. Canlı hücrelerinde su oranının %20 oranına düşmesi doku ve hücrelerin ölmesiyle

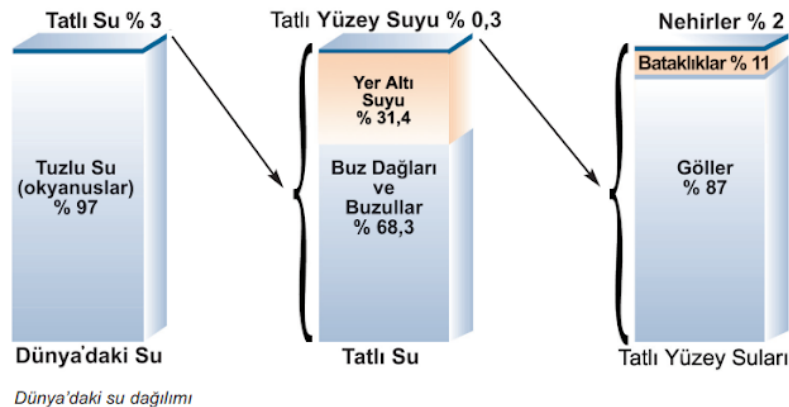
sonuçlanır. Kan %90, kaslar ise %80 den fazla su barındırmaktadır (Ilgar, 2009). Bu oranlar bize suyun yaşam için ne kadar gerekli olduğunu göstermektedir.

Su yaşam alanlarında çoğunlukla temizlik, beslenme ve tarımsal faaliyetlerde kullanılmaktadır. İçme suyu ve temizlik nedeni ile kullanılan suyun temizlik kalitesine dikkat edilmediği takdirde hastalıklara yol açmaktadır. (Oğuz, 2015)

## B. Dünyada Suyun Durumu ve Kullanım Alanları

Dünya'nın yüzölçümü 510 milyon km<sup>2</sup>'dir. 149 milyon km<sup>2</sup>'si oran olarak %29,2'lik kısmı karalarla, %70,8 oranı yani 361 milyon km<sup>2</sup>'lik kısmı ise sularla kaplıdır. (21yyte.org, 2022).

Dünyadaki suyun miktarı yaklaşık 1,4 milyar km<sup>3</sup> 'tür. Bu suların % 97,5'i tuzlu su olarak okyanuslarda ve denizlerde yaklaşık 1,3 milyar km<sup>3</sup>'ü, % 2,5'i yaklaşık 35 milyon km<sup>3</sup> ise göl ve nehirlerde tatlı su olarak bulunmaktadır. (Büyükkamacı, 2009). Toplam tatlı suyun yüzde 68'inden fazlası buz ve buzullarda bulunmaktadır. Yüzde 30'u da yer altında. Nehirler ve göller gibi tatlı yüzey suyu kaynakları yalnızca yaklaşık 22.300 mil<sup>3</sup> (93.100 km<sup>3</sup>) oluşturur. Bu dünyada bulunan toplam suyun yaklaşık yüzde 1/150'sidir. Yüzde 20,9'u da göllerde bulunuyor. Nehirler ise yüzeydeki tatlı suyun yüzde 0,49'unu oluşturur (Şekil 1). Canlıların her gün kullandığı suyun çoğunun kaynağı göller ve nehirlerden karşılanır.



Şekil 1. Şekil 1. Yerküredeki su kaynaklarının dağılımı (usgs.gov, 2023)

Dünyada genel olarak suyun kullanım miktarı evsel kullanım amaçlı %12, endüstriyel kullanım amaçlı %19, tarımsal kullanım amaçlı %69 civarındadır.

Yerüstü ve yeraltı olarak kullanılabilir tatlı suyun sektörlere göre dağılımı, ülkelerin gelişmişlik seviyesine göre farklılık göstermektedir. Sektörlere göre suyun dağılımı, coğrafi şartlar ve gereklilikten kaynaklı sektör gelişimlerine bağlı olarak kıtalar bazında da değişiklik göstermektedir (Dorak, v.d. 2019). Türkiye'deki kullanılabilir su potansiyelinin yaklaşık %75'lik oranı sulamada kullanılmaktadır. Örnek olarak Avrupa ülkelerinde toplam su potansiyelinin %33'ü tarımsal sulamada kullanılmaktadır. Avrupa'nın güneyinde bu oran %75'e çıkmaktadır. Orta ve Batı Avrupa'da ise kentlerde kullanılan suyun %57'si gıda, temizlik ve enerji üretimi için kullanılmaktadır. (Aydoğdu, v.d., 2015)

Yeryüzündeki su kaynaklarının kullanım önceliği aşağıdaki gibi sıralanmıştır (Dorak, v.d., 2019).


- 1) Gıda ve temizlik ihtiyacı
- 2) Doğal hayatın devamı ve hayvanlar için gerekli su ihtiyacı.
- 3) Tarımsal faaliyetler için su ihtiyacı
- 4) Enerji ve sanayi faaliyetleri için su ihtiyacı
- 5) Balıkçılık, Ticaret, turizm vb. su ihtiyacı

### **C. Yeryüzünde Su Potansiyeli ve Hidrolojik Döngü**

Dünyadaki suyun %99'u yeryüzünde ve atmosferde bulunur. Yeryüzünün 15 km üstünde ve 8 km derinliklerinde farklı formlarda su bulunmaktadır. Su, güneş enerjisi ve yerçekimi kuvveti etkisiyle hareket eder. Dünyada su, bu iki enerjinin etkisi ile devamlı olarak hareket etmektedir. Bu hareketlilik form ve hal değiştirerek bir su döngüsünü meydana getirir. Su döngüsü yüzey sularından buharlaşmaya, toprak ve bitkilerden terlemeye, yoğunlaşarak yağışa, yeraltı akışı ve yüzey akışı aşamalarından oluşur (Sargıncı, v.d., 2022). Yeryüzünde buharlaşma her mevsimde gerçekleşmektedir. Güneş enerjisi yoluyla su buharlaşma ve bitkilerde terleme neticesinde atmosfere çıkarak bulutları meydana getirir. Buharın ısı kaybetmesi neticesinde yağış olarak yerçekiminin etkisi ile yeryüzüne düşer. Isı kaybının şiddetine göre suyun formu değişebilir. Yağış sonrası bir kısım su toprak emilimi gerçekleşerek yeraltı sularına, yeraltı su rezervlerine (akiferlere) karışır. Toprağın su geçirmeyen veya doymuş kısımlarına



düşmesi neticesinde eğim yönüne doğru akışa geçer. Dere, çay, ırmak ve nehirler meydana gelir. Ayrıca dolu ve kar şeklinde düşen yağışlar belli bir süreden sonra ısı etkisi ile eriyerek yüzey akışına dönüşür veya sızmalar neticesinde yeraltı sularına karışır. Akarsular göl, deniz, barajlarda birikirler. Bu süreçler içerisinde buharlaşma ve yoğunlaşma olayları sürekli olarak gerçekleşmektedir. Suyun yer yüzeyi ve yeraltı sularından, deniz, okyanuslar ve atmosfer arasındaki sürekli hareketi hidrolojik döngü olarak tanımlanmaktadır. Bu hareketler esnasında canlılar tarafından kullanılan nitelikli sularda atık su olarak su döngüsüne katılmaktadır (suverimliliği.gov.tr, 2023). Hidrolojik döngüde oluşan olaylar zinciri Şekil 2’de gösterilmiştir.



Şekil 2. Hidrolojik Döngünün Şematik Gösterimi (Tatar, 2019).

#### D. Yağış ve Akarsu oluşumu

Sular yeryüzü ve atmosfer arasında hareket ederek hidrolojik döngüye uğramaktadır. Her yıl okyanus ve denizlerden 333 bin km<sup>3</sup>, karaların yüzeyinden ise 63 bin km<sup>3</sup> su buharlaşmaktadır (Küçükılavuz, 2009). Atmosferde yoğunlaşarak tekrar 110 bin km<sup>3</sup> yağış olarak yeryüzüne düşmektedir. 40 km<sup>3</sup>'ü nehirler vasıtası ile deniz ve havzalara ulaşmaktadır. (Karaman, Gökalp. 2010).

Türkiye’de 2023 su yılı (1 Ekim 2022-31 Temmuz 2023) yağışı 517.3 mm, normali 1991-2020 yılları arası yıllık yağış ortalama 533,7 mm olarak ölçülmüştür (mgm.gov.tr, 2023). Türkiye’ye yaklaşık olarak yıllık 501 milyar m<sup>3</sup>

toplam yağış düşmektedir. Düşen yağışın 274 milyar m<sup>3</sup>'ü atmosfere geri dönmektedir. Yeraltı sularını 69 milyar m<sup>3</sup> 'ü beslemektedir. Akarsu akışlarıyla denize ve göllere ulaşan miktar ise 158 milyar m<sup>3</sup> 'tür. (Usta, 2016)

Yağış ve kaynak sularının doymuş toprak ve sert katmanlar üzerinden yeryüzünün meyilli doğrultusunda oluşturduğu yataklardan akması ile oluşan yeryüzü şekillerine akarsu denilmektedir. Akarsuların oluşumunda iklim, zemin özellikleri, jeomorfolojik özellikler ve birçok etken yer almaktadır. (ankara.edu.tr, 2023).

### **E. Akarsu Tipleri**

Akarsular akış şekline ve süresine, boylarına, taşıdığı su miktarına, havza büyüklüğüne, “kapalı” ya da “açık havza” olarak sınıflandırılabilir. Bazı akarsular göllerde sonlanır. Yer altına sızma veya aşırı buharlaşma gibi etkenlerden dolayı kurur. Bu tür denize ulaşmayan akarsulara kapalı havza akarsu denilir. Denize ve okyanuslara ulaşan akarsular açık havzalı akarsu olarak adlandırılır (Garipağaoğlu, 2012).

Akarsular farklı kaynaklardan beslenir. Yeraltı sularından beslenen akarsular bulunduğu gibi, kar, buz, yağmur sularından beslenen akarsular da mevcuttur.

Akarsular taşıdıkları su miktarı açısından yıl içerisinde seviyesinde değişiklik olmayan akarsular rejimi düzenli akarsu, yıl içerisinde seviye çok değişiklik gösteriyorsa rejimi düzensiz akarsu olarak tanımlanır. Bol yağış alan bölgelerde bulunan akarsulardan Amazon ve Kongo nehri rejimi düzenli akarsulardır. Bir dönemi kurak, bir dönemi yağışlı olan Ganj ve İndus düzensiz rejimli akarsulardır. (cografyaci.gen.tr,2023)

### **F. Akım Ölçümleri ve Verileri**

Yağış ve akıntılarının, yüzey sularının ölçümlerini ve analizini inceleyen bilim dalına hidrometri denilmektedir.

Akarsuların belirli noktalarına kurulan akarsu akım gözlem istasyonları sayesinde su yüzeyi seviyesinin, akarsudan geçen su miktarı, hızı, debisi günlük ve sürekli olarak ölçülmektedir.

Akarsudaki su ölçümleri limnigraf ve limnimetre gibi aletlerle belirli bir seviye baz alınarak ölçülmektedir. Baz alınan yerin nehirdeki minimum su seviyesinin daha altında bir seviye olması gerekir (Yurtseven ve Kalkavan, 2023).

Türkiye için akarsu akım verilerine DSİ (Devlet Su İşleri) web sayfasında 1934-2015 yılları verilerine çevrimiçi olarak ulaşılmaktadır. Meteorolojik veriler için Meteoroloji genel müdürlüğü web sitesinden veriler elde edilebilmektedir.

Doğrusal Regresyon, Destek Vektör Regresyon, Karar Ağacı, Rastgele Orman ve Ekstra Ağaçlar Regresyon algoritmalarını kullanarak, girdi parametreleri olarak günlük ortalama akışı, toplam günlük yağışı ve günlük ortalama hava sıcaklığını kullanarak tahmin performanslarını karşılaştırılmıştır. Tahmin performansını optimize etmek için, her algoritma için Wavelet analizini kullanan hibrit bir yöntem ve eksik verileri işlemek için derecelendirme üstel düzeltmenin yanı sıra geliştirilmiştir (Gupta ve Alam, 2022). Makine öğrenmesi ve en son analitik yöntemlerin uygulanması, su kaynaklarının yönetimini geliştirmeye ve nehir akışını tahmin etme, su kullanım etkinliğini artırma ve çevresel sürdürülebilirliği teşvik etme ile ilgili sorunları ele almayı amaçlamaktadır. Bu yöntemleri daha derinlemesine inceleyerek etkili su yönetimi uygulamalarını teşvik edilebilir, gelecek nesillerin refahı için suyun daha etkin kullanılabilirliğini sağlayabiliriz.

DD(Dalgacık dönüşüm) tekniğini çalışmaya LR, SVR ve DT gibi geleneksel yöntemlerin aksine yaklaşımımız DD' yi dahil ederek yeni bir boyut getirmektedir. Bu yolla karmaşık zamansal özellikleri kullanarak tahmin doğruluğunu artmakta ve tahmin kesinliğini güçlenmekte, araştırmaya belirgin bir üstünlük sağlamaktadır. Bu yaklaşım yalnızca araştırma yöntemini zenginleştirmekle kalmıyor, aynı zamanda veriye dayalı hidrolojik çalışmalar alanında daha geniş çıkarımlara da olanak oluşturuluyor.

## II. İNCELEME BÖLGELERİ VE YERİ

### A. Giriş

Ülkemizde su kaynaklarına ait planlama, yönetim, işletmesinden ve geliştirilmesi yönünden sorumlu kuruluş Devlet Su İşleri'dir. DSİ tarafından belirlenen 26 akarsu havzası vardır (dsi.gov.tr, 2020). Türkiye'de 26 akarsu havzasında Falkenmark su stres indeksi'ne göre sınıflandırılma su kıtlık ve su fazlası olanlar için hesaplamalar yapılmaktadır (Gökçe, 2022). Yıllık kişi başına düşen su miktarı Türkiye'de tarımsal faaliyetler için kullanılan su toplam su tüketimi içinde önemli ölçüde pay almaktadır (Karşılı, 2011).

Meteoroloji Genel Müdürlüğü 2022 yılı verilerine göre 16 bölge müdürlüğüne ait toplam 2057 adet gözlem sistem ve istasyonları mevcuttur. Bu istasyonlarda yağış, sıcaklık, basınç, nem, rüzgâr hızı ve yönü, görüş uzaklığı vb. meteorolojik parametreler dakikalık olarak alınmaktadır. (mgm.gov.tr, 2023).

Türkiye'de içme ve kullanma suyu şebekelerinden çekilen su 1994 yılında 3,24 milyar m<sup>3</sup>, 2006 yılında 5,16 milyar m<sup>3</sup>, 2018 yılı itibarı ile 6,2 milyar m<sup>3</sup> olmuştur. (Sarış, 2021).

Artan nüfus, endüstri faaliyetleri ve çevresel etkenler su ihtiyacını artırmaktadır. İhtiyacın artması verimli kullanımı gerekliliğini ihtiyaç haline getirir. Suyun verimli kullanımı için Türkiye'ye gelecek yıllarda tatlı suların tahmini planlamasının yapılması gereklidir.

Makine öğrenmesi algoritmaları ve dalgacık dönüşüm kullanarak incelemiş olduğumuz 7 adet akım gözlem istasyonu bilgileri aşağıda açıklanmaktadır.


### B. Marmara Havzası- Çatalca- Karamandere

Marmara havzasına ait D02A028 numaralı Istranca Deresinin üzerinde Karamandere (Şekil 3) yakınlarındaki akım gözlem istasyonu (A.G.İ.) verileri analiz edilmiştir (Çizelge 1). D02A028 numaralı akım gözlem istasyonuna ait

1980- 2020 yılları arası günlük ortalama akım verileri düzenlenmiş fakat bölgedeki meteoroloji istasyonu 2004 yılında ölçüm yapmaya başladığı için 2004-2020 su yılları arası günlük ortalama akım hızı verileri çalışmaya dahil edilmiştir. Kullanılan veriler Devlet Su İşlerinin internet sitesinden ve İstanbul Devlet Su İşleri Müdürlüğünden alınmıştır. (dsi.gov.tr, 2021)

Çizelge 1. İstiranca İnceleme Bölgesi konum bilgileri

Havza/Şehir	İstasyon İsmi	Enlem Boylam	Veri Aralığı
Marmara/İstanbul Çatalca	D02A028 nolu AGİ İstiranca Deresi Karamandere	Enlem: 41° 22' 45" Kuzey Boylam: 28° 18' 44" Doğu Rakım: 381m	1980-2020
Marmara/İstanbul Çatalca	17047 Çatalca Meteoroloji Genel Müdürlüğü	Enlem: 41.3409 Kuzey Boylam: 28.3568 Doğu Rakım: 381m	2004-2020



Şekil 3. İstiranca Deresi üzerindeki istasyonların konumu (Saç ve Özuluğ, 2014)

Meteoroloji Genel Müdürlüğü (MGM) 17047 nolu Çatalca sahası istasyonu 2004-2020 yılları arası günlük yağış ve sıcaklık verileri kullanılmıştır (Çizelge 1).

### C. Antalya Havzası – Çaydere Göl Girişi - Gelendost

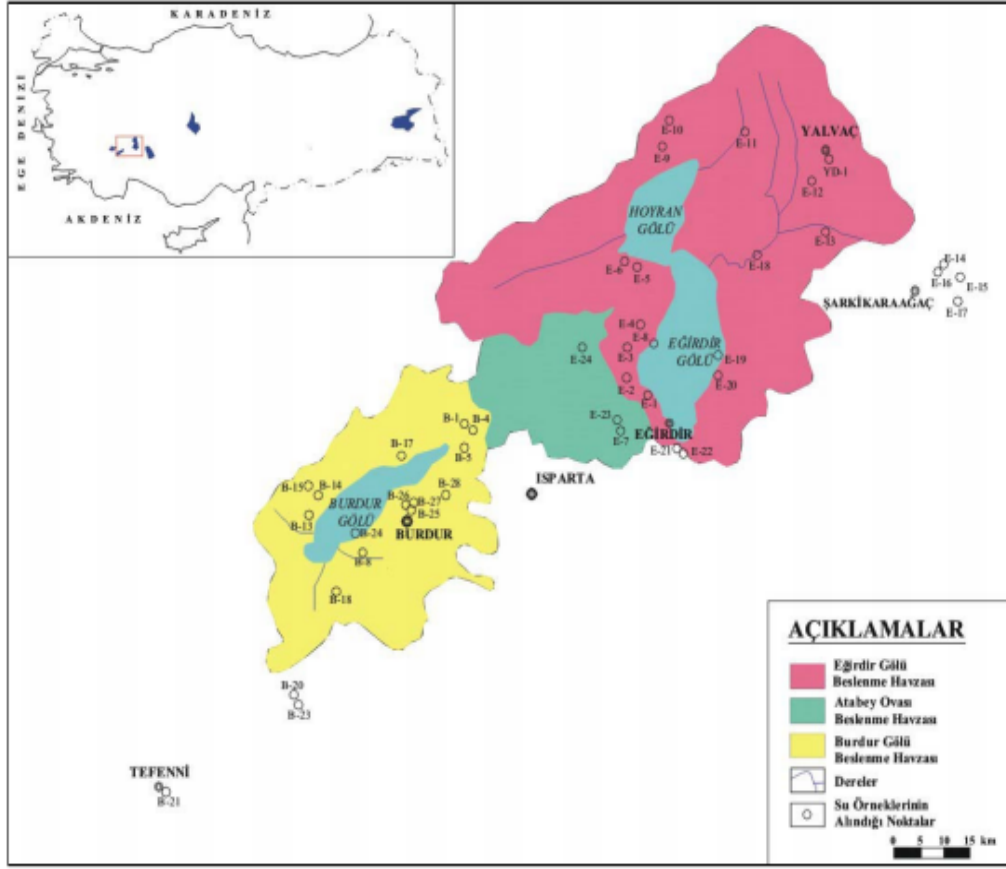
Antalya havzasında inceleme bölgesi olarak Isparta Eğirdir göl giriş yakınındaki akım gözlem istasyonu seçilmiştir. Türkiye'nin önemli göllerinden Eğirdir Gölünü besleyen kaynaklardan biri olan Çaydere üzerinde bulunan gözlem istasyonu verilerini kullanarak akım tahmini yapılmıştır. Eğirdir gölünün yıllar içindeki değişiminin tahmini, doğal kaynakların korunması amacıyla önemlidir.

D09A060 Numaralı Çaydere Eğirdir A.G.İ. Eğirdir-Yalvaç devlet yolunun takiben Eğirdir kazasının 5.km'deki ana yolun sağ tarafındadır. Çaydere Eğirdir göl giriş akım gözlem istasyonunun 1978-2020 yılları arası aylık ortalama akım verileri, yağış ve sıcaklık verileri MGM 17882 numaralı Eğirdir istasyonu 1978-2020 yılları arası aylık verileri kullanılmıştır. (Çizelge 2)

Çizelge 2. Çaydere Eğirdir Göl Girişi- Gelendost İnceleme Bölgesi konum bilgileri

Havza / Şehir	İstasyon	Enlem-Boylam	Veri Aralığı
Antalya/ Isparta/Eğirdir	D09A060 Çaydere Eğirdir Göl Girişi Gözlem İstasyonu	Enlem : 41° 22' 45" Kuzey Boylam: 28° 18' 44" Doğu Rakım : 381m	Aralık 1978- Haziran1987 ve Ekim 1997-Eylül 2020
Isparta/Eğirdir	17882 Eğirdir Meteoroloji Genel Müdürlüğü	Enlem : 37.8377 Kuzey Boylam : 30.8720 Doğu Rakım : 920m	Aralık 1978- Eylül 2020
Antalya/Isparta – Gelendost Yalvaç Deresi	D09A075 Gelendost D. Avşar Köp. Gözlem İstasyonu	Enlem : 38°07'26.37" Kuzey Boylam: 31°00'55.24" Doğu Rakım : 952m	Aralık 1978- Haziran1991 ve Kasım 1997-Eylül 2020
Antalya/Isparta – Yalvaç	18114 Yalvaç Meteoroloji Genel Müdürlüğü	Enlem: 38.1242 Kuzey Boylam: 30.9986 Doğu Rakım: 1010m	Aralık 1978- Eylül 2020

D09A075 Numaralı Gelendost D. Avşar Köprüsü A.G.İ. 1978 - 2020 yılları arası aylık ortalama akım hızı verileri, yağış ve sıcaklık verileri için MGM 18114 numaralı Yalvaç istasyonu 1978-2020 yılları arası aylık verileri kullanılmıştır (Çizelge 2).



Şekil 4. Eğirdir göl girişi istasyonu konumu

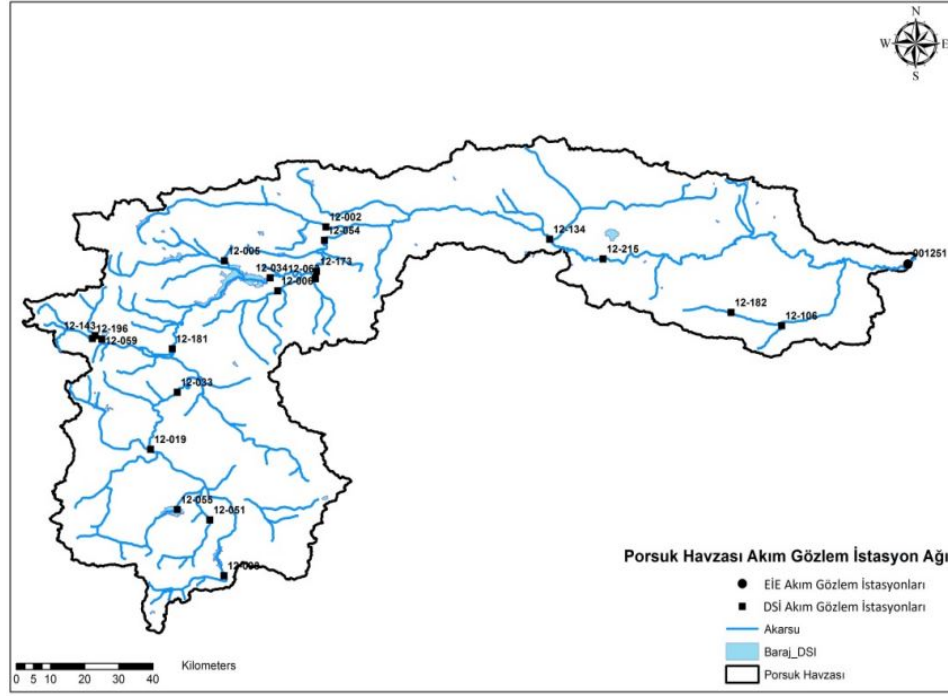
#### D. Sakarya Havzası - Porsuk Çayı

Sakarya Havzasında Porsuk çayı alt havzası ait E12A003 numaralı Porsuk Çayı Beşdeğirmen akım gözlem istasyonu ait akım verileri ele alınmış analiz edilmiştir (Çizelge 3). Kütahya-Eskişehir karayolunda Kütahya'ya 17 km uzaklıktaki Beşdeğirmenler yakınındadır (Şekil 5). E12A003 numaralı Porsuk Çayı Beşdeğirmen akım gözlem istasyonu 1980-2011 su yılları arası günlük ortalama akım hızı verileri kullanılmıştır.

Çizelge 3. İnceleme Bölgesi konum bilgileri

Şehir / Havza	İstasyon	Enlem-Boylam	Veri Aralığı
Kütahya/Sakarya-Porsuk Çayı	E12A003 - Porsuk Çayı Beşdeğirmen	Enlem: 39° 31' 43" Kuzey Boylam: 30° 02' 56" Doğu Rakım: 855m	1980-2011
Kütahya	17155 Kütahya	Enlem: 39.4171 Kuzey Boylam: 29.9891 Doğu Rakım: 969m	1980-2011

Sıcaklık ve yağış verileri 1980-2011 yılları arası 17155 numaralı Kütahya sahası günlük verileri kullanılmıştır.



Şekil 5. Çalışma alanı (E12A003) akarsu istasyonlarının konumu

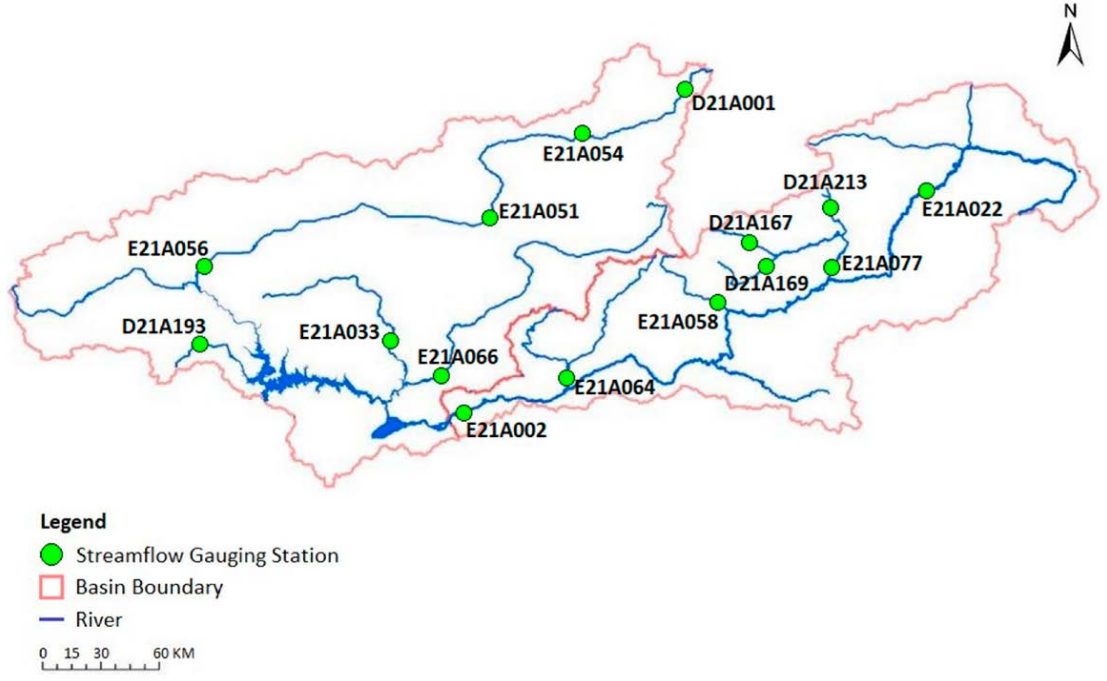
#### E. Fırat Havzası Tunceli Munzur Suyu

Fırat Havzası E21A033 numaralı Munzur Suyu Melekbağçe akım gözlem istasyonlarına ait akım verileri ele alınmış analiz edilmiştir. E21A033 Numaralı Munzur Suyu Melekbağçe akım gözlem istasyonununun 1986-2009 su yılları arası günlük ortalama akım hızı verileri kullanılmıştır (Çizelge 4). Sıcaklık ve yağış verileri MGM 1986-2009 yılları arası 17165 Numaralı Tunceli sahası istasyonu günlük verileri kullanılmıştır (Şekil 6).

Çizelge 4. İnceleme Bölgesi konum bilgileri

Şehir /Havza	İstasyon	Enlem-Boylam	Veri Aralığı
Tunceli/Fırat-Munzur Suyu	E21A033 Munzur Suyu Melekbağçe	Boylam: 39° 31' 34" Doğu – Enlem: 39° 02' 45" Kuzey Rakım: 875	1989-2009
Tunceli	17165 Merkez	Boylam: 39.5401 Enlem: 39.1058 Rakım:981	1986-2009





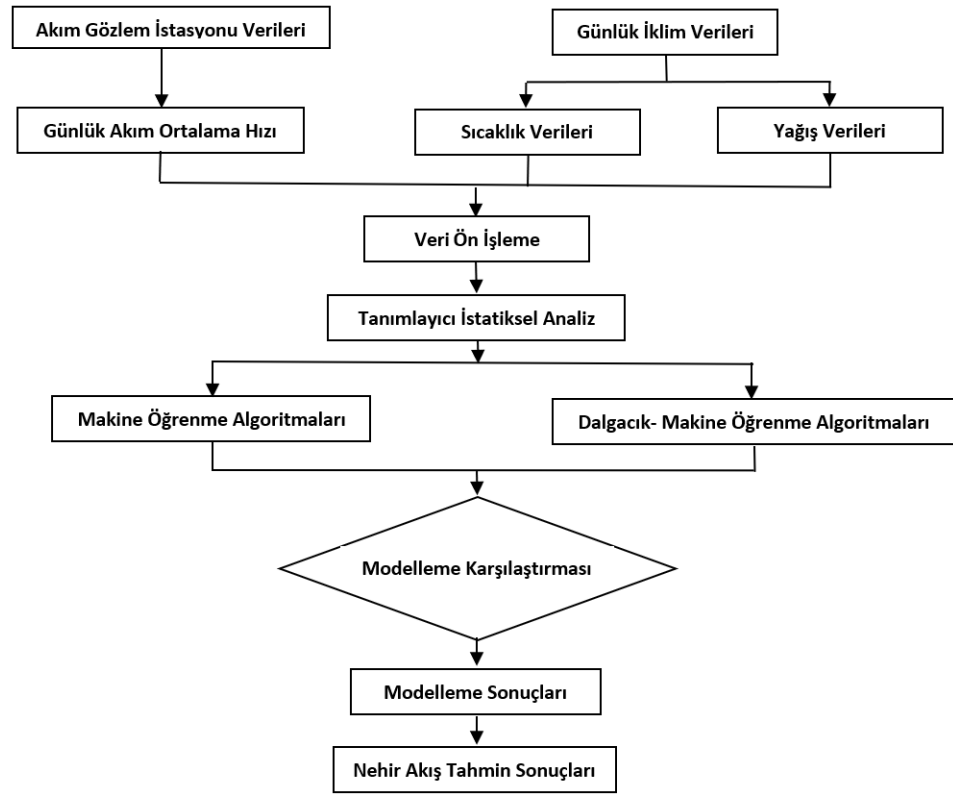
Şekil 6. Çalışma alanı (E21A033) akarsu istasyonlarının konumu

### **III. YÖNTEM**

#### **A. Giriş**

Araştırmanın metodolojisinin açıklaması Şekil 3'te özetlenmiştir. Bu grafiksel gösterim, araştırma hedeflerimizi anlamak için attığımız ardışık adımları ortaya koymaktadır. Araştırmada iki temel veri kaynağından yararlanıldı.

Grafikte, araştırma hedeflerine ulaşmak için yaptığımız ardışık aşamaları sergilemektedir. Araştırmada iki temel veri kaynağı kullanıldı. Akarsuların belirli yerlerinde bulunan akım gözlem istasyonlarına(AGİ) ait veriler ve AGİ yakınlarındaki meteoroloji istasyonlarından incelediğimiz döneme ait sıcaklık ve yağış verileri kullanıldı. İlk aşamada ham verilerin iyileştirilmesi ve eksik verilerin giderilmesi için veri ön işleme adımları uygulandı. Doğruluk ve tekdüzeliği sağlamak için standart bir takvime dayalı ön işleme tekniği uygulanarak ve verilerimizi daha derinlemesine inceleme için uyumlu hale getirildi (Şekil 7). Bu hazırlık aşaması, sonraki analizlerimizin üzerine inşa edileceği temel taşı görevi görmektedir.



Şekil 7. Uygulama Analizi Akış Diyagramı

Uygulamada ETR ve RF aracılığıyla daha ayrıntılı olarak incelenen LR, SVR ve DT'yi kapsayan bir dizi otonom makine öğrenimi tekniklerine doğru dönüyor. Bu metodolojiler, veri kümesinde gizlenen karmaşık kalıpların şifresini çözmek için titizlikle uygulanmıştır. Ancak metodolojinin yeni ve önemli bir yönü WT tekniğinin diğer modellere entegrasyonudur. Hem zamansal hem de frekans ortamında güçlü bir yorumlayıcıya benzer olan bu teknik, zaman serisi verilerini frekans bileşenlerinin bir spektrumuna ayrıştırmada üstünlük sağlar. Bu analitik çeviklik, normalde fark edilemeyecek ince dalgalanmaları fark edilmesini sağlar.

## B. Linear Regression(LR)

Tahmine dayalı modelleme alanında, Doğrusal Regresyon güçlü bir araç olarak ortaya çıkar; faydası, bir değişkenin davranışını diğerinin nüanslarına dayalı olarak tahmin etme yeteneğinden kaynaklanır. Bu yaklaşım, iki temel verinin yan yana gelmesi ve birbirine bağlı olarak aralarındaki etkileri baz alan teoriler ortaya çıkarır (Rebala,2019). Amaç, tahminin odağı olan bağımlı değişken ile etkilerini kullanarak sonucu tahmin eden bağımsız değişkenler

arasında bir bağlantı kurmaktır. (Montesinos ve Crossa 2022). Bu yöntemin temeli, Denklem yapısı içinde güçlendirilen iki değişken arasında doğrusal bir korelasyon arayışını içerir.

$$y' = b + W1X1 \quad (\text{formül 1})$$

Burada:

- y' tahmini veya istenen sonucu temsil eder.
- b, bilinen sapmayı gösterir.
- W1, özellik 1'in ağırlığı.
- X1, modelde bilinen bir girdi.

Doğrusal Regresyon, temelde iki veriye ait olan özellikleri birbirine bağlayan doğrusal bir sonuç çıkarmaya çalışan sıkça kullanılan istatistiksel bir yaklaşımdır. Bu tez çalışmasında, nehir akış hızını (bağımlı değişken) tahmini için günlük ortalama sıcaklık ve yağış verileri (bağımsız değişkenler) kullanarak Doğrusal Regresyonu uygulanmaktadır.

### **C. Destek Vektör Regresyonu (SVR)**


SVR, belirtilen veri aralıklarında regresyon üretme yeteneği ile bilinen son derece uzmanlaşmış ve gelişmiş bir makine öğrenme modelidir. Şekil 8'de belirlenen aralıkların dışında kalan veriler analize dahil edilmez. SVR'in dikkate değer bir yönü, belirlenen aralığın ötesine geçen veri noktalarını dahil etmek için sistemin kendinden kaynaklanan farklı vektörler üretme kapasitesidir.

SVR, sadece deneyimlenerek oluşacak riskleri en aza indirmeyi değil, aynı zamanda genelleme hatasının üst sınırını kısaltmayı amaçlayan yapısal risk minimizasyonu ilkesi üzerinde çalışmaktadır. Bu ilke, modelin görünmeyen veriler üzerinde genelleme ve doğru tahminler üretme yeteneğini geliştirir. Bu çalışmada, SVR modelinin becerileri, güçlü Radyal Temel Fonksiyon ( RBF ) Çekirdek ile entegrasyon yoluyla artırılmaktadır.

Süreç, iki veri arasındaki bilginin ne kadar yakın olduğunu ve ne kadar benzer olduklarını bulmaya yardımcı olur. Bu harmanlama süreci, SVR'in öngörücü yeteneklerini destekleyen kritik bir unsur olan iki veri noktası arasındaki yakınlığı ve benzerliği hesaplamada etkilidir. (Mohammadi, &

Mehdizadeh 2020). SVR ve RBF Çekirdeğinin akıllıca birleşimi, modelin veriler içindeki karmaşık kalıpları ve ilişkileri yakalama kapasitesini güçlendirerek çalışmamızda doğru tahmin ve tahmin için güçlü bir araç ortaya koymaktadır.

RBF Çekirdeğini kullanan SVR'nin pratik uygulamaları, çeşitli durumlarda etkinliğini göstermektedir. Bu teknolojinin potansiyel uygulamaları arasında mülk niteliklerine göre emlak fiyatlarının tahmin edilmesi, incelemelere göre film derecelendirmelerinin analiz edilmesi, fiyatlandırma dinamiklerine göre ürün talebinin değerlendirilmesi ve bir şirketin satış gidişatının tahmin edilmesi yer almaktadır. Veri ortamının doğrusal olmadığı veya gürültüden etkilendiği durumlarda, RBF Çekirdeği ile SVR, dikkate alınması ve uygulamaya konulması gereken uygun bir seçenektir. Karmaşık, doğrusal olmayan verilerle veya gürültülü verilerle karşılaşıldığında, SVR'nin RBF çekirdeği ile kullanılmasının değerlendirilmesi uygundur (Baydaroğlu, 2014). Bu seçim dikkatli bir değerlendirmeyi ve pratik uygulamayı olanaklı kılmaktadır. Veri ortamının karmaşık doğrusal olmayan ilişkilerle karakterize edildiği veya rahatsız edici gürültüye karşı savunmasız olduğu durumlarda, SVR'nin RBF Çekirdeği ile uygulanması, kapsamlı değerlendirmeyi ve amaçlı dağıtımı hak eden uygun bir seçenek olduğunu kanıtlamaktadır. (Ulas v.d. 2020).



Şekil 8. Destek Vektör Regresyonu Modeli (Kına ve Biçek, 2023)

$$\hat{y} = \begin{cases} 0 & \text{eğer } w^T \cdot x + b < 0, \\ 1 & \text{eğer } w^T \cdot x + b \geq 0 \end{cases}$$

(Formül 2)

w; ağırlık vektörü,

x; girdi vektörü,

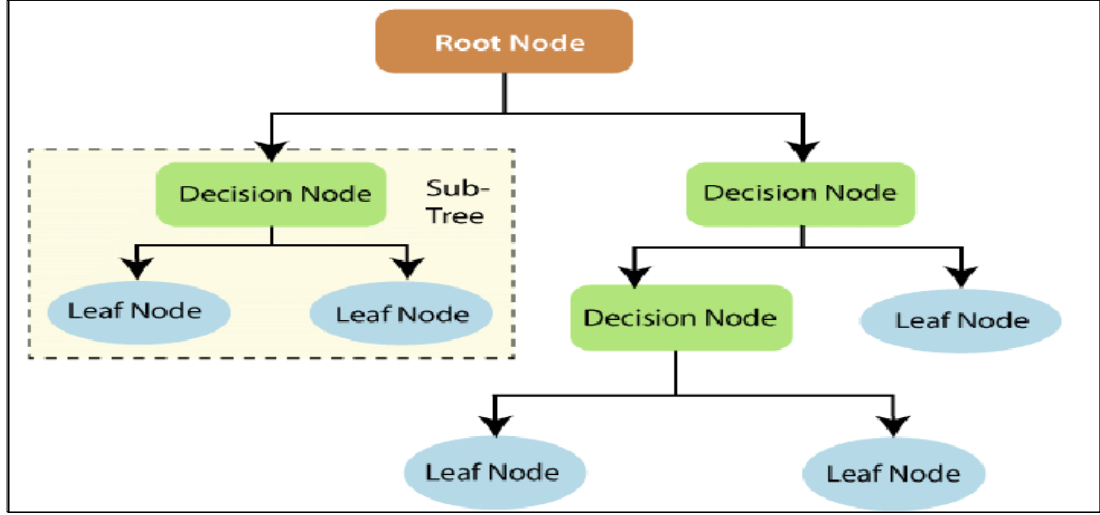
b; sapma olarak ifade edilmektedir.

#### D. Karar Ağacı (DT)

KA, tahmine dayalı ve sınıflandırma çözümlerinde kolay anlaşılmasını sağlama kapasiteleriyle tanınan, önde gelen ve yaygın olarak kullanılan makine öğrenimi yöntemleridir. İşsel yorumlana bilirlikleri ve karar verme için açık, sezgisel kurallar oluşturma yetenekleri nedeniyle büyük önem taşırlar. Bir KA oluşturma süreci, giriş verilerinin belirli özelliklere veya niteliklere dayalı olarak farklı gruplara veya alt kümelere bölünmesini içerir. Her bölüm ağaçtaki bir düğümü temsil eder ve bu süreç, yaprak düğümlerde bir karara veya tahmine ulaşılan kadar yinelemeli olarak devam eder. KA'nın her düğümünde, karar vermek için belirli bir nitelik seçilir. Bu seçim, verileri homojen özelliklere sahip farklı gruplara en iyi şekilde ayırma yeteneğine dayanmaktadır. Safsızlıkta en önemli azalmaya veya bilgi kazancında artışa yol açan özellik seçilir, böylece ağacın tahmin gücü artar(Sel, 2014). KA oldukça çok yönlüdür ve hem regresyon hem de sınıflandırma görevlerine uygulanabilir. Sınıflandırma problemlerinde ağacın yaprak düğümleri belirli sınıf etiketlerine karşılık gelirken, regresyon problemlerinde tahmin edilen sürekli değerleri temsil ederler(Şekil 9).

KA'nin kolay yorumlanabilir olması önemli bir avantajdır; çünkü her bir bölünmeyi yöneten kurallar kolaylıkla anlaşılabilir ve görselleştirilebilir, bu da onları karar verme süreçlerinde özellikle faydalı kılar. Üstelik KA aykırı değerlere karşı dayanıklıdır ve hem kategorik hem de sayısal verileri etkili bir şekilde işleyebilir. KA, kümeleme algoritmasından yararlanarak verileri tekrar tekrar alt kümelere böler ve sonuçta doğru tahminler ve sınıflandırmalar yapılmasına yardımcı olan karar çıktıları sağlar. Bu uyarlanabilirlik ve

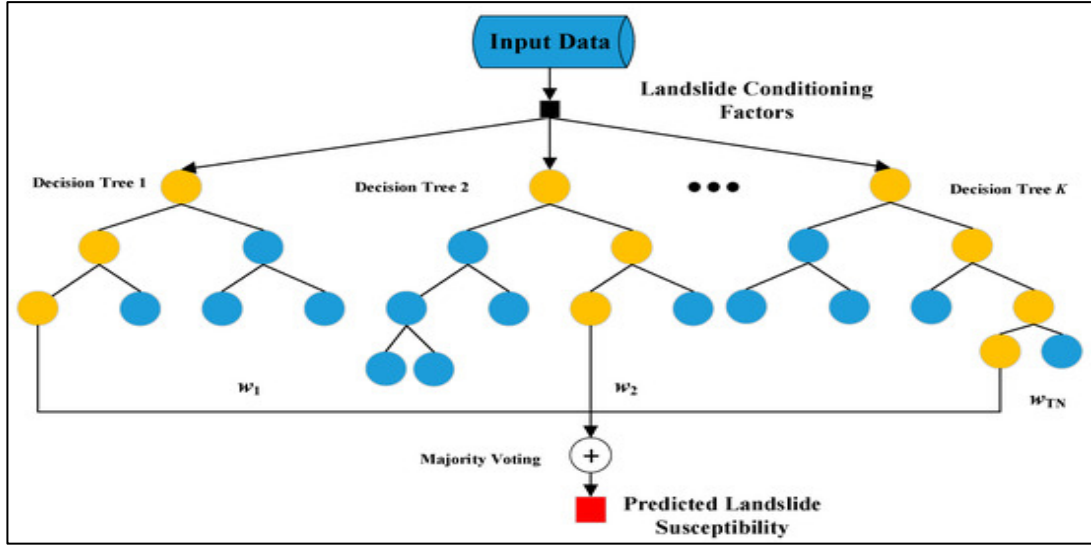
yorumlama kolaylığı, KA'nin finans ve sađlık hizmetlerinden pazarlama ve çevre arařtırmalarına kadar çeřitli alanlarda yaygın olarak uygulanmasına katkıda bulunmaktadır. (Bahzad, 2021)



Şekil 9. Karar Ağacı modeli

#### E. Rastgele Orman (RF)

RF hem sınıflandırma hem de regresyon sorunlarını çözmek için çoklu karar ağaçlarının kolektif zekasından yararlanan, güçlü ve yaygın olarak kullanılan bir denetimli öğrenme algoritmasıdır. Çok yönlü bir topluluk yöntemi olarak, bireysel karar ağaçlarının gücünden yararlanır. Sağlam ve doğru tahminlere ulaşmak için çıktıları birleştirir(Şekil 10). Sınıflandırma görevleri bağlamında, bir RF, her biri değiştirilerek (önyükleme) farklı veri alt kümeleri üzerinde eğitilen birden fazla karar ağacı oluşturur. Her ağaç, çeşitliliğin sağlanması ve aşırı uyumun azaltılması için rastgele bir özellik alt kümesi kullanılarak eğitilir. Nihai sınıflandırma kararı, tüm bireysel ağaçların çoğunluk oyu temel alınarak yapılır. Regresyon problemleri için RF yöntemi benzer şekilde çalışır ancak çoğunluk oyu yerine, nihai regresyon tahminine ulaşmak için tüm karar ağaçlarının çıktılarının ortalamasını alır.



Şekil 10. Rastgele Orman modeli


RF kullanmanın avantajlarından biri, yüksek boyutlu verileri ve büyük veri kümelerini işleyebilme yeteneğidir. Ek olarak RF yaklaşımı, tekli karar ağaçlarıyla karşılaştırıldığında fazla uyum sağlamaya daha az eğilimlidir. Bu çalışmada RF yöntemi belirli hiper parametre ayarlarıyla kullanılmıştır. Bu hiper parametreleri etkili bir şekilde optimize etmek için GridSearchCV yöntemi kullanıldı. GridSearchCV, verileri birden fazla alt kümeye (katlamalara) bölmeyi ve modeli eğitim ve doğrulama verilerinin farklı kombinasyonları üzerinde eğitmeyi içeren çapraz doğrulama gerçekleştirir. Bu süreç, hiper-parametrelerin modelin performansı üzerindeki etkisinin daha güvenilir bir şekilde değerlendirilmesini sağlar. Ayrıca, 5 katlı çapraz doğrulama uygulanmıştır; bu uygulama, veri kümesinin beş alt kümeye bölüldüğü ve her alt kümenin bir kez doğrulama kümesi olarak hizmet vereceği şekilde modelin beş kez eğitilip doğrulandığı anlamına gelir. Bu prosedür, modelin performansının ve genellenebilirliğinin daha sağlam bir şekilde değerlendirilmesine yardımcı olur. RF'nin GridSearchCV ve çapraz doğrulama kullanılarak hiper-parametre ayarıyla birleşimi, modelin iyi optimize edilmesini ve incelenen spesifik sınıflandırma veya regresyon problemi için doğru ve güvenilir tahminler sunabilmesini sağlar (Viet-Hung Dang 2020)(Akbulut ve Aslan, 2021) .

## F. Ekstra Ağaçlar (ETR)

Ekstra Rastgele Ağaçlar olarak da bilinen ET, RF algoritmasına benzer, topluluk öğrenme ailesine ait bir makine öğrenme modelidir. Hem sınıflandırma



hem de regresyon görevleri için özellikle kullanışlıdır. ET modeli ile geleneksel RF arasındaki temel fark, ağaçtaki her düğümde karar vermenin gerçekleştirilme biçiminde yatmaktadır. Bir RF'de, her düğümdeki karar, mevcut özellikler kümesinden rastgele seçilen bir özellik alt kümesine dayanır ve bu ağaçlardaki çoğunluk oyu, nihai sınıflandırma kararını belirler. Buna karşılık ET daha rastgele bir yaklaşım benimsemektedir. Yalnızca her düğüm için rastgele özellik alt kümeleri seçmekle kalmaz, aynı zamanda her düğümdeki verileri bölmek için rastgele kesme noktaları da seçer. Bu rastgele süreci topluluktaki bireysel ağaçlar arasında ek çeşitlilik ve değişkenlik sağlar. Şekil 11'de örnek görseli mevcuttur.




Şekil 11. Ekstra Ağaçlar modeli

Diğer bir önemli fark, ET'nin eğitim süreci sırasında orijinal örneğin tamamını girdi olarak kullanması, RF'nin ise her ağaç için tipik olarak ön yüklemeli numuneleri (yani değiştirilen rastgele numuneleri) kullanmasıdır. ET, bu rastgelelik kaynaklarını dahil ederek modeldeki varyansı azaltmayı, onları aşırı uyumdan daha az duyarlı hale getirmeyi ve genelleme yeteneklerini geliştirmeyi amaçlamaktadır. Bu özellik özellikle yüksek boyutlu verilerle veya gürültülü veri kümeleriyle çalışırken değerlidir. Sınıflandırma aşamasında ET modeli, tüm bireysel ağaçlardan gelen tahminleri bir araya getirir ve ağaçlar arasındaki çoğunluk oyuna dayalı olarak nihai sınıflandırma kararını belirler. Bu demokratik oylama süreci, sağlam ve doğru tahminlerin yapılmasına yardımcı olur. Sağlamlıkları, basitlikleri ve yüksek boyutlu veri kümelerini işleme yetenekleri nedeniyle ET, bilgisayarlı görme, biyoinformatik ve finans dahil olmak üzere çeşitli alanlarda yaygın uygulanma olanağı bulmuştur (Vargas v.d. 2023). ET tarafından kullanılan rastgele teknikler, güçlü ve esnek bir makine öğrenme algoritması olarak etkinliklerine katkıda bulunur.


## G. Dalgacık Dönüşümü (WT)

Zaman serileri her ne kadar karmaşık görünse de belli bir matematik kurala dayandırılabilir (Koçak,2004). WT, zaman-frekans alanındaki sinyalleri gözlemlemek ve analiz etmek için yaygın olarak kullanılan güçlü bir sinyal analiz aracıdır. Bu yöntem, zaman serisi verilerini alt bileşenlerine ayırarak, baskın tekrarları ve bunların zaman içindeki değişimlerini analiz ederek ardışık olmayan ve durağan sinyallerin incelenmesine olanak sağlar ( Zhang, v.d. 2022). Şekil 12’de öteleme ve genlik dalgacık bileşenleri gösterilmiştir.



Şekil 12. Dalgacık dönüşümü

Çalışmamızda orijinal veriler ortalama nehir akış hızı, toplam yağış ve ortalama sıcaklıktan oluşmaktadır. Nehir akışı tahmininin doğruluğunu arttırmak için verileri alt bölümlere ayıran ve dönüştüren dalgacık dönüşüm analizini uygulanmıştır. Özellikle, WT kullanılarak geliştirilen hibrit yöntem, nehir akış tahmininde önemli bir gelişme göstermiştir. Araştırmada öncelikle, Türkiye'deki yedi dere ölçüm istasyonundan alınan günlük ortalama akış verilerinin yanı sıra günlük ortalama sıcaklık ve toplam yağış verilerini kullanarak akarsu akış verilerini tahmin etmeye yönelik makine öğrenimi uygulamalarına yer verilmiştir. Beş farklı makine öğrenimi algoritması kullanılarak sonuçlarını karşılaştırılmıştır. Dikkat çekici bir şekilde, RF ve ETR modelleri akış hızlarını tahmin etme de diğerlerinden daha iyi performans göstermiştir. Makine öğrenme modellerinin performansını daha da artırmak için Dalgacık Dönüşüm entegre edilmiş ve bu da daha da iyi sonuçlara ulaşılmıştır. Şekil 13'te gösterilen Biorthogonal, Mexican Hat, Haar, Coiflets, Daubechies, Symlets, Morlet ve Meyer dahil olmak üzere dikkate alınan çeşitli dalgacık filtreleri arasından Daubechies (db10) dalgacık ailesi göz önüne alınmıştır.



Şekil 13. Örnek dalgacık şekilleri ( Öner, v.d. 2017 ).

Dalgacık dönüşümünün her adımı, dalgacık fonksiyonunun giriş verilerine uygulanmasını içermektedir. Hesaplamalı sonuçları iyileştirmek için kullanılan yinelenen değerleri elde etmek amacıyla dalga fonksiyonu değerlerini ve ölçeklendirme fonksiyonu değerlerini on tekrar hesaplanmıştır. (Waqas, v.d. 2020). WT'nin, özellikle de Daubechies dalgacık ailesinin kullanılması, araştırmanın nehir akış hızlarını tahmin etmede daha yüksek doğruluk elde etme başarısına önemli ölçüde katkıda bulunmuştur. Bu yaklaşım, benzer hidrolojik analizlerde makine öğrenimi modellerinin performansının artırılması açısından değerli olduğunu kanıtlamaktadır. Araştırmacılara ve uygulayıcılara su kaynakları yönetimi ve çevresel izleme konularında daha güvenli kararlar almaları için önemli katkı sağlamaktadır.

Bu çalışmada sunulan sonuçlar, nehir akış tahminlerinin doğruluğunu arttırmada WT uygulamasının önemli etkisini vurgulamaktadır. Bu artışın boyutu, makine öğrenimi algoritmalarının yetenekleri etkili bir şekilde birleştirildiğinde daha belirgin hale gelmektedir. Daubechies dalgacık ailesi, bu karmaşık kombinasyonda çok uygun bir seçimdir ve kesin tahminler için gerekli olan zaman-frekans çözünürlüğüne yönelik kritik ihtiyacı etkili bir şekilde

yönetmektedir. Hem dalga fonksiyonu değerleri hem de ölçeklendirme fonksiyonu değerleri için on hesaplama yinelemesinin kullanılması, elde edilen bulgularda elde edilebilecek kesinliği artırmaktadır. Dikkat çekici bir şekilde, bu yeni metodoloji, nehir akışı tahminleri ve taşkın tahmini ve kritik kuraklık izleme alanı da dahil olmak üzere diğer hidrolojik bağlamlar alanında uygulama potansiyeline sahiptir. Bu stratejinin uyarlanabilirliği, sınırlı kullanılabilirliğinin ötesindeki gücünü de göstermektedir. Hidrolojideki uygulamalarına ek olarak bu yaklaşımın, sağlık ve finans gibi karmaşık sistemler ve dinamiklerle karakterize edilen birçok alana önemli ölçüde katkısı vardır. Her iki alanın da zaman içinde değişen sinyallerin ayrıntılı analizine ihtiyacı vardır. WT yöntemi, karmaşık zamansal kalıpları etkili bir şekilde tanımlayabilmekte, bu özellik onu zaman içinde ortaya çıkan tıbbi tanıların kodunun çözülmesinde önemli bir araç haline getirmekte ve finansal piyasaları etkileyen ince değişikliklere ışık tutar (Takaoğlu,2021). Bu nedenle, bu çalışmanın önemi, elde edilen sonuçların ötesine uzanmakta ve geniş bir yelpazedeki bilimsel ve pratik uygulamaları etkilemektedir. WT (Wavelet Transform) ile makine öğrenimi arasındaki ortak yaşamla ilişkili bilginin tahmin doğruluğunu artırmada son teknoloji bir güç olarak kabul edilmesi, multidisipliner iş birliğinin süregelen öneminin kanıtıdır. Sinyal işleme ve makine öğrenimindeki uzmanlığın birleşimi, yalnızca hidrolojik dinamiklere ilişkin anlayışımızı geliştirmekle kalmaz, aynı zamanda belirli alanların ötesine geçen yaratıcı problem çözme için bir model oluşturur.

## IV. ANALİZ-UYGULAMA

### A. Marmara Havzası Çatalca İstiranca Deresi Karamandere İstasyonu

Marmara Havzası İstiranca deresinde Karamandere mevki günlük ortalama akım hızı verileri DSİ'ye ait web sitesinden alınmıştır. İstanbul ili Çatalca ilçesindeki Karacaköy Bucağı yolu 23'üncü km'sindeki Karamandere köyü yakınında bulunur.

D02A028 Numaralı AGİ ait günlük ortalama akım hızı, MGM'ne ait verilerden günlük ortalama hava sıcaklığı, günlük toplam yağış verileri kullanılmıştır. 01/01/2005-30/09/2020 tarihleri arası 5752 adet günlük veriden, 01/01/2005 – 30/09/2017 yılları arasındaki 4656 adet günlük veri eğitim için, 01/10/2017 – 30/09/2020 yılları arasındaki 1096 adet günlük veri test amaçlı kullanılmıştır. Bölgeye ait istatistik değerleri Çizelge 5'te verilmektedir.

Çizelge 5. Karamandere AGİ veri setine ait istatistik değerleri.


Istiranca D. Karamandere D02A028	Ortalama Mean	Minimum Minimum	Maksimum Maximum	Standart Sapma Standard Deviation	Çarpıklık Distortion	Değişinti Change	Mode (En Çok Tekrar)	Ortanca Median
Günlük Ortalama Debi Daily average flow (m <sup>3</sup> /sn)	2.98	0.061	207	8.19	9.17	67.03	0.21	0.78
Günlük Toplam Yağış Daily total rainfall (mm=kg/m <sup>2</sup> )	2.74	0	184.2	8.93	8.62	79.53	0	0
Günlük Ortalama Sıcaklık Daily average temperature (°C)	12.58	-8.9	31.1	7.46	-0.21	55.81	21.5	12.8

## 1. Makine Öğrenme yöntemleriyle Uygulamalar(Karamandere)

Çizelge 6’da beş farklı makine öğrenimi algoritmasına dayalı olarak mevcut değerlerin tahmin edilmesine yönelik sonuçlar verilmiştir. Şekil 14’te grafik görünümü mevcuttur. En başarılı tahmin sonucu Linear ve Support Vektör Regresyon modellerinde görülmektedir.

Çizelge 6. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Karamandere)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	98,29	97,77	67,73	70,81	102,75	159,62
SVR	99,86	87,87	8,93	33,9	29,63	372,07
DT	99,89	53,76	8,24	96,67	28,94	726,5
RF	98,08	66,53	17,07	77,79	108,93	618,06
ETR	99,87	70,64	8,36	55,17	29,01	578,93




Şekil 14. Makine öğrenmesi algoritmaları eğitim ve test grafiği (Karamandere)

## 2. Hibrit Model Yöntemi Uygulamaları (Karamandere)

Dalgacık ayrıntı değerleri oluşturulmuş makine öğrenmesi algoritmaları ile oluşturulan hibrit uygulama sonuçlarına göre Decision Tree, Random Forest ve Extra Trees yöntemlerinde başarı performanslarının arttığı sonuçlar elde edilmiştir. Hibrit uygulama sonucu, belirgin oranda başarı artış oranı görülmektedir. Çizelge 7’de dalgacık-makine öğrenmesi hibrit modelinden çıkan uygulama sonuçları sunulmuştur. Şekil 15’te grafik görünümü mevcuttur.

Çizelge 7. Hibrit model eğitim ve test sonuçları (Karamandere)

	<i>R2_train</i>	<i>R2_test</i>	<i>d_train</i>	<i>d_test</i>	<i>rmse_train</i>	<i>rmse_test</i>
<b>LR</b>	72,52	54,04	243,76	236,49	440,4	422,4
<b>SVR</b>	95,83	83,87	72,76	92,53	171,66	250,26
<b>DT</b>	99,23	79,36	12,04	95,97	65,6	283,07
<b>RF</b>	98,86	89,16	28,11	71,28	89,91	205,12
<b>ETR</b>	99,25	90,99	10,96	68,6	64,3	187,13



Şekil 15. Hibrit model eğitim ve test sonuçları grafiği (Karamandere)

Şekil 17’de ortalama akım hızı değerlerinin ayrıntıları grafiği mevcuttur. Büyük, orta ve küçük ölçekli olayların rolünde son dönemlerinde artış gözlemlenmektedir.

Ortalama debi değerlerinin ayrıntıları Şekil 16’da sunulmaktadır. Son inceleme dönemi akım değerlerinde, büyük, orta ve küçük ölçekli etkilerin rolünde artış gözlenmiştir.

Küçük (d1) ve büyük ölçekli olayların (d3) orta ölçekli olaylardan (d2) ve büyük ve daha etkin olduğu söylenebilir. Son dönemde gözlenen ekstrem debi değerinde (yaklaşık 200m<sup>3</sup>/s), küçük, orta ve büyük ölçekli olayların tümünün etkili olduğu gözlenmektedir



Şekil 16. Dalgacık(Wavelet) 1- D Db, Level 3 grafiği (Karamandere)



Şekil 17. Dalgacık (Wavelet) Continuous 1-D(Karamandere)

Şekil 17’de Ortalama akım değişiminde etkin rol oynayan kırmızı küçük, yeşil orta ve mavi büyük ölçekli olayları göstermektedir. Frekans ve ölçek ile ilgili ayrıntılar sunulmaktadır. Son inceleme dönemi akım hızı değerlerindeki artış küçük, orta ve büyük ölçekli olayların üçünün de debi değişimi üzerinde etkili olduğunu göstermektedir.

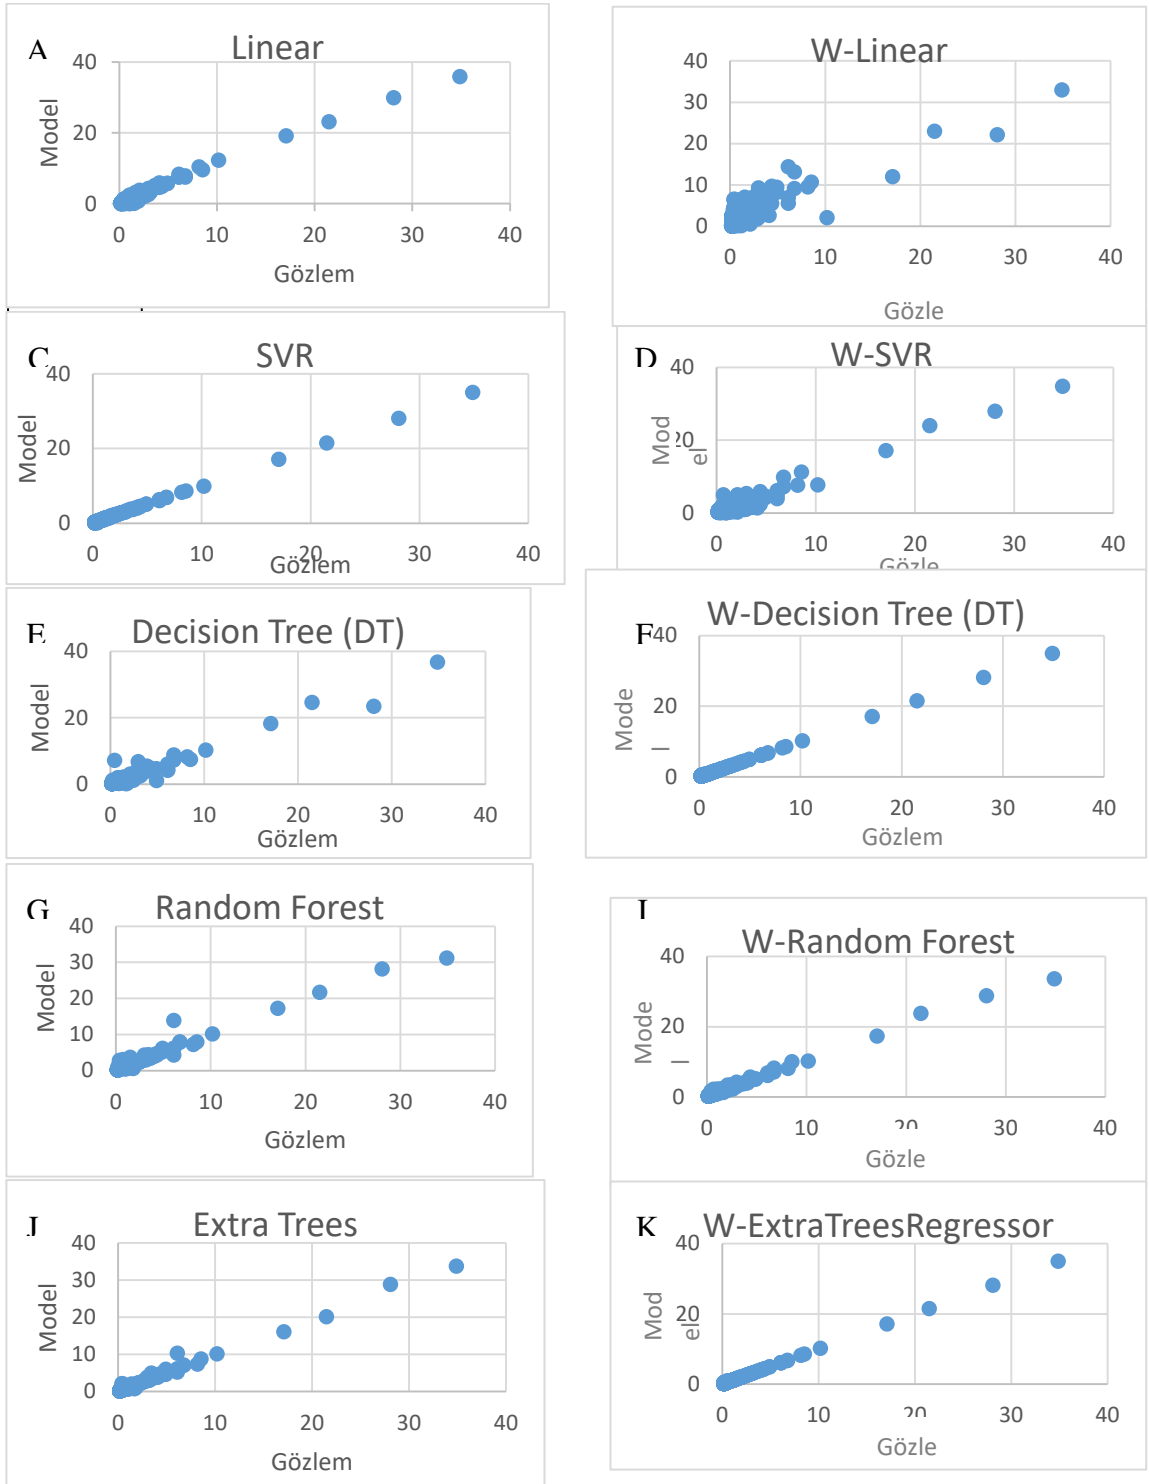


Çizelge 8. Yalın-Hibrit yöntem karşılaştırılması (Karamandere)

Yöntem	Yalın Yöntem Öğrenme (train-test) Farkı %	Hibrit Yöntem Öğrenme (train-test) Farkı %	Hibrit yöntem uygulama farkı (HibritR2-YalınR2) %
LR	0,52	18,48	-43,73
SVR	11,99	11,96	-4
DT	46,13	19,87	25,6
RF	31,55	9,7	22,63
ETR	29,23	8,26	20,35

Karamandere AGİ verileriyle yapılan uygulamada yalın yöntemde en başarılı sonuç LR 97,77 oranıyla ve 0,52 öğrenme kaybı ile, yöntemi ile sağlanmıştır. Hibrit yöntemde en başarılı sonuç ETR 90,99 oranıyla öğrenme kaybı 8,26 olarak çıkmıştır. İki yöntem arasındaki en fazla başarı artışı ise DT yönteminde %25,6 artış oranıyla olmuştur. Çizelge 8’de gösterilmiştir.

• Ortalama Debi Tahmini Dağılımı



Şekil 18.. A: Doğrusal Regresyon B: Dalgacık Dönüşümü ve Doğrusal Regresyon (Hibrit) C: Destek Vektör Regresyon(SVR) D: Dalgacık Dönüşümü ve SVR (Hibrit) E: Karar Ağacı F: Dalgacık Dönüşümü ve Karar Ağacı (Hibrit) G: Rastgele Orman H: Dalgacık Transformasyonu ve Rastgele Orman (Hibrit)I: Ekstra Ağaçlar J: Dalgacık Transformasyonu ve Ekstra Ağaçlar (Hibrit) K:

Şekil 18’de 10 farklı model test sonuçları grafiği sunulmuştur. W-Doğrusal ve W-Destek Vektor regresyonları dışında sekiz modelde gözlem ve model sonuçları arasında  $\alpha = 0,01$  güven seviyesinde anlamlı ilişkili olduğu saptanmıştır.

## B. Antalya Havzası Isparta Çaydere Eğirdir Göl girişi İstasyonu

Bu çalışma içinde incelenen alanlardan ikincisi Antalya Havzası D09A060 Çaydere Eğirdir göl giriş akım gözlem istasyonudur. Veriler DSİ kayıtlarından alınmıştır. Araştırma bölgesi, Eğirdir-Konya yolunu takiben 5 km sonra Çaydere köprüsünden 300 m uzaktaki ölçüm istasyonu olarak seçilmiştir. Eğirdir gölü girişi Aralık 1978 – Haziran 1987 ve Ekim 1997-Eylül 2020 tarihleri arası Aylık Ortalama Akım hızı değerleri bağımlı değişken, Aylık toplam yağış, Aylık Ortalama hava sıcaklığı verileri ise bağımsız değişkenler olarak göz önüne alınmıştır. Aralık 1978 -Eylül 2012 yılları arasındaki aylık veriler eğitim için (406 Adet) Ekim 2012- Eylül 2020 yılları arasındaki aylık veriler test için (96 Adet) kullanılmıştır. AGİ’ye ait istatistik değerleri Çizelge 9’da verilmektedir.

Çizelge 9. Çaydere Eğirdir Göl girişi AGİ veri setine ait istatistik değerleri.

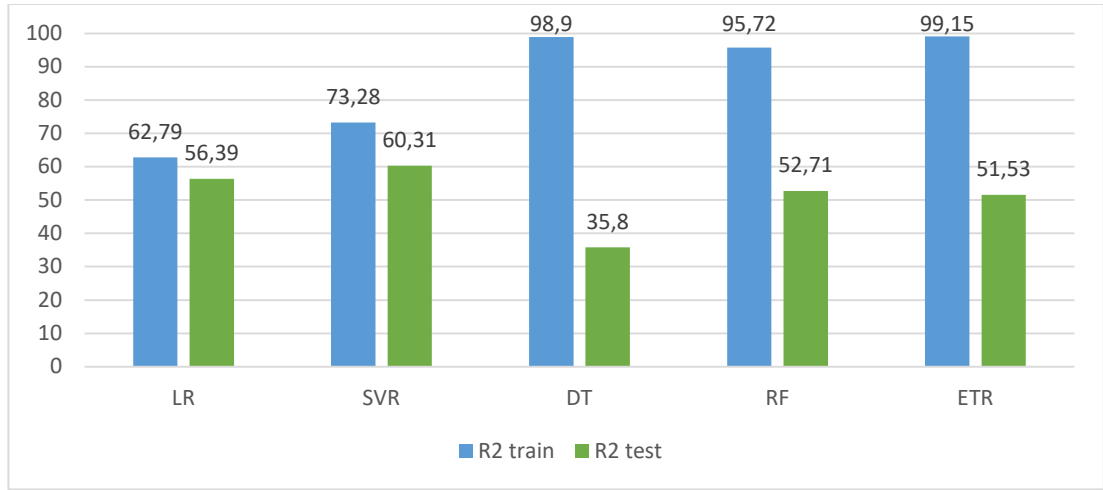
D09A060 ÇAYDERE EĞİRDİR GÖL GİRİŞ	Ortalama	Minimu m	Maksimu m	Standart Sapma	Çarpıklık	Değişim ti	Mod (En Çok Tekrar)	Medyan (Ortanca)
Aylık Ortalama Debi (m <sup>3</sup> /sn)	5,79	0,00	31,10	6,87	1,32	47,22	0,00	2,73
Aylık Toplam Yağış(mm=kg/m <sup>2</sup> )	69,86	0,00	560,70	71,64	1,90	5131,75	0,00	50,20
Aylık Ortalama Sıcaklık(°C)	12,52	-3,50	25,70	7,78	0,05	60,52	4,40	12,00

### 1. Makine Öğrenme yöntemleriyle Uygulamalar(Çaydere)

Çizelge 10 ve Şekil 19’da beş farklı makine öğrenimi göz önüne alınarak oluşturulan model uygulama sonuçları ve grafiği sunulmuştur.

Çizelge 10. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Çaydere)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	62,79	56,39	268,61	289,68	364,44	357,97
SVR	73,28	60,31	188,81	237,78	308,81	341,49
DT	98,9	35,8	15,65	298,5	58,63	434,32
RF	95,72	52,71	28,11	274,29	89,91	372,74
ETR	99,15	51,53	14,32	280,48	54,23	377,39



Şekil 19. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Çaydere)

Beş ayrı makine öğrenme yöntemine göre akım değerlerinin tahmin sonucu Rastgele Orman (RF), Destek Vektör Regresyonu(SVR), Doğrusal Regresyon (LR) ve Ekstra Ağaçlar Regresyon (ETR) modellerinde birbirine yakın sonuçlar gözlenmiştir.

## 2. Hibrit Model Yöntemi Uygulamaları (Çaydere)


Wavelet ayrıntı değerleri ile oluşturulan hibrit model uygulama sonuçlarına göre Doğrusal Regresyon (LR), Destek Vektör Regresyonu (SVR), Rastgele Orman (RF), Ekstra Ağaçlar Regresyon (ETR) ve Karar Ağacı (DT) yöntemlerinde hibrit olmayan modellere göre tahmin başarı oranının yüksek olduğu sonuçlar elde edilmiştir. Hibrit uygulanan modellerde belirgin bir başarı artışı gözlemlenmiştir.

Yöntemlerin ayrı ayrı uygulanmasında, test verilerinin gözlem verileri ile ilişkisi, 35,8 ile 60,1 arasında değişmiştir. Hibrit olarak bu yöntemlerin her birinin wavelet yöntemi ile kullanımı sonucunda, ilişki katsayısı 77,3-89,1

değerine yükselmiştir. Gözlem ve hibrit model sonuçları arasında  $\alpha=0,001$  anlam seviyesinde güvenli bir ilişki olduğu saptanmıştır.

Çizelge 11. Hibrit model eğitim ve test sonuçları (Çaydere)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	82,66	81,35	199,47	166,43	252,73	221,44
SVR	93,85	82,92	91,46	155,91	150,47	211,89
DT	98,79	77,34	45,85	142,13	78,54	244,05
RF	97,87	89,12	59,24	113,48	88,53	169,1
ETR	99,25	87,84	43,21	113,99	75,85	178,79



Şekil 20. Hibrit model eğitim ve test sonuçları grafiği (Çaydere)

Çizelge 11’de ve Şekil 20’de Wavelet ayrıntı değerleri ile oluşturulan hibrit model uygulama sonuçları ve grafiği sunulmuştur.


Çizelge 12. Yalın Hibrit yöntem karşılaştırılması (Çaydere)

Yöntem	Yalın Yöntem Öğrenme (train-test) Farkı %	Hibrit Yöntem Öğrenme (train-test) Farkı %	Hibrit yöntem uygulama farkı (HibritR2-YalınR2) %
LR	6,4	1,31	24,96
SVR	12,97	10,93	22,61
DT	63,1	21,45	41,54
RF	43,01	8,75	36,41
ETR	47,62	11,41	36,31

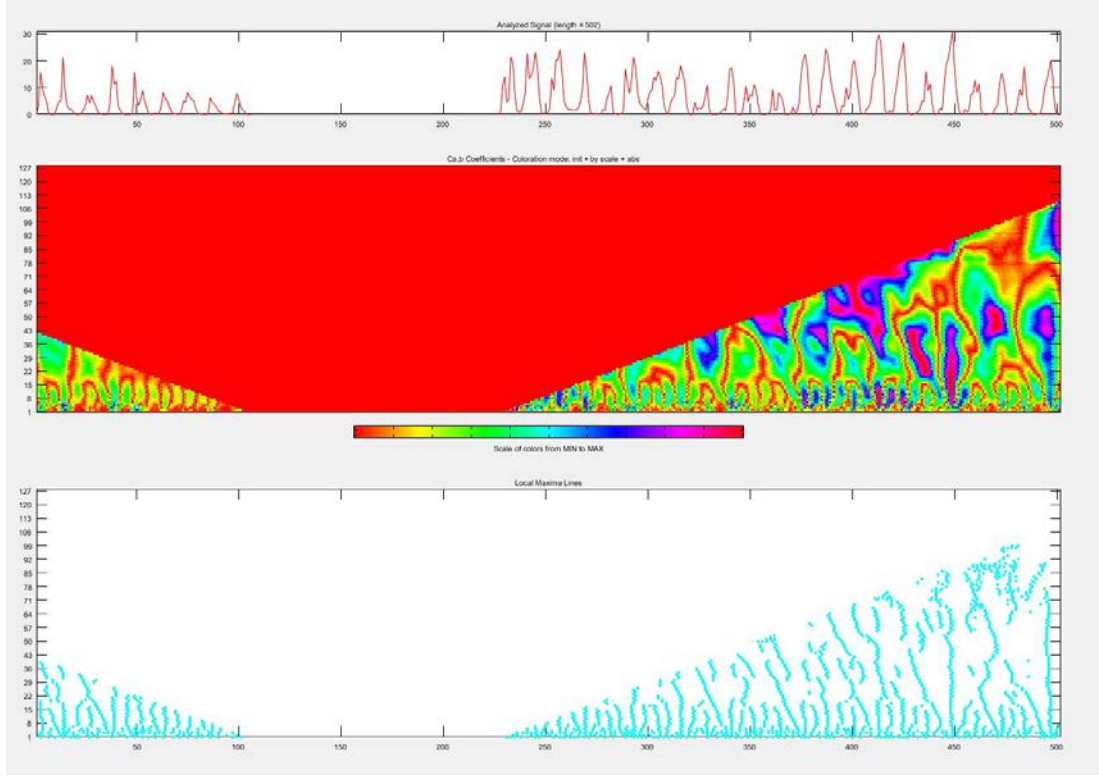
Çaydere AGİ verileriyle yapılan uygulamada yalın yöntemde en başarılı sonuç SVR 60,31 yöntemi ile elde edilmiştir. Çizelge 10’da gösterilmiştir. Hibrit

yöntemde en başarılı sonuç RF yöntemi 89,12 oranıyla en başarılı yöntemdir. Çizelge 11’de gösterilmiştir. Çizelge 12’de gösterildiği gibi öğrenme kaybı en az 6,4 oranla LR olmuştur. Hibrit yöntemde en az öğrenme kaybı 1,31 olarak LR yönteminde olmuştur. İki yöntem arasındaki en çok başarı artışı ise DT yönteminde 41,54 oranıyla olmuştur.

Şekil 21’de özellikle inceleme dönemi son bölümünde küçük, orta ve büyük ölçekli olayların akım hızı değişimi üzerindeki birlikte etkisi gözlenmektedir.



Şekil 21. Dalgacık(Wavelet) 1- D Db, Level 3 grafiği (Çaydere)



Şekil 22. Eğirdir Göl Giriş Ortalama Akım Dalgacık(Çaydere)

Şekil 22’de Ortalama akım hızı değişiminde Büyük ölçekli olaylar koyu mavi, koyu kırmızı, küçük ölçekli olaylar sarı ve orta ölçekli olaylar yeşil açık mavi renkleriyle gösterilmektedir. Frekans ve ölçek ile ilgili ayrıntıları sunulmaktadır.

Artan akım hızı değerleri bir-iki hafta veya üç aylık periyodisiteye sahiptir. Bu değişimler büyük, orta ve küçük ölçekli olayların tümü etkilidir.

### C. Sakarya Havzası -Porsuk Çayı Beşdeğirmen İstasyonu

Çizelge 13. Beşdeğirmen AGİ veri setine ait istatistik değerleri.

E12A003 Porsuk Çayı Beşdeğirmen	Ortalama	Minimum	Maksimum	Standart Sapma	Çarpıklık	Değişim	Mod (En Çok Tekrar)	Medyan (Ortanca)
Günlük Ortalama Debi $(m^3/sn)$	5,94	1,01	95,10	6,29	4,00	39,59	5,94	3,85
Günlük Toplam Yağış $(mm=kg/m^2)$	1,46	0,00	92,20	4,50	5,80	20,24	0,00	0,00
Günlük Ortalama Sıcaklık $(^{\circ}C)$	10,77	-14,10	29,80	8,25	-0,20	68,13	20,10	11,10


Bu çalışmada Sakarya Havzası Porsuk çayı alt havzası ait E12A003 numaralı Porsuk Çayı Beşdeğirmen akım gözlem istasyonu 01 Ekim 1979-30 Eylül 2011 tarihleri arası Günlük Ortalama Akım, Günlük Ortalama hava sıcaklığı ve Günlük Toplam Yağış verileri kullanılmıştır. 01 Ekim 1986 – 30 Eylül 2006 yılları arası 7305 adet günlük veri eğitim için, 01 Ekim 2006-30 Eylül 2011 yılları arasındaki 1461 adet günlük veri test için kullanılmıştır. Çizelge 13'te Beşdeğirmen istasyonuna ait istatistik değerleri paylaşılmıştır.

## 1. Makine Öğrenme yöntemleriyle Uygulamalar (Beşdeğirmen)

Beş ayrı makine öğrenme algoritması yöntemine göre akım hızı değerlerinin tahmin sonuçları aşağıda Çizelge 14'te gösterilmektedir. Şekil 23'te grafiği sunulmuştur.

Çizelge 14. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Beşdeğirmen)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	39,59	35,01	354,59	359,25	499,99	515,64
SVR	90,97	73,75	121,48	179,97	193,33	327,69
DT	98,36	70,2	46,81	184,38	88,53	349,16
RF	97,94	85,84	54,46	144,23	92,35	240,7
ETR	99,14	88,09	44,38	135,38	86,22	220,76



Şekil 23. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Beşdeğirmen)



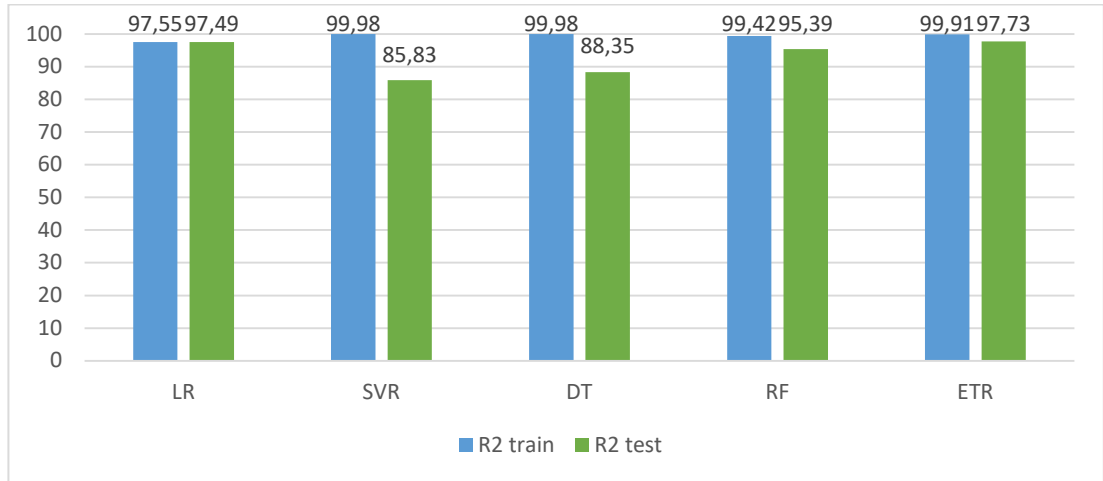
Beş ayrı makine öğrenme algoritma yöntemine göre akım hızı için en başarılı tahmin sonuçları Rastgele Orman(RF), Ekstra Ağaçlar Regresyon (ETR) ve Destek Vektör Regresyonu (SVR) modellerinde görülmektedir.

## 2. Hibrit Model Yöntemi Uygulamaları (Beşdeğirmen)

Çizelge 15 ve Şekil 24'te Wavelet ayrıntı değerleri eklenerek oluşturulmuş hibrit uygulama sonuçları sunulmaktadır.

Çizelge 15. Hibrit model eğitim ve test sonuçları (Beşdeğirmen)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	97,55	97,49	92,15	93,19	10,68	101,42
SVR	99,98	85,83	6,96	47,79	9,07	240,77
DT	99,98	88,35	6,25	68,63	8,96	218,37
RF	99,42	95,39	16,34	44,25	49,17	137,38
ETR	99,91	97,73	7,23	32,04	9,78	96,32



Şekil 24. Hibrit model eğitim ve test sonuçları grafiği (Beşdeğirmen)

Wavelet Ayrıntı değerleri eklenerek oluşturulmuş hibrit model uygulama sonuçlarına göre bütün modellerde başarı sonuçlarına olumlu yansımalar olmuştur. Hibrit uygulanan modellerde başarı artış oranları belirgin olarak gözlemlenmiştir.


Hibrit model uygulama sonucunda en yüksek performans bağımsız test verileri analizine göre ETR( $r^2=0,9773$ ) ve LR( $r^2=0,9749$ ) ile elde edilmiştir. Çizelge 15'de gösterilmektedir.

Çizelge 16. Yalın-Hibrit yöntem karşılaştırılması (Beşdeğirmen)

Yöntem	Yalın Yöntem Öğrenme (train-test) Farkı %	Hibrit Yöntem Öğrenme (train-test) Farkı %	Hibrit yöntem uygulama farkı (HibritR2-YalınR2) %
LR	4,58	0,06	62,48
SVR	17,22	14,15	12,08
DT	28,16	11,63	18,15
RF	12,1	4,03	9,55
ETR	11,05	2,18	9,64

Beşdeğirmen AGİ verileriyle yapılan uygulamada yalın yöntemde ETR 88,09 oranıyla en başarılı yöntem olmuştur. Çizelge 14'te gösterilmiştir. Çizelge 16'da gösterildiği gibi öğrenme kaybı en az 4,58 oranla LR olmuştur. Hibrit yöntemde en başarılı sonuç ETR yöntemi 97,73 oranıyla en başarılı yöntemdir. Çizelge 15'te gösterilmiştir. Hibrit yöntemde en az öğrenme kaybı 0,06 olarak LR yönteminde olmuştur. İki yöntem arasındaki en çok başarı artışı ise LR yönteminde 62,48 oranıyla olmuştur.

İnceleme periyodu orta ve son dönemlerinde bu üç etkinin rolünde azalma olmaktadır. Şekil 25'te Beşdeğirmen Akım gözlem istasyonu ortalama akım hızı değerlerinin ayrıntıları sunulmaktadır. İnceleme dönemi süresince akım değerlerinde etkili küçük, orta ve büyük ölçekli olaylar gözlenmiştir.

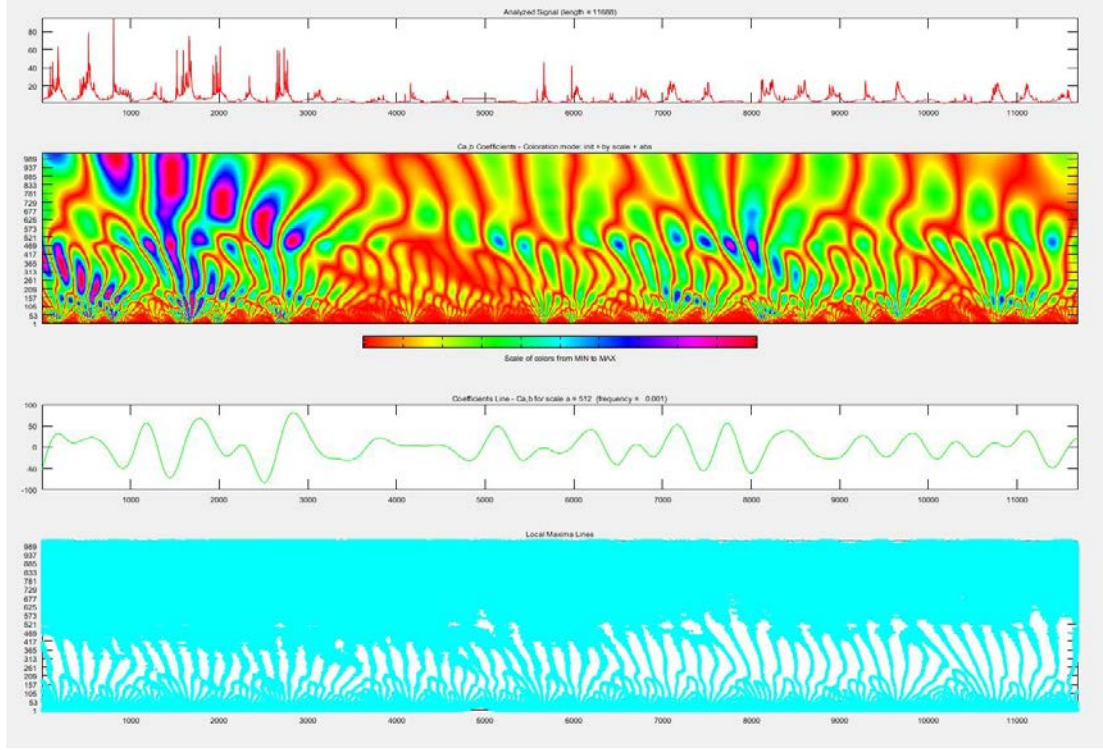


Şekil 25. Ortalama Akım Dalgacık(Wavelet) 1- D Db, Level 3 grafiği. (Beşdeğirmen)

Şekil 26 için Ortalama akım değişiminde büyük(mavi), orta(yeşil) ve küçük (kırmızı) ölçekli olayların rolü gözlenmektedir. Ölçek ve frekans ayrıntıları sunulmaktadır.

Özellikle yüksek akım hızı değerlerinin gözlenmesinde bu üç ölçeğin birlikte rolü öne çıkmaktadır.

Büyük ve orta ölçekli olayların etkinliği, inceleme dönemi başında ve ortasında gözlenmektedir.



Şekil 26. Ortalama Akım Dalgacık (Wavelet) Continuous 1-D (Beşdeğirmen)

#### D. Fırat Havzası Tunceli Munzur Suyu Melekbahçe

Yukarı Fırat havzası, Munzur suyu alt havzasına ait E21A033 Numaralı Melekbahçe akım gözlem istasyonu 01 Ekim 1986- 30 Eylül 2009 tarihleri arası Günlük Ortalama Akım Hızı, Günlük Ortalama hava sıcaklığı ve Günlük Ortalama Yağış verileri kullanılmıştır. Eğitim için 01 Ekim 1986 – 30 Eylül 2006 tarihleri arası 7305 adet günlük veri, 01 Ekim 2006-30 Eylül 2009 yılları arasındaki 1461 adet günlük veri test için kullanılmıştır. Melekbahçe AGİ'ye ait istatistiksel değerler Çizelge 17'de verilmektedir.

Çizelge 17. Melekbahçe AGİ veri setine ait istatistik değerleri.

E21A033 Munzur Suyu Melekbahçe	Ortalama	Minimu m	Maksimu m	Standart Sapma	Çarpıklık	Değişim ti	Mod (En Çok Tekrar)	Medyan (Ortalama)
Günlük Ortalama Debi (m <sup>3</sup> /sn)	89,38	17,70	739,00	82,21	2,11	6758,33	36,20	54,20
Günlük Toplam Yağış(mm=kg/m <sup>2</sup> )	2,24	0,00	74,60	6,33	4,25	40,04	0,00	0,00
Günlük Ortalama Sıcaklık(°C)	12,85	-18,90	33,50	10,77	-0,14	115,99	2,20	13,00

Beş ayrı makine öğrenme algoritma yöntemine göre akım hızı değerlerinin tahmin sonuçları aşağıda şemada gösterilmektedir.


### 1. Makine Öğrenme yöntemleriyle Uygulamalar (Melekbağçe)

Beş ayrı makine öğrenme algoritma yöntemine göre akım hızı değerlerinin test verilerine göre en başarılı tahmin sonuçları Rastgele Orman(RF), Destek Vektör Regresyonu (SVR) ve Ekstra Ağaçlar Regresyon (ETR) modellerinde görülmektedir.

Çizelge 18 ve Şekil 27’de beş ayrı makine öğrenme algoritma yöntemine göre uygulama sonuçları sunulmaktadır.

Çizelge 18. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Melekbağçe)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	48,27	47,12	4024,67	4130,56	5376,52	5897,48
SVR	71,35	68,68	2331,86	2567,78	4269,45	4627,16
DT	99,87	54,22	27,64	3351,12	284,58	5593,95
RF	96,12	70,94	907,63	2690,43	1571,32	4456,79
ETR	99,87	68,63	27,92	2719,59	284,62	4630,37




Şekil 27. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Melekbağçe)

## 2. Hibrit Model Yöntemi Uygulamalar

Wavelet ayrıntı değerleri eklenerek oluşturulmuş hibrit model uygulama sonuçlarına göre bütün modellerde başarı sonuçlarına olumlu yansımalar olmuştur. Hibrit uygulanan modellerde başarı artış oranları belirgin olarak gözlemlenmiştir. Model performansı sıra ile RF, ETR ve SVR yöntemlerinde daha fazla artış göstermiştir. Çizelge 19 ve Şekil 28’de sonuç ve grafiği mevcuttur.

Çizelge 19. Hibrit model eğitim ve test sonuçları (Melekbahçe)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	53	52,11	3982,4	4028,34	5467,96	5661,37
SVR	84,96	79,75	1742,71	2072,43	3093,6	3720,63
DT	99,87	72,58	578,35	2533,75	926,75	4329,59
RF	97,85	85,24	673,22	1871,06	1169,32	3176,62
ETR	99,1	84,85	540,54	1891,2	865,35	3217,89




Şekil 28. Hibrit model eğitim ve test sonuçları grafiği (Melekbahçe)

Çizelge 20. Yalın-Hibrit yöntem karşılaştırılması (Melekbahçe)

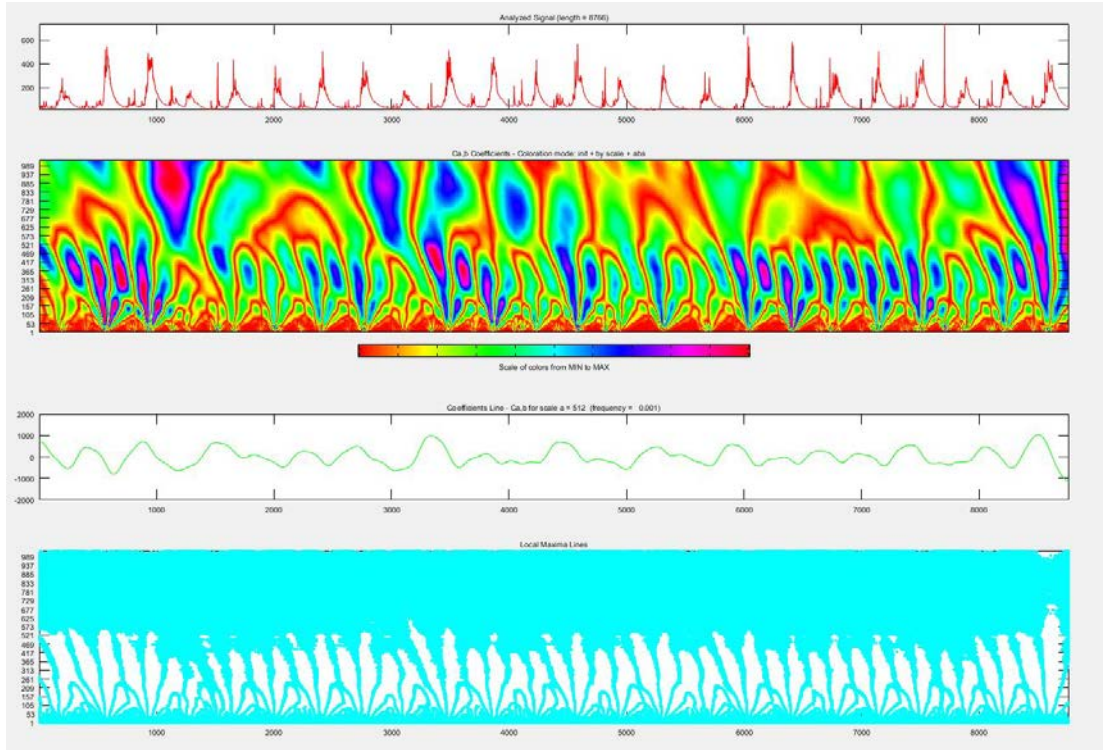
Yöntem	Yalın Yöntem Öğrenme (train-test) Farkı %	Hibrit Yöntem Öğrenme (train-test) Farkı %	Hibrit yöntem uygulama farkı (HibritR2-YalınR2) %
LR	1,15	0	5,99
SVR	2,67	5,21	11,07
DT	45,65	27,29	18,36
RF	25,18	12,61	14,3
ETR	31,24	14,25	16,22

Melekbahçe AGİ verileriyle yapılan uygulamada yalın yöntemde RF 70,94 oranıyla en başarılı yöntem olmuştur. Çizelge 18’de gösterilmiştir. Çizelge 20’de gösterildiği gibi öğrenme kaybı en az 1,15 oranıyla LR olmuştur. Hibrit yöntemde W-RF yöntemi 85,24 oranıyla en başarılı yöntemdir. Çizelge 19’da gösterilmiştir. Hibrit yöntemde en az öğrenme kaybı 5,21 olarak LR yönteminde oluşmuştur. İki yöntem arasındaki en çok başarı artışı ise DT yönteminde 18,36 oranıyla olmuştur.

Şekil 29’da Melekbahçe Akım gözlem istasyonu ortalama akım hızı değerlerinin ayrıntıları sunulmaktadır. İnceleme dönemi boyunca akım değerlerinde büyük, orta ve küçük ölçeklerle ilgili etkilerin rolü gözlenmiştir. Bu etkilerin tekrarlanma frekansı 2 ay ile 1.5 yıl arasında değişmektedir. Şekil 30’da ortalama akım hızı değişiminde büyük(mavi), orta(yeşil) ve küçük (kırmızı) ölçekli olayların rolü gösterilmektedir. Ölçek ve frekans ayrıntıları sunulmaktadır. İnceleme dönemi boyunca akım değerlerinde küçük, orta ve büyük ölçekli olayların üçünün birlikte etkili olduğu söylenebilir.



Şekil 29. Ortalama Akım Dalgacık(Wavelet) 1- D Db, Level 3 grafiği. (Melekbahçe)



Şekil 30. Ortalama Akım Dalgacık (Wavelet) Continuous 1-D Melekbahçe

### E. Sakarya Havzası -Porsuk Çayı Porsuk Çiftliği

Sakarya Havzası, D12A033 numaralı Porsuk Çayı Porsuk Çiftliği yakınındaki akım gözlem istasyonu “Günlük Ortalama Akım”, “Günlük Ortalama Yağış”, “Günlük Ortalama hava sıcaklığı” verileri kullanılmıştır. 01 Ekim 2014 -



30 Eylül 2021 tarihleri arası toplam 2556 adet günlük veri ile inceleme yapılmıştır. Eğitim verisi için 01 Ekim 2014 – 30 Eylül 2020 yılları arası 2191 adet günlük veri, test verisi için 01 Ekim 2020-30 Eylül 2021 yılları arasındaki 365 adet günlük veri kullanılmıştır. Verilere ait istatistiksel değerler Çizelge 21’de gösterilmektedir.

Çizelge 21. Porsuk Çiftliği veri kümesine ait istatistiksel değerler


D12A033 Porsuk Çayı Porsuk Çiftliği	Ortalama	Minimum	Maksimum	Standart Sapma	Çarpıklık	Değişim	Mod (En Çok Tekrar)	Medyan (Ortanca)
Günlük Ortalama Akım(m <sup>3</sup> /sn)	2,93	0,11	28,7	3,22	2,72	10,37	0,19	2,2
Günlük Toplam Yağış(mm=kg/m <sup>2</sup> )	5,66	0,10	49,40	7,45	2,46	55,53	0,20	2,80
Günlük Ortalama Sıcaklık(°C)	12,01	-12,60	28,00	8,11	-0,26	65,72	13,10	12,40

## 1. Makine Öğrenme yöntemleriyle Uygulamalar

Beş ayrı makine öğrenme yöntemine göre gözlem ve model sonuçlarında en yüksek R<sup>2</sup>\_test değeri sırasıyla ETR ve RF yöntemleriyle %67,7 ve %65,6 bulunmuştur, ( $\alpha=0.01$ ). Çizelge 22 ve Şekil 31’de değerler ve grafikler sunulmuştur.

Çizelge 22. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Porsuk Çiftliği)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	53,5	52,11	152,84	148,81	256,86	241,08
SVR	82,29	34,26	101,47	169,5	158,97	277,55
DT	98,8	53,41	34,54	152,81	65,1	233,66
RF	95,9	65,61	47,61	137,6	76,48	200,73
ETR	99,1	67,67	30,51	129,51	53,8	194,65



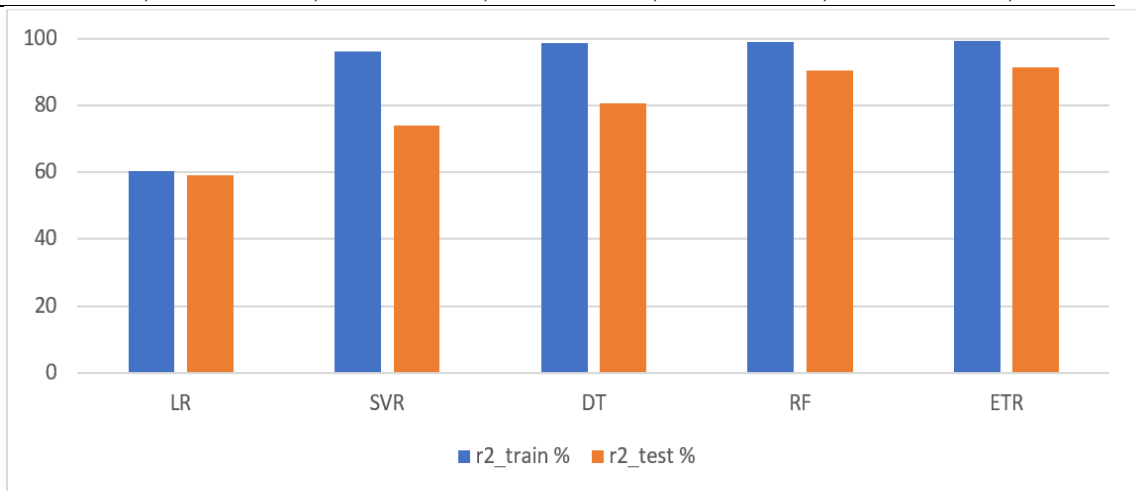
Şekil 31. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Porsuk Çiftliği)

## 2. Hibrit model yöntemleriyle Uygulamalar

Dalgacık dönüşümü uygulanarak yeni ayrıtlar elde ettiğimiz verileri tekrar makine öğrenmesi hibrit modelde elde edilen sonuçların daha başarılı sonuçlar elde edilmiştir. Porsuk çayı Porsuk Çiftliği akım gözlem istasyon sonuçları Çizelge 23 ve Şekil 32’de sunulmuştur. Dalgacık dönüşüm kullanılarak yapılan analizde en iyi performans gösteren iki yöntemin r2\_test değeri RF ve ETR için sırasıyla %90,38, %91,46 bulunmuştur, ( $\alpha=0.01$ ).

Çizelge 23. Hibrit model eğitim ve test sonuçları (Porsuk Çiftliği)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	60,31	58,98	142,73	130,23	215,32	188,49
SVR	96,05	74,03	46,29	112,28	75,09	174,44
DT	98,7	80,61	30,41	92,56	41,75	159,49
RF	98,79	90,38	25,25	64,5	41,49	106,17
ETR	99,3	91,46	23,45	58,57	13,58	110,36



Şekil 32. Hibrit model eğitim ve test sonuçları grafiği (Porsuk Çiftliği)


Çizelge 24. Yalın-Hibrit yöntem karşılaştırılması (Porsuk Çiftliği)

Yöntem	Yalın Yöntem Öğrenme (train-test) Farkı	Hibrit Yöntem Öğrenme (train-test) Farkı	Hibrit yöntem uygulama farkı (HibritR2-YalınR2)
LR	1,39	1,33	6,87
SVR	48,03	22,02	39,77
DT	45,39	18,09	27,2
RF	30,29	8,41	24,77
ETR	31,43	7,84	23,79

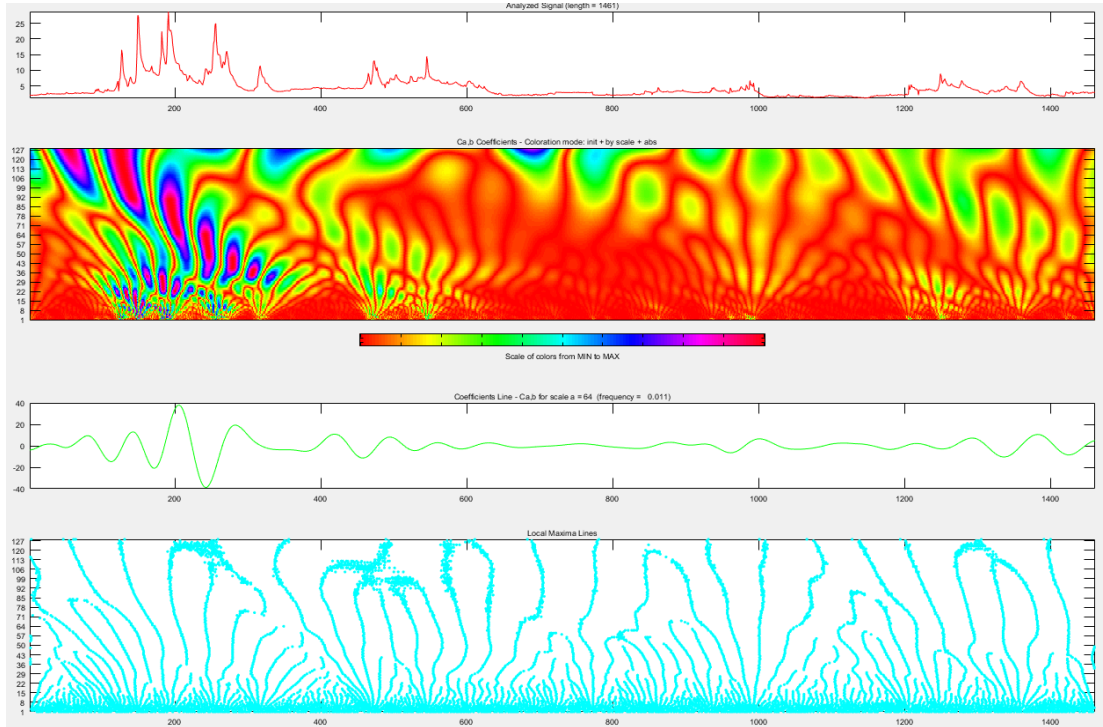
Porsuk Çiftliği AGİ verileriyle yapılan uygulamada yalın yöntemde ETR 67,67 oranıyla en başarılı yöntem olmuştur. Çizelge 22’de gösterilmiştir. Çizelge 24’te gösterildiği gibi öğrenme kaybı en az 1,39 oranıyla LR olmuştur. Hibrit yöntemde W-ETR yöntemi 91,46 oranıyla en başarılı yöntemdir. Çizelge 23’te gösterilmiştir. Hibrit yöntemde en az öğrenme kaybı 1,33 olarak LR yönteminde oluşmuştur. İki yöntem arasındaki en çok başarı artışı ise SVR yönteminde 39,77 oranıyla olmuştur.

Şekil 33 ve Şekil 34’de Porsuk Çiftliği istasyonu ortalama akım hızı tahmin sonuçlarına göre, 1D-Wavelet ve 1D-Continuous Wavelet analizleri sunulmaktadır. Dalgacık analizinde üç ölçeğin katkısı birbirine yakın yorumlanabilir. d1 (küçük ölçekli), d2 (orta ölçekli) ve d3 (büyük ölçekli) ayrıntıları ile ilişkili olmaktadır. Wavelet hibrit yöntemi ETR ve RF yöntemlerine göre sonuçlarda %26 iyileştirme sağlamıştır. Yüksek akım hızı değerleri bir ay ile 4 ay arasında değişen, tekrarlanma periyoduna sahiptir. İnceleme döneminin başında her üç ölçekten olaylar etkin olmakta orta ve son bölümlerinde 10-15 m<sup>3</sup>/s akım hızı değerleri küçük ve orta ölçekli olaylardan etkilenmektedir.

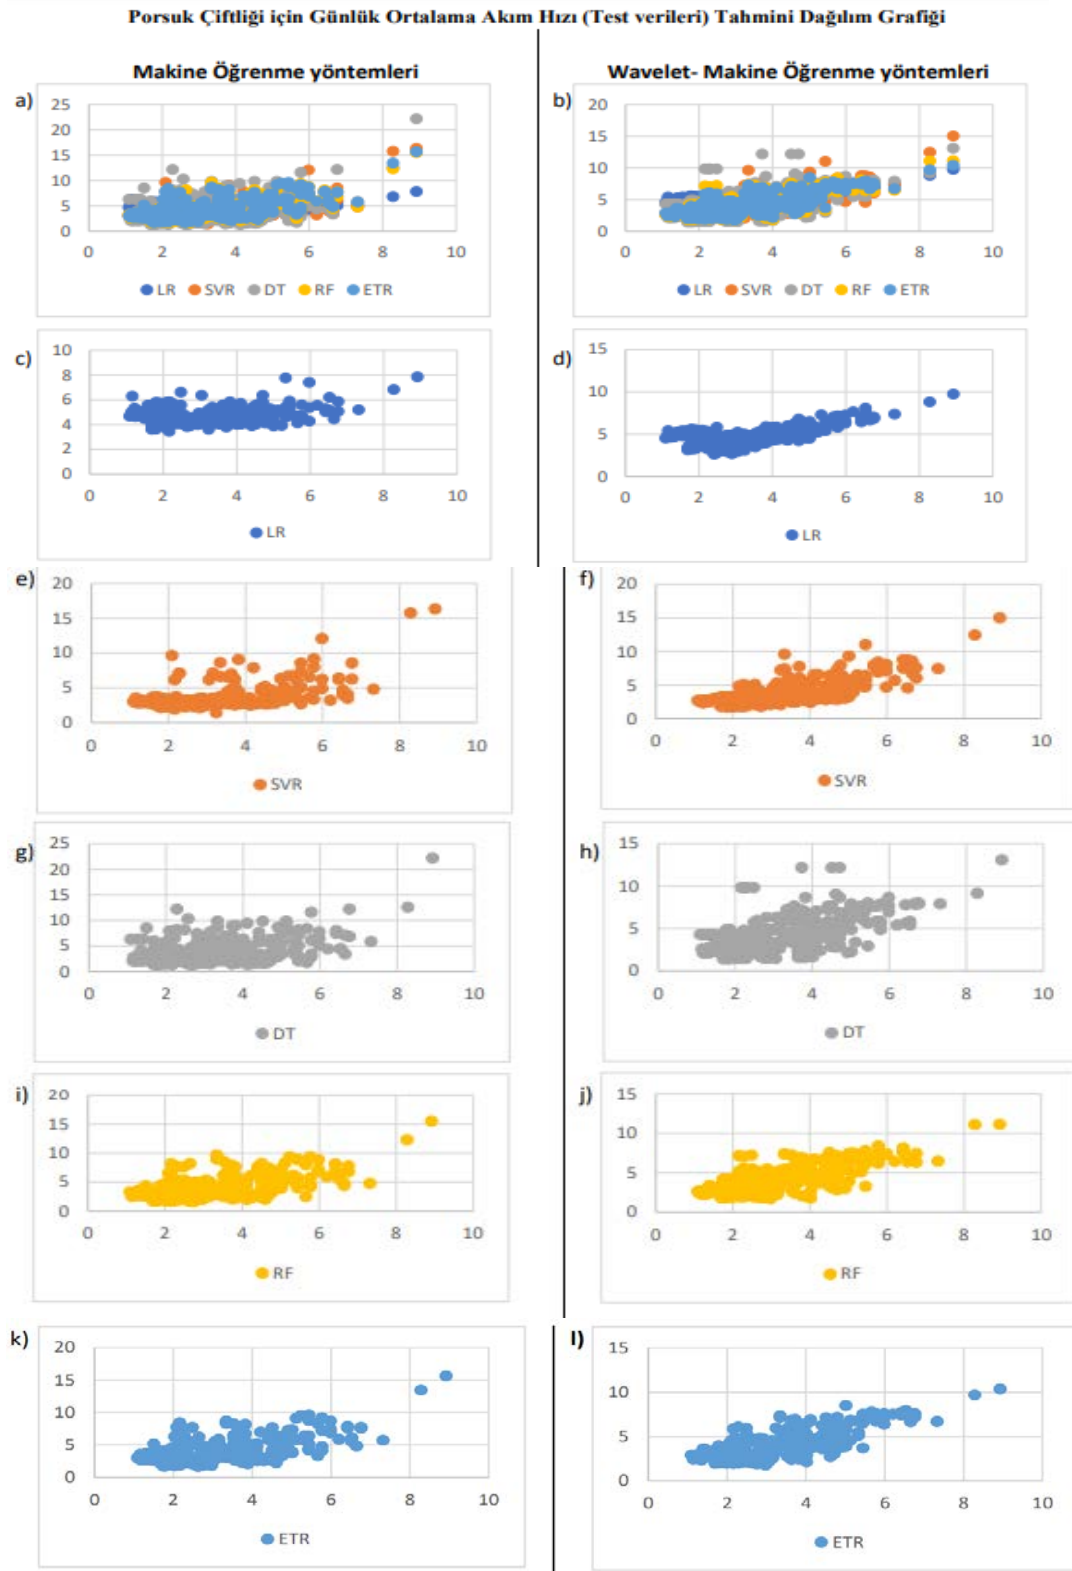
Büyük ölçekli olayların inceleme dönemi ilk yarısında baskın oluşu (mavi, mor renkler) ve bu etkinin periyodundaki azalma trendi Şekil 34’te görülmektedir.



Şekil 33. Günlük Ortalama Akış Dalgacık 1-D Db, Level 3 (Porsuk Çiftliği)



Şekil 34. Günlük Ortalama Akış, Wavelet Continuous 1-D (Porsuk Çiftliği)



Şekil 35. Porsuk Çiftliği için Ortalama Akım Hızı Tahmini Dağılım Grafiği a) Makine Öğrenmesi modelleri b) Dalgacık Dönüşümü ve Makine öğrenmesi modelleri (Hibrit) c) Doğrusal Regresyon d) Dalgacık Dönüşümü ve Doğrusal Regresyon (Hibrit) e) Destek Vektör Regresyon(SVR) f) Dalgacık Dönüşümü ve SVR (Hibrit) g) Karar Ağacı h) Dalgacık Dönüşümü ve Karar Ağacı (Hibrit) i) Rastgele Orman j) Dalgacık Dönüşümü ve Rastgele Orman (Hibrit) k) Ekstra Ağaçlar l) Dalgacık Dönüşümü ve Ekstra Ağaçlar (Hibrit)

Şekil 35, Porsuk Çiftliği için ortalama debi değerlerinin farklı yöntemlerle bağımsız test verilerine dayalı olarak tahmin sonuçlarını göstermektedir.

## F. Yukarı Fırat Havzası - Tagar Çayı Küçükkumluk

Yukarı Fırat havzası, D21A228 Numaralı Tagar Çayı Küçükkumluk yakınındaki akım gözlem istasyonu “Günlük Ortalama Akım”, “Günlük Ortalama Yağış”, “Günlük Ortalama hava sıcaklığı” verileri kullanılmıştır. 01 Şubat 2014-30 Eylül 2021 tarihleri arası toplam 2799 adet günlük veri ile inceleme yapılmıştır. Eğitim verisi için 01 Şubat 2014-30 Eylül 2020 yılları arası 2432 adet günlük veri, test verisi için 01 Ekim 2020-30 Eylül 2021 yılları arasındaki 365 adet günlük veri kullanılmıştır. Verilere ait istatistik değerleri Çizelge 25’de gösterilmektedir.

Çizelge 25. Küçükkumluk veri kümesine ait istatistiksel değerler


D21A228 Tagar Çayı Küçükkumluk	Ortalama	Minimum	Maksimum	Standart Sapma	Çarpıklık	Değişim ti	Mod (En Çok Tekrar)	Medyan (Ortanca)
Günlük Ortalama Akım(m <sup>3</sup> /sn)	7,67	0,98	72,80	9,85	2,51	97,04	1,45	3,20
Günlük Toplam Yağış(mm=kg/m <sup>2</sup> )	2,17	0,00	74,50	6,15	4,88	37,87	0,00	0,00
Günlük Ortalama Sıcaklık(°C)	14,28	-14,50	32,00	9,91	-0,08	98,16	2,50	14,20

### 1. Makine Öğrenme Yöntemleriyle Uygulamalar (Küçükkumluk)

Beş ayrı makine öğrenmesi algoritması yöntemine göre Küçükkumluk istasyonu için makine öğrenmesiyle gözlem ve model sonuçlarında en yüksek R<sup>2</sup>\_test başarı oranı RF için %69.9, ETR için %70.8 bulunmuştur, ( $\alpha=0.01$ ). Çizelge 26 ve Şekil 36’da değerler ve grafikler sunulmuştur.

Çizelge 26. Makine öğrenmesi algoritmaları eğitim ve test sonuçları (Küçükkumluk)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	57,33	40,17	429,07	536,15	662,66	971,16
SVR	79,03	58,31	244,26	409,16	457,98	706,47
DT	94,92	55,44	128,61	427,75	205,42	730,38
RF	96,28	69,91	107,24	356,11	192,91	600,26
ETR	97,84	70,8	92,45	352,12	178,43	591,27



Şekil 36. Makine öğrenmesi algoritmaları eğitim ve test sonuçları grafiği (Küçükkumluk)


Birinci ve ikinci derecede başarılı yöntemler ETR ve RF olarak belirlenmiştir.

## 2. Hibrit Model Yöntemleriyle Uygulamalar (Küçükkumluk)

Küçükkumluk için Dalgacık-Makine Öğrenmesi hibrit model için Çizelge 27 ve Şekil 37'de analiz sonuçları verilmiştir. Yukarı Fırat Havzası - Tagar Çayı Küçükkumluk akım gözlem istasyon R2\_test sonuçlarına göre en başarılı iki yöntem RF için %84.41 ve ETR için %86.39 başarı oranları bulunmuştur. Hibrit yöntem uygulandıktan sonra başarı oranı en fazla artan yöntem %20.82 oranında artışla SVR olarak gözlemlenmiştir.

Çizelge 27. Hibrit model eğitim ve test sonuçları karşılaştırılması (Küçükkumluk)

	R2 train	R2 test	d_train	d_test	rmse_train	rmse_test
LR	61,65	51,49	372,39	426,56	596,66	693,91
SVR	94,78	79,13	98,09	277,65	228,57	499,9
DT	95,24	73,92	91,09	292,82	219,63	558,82
RF	98,02	84,41	73,38	250,69	140,57	431,98
ETR	98,85	86,39	68,57	227,81	132,24	403,69




Şekil 37. Hibrit model eğitim ve test sonuçları (Küçükkumluk)

Çizelge 28. Yalın Hibrit yöntem karşılaştırılması (Küçükkumluk)

Yöntem	Yalın Yöntem Öğrenme (train-test) Farkı	Hibrit Yöntem Öğrenme (train-test) Farkı	Hibrit yöntem uygulama farkı (HibritR2-YalınR2)
LR	17,16	10,16	11,32
SVR	20,72	15,65	20,82
DT	39,48	21,32	18,48
RF	26,37	13,61	14,5
ETR	27,04	12,46	15,59

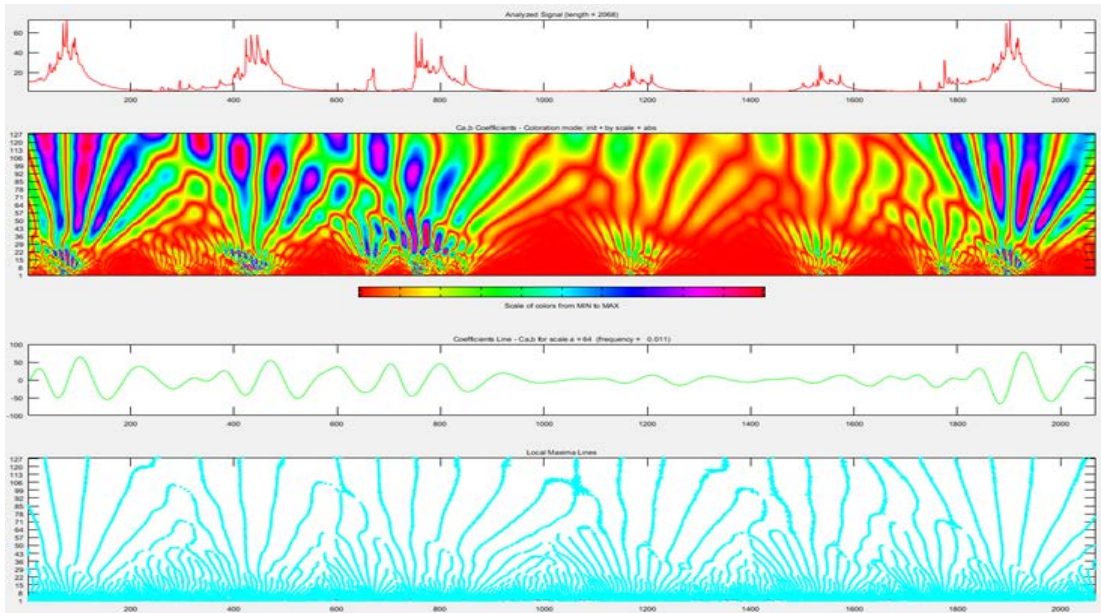
Küçükkumluk AGİ verileriyle yapılan uygulamada yalın yöntemde ETR 70,8 oranıyla en başarılı yöntem olmuştur. Çizelge 26'da gösterilmiştir. Çizelge 28'de gösterildiği gibi öğrenme kaybı en az 17,16 oranıyla LR olmuştur. Hibrit yöntemde W-ETR yöntemi 86,39 oranıyla en başarılı yöntemdir. Çizelge 27'de gösterilmiştir. Hibrit yöntemde en az öğrenme kaybı 10,16 olarak LR yönteminde oluşmuştur. İki yöntem arasındaki en çok başarı artışı ise SVR yönteminde 20,82 artış oranıyla olmuştur.





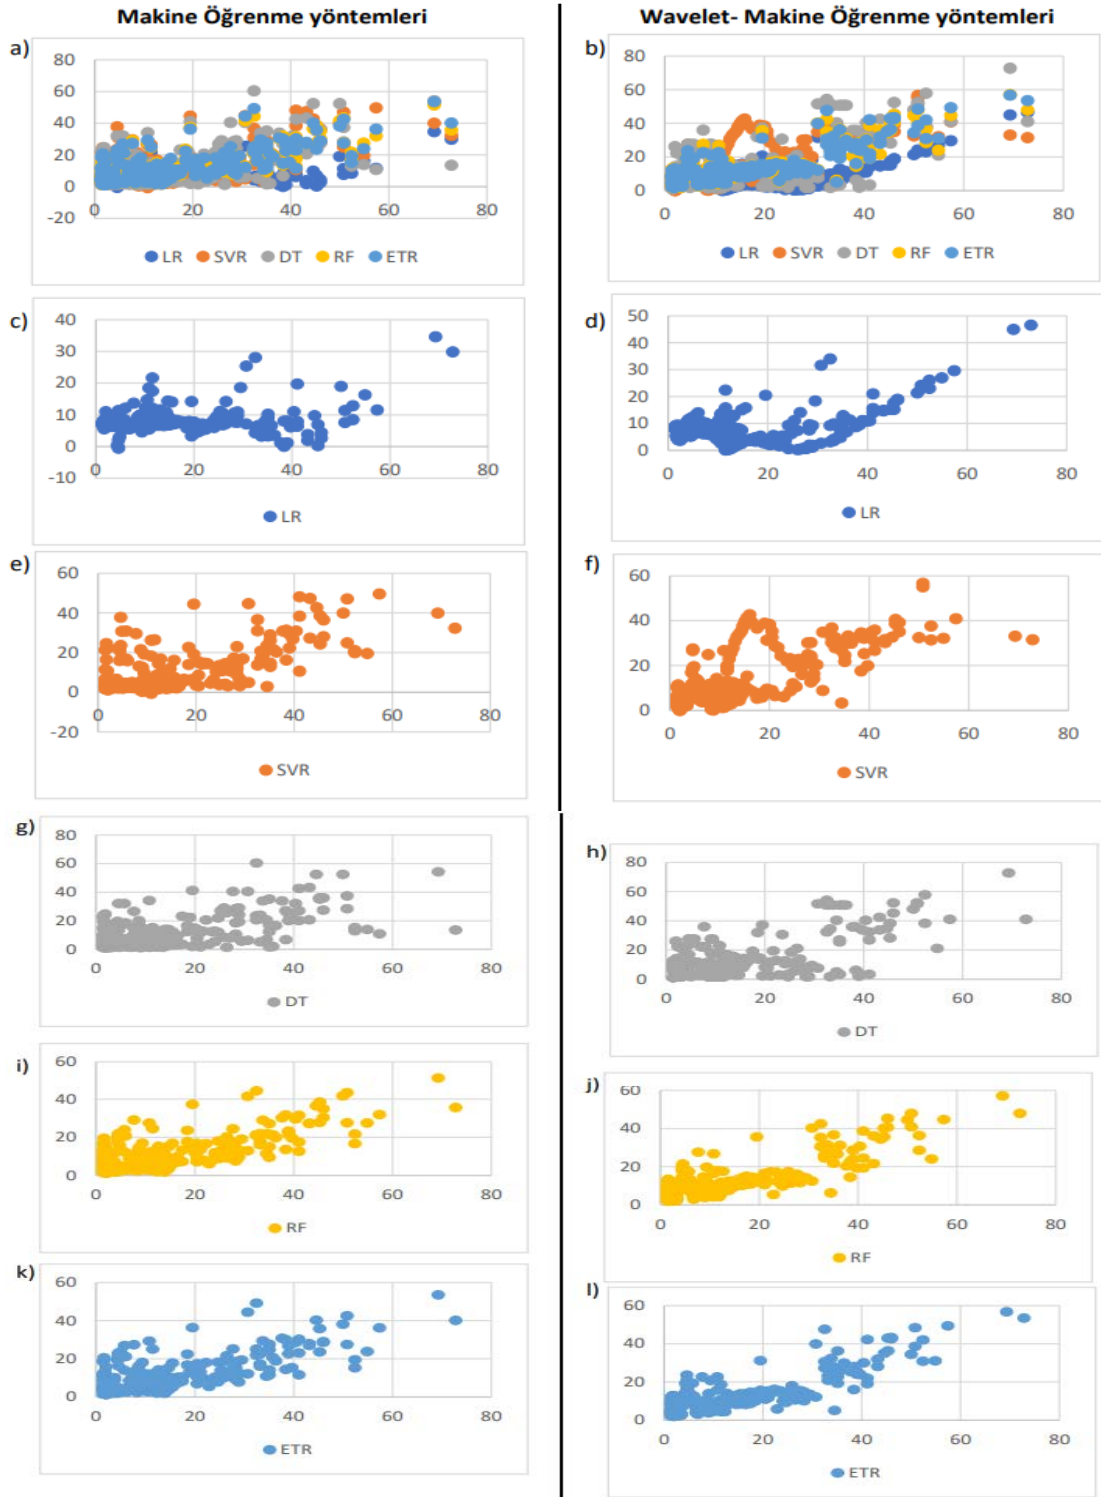
Şekil 38. Günlük Ortalama Akım Hızı Wavelet Continuous 1-D,( Küçükkumluk)

Şekil 38 ve 39’da Küçükkumluk için akım değerlerinin 1D Wavelet ve 1D Continuous Wavelet analizleri sunulmaktadır. Yüksek akım değerleri üzerinde d1-d3 ayrıntı bileşenleri ortak etki göstermekle beraber, büyük ölçekli olayların rolünün (d3 genlikleri) daha fazla olduğu vurgulanabilir. Wavelet hibrit model ile ETR ve RF modellerinde %17-%18 arasında değişken oranda iyileştirme gözlenmiştir. Şekil 39’da göre büyük ölçekli olayların (lacivert, pembe renkli ölçekler) tekrarlanma frekansının 1gün ile 4 ay arasında değiştiği söylenebilir, (ilk üç yüksek akım döngüsü). Diğer dönemlerde küçük ölçekli olayların (sarı ve kırmızı) etken olduğu söylenebilir.



Şekil 39. Günlük Ortalama Akım Hızı Dalgacık 1-D Db, Level 3 (Küçükkumluk)

Küçükkumluk için Ortalama Akım Tahmini Dağılım Grafiği



Şekil 40. Küçükkumluk için Ortalama Akım Hızı Tahmini Dağılım Grafiği **a)** Makine Öğrenmesi modelleri **b)** Dalgacık Dönüşümü ve Makine öğrenmesi modelleri (Hibrit) **c)** Doğrusal Regresyon **d)** Dalgacık Dönüşümü ve Doğrusal Regresyon (Hibrit) **e)** Destek Vektör Regresyon(SVR) **f)** Dalgacık Dönüşümü ve SVR (Hibrit) **g)** Karar Ağacı **h)** Dalgacık Dönüşümü ve Karar Ağacı (Hibrit) **i)** Rastgele Orman **j)** Dalgacık Dönüşümü ve Rastgele Orman (Hibrit) **k)** Ekstra Ağaçlar **l)** Dalgacık Dönüşümü ve Ekstra Ağaçlar (Hibrit)

Şekil 40, Küçükkumluk için debi değerlerinin farklı yöntemlere göre tahmin başarılarını göstermektedir.

## V.SONUÇLAR VE ÖNERİLER

### A. Yorumlar ve Öneriler

Bu çalışmada akarsuların günlük akım hızı değerleri ve meteorolojik verilerden toplam yağış ve ortalama sıcaklık verileri dikkate alınarak, akarsu akım hızı (debi) tahmini için ileri veri işlem yöntemlerinden faydalanılmıştır. Tahmin başarısına katkı sağlayacak, farklı çalışmalarda sıklıkla kullanılan makine öğrenmesi algoritmaları karşılaştırılmıştır. Makine öğrenmesi algoritmaları dalgacık dönüşüm ile kullanarak hibrit bir yöntem oluşturulmuştur. Oluşturulan bu yöntemin hidrolojik verilere uygulanabilirliği denenmiştir. Hibrit yöntem ile daha başarılı sonuçlar şekilde elde edilmiştir. Araştırmada göz önüne alınan Akım Gözlem İstasyonları (AGİ) için en başarılı sonuç veren yöntemler ve bulgular Çizelge 29’da gösterilmiştir.

Çizelge 29. Debi tahmininde farklı havzalardaki AGİ’ler için en başarılı yöntemler

Yöntem	Havza / İstasyon	Yöntem Girdileri	En iyi Yöntem	RMSE (mm <sup>2</sup> )	R <sup>2</sup> (%)
LR-SVR-	Marmara / Karamandere	$A_{ort}, Y_{top}, S_{ort}$	LR	159,62	97,77
DT-RF-	Antalya/Çaydere	$A_{ort}, Y_{top}, S_{ort}$	SVR	341,49	60,31
ETR	Sakarya / Beşdeğirmen	$A_{ort}, Y_{top}, S_{ort}$	ETR	220,7	88,09
	Sakarya / Porsuk Çiftliği	$A_{ort}, Y_{top}, S_{ort}$	ETR	194,65	67,67
	Yukarı Fırat / Melekbahçe	$A_{ort}, Y_{top}, S_{ort}$	RF	4456,7	70,9
	Yukarı Fırat / Küçükkuşluk	$A_{ort}, Y_{top}, S_{ort}$	ETR	591,27	70,8
W-LR-SVR-DT-	Marmara / Karamandere	Wavelet- $A_{ort}, Y_{top}, S_{ort}$	WT-ETR	187,13	90,99
RF-ETR	Antalya/Çaydere	Wavelet- $A_{ort}, Y_{top}, S_{ort}$	WT-RF	169,1	89,12
	Sakarya / Beşdeğirmen	Wavelet- $A_{ort}, Y_{top}, S_{ort}$	WT-ETR	96,3	97,7
	Sakarya / Porsuk Çiftliği	Wavelet- $A_{ort}, Y_{top}, S_{ort}$	WT-ETR	110,36	91,46
	Yukarı Fırat / Melekbahçe	Wavelet- $A_{ort}, Y_{top}, S_{ort}$	WT-RF	3176,6	85,2
	Yukarı Fırat / Küçükkuşluk	Wavelet- $A_{ort}, Y_{top}, S_{ort}$	WT-ETR	132,24	86,39

Bu tez çalışması sonucunda elde edilen bulgular, su kaynakları yönetimi ve hidrolojik arařtırmalarda yardımcı olabilecek niteliktedir. Çalışma, makine öğrenimi modellerinin debi tahmininin karmaşıklığını anlamak için yeterli olabileceğinin altını çizmektedir. ETR ve RF'nin, bu bağlamda üstün tahmin yetenekleri olduğu anlaşılmıştır. Bu bulgulara göre, makine öğreniminin gerçek dünyadaki problemlerin çözümünde güçlü bir araç olarak ortaya çıkmasıyla birlikte su kaynakları yönetiminde de yararlı olabileceği anlaşılmıştır. Modellerin başarısının, girdi verilerin güvenilirliğine ve seçilen özelliklerin birbirine etkisine bağlı olduğu açıktır. Bu varsayımların tahminlerin performansı üzerindeki potansiyel etkisi, dikkate alınması gereken bir özelliktir. Gelecek çalışmalarda, tahminin performansı iyileştirmek için yeni metotlar ve farklı hibrit yaklaşımlar denenebilir. Daha fazla araştırma ve özellik seçimi ile dinamikler saptanabilir ve potansiyel olarak daha fazla alana özgü değişkenler göz önüne alınarak, model performansını artırılabilir. Ayrıca, model parametrelerinin daha kapsamlı bir şekilde araştırılması, daha yüksek güvenilirlikte tahmin doğruluğu elde etmek açısından yararlı olacaktır. Çizelge 30'daki çalışmaları analiz ettikten sonra, makine öğrenimi teknikleri ile hidrolojik yapı arasındaki karmaşıklığı anlamaya yönelik çalışma yapılmıştır. Makine öğrenimi metodolojileri, dalgacık dönüşümün desteği ile bütünlük sağlayarak hidrolojik tahminler için yeni olanaklar sunmaktadır. Bu yaklaşımlarla su kaynakları yönetiminde daha güvenilir sonuçlara ulaşılabilmektedir.

Bu çalışma, su kaynaklarının yönetimi ve sürdürülebilir kullanımı açısından hayati bir öneme sahiptir. Su, yaşamın temel taşıdır ve tüm canlı organizmaların vazgeçilmez bir ihtiyacıdır. Ancak son yıllarda, nüfus artışı, hızlı sanayileşme, iklim değişikliği ve doğal kaynakların aşırı kullanımı, dünya genelinde su kaynaklarına yönelik baskıyı önemli ölçüde artırmıştır. Bu faktörler, su kaynaklarının sınırlı olduğu gerçeğini daha da önemli hale getirirken, gelecek nesiller için bu kaynakların etkin bir şekilde yönetilmesi ve korunması gerekmektedir.

Son yıllarda dünya genelinde nüfus artışı, sanayileşme ve iklim değişikliği gibi faktörler su yönetimini zorlaştıran nedenlerin başında gelmektedir. Su krizi, temiz içme suyunun bulunmaması, sulama suyu kaynaklarının kıtlığı ve çevresel bozulma gibi ciddi sorunlara yol açmaktadır. Bu krizler tarım, sanayi ve

ekosistemlerin yanı sıra insan sađlıđına da zarar vermektedir. D nyadaki su kaynaklarının durumu kriz seviyesine ulařmaktadır. D nyadaki suyun %97'si okyanuslarda olup, tatlı su kaynaklarının oranı ise sadece %3 civarındadır. Tatlı su kaynaklarının bir kısmı buzullar ve yer altı suları řeklindeyir. Bir diđer sorun ise d nyada su kaynaklarının dengesiz dađılımıdır. Bazı b lgelerde su bolluđu yařanırken bazı b lgelerde ise kuraklık yařanmaktadır. Bu nedenle su kaynaklarının s rd r lebilir y netimi ve dađıtımını b y k  nem tařımaktadır.

T rkiye de su kaynaklarının y netimi diđer  lkelerde olduđu gibi  ok  nemlidir. T rkiye, su kaynaklarının etkin y netmesi gereken bir b lgedir. T rkiye'nin yıllık ortalama yađıř miktarı 574 mm ( $\text{kg/m}^2$ ) olup. Bu yađıř miktarının verimli kullanılması gerekmektedir.  lkemin yıllık su varlıđı 112 milyar metrek p olmasına rađmen bunun ancak 95 milyar metrek p  etkin olarak kullanılabiliyor (Akbulut ve Aslan, 2021). T rkiye'de 1991-2020 d nemi yıllık ortalama yađıř miktarı 573,4 mm iken, son d nemde 550,9mm yađıř kaydedilmiř, %6 azalma olduđu saptanmıřtır. (mgm.gov.tr, 2023)

Su kaynakları T rkiye'nin ekonomik kalkınması ve insanların yařam kalitesi aısından hayati  neme sahiptir. Bu alıřma, su kaynaklarının yerel ve ulusal d zeyde daha verimli ve s rd r lebilir bir řekilde y netilmesine yardımcı olabilecek yeraltı suyu seviyelerinin ve su kaynakları y netiminin tahmin edilmesine y nelik benzer alıřmaların  nemini vurgulamaktadır. Arařtırmacılar suyun dinamik yapısını inceleyerek su potansiyeline iliřkin ileriye d n k tahminler yapabilir ve kentsel su y netimi iin  nemli  nerilerde bulunabilir. Ayrıca bundan sonraki alıřmalarda, farklı hidrolojik ve meteorolojik verilerin analiz edilmesiyle daha anlamlı sonular elde edilebilir.

Çizelge 30. Literatürdeki çalışmaların kapsamlı özetleri

Kaynak	Başlık	Açıklama
Demir, 2022 Bozkurt, 2019	Sanayileşme ve Nüfus Artışının Hidrolojik Dengede Etkisi	Bu çalışma, sanayileşmenin ve nüfus artışının hidrolojik denge üzerindeki etkilerini araştırıyor.
Ewaid, 2019 Ünlü, 2013 Muratoğlu, 2019 Bulut, 2022	Su Kaynakları ve Su Krizi	Küresel ölçekte su krizinin, artan nüfus ve iklim değişikliği nedeniyle bir sorun haline geldiğini belirtiyor.
Muratoğlu, 2019 Bulut, 2022 Yılmaz, 2015	Dünya ve Türkiye'deki Su Kaynakları İstatistikleri	Dünya su kaynaklarının istatistiklerini sunuyor; denizler, buzullar, yeraltı suları ve yerüstü sularının miktarlarını içeriyor.
Bilgiç, 2008 Gleick, 2019	Temiz Su Erişimi ve Kaliteli Su Eksikliği	Dünya genelinde temiz su erişiminin sınırlı olduğu ve birçok insanın kaliteli su eksikliği yaşadığına dikkat çekiyor.
Altan, 2020 URL-11 Sarış, 2021 Altan, 2020	Türkiye'nin Yağış ve Su Kaynakları Kişi Başına Düşen Yıllık Su Miktarı	Türkiye'nin yıllık yağış miktarını ve su kaynaklarını detaylı bir şekilde sunuyor. Türkiye'de kişi başına düşen yıllık su miktarının azaldığını gösteriyor ve ülkenin su stresi yaşadığını vurguluyor.
Ehteram, 2018	Su Yönetimi ve Planlaması İçin Önem	Su kaynaklarının etkili ve sürdürülebilir bir şekilde yönetilmesi gerektiğini vurguluyor.
Ehteram, 2019 Başaran, 2020	Yeraltı Su Seviyelerinin Tahmin Edilmesi	Araştırmacıların yeraltı su seviyelerini tahmin etmek için matematiksel modelleri kullandığını açıklıyor.
Navarro, 2016	Zaman Serileri ve Tahminler	Zaman serilerinin gelecekteki su potansiyeli tahminleri için önemli olduğunu belirtiyor.
González, 2022	Su Kaynaklarının Bölgesel Farklılıkları	Türkiye'deki su havzalarının farklı dinamiklere ve sorunlara sahip olduğunu ve her havzanın ayrı değerlendirilmesi gerektiğini vurguluyor.
Tosunoğlu, 2017 Bakış, 2015 Gyau, 1994 Baykal, 2017 İsmail, 2017 Nadiri, 2019 Karami, 2019 Bahadırılı, 2021	Regresyon Modelleri ve Su Verileri	Regresyon modellerinin su kaynakları ve hidrolojik verilerin tahmininde kullanıldığını ve iyi sonuçlar verdiğini belirtiyor.
Karami, 2019	Yeraltı Su Seviyelerini Tahmin Etme Algoritmaları	Yeraltı su seviyelerini tahmin etmek için kullanılan SVR, DT, ve RF algoritmalarının yüksek başarı oranlarına sahip olduğunu açıklıyor.
Karami, 2019	Makine Öğrenme ve Su Tahminleri	Makine öğrenme yöntemlerinin su tahminlerinin performansını artırmak için kullanılabileceğini belirtiyor.
Bahadırılı, 2021	Dalgacık Dönüşümü ve Su Kaynakları Analizi	Dalgacık dönüşümünün zaman serilerini analiz etmek için etkili bir teknik olduğunu vurguluyor.
Biau, 2016 Baudron, 2013 Tyralis, 2019	Türkiye'deki Su Akışı Tahmini	Bu çalışma, Türkiye'deki farklı bölgelerdeki su akım hızını tahmin etmek için LR, SVR, DT, RF ve ETR algoritmalarını kullanıyor.
Bravo, 2020 İşler, 2021	Hibrit Model ve Su Tahmin Performansı İleriye Dönük Tahminler ve Su Kullanımı	Hibrit bir modelin kullanılarak su tahmin performansının iyileştirildiğini açıklıyor. Üstel düzleştirme yöntemi kullanılarak suyun gelecekteki kullanımını tahmin etmek için 2030 yılına kadar bir simülasyon sunuyor.

Bu arařtırmada, Trkiye'nin belirlenen blgelerinden seilen akarsu lm istasyonlarından elde edilen verilerden ve blgelere ait meteorolojik verilerden yararlanarak, akarsu akım hızı tahminine ynelik bir inceleme yapılmıřtır. Yntemler, gnlk ortalama akım hızı, gnlk ortalama hava sıcaklıęı ve gnlk toplam yaęıř verilerinin entegre edilmesine dayalıdır. Arařtırılan makine ęrenimi algoritmaları arasında, RF ve ET modellerinin daha yksek gven derecesinde akım hızı tahmini saęladıęı belirlenmiřtir. Dalgacık dnřmn makine ęrenimine dahil edilmesi sonularda belirgin iyileřmeler saęlayarak başarı oranlarını arttırmıřtır. Dalgacık dnřm ve makine ęreniminin model başarısında yaklaşık %10'luk bir artışa yol aarak, zamansal olarak karmařık ve dzensiz veri kmelerindeki eęilimlerin kesinlięi ve aydınlatılması zerindeki olumlu etkisi kanıtlanmıřtır. alıřmanın sonularının, Tarım ve Orman Bakanlıęı ve dięer ilgili kurum ve kuruluřlarda yararlı olması beklenmektedir. Akım hızlarına iliřkin bu tahmin alıřmaları, toprak ve su kaynaklarının korunması, kırsal su talebi ve atık suyun akıllıca ynetilmesini kapsayan temel giriřimlerin dzenlenmesinde byk nem tařımaktadır. Bulgulara gre, Dalgacık dnřm, sinerjik bir řekilde i ie gemiř hibrit makine ęrenimi algoritmaları ile akım hızı tahmininde yksek performans saęlamıřtır.

Bu tez alıřmasında sunulan yaklařım modellerinin, sadece su kaynaklarına iliřkin problemlerinin anlařılmasını kolaylařtırmakla kalmaması, aynı zamanda arařtırmacıların ve politika yapıcıların kararlarını glendirerek su ynetimi ve tarımsal stratejilerin oluřturulmasında, simlasyonlarda olumlu sonular elde edilmesini saęlaması beklenmektedir.



## VI. KAYNAKÇA

### KİTAPLAR

JHA, A. (2015). **“The water book**, Hachette UK.

MONTESINOS LÓPEZ, O. A., MONTESINOS LÓPEZ, A., & CROSSA, J. (2022). **Multivariate statistical machine learning methods for genomic prediction** (p. 691). Springer Nature.

REBALA, G., RAVI, A., & CHURIWALA, S. (2019). **An introduction to machine learning**. Springer.

### MAKALELER

AHMET S. E. L. (2020). “Pandemi Sürecinde Altın Fiyatları İle Kripto Para İlişkisinin Makine Öğrenme Metotları İle İncelenmesi”, **İstatistik Ve Uygulamalı Bilimler Dergisi**, 1(2), 85-98, 2020.

AKBULUT U., ASLAN, Z. (2022) “İleri Veri İşlem Yöntemleri İle Su Kaynaklarının Kullanımı Ve Planlanmasının Optimizasyonu”. **Aksaray University Journal Of Science And Engineering**, 6(2), 79-94, 2022.

ALTAN, K., TEKSOY, A., & SOLMAZ, S. K. A. (2020). “Türkiye’de Yağış ve Sıcaklığın Su Kaynakları, Tarımsal Ürün Verimi Ve Su Politikalarına Etkisi”, **Uludağ Üniversitesi Mühendislik Fakültesi Dergisi**, 25(3), 1253-1270.

AYDOĞDU, M., MANCI, A., & AYDOĞDU, M. (2015). “Tarımsal Su Yönetiminde Değişimler; Sulama Birlikleri, Fiyatlandırma Ve Özelleştirme Süreci”, **Elektronik Sosyal Bilimler Dergisi**, 14(52).

BAHZAD T. J., ADNAN M. A., “Classification Based On Decision Tree Algorithm For Machine Learning”, **Journal Of Applied Science And Technology Trends** , Vol. 02, No. 01, Pp. 20 – 28 (2021) Issn: 2708-0757

- BAKIŞ, R., & GÖNCÜ, S. (2015). “Akarsu debi ölçümlerinde eksik verilerin tamamlanması: Zap Suyu Havzası örneği.”, **Anadolu Üniversitesi Bilim ve Teknolojisi Dergisi A- Uygulamalı Bilimler ve Mühendislik**, 16(1):63-79.
- BAŞARAN, A., DURSUN, F., & TİPİ, A. F. (2022). “”Balıkesir’de Sürdürülebilir Kalkınmanın İncelenmesi”, **Anadolu Akademi Sosyal Bilimler Dergisi**, 4(1), 48-65.
- BAUDRON, P., ALONSO-SARRÍA, F., GARCÍA-ARÓSTEGUI, J. L., CÁNOVAS-GARCÍA, F., MARTÍNEZ-VICENTE, D., & MORENO-BROTÓNS, J. (2013). Identifying the origin of groundwater samples in a multi-layer aquifer system with Random Forest classification, **Journal of Hydrology**, 499, 303-315.
- BAYDAROĞLU, Ö., & KOÇAK, K. (2014). “SVR-based prediction of evaporation combined with chaotic approach”, **Journal of Hydrology**, 508, 356-363.
- BAYKAL, T., & TERZİ, Ö. (2017). “Küçük Aksu Çayı taşkın frekans analizi”, **Cumhuriyet Sci. J**, 38(4), 639-646.
- BIAU, G., & SCORNET, E. (2016). “A random forest guided tour” **Test**, 25, 197-227.
- BOZKURT, C., KARAKAYA, N., GENÇ, Ö., & FİDAN, H. (2021). “Fırtına Deresi Havzasında Gefc Metodu Kullanılarak Çevresel Su İhtiyacı Tahmini.”, **14. Ulusal 2. Uluslararası Çevre Mühendisliği Kongresi 2021 Bildiri Taslağı**, 293-302
- BRAVO, S., GONZÁLEZ-CHANG, M., DEC, D., VALLE, S., WENDROTH, O., ZUÑIGA, F., & DÖRNER, J. (2020). “Using wavelet analyses to identify temporal coherence in soil physical properties in a volcanic ash-derived soil.” **Agricultural and Forest Meteorology**, 285, 107909.
- BULUT, A. P., & CANBAZ, G. T. (2022). “Sivas İlinde Buğday, Arpa, Şeker Pancarı Ve Ayçiçeği Üretimi İçin Su Ayak İzinin

Hesaplanması.”, **Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi**, 9(1), 249-255.

BÜYÜKKAMACI, N. (2009). “Su Yönetiminin Etkin Bileşeni: Yeniden Kullanım.”, **İzmir Kent Sorunları Sempozyumu**, 8-10.

DEMİR, V., & KESKİN, A. Ü. (2022). “Yeterince Akım Ölçümü Olmayan Nehirlerde Taşkın Debisinin Hesaplanması Ve Taşkın Modellemesi (Samsun, Mert Irmağı Örneği).”, **Geomatik**, 7(2), 149-162.

DORAK, S., AŞIK, B. B., & ÖZSOY, G. (2019). “Tarımda Su Kalitesi Ve Su Kirliliğinin Önemi: Bursa Nilüfer Çayı Örneği.”, **Bursa Uludağ Üniversitesi Ziraat Fakültesi Dergisi**, 33(1), 155-166.

EHTERAM, M., KARAMİ, H., MOUSAVİ, S. F., FARZİN, S., CELESTE, A. B., & SHAFİE, A. E. (2018). “Reservoir operation by a new evolutionary algorithm: kidney algorithm.”, **Water Resources Management**, 32, 4681-4706.

EHTERAM, M., SİNGH, V. P., FERDOWSİ, A., MOUSAVİ, S. F., FARZİN, S., KARAMİ, H., ... & EL-SHAFİE, A. (2019). “An improved model based on the support vector machine and cuckoo algorithm for simulating reference evapotranspiration.”, **PloS one**, 14(5), e0217499.

EWAİD, S. H., ABED, S. A., & AL-ANSARİ, N. (2019). “Water Footprint Of Wheat In Iraq.”, **Water**, 11(3), 535.

GARİPAĞAOĞLU, N. (2012). “Havza Planlamalarında Coğrafyanın Rolü Ve Türkiye’de Havza Planlamacılığı”, **Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, 16(2), 303-336.

GLEİCK, P. H. (2019). “Water As A Weapon And Casualty Of Conflict: Freshwater And International Humanitarian Law”, **Water Resources Management**, 33(5), 1737-1751.

GONZÁLEZ-TERUEL, J. D., RUIZ-ABELLON, M. C., BLANCO, V., BLAYAROS, P. J., DOMÍNGO, R., & TORRES-SÁNCHEZ, R. (2022). “Prediction of water stress episodes in fruit trees based on soil and weather time series data”, **Agronomy**, 12(6), 1422.

- GÖKÇE, N. (2022). “Küresel Su Stresi Ve Ölçüm Yöntemleri”, **Bulletin Of Economic Theory And Analysis**, 7(1), 189-208.
- GUPTA, R., & ALAM, T. (2022). “Survey On Federated-Learning Approaches In Distributed Environment”, **Wireless Personal Communications**, 125(2), 1631-1652.
- GYAU-BOAKYE, P., & SCHULTZ, G. A. (1994). “Filling gaps in runoff time series in West Africa”, **Hydrological sciences journal**, 39(6), 621-636.
- ILGAR, R., (2009). “Dünya Su Yönetimi, Su Eğitimi / World Water Management And Water Education”, **1. Uluslararası Türkiye Eğitim Araştırmaları Kongresi**, (Pp.1-22). Çanakkale, Turkey
- ISMAİL, W. N. W., ZİN, W. Z. W., & İBRAHİM, W. (2017). “Estimation of rainfall and stream flow missing data for Terengganu, Malaysia by using interpolation technique methods”, **Malays. J. Fundam. Appl. Sci**, 13, 214-218.
- İŞLER, B., & ASLAN, Z. (2021). “Bitki örtüsü ve mekânsal ve zamansal varyasyonların modellenmesi”, **Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, 36(4), 1863-1874.
- YURTSEVEN B. R., KALKAVAN S.,(2023). “Hidrometri (Su Ölçümü) Uygulamalarında Debi Ölçümleri”, **Meteoroloji Mühendisleri Odası Hidroloji Komisyonu**.
- KARAL Ö., “Ekg Verilerinin Destek Vektör Regresyon Yöntemiyle Sıkıştırılması”, **Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, 33(2), 743-756,2018.
- KARAMAN, S., & GÖKALP, Z. (2010). “Küresel Isınma Ve İklim Değişikliğinin Su Kaynakları Üzerine Etkileri”, **Tarım Bilimleri Araştırma Dergisi**, (1), 59-66.
- KARAMİ, H., FARZİN, S., JAHANGİRİ, A., EHTERAM, M., KİSİ, O., & EL-SHAFİE, A. (2019). “Multi-reservoir system optimization based on hybrid gravitational algorithm to minimize water-supply deficiencies”, **Water Resources Management**, 33, 2741-2760.

- KINA, E., & BİÇEK, E. “Duygu Analizinde Denetimli Makine Öğrenme Algoritmalarının Karşılaştırılmaları,(Kahramanmaraş Depremi Örneği)”, **Batman Üniversitesi Yaşam Bilimleri Dergisi**, 13(1), 21-31.
- KOÇAK, K., ŞAYLAN, L., & EİTZİNGER, J. (2004). “Nonlinear prediction of near-surface temperature via univariate and multivariate time series embedding”, **Ecological Modelling**, 173(1), 1-7.
- LÓPEZ, O.A., MONTESINOS LÓPEZ, A., CROSSA, J. (2022). “Support Vector zMachines And Support Vector Regression. In: Multivariate Statistical Machine Learning Methods For Genomic Prediction”, **Springer, Cham**. [https://doi.org/10.1007/978-3-030-89010-0\\_9](https://doi.org/10.1007/978-3-030-89010-0_9)
- MOHAMMADİ, B., & MEHDİZADEH, S. (2020). “Modeling Daily Reference Evapotranspiration Via A Novel Approach Based On Support Vector Regression Coupled With Whale Optimization Algorithm”, **Agricultural Water Management**, 237, 106145.
- MURATOĞLU, A. (2020). “Üretimin Su Ayak İzinin İncelenmesi: Diyarbakır İli İçin Bir Vaka Çalışması”, **Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, 35(2), 845-858.
- NADİRİ, A. A., NADERİ, K., KHATİBİ, R., & GHAREKHANİ, M. (2019). “Modelling groundwater level variations by learning from multiple models using fuzzy logic”, **Hydrological Sciences Journal**, 64(2), 210-226.
- NAVARRO-HELLÍN, H., MARTÍNEZ-DEL-RINCON, J., DOMÍNGO-MÍGUEL, R., SOTO-VALLES, F., & TORRES-SÁNCHEZ, R. (2016). “A decision support system for managing irrigation in agriculture”, **Computers and Electronics in Agriculture**, 124, 121-131.
- ÖNER, İ. V., YEŞİLYURT, M. K., & YILMAZ, E. Ç. (2017). “Wavelet Analiz Tekniği Ve Uygulama Alanları”, **Ordu Üniversitesi Bilim Ve Teknoloji Dergisi**, 7(1), 42-56.

- ÖZENİR, A., & BEYEN, K. (2023). “Taban Yalıtımlı Bir Binanın Deprem Davranışının Zaman-Frekans Ortamında Dalgacık Dönüşümü Yöntemiyle Araştırılması Seismic Performance Of A Base Isolated Structure In Time-Frequency Domain With Wavelet Transform”, **Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi**, 1000(1000), 0-0.
- POURİYEH, S., SHAHİD, O., PARİZİ, R.M., SHENG, Q.Z., SRİVASTAVA, G., ZHAO, L., AND NASAJPOUR, M. (2022). “Secure Smart Communication Efficiency In Federated Learning: Achievements And Challenges”, **Applied Sciences**, 12(18), 8980.
- SAÇ, G., & ÖZULUĞ, M. (2014). “Five new records for the fish fauna of Durusu Lake Basin (İstanbul)”, **Journal of Fisheries Science**, 8(4), 291-297.
- SARGINCI, M., DÖNMEZ, A. H., & YILDIZ, O. (2022). “Biyosferde Su Döngüsü Ve Bitkiler Tarafından Suyun Alınma Mekanizmalar”, **Düzce Üniversitesi Süs Ve Tıbbi Bitkiler Botanik Bahçesi Dergisi**, 1(1), 8-20.
- SARIŞ, F. (2021). “Türkiye’de Eysel Su Tedarik Ve Tüketim İstatistiklerinin Değerlendirilmesi”, **Coğrafi Bilimler Dergisi**, 19(1), 195-216.
- TAKAOĞLU, M., ÖZYAVAŞ, A., AJLOUNİ, N., ALSHAHRANİ, A., & ALKASASBEH, B. (2021). “A novel and robust hybrid blockchain and steganography Scheme”, **Applied Sciences**, 11(22), 10698.
- TOSUNOĞLU, F., İSPIRLİ, M. N., GÜRBÜZ, F., & ŞENGÜL, S. (2017). “Fırat Havzası’ndaki Eksik Akım Verilerinin Debi Süreklilik Çizgileri Ve Regresyon Modelleri İle Tahmin Edilmesi”, **Journal Of The Institute Of Science And Technology**, 7(4), 85-94.
- TYRALİS, H., PAPACHARALAMPOUS, G., & LANGOUSİS, A. (2019). “A brief review of random forests for water scientists and practitioners and their recent history in water resources”, **Water**, 11(5), 910.
- ULAS, M., AYDUR, O., GURGENC, T., & OZEL, C. (2020). “Surface Roughness Prediction Of Machined Aluminum Alloy With Wire Electrical Discharge Machining By Different Machine Learning

Algorithms”, **Journal Of Materials Research And Technology**, 9(6), 12512-12524.

UNLU, A., COBAN, F., & TUNC, M. S. (2008). “Investigation Of Lake Hazar Water Quality According To Physical And İnorganic Chemical Parameters”, **Journal Of The Faculty Of Engineering And Architecture Of Gazi University**, 23(1), 119-127.

USTA, A. (2016). “Türkiye’nin Su Potansiyelinin Belirlenmesi Üzerine Bir Araştırma”, **Küresel Mühendislik Çalışmaları Dergisi**, 3(2), 107-115.

VARGAS-SOLAR, G., ZECHİNELLI-MARTİNİ, J. L., ESPİNOSA-OVIEDO, J. A., & VİLCHES-BLÁZQUEZ, L. M. (2023). “Multi-Perspective Approach For Curating And Exploring The History Of Climate Change İn Latin America Within Digital Newspapers”, **Computer Science And Information Systems**, (00), 8-8.

VIET-HUNG D. , NHAT-DUC H. , LE-MAI-DUYEN N. , DIÊU TIÊN B. AND PİJUSH S. (2020). “A Novel G1s-Based Rfmachine Algorithm For The Spatial Prediction Of Shallow Landslide Susceptibility”, **Forests** , 11, 118; Doi:10.3390/F11010118 [www.Mdpi.Com/Journal/Forests](http://www.Mdpi.Com/Journal/Forests)

WAQAS, U. A., KHAN, M., & BATOOL, S. I. (2020). “A new watermarking scheme based on Daubechies wavelet and chaotic map for quick response code images”, **Multimedia tools and applications**, 79, 6891-6914.

YILMAZ, A. (2015). “Küresel Isınmanın Dünya Su Rezervleri Üzerindeki Etkileri”, **Kent Akademisi**, 8(22), 63-72.

ZHANG, J., Lİ, M., LİU, C., ZHANG, L., & Lİ, X. (2022). “Urban Waterlogging Simulation Based On The Soil And Water Assessment Tool Model And A Bp Neural Network: A Case Study İn Harbin City, China”, **Water**, 14(10), 2954.

## **ELEKTRONİK KAYNAKLAR**

- URL- 1 “Evrende Biyomoleküller ve Olası Yaşam Biçimleri”  
<https://services.tubitak.gov.tr/edergi/yazi.pdf;jsessionid=wodTc1mw4adsRDAVwsX3zjpl?dergiKodu=4&cilt=42&sayi=646&sayfa=26&yaziid=28537>, (Erişim Tarihi: 07.05.2022)
- URL- 2 “Okyanuslar nasıl oluştu? - Alok Jha -BBC Earth-18 Haziran.2015”  
<https://bbc.in/45drTKk> (Erişim Tarihi: 27.07.2023)
- URL- 3 “Suyun Hikâyesi - Muhittin Ziya Gözler - 11 Kasım 2020”  
<https://www.21yyte.org/tr/merkezler/islevsel-arastirma-merkezleri/politik-sosyal-kulturel-arastirmalar-merkezi/suyun-hikayesi> (Erişim Tarihi: 15.10.2022)
- URL- 4 “Where is Earth's Water? | U.S. Geological Survey. (n.d.). USGS.gov | Science for a changing world”, <https://www.usgs.gov/special-topics/water-science-school/science/where-earths-water> (Erişim Tarihi: 15.03.2023)
- URL- 5 “Su Döngüsü” Su Verimliliği “<https://www.suverimliliği.gov.tr/su-dongusu/>” (Erişim Tarihi: 15.07.2023)
- URL- 6 “Kümülatif Yağış Raporu. (n.d.). Aylık Alansal Yağış Raporu Kümülatif.”, <https://www.mgm.gov.tr/veridegerlendirme/yagis-raporu.aspx> (Erişim Tarihi: 16.05.2023)
- URL- 7 “(n.d.). Ankara Üniversitesi Açık Ders Malzemeleri.”, [https://acikders.ankara.edu.tr/pluginfile.php/121797/mod\\_resource/content/0/Konu%208.pdf](https://acikders.ankara.edu.tr/pluginfile.php/121797/mod_resource/content/0/Konu%208.pdf) (Erişim Tarihi: 12.04.2023)
- URL- 8 “Akarsular ve Çeşitleri - Coğrafyacı. (n.d.). Coğrafyacı.”  
<https://www.cografyaci.gen.tr/akarsular-ve-cesitleri> (Erişim Tarihi: 20.07.2023)
- URL-9 “Devlet Su İşleri Genel Müdürlüğü. (n.d.). Devlet Su İşleri Genel Müdürlüğü.”, <https://www.dsi.gov.tr/Sayfa/Detay/692> (Erişim Tarihi: 18.05.2020)
- URL-10 “2022 Yılı İdare Faaliyet Raporu. (2023). Meteoroloji Genel Müdürlüğü Strateji Geliştirme Dairesi Başkanlığı.”,



<https://mgm.gov.tr/FILES/kurumsal/yatirimfaaliyet/2022-faaliyet-raporu.pdf> , (Eriřim Tarihi: 29.04.2023)

URL-11 “Devlet Su İşleri Genel Müdürlüğü. (n.d.). Devlet Su İşleri Genel Müdürlüğü”, <https://www.dsi.gov.tr/Sayfa/Detay/744>, (Eriřim Tarihi: 20.11.2021)

URL-12 “Kümülatif Yağış Raporu. (n.d.). Alansal Yağış Raporu Kümülatif.”, <https://www.mgm.gov.tr/veridegerlendirme/yagis-raporu.aspx?b=k#sfB>, (Eriřim Tarihi: 10.10.2023)

## **TEZLER**

BAHADIRLI, Z. M. (2021). Yeraltı suyu seviye deęişiminin M5 karar ağacı ve yapay sinir ağları yöntemleriyle belirlenmesi (Master's thesis, İskenderun Teknik Üniversitesi/Lisansüstü Eğitim Enstitüsü/İnşaat Mühendisliği Ana Bilim Dalı).

BİLGİÇ, Y. (2008). Güneş enerjili su damıtma sistemlerinde genişletilmiş yüzeylerin ısı ve kütle transferi üzerindeki etkisi (Doctoral dissertation, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü).

KARŞILI, C. (2011). Türkiye’de akarsu havzalarında kişi başına düşen su miktarının coğrafi bilgi sistemleriyle analizi (Doctoral dissertation, Yüksek Lisans Tezi. Ankara Üniversitesi Sosyal Bilimler Enstitüsü).

KÜÇÜKKILAVUZ, E. (2009). Küresel ısınmanın su kaynakları üzerine etkileri: Türkiye örneęi/The effects of global warming about water resources: Turkey sample (Doctoral dissertation).

OĞUZ, T. C. (2015). “İçme Suyu Arıtımında Yaygın Olarak Karşılaşılan Su Kalite Problemleri Ve Arıtımı İçin Çözüm Önerileri”, Uzmanlık Tezi, Tc Orman Ve Su İşleri Bakanlığı, Ankara, (S 93).

SOYTÜRK, O. (2014). Su Çerçeve Direktifine Göre Yeraltı Sularının İzlenmesi ve Türkiye İçin Bir Değerlendirme. Orman ve Su İşleri Bakanlığı, Uzmanlık Tezi, 129s.

TATAR, S. (2019). Türkiye ve Avrupa Birliği'nde Yerüstü Su Kaynaklarının Yönetimi.

## **EKLER**

**Ek-1** AGİ(Akım Hızı) ve Meteorolojik(Yağış, Sıcaklık) ham verileri (xls formatında)

**Ek-2** Çözümlemiş verileri (excel formatında)

**Ek-3** Çözümleme kodu (python kodu)

**Ek-4** Makine Öğrenmesi Model Hesaplamaları

**Ek-5** Makine Öğrenmesi Model Test

**Ek-6** DSİ Akım Gözlem Yıllıkları Örnek

**Ek-1** AGİ(Akım Hızı) ve Meteorolojik(Yağış, Sıcaklık) ham verileri (xls formatında)

Tez CD içerisinde AGİ(Akım Hızı) ve Meteorolojik (Yağış,Sıcaklık) verileri .xls formatında verilmiştir. Bu verilere göre çalışmanın input ve output değerleri oluşturularak, algoritma içerisinde kullanılmıştır.

**Ek-2** Çözümlemiş verileri (excel formatında)

Tez CD içerisinde AGİ(Akım Hızı) ve Meteorolojik(Yağış, Sıcaklık) verileri csv dosyalarına dönüştürülerek, python yazılım dili kullanılarak anlamlı veriler haline getirilmiştir. Bu veriler excel formatında tutulmaktadır.

**Ek-3** Çözümleme kodu (python kodu)

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import xlswriter

# preprocessing
from sklearn.preprocessing import LabelEncoder, StandardScaler
from sklearn.model_selection import train_test_split, cross_val_score,
GridSearchCV, StratifiedKFold
# import pandas_profiling as pp

# models
from sklearn.linear_model import LinearRegression, SGDRegressor, RidgeCV
from sklearn.svm import SVR, LinearSVR
from sklearn.ensemble import RandomForestRegressor, GradientBoostingRegressor,
ExtraTreesRegressor
from sklearn.ensemble import BaggingRegressor, AdaBoostRegressor, VotingRegressor
from sklearn.neural_network import MLPRegressor
from sklearn.tree import DecisionTreeRegressor
from sklearn.neighbors import RadiusNeighborsRegressor
import sklearn.model_selection
from sklearn.model_selection import cross_val_predict as cvp
from sklearn import metrics
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error

# import xgboost as xgb
# import lightgbm as lgb

# model tuning
# from hyperopt import STATUS_OK, Trials, fmin, hp, tpe, space_eval

# import warnings
# warnings.filterwarnings("ignore")

def acc_d(y_meas, y_pred):
    # Relative error between predicted y_pred and measured y_meas values
```

```

# return mean absolute error(y meas, y pred)*len(y meas)/sum(abs(y meas))
return mean absolute error(y meas, y pred)

def acc_rmse(y_meas, y_pred):
# RMSE between predicted y_pred and measured y_meas values
return (mean_squared_error(y_meas, y_pred))*0.5

def acc_model(num, model, train, test):
# Calculation of accuracy of model акшь Sklearn by different metrics

global acc_train_r2, acc_test_r2, acc_train_d, acc_test_d, acc_train_rmse,
acc_test_rmse

ytrain = model.predict(train)
ytest = model.predict(test)

print('target = ', target[:5].values)
print('ytrain = ', ytrain[:5])

acc_train_r2_num = round(r2_score(target, ytrain) * 100, 2)
print('acc(r2 score) for train =', acc_train_r2_num)
acc_train_r2.insert(num, acc_train_r2_num)

acc_train_d_num = round(acc_d(target, ytrain) * 100, 2)
print('acc(relative error) for train =', acc_train_d_num)
acc_train_d.insert(num, acc_train_d_num)

acc_train_rmse_num = round(acc_rmse(target, ytrain) * 100, 2)
print('acc(rmse) for train =', acc_train_rmse_num)
acc_train_rmse.insert(num, acc_train_rmse_num)

print('target_test =', target_test[:5].values)
print('ytest =', ytest[:5])

acc_test_r2_num = round(r2_score(target_test, ytest) * 100, 2)
print('acc(r2 score) for test =', acc_test_r2_num)
acc_test_r2.insert(num, acc_test_r2_num)

acc_test_d_num = round(acc_d(target_test, ytest) * 100, 2)
print('acc(relative error) for test =', acc_test_d_num)
acc_test_d.insert(num, acc_test_d_num)

acc_test_rmse_num = round(acc_rmse(target_test, ytest) * 100, 2)
print('acc(rmse) for test =', acc_test_rmse_num)
acc_test_rmse.insert(num, acc_test_rmse_num)

```

## Ek-4 Makine Öğrenmesi Model Hesaplamaları

Tez CD içerisinde eğitim verisinin analiz sonuçları excel (xls) formatında verilmiştir.

```
train0 = pd.read_csv('dataset/Ortyagissicakwave80.csv')

# train0 = pd.read_csv('dataset/Ortalama-Günlük-Akım-80-20-arası-wavelet-80.csv')
# train0 = pd.read_csv('dataset/Ort,yağış sıcaklıkrrrr.csv')

#train0 = pd.read_csv('dataset/calcaW5680.csv')
# train0 = pd.read_csv('dataset/calcaW580.csv')
# train0 = pd.read_csv('dataset/calca380.csv')
train0 = train0.drop(['TARİH'], axis=1)
train0 = train0.dropna()

target_name = 'ORTALAMA'

train_target0 = train0[target_name]
train0 = train0.drop([target_name], axis=1)

#For models from Sklearn
scaler = StandardScaler()
train0 = pd.DataFrame(scaler.fit_transform(train0), columns = train0.columns)

valid_part = 0.15
train, test, target, target_test = train_test_split(train0, train_target0,
test_size=valid_part, random_state=0)

acc_train_r2 = []
acc_test_r2 = []
acc_train_d = []
acc_test_d = []
acc_train_rmse = []
acc_test_rmse = []

#Linear Regression
linreg = LinearRegression()
linreg.fit(train, target)
acc_model(1, linreg, train, test)
#plt.scatter(train,target)

#Linear Grafik
#xtrain = train.iloc[:,0]

# ytrain = linreg.predict(train)
#print('target = ', target[:5].values)
#print('ytrain = ', ytrain[:5])
```

```

plt.scatter(train0.iloc[:,0], train target0, color='darkorange', label='data')
# plt.hold(True)
plt.plot(train0.iloc[:,0][:25], predFull, color='navy', label='RBF model')
# plt.plot(X, y_lin, color='c', lw=lw, label='Linear model')
# plt.plot(X, y_poly, color='cornflowerblue', lw=lw, label='Polynomial model')
plt.xlabel('Data')
plt.ylabel('Prediction')
plt.title('LinearRegression')
plt.legend()
plt.savefig('graphLinear.png')
plt.show()

# SVR model
svr = SVR(kernel='rbf', C=100, gamma=0.1, epsilon=.1)
svr.fit(train, target)
acc_model(2, svr, train, test)

#lw = 2
plt.scatter(xtrain, target, color='darkorange', label='data')
# plt.hold(True)
plt.plot(train, svr.predict(train), color='navy', label='RBF model')
# plt.plot(X, y_lin, color='c', lw=lw, label='Linear model')
# plt.plot(X, y_poly, color='cornflowerblue', lw=lw, label='Polynomial model')
plt.xlabel('Data')
plt.ylabel('Prediction')
plt.title('Support Vector Regression')
plt.legend()
plt.show()

# Decision Tree
decision_tree = DecisionTreeRegressor()
decision_tree.fit(train, target)
acc_model(3, decision_tree, train, test)

plt.scatter(xtrain, target, color='darkorange', label='data')
# plt.hold(True)
plt.plot(train, decision_tree.predict(train), color='navy', label='RBF model')
# plt.plot(X, y_lin, color='c', lw=lw, label='Linear model')
# plt.plot(X, y_poly, color='cornflowerblue', lw=lw, label='Polynomial model')
plt.xlabel('Data')
plt.ylabel('Prediction')
plt.title('decision_tree')
plt.legend()
plt.show()

# Random Forest
random_forest = GridSearchCV(estimator=RandomForestRegressor(),
param_grid={'n_estimators': [100, 1000]}, cv=5)
random_forest.fit(train, target)

```

```

print(random forest.best params )
acc_model(4, random forest, train, test)

# ExtraTrees Regression
etr = ExtraTreesRegressor()
etr.fit(train, target)
acc_model(5, etr, train, test)

models = pd.DataFrame({
    'Model': ['Linear Regression', 'Support Vector Machines Regression',
             'Decision Tree Regressor', 'Random Forest',
             'ExtraTreesRegressor',
             ],
    'r2_train': acc_train_r2,
    'r2_test': acc_test_r2,
    'd_train': acc_train_d,
    'd_test': acc_test_d,
    'rmse_train': acc_train_rmse,
    'rmse_test': acc_test_rmse
})

plt.figure(figsize=[25, 6])
xx = models['Model']
plt.tick_params(labelsize=14)
plt.plot(xx, models['r2_train'], label='r2 train')
plt.plot(xx, models['r2_test'], label='r2 test')
plt.legend()
plt.title('R2-models for train and test datasets')
plt.xlabel('Models')
plt.ylabel('R2-criterion, %')
plt.xticks(xx, rotation='vertical')
plt.savefig('graph.png')
plt.show()

```

## Ek-5 Makine Öğrenmesi Model Test

```

testn = pd.read_csv('dataset/Ortyagissicakwave20.csv')

# testn = pd.read_csv('dataset/AnyConv.com_Tuncelitamamondeisicakliktestff.csv')
# testn = pd.read_csv('dataset/Ortalama-Günlük-Akım-80-20-arası-wavelet-son20.csv')
# testn = pd.read_csv('dataset/Ort,yağış sıcaklıkrrrr.csv')

# testn = pd.read_csv('calcaW320.csv')#BU
# testn = pd.read_csv('calcaW620.csv')
#testn = pd.read_csv('calcaW5620.csv')#BU

targettest= testn['ORTALAMA']
testn = testn.drop(['TARİH', 'ORTALAMA'], axis=1)

testn = pd.DataFrame(scaler.transform(testn), columns=testn.columns)
testn = np.nan_to_num(testn) # nan değerleri num yapıyor
print('target Test = ', targettest[:].values)

# Linear Regression model for basic train

```



```

linreg.fit(train0, train_target0)
pred = linreg.predict(testn[:])

print('prediction Linear = ', pred)
# print('prediction Linear1 = ', linreg.predict(testn[:])

svr.fit(train0, train_target0)
predSvr = svr.predict(testn[:])

print('prediction SVR = ', predSvr)
# predSvr[:].values

decision_tree.fit(train0,train_target0)
preddecision_tree=decision_tree.predict(testn[:])
print('prediction Decision_tree',preddecision_tree)

random_forest.fit(train0, train_target0)
predrandom_forest = random_forest.predict(testn[:])
print('prediction Random Forest', predrandom_forest)

etr.fit(train0, train_target0)
predEtr = etr.predict(testn[:])
print('prediction ETR', predEtr)

isim_listesi = ["AHMET", "HASAN", "MEHMET"]
soyisim_listesi = ["ŞEN", "ÇAKMAK", "GÜL"]

workbook = xlswriter.Workbook('benim listem.xlsx')
worksheet = workbook.add_worksheet()

# birinci sütun(0) yani A sütununa isim_listesini yazdırma
# worksheet.write(satir,0,veri) A=0 sütunu sabittir

for satir, veri in enumerate(targettest):
    worksheet.write(satir, 0, veri)
for satir, veri in enumerate(pred):
    worksheet.write(satir, 1, veri)
for satir, veri in enumerate(predSvr):
    worksheet.write(satir, 2, veri)
for satir, veri in enumerate(preddecision_tree):
    worksheet.write(satir, 3, veri)
for satir, veri in enumerate(predrandom_forest):
    worksheet.write(satir, 4, veri)
for satir, veri in enumerate(predEtr):
    worksheet.write(satir, 5, veri)
# ikinci sütun(1) yani B sütununa soyisim listesini yazdırma
# worksheet.write(satir,1,veri) B=1 sütunu sabittir

# dosya işlemlerini bitiriyoruz.
workbook.close()

```

```

        print('target Test = ', targettest[:].values)

# Linear Regression model for basic train
linreg.fit(train0, train_target0)
pred = linreg.predict(testn[:])

print('prediction Linear = ', pred)
# print('prediction Linear1 = ', linreg.predict(testn[:]))

svr.fit(train0, train_target0)
predSvr = svr.predict(testn[:])

print('prediction SVR = ', predSvr)
# predSvr[:].values

decision_tree.fit(train0,train_target0)
preddecision_tree=decision_tree.predict(testn[:])
print('prediction Decision_tree',preddecision_tree)

random_forest.fit(train0, train_target0)
predrandom_forest = random_forest.predict(testn[:])
print('prediction Random_Forest', predrandom_forest)

etr.fit(train0, train_target0)
predEtr = etr.predict(testn[:])
print('prediction ETR', predEtr)

workbook = xlswriter.Workbook('benim_listem.xlsx')

worksheet = workbook.add_worksheet()

```

```
for satir, veri in enumerate(targettest):
    worksheet.write(satir, 0, veri)
for satir, veri in enumerate(pred):
    worksheet.write(satir, 1, veri)
for satir, veri in enumerate(predSvr):
    worksheet.write(satir, 2, veri)
for satir, veri in enumerate(preddecision_tree):
    worksheet.write(satir, 3, veri)
for satir, veri in enumerate(predrandom_forest):
    worksheet.write(satir, 4, veri)
for satir, veri in enumerate(predEtr):
    worksheet.write(satir, 5, veri)
```

## Ek-6 DSİ Akım Gözlem Yıllıkları Örnek

02. Marmara Havzası  
DOĞA028 İSTİRAHCA D. KARANDERE

**YERİ** : ÇAYALCA KARACARÜY BUCAĞI YOLUNUN 23 KM'SİNDEKİ KARANDERE KÖYÜNÜN 1 KM MANSAHINDADIR  
(BAPTA F20-B1)  
28°18'44" Doğu - 41°22'45" Kuzey

**YIĞIŞ ALANI** : 287,10 km<sup>2</sup> **YAKLAŞIK KOT** : 32 m

**GÖZLEM SÜRESİ** : 01.07.1966 - 30.09.1974

**ORTALAMA AKIMLAR** : Gözlem süresinde 2.131 m<sup>3</sup>/sn. (8 Yıllık ) 1974 Su yılında 1.709 m<sup>3</sup>/sn.

**ANLIK EN ÇOK VE EN AZ AKIMLAR:**

1974 Su yılında anlık ençok akım : 290.000 m<sup>3</sup>/sn 05.10.1973  
1974 Su yılında anlık enaz akım : 0.115 m<sup>3</sup>/sn 03.08.1974  
Gözlem süresinde anlık ençok akım : 380.000 m<sup>3</sup>/sn 05.10.1973  
Gözlem süresinde anlık enaz akım : 0.066 m<sup>3</sup>/sn 01.08.1972

### 16. Anahtar Eğrisi (Seviyeler cm olarak)

Seviye	Akım	Seviye	Akım	Seviye	Akım	Seviye	Akım
10	0.003	30	0.112	190	34.5	390	210.
14	0.009	50	0.677	230	58.0	430	250.
18	0.020	70	2.0	270	90.0	470	290.
22	0.040	110	7.6	310	130.	510	330.
26	0.068	150	17.5	350	170.		

### Akımlar 01 Ekim 1973 'den 30 Eylül 1974' a kadar m<sup>3</sup>/sn olarak

Gün	Ekim	Kasım	Aralık	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül
01	0.350	0.410	1.80	0.670	4.50	4.80	1.15	0.760	0.670	0.260	0.155	0.730
02	0.350	0.380	1.05	0.620	3.00	4.80	1.55	0.760	0.620	0.310	0.135	0.410
03	0.350	0.380	1.15	0.580	3.50	6.70	1.30	0.760	0.580	0.260	0.115	0.260
04	0.880	0.380	3.70	0.580	4.80	5.90	1.25	0.760	1.80	0.230	0.135	0.230
05	37.0	0.380	5.00	0.580	11.5	4.10	1.15	0.730	1.70	0.200	0.155	0.230
06	5.70	0.380	2.90	0.580	8.00	3.20	1.10	0.670	0.950	0.230	0.135	0.230
07	1.60	0.410	1.55	0.580	5.90	4.60	1.10	0.670	0.760	0.200	0.135	0.230
08	1.70	0.410	1.15	0.580	5.80	4.60	1.05	0.670	0.670	0.200	0.135	0.230
09	0.950	0.490	0.950	0.580	3.70	6.90	1.00	0.670	0.620	0.200	0.135	0.230
10	0.670	0.580	0.880	0.580	2.40	4.80	1.00	0.730	0.580	0.230	0.135	0.200
11	0.580	0.490	0.880	0.670	1.80	18.0	1.00	5.80	0.580	0.200	0.135	0.175
12	0.530	0.410	0.760	0.810	1.55	17.0	1.00	13.5	0.530	0.200	0.155	0.175
13	0.460	0.410	0.670	1.15	1.40	6.40	1.00	3.80	0.490	0.200	0.175	0.175
14	0.580	0.410	0.670	1.10	1.25	5.80	1.00	2.20	0.490	0.175	0.175	0.175
15	0.670	0.620	0.730	1.10	1.15	14.0	1.25	1.55	0.580	0.175	0.175	0.175
16	0.730	0.620	2.40	0.880	1.10	11.5	2.40	1.30	0.530	0.175	0.175	0.175
17	0.530	0.490	1.80	0.810	1.00	7.40	1.80	3.30	0.490	0.175	0.175	0.230
18	0.460	0.410	1.10	1.00	1.00	4.80	1.30	2.90	0.490	0.175	0.175	0.230
19	0.410	0.410	1.00	3.50	0.950	3.50	1.25	1.60	0.460	0.175	0.175	0.230
20	0.380	0.410	0.880	4.50	0.950	2.70	1.10	1.30	0.410	0.155	0.155	0.200
21	0.350	0.410	0.810	26.0	0.880	2.30	1.05	1.10	0.410	0.155	0.155	0.175
22	0.350	0.410	0.760	2.10	0.880	2.00	1.00	1.00	0.410	0.155	0.155	0.175
23	0.460	0.410	0.760	1.55	0.810	1.85	1.00	1.00	0.410	0.155	0.155	0.175
24	1.15	0.410	0.730	1.40	2.90	1.80	0.950	1.50	0.380	0.175	0.155	0.175
25	0.950	0.410	0.670	1.55	66.0	1.60	0.880	1.60	0.380	0.175	0.155	0.175
26	0.620	0.410	0.620	1.55	10.0	1.55	0.880	1.10	0.380	0.175	0.135	0.175
27	0.490	0.460	0.580	1.55	4.60	1.50	0.880	1.00	0.350	0.175	0.135	0.310
28	0.460	1.00	0.580	1.80	4.40	1.30	0.810	0.880	0.310	0.155	0.135	0.310
29	0.410	0.730	0.620	1.85	-----	1.25	0.760	0.760	0.290	0.155	0.135	0.260
30	0.410	0.730	0.810	2.10	-----	1.25	0.760	0.760	0.260	0.175	0.230	0.230
31	0.410	-----	0.760	6.00	-----	1.15	-----	0.730	-----	0.175	1.55	-----
Maks.	290.	1.10	6.00	8.20	130.	44.0	2.90	27.0	4.10	0.350	26.0	0.760
Min.	0.350	0.350	0.580	0.580	0.760	1.10	0.760	0.620	0.260	0.135	0.115	0.175
Ortalama	1.97	0.475	1.25	2.22	5.56	5.13	1.12	1.80	0.586	0.192	0.198	0.236
LT/SN/Km <sup>2</sup>	6.85	1.66	4.35	7.74	19.4	17.9	3.92	6.28	2.04	0.669	0.689	0.822
AKIM mm.	18.3	4.29	11.7	20.7	46.9	47.9	10.1	16.8	5.29	1.79	1.85	2.13
MİL. M3	5.27	1.23	3.35	5.95	13.5	13.7	2.91	4.83	1.52	0.514	0.530	0.612
SU YILI ( 1974 ) YILLIK TOPLAM AKIM 53.92 MİLYON M3 188 MM. 6.0 LT/SN/Km <sup>2</sup>												

ZEMKARA HAİZASI  
İSTİBARCA S... İAİMABLERİ (2:28)

**KVKKI 1** (49°98'KUC°76'B) Çataca-Taracak köyü bucağı yolunun 23. ka.daklı (trinalite) tsjOnün 1. ka. unma\* udadır.  
(sö\* 111)

**YASIN ALANI 1** 267.1 Km<sup>2</sup>

**KULLANILABİLİR RUSAT 393131 1** 1.10.1966 □ 30.9.1973 Tarihli Hakin 1 31 s.

**ORNLAMA ARCTIAB 1** Raaat aUraahde 1 2.203.5<sup>3</sup>/an. 7.67 LU/anAs<sup>2</sup> 226.5 an.  
1973 au yilinda < /2.200 a<sup>3</sup>/an. 7.66 LU/anAs<sup>2</sup> 230.2 an.

**ASAMI VE ASQMI ASOLAB** Raaat aUraahde ataal alam 240  $\theta$ /ma. oşal aarıyaal 5.30 en.dir. { 2\*. 11. 1970 }  
Raaat aUraahde asgari aka 0.066<sup>3</sup>/an. oşal aarıyaal 18 ca.dir. { 4.8. 1972 }  
1973 au yilinda aanaal aka 0.68 <sup>3</sup>/an. >pad\*\* Tiyaa 270 ca.dir. ( 26.2. 1973 }  
1973 au yilinda asgari aka 0.100<sup>3</sup>/an. \*s\* / \*\* slyes 20 ca.dir. ( 25.7. 1973 )

**TOPLAM AKIM 1** 68.40 1 10<sup>6</sup> a<sup>3</sup> tr.

1.10.1971 □ 30.9.1973 tarihleri arasında anahtar ogrisi! (\*\* riyalar ca., akular eVan.dir.)

Seviye	İkka	Seviye	Alma
20	0.100	160	21.00
40	1.30	190	32.00
75	3.60	215	42.00
105	5.40	245	55.00
130	13.00	270	68.00

1973 SU YILINDA GONLEK AKIMLAR (□/□)

Gün	Ekin	Kasım	Anlık	Otl	Şat	H u	Nlun	Phys	Mu*	remur	JJuoi	e. 101
1	0.40	0.44	0.73	3.7	4.9	4.9	1.10	1.30	0.93	0.30	0.190	0.190
2	0.33	0.44	0.68	5.7	3.7	3.6	1.30	1.25	0.73	0.27	0.30	0.190
3	0.27	0.37	0.64	6.3	2.9	4.5	1.23	1.20	0.70	0.22	0.43	0.190
4	0.25	0.37	0.60	5.4	2.8	3.7	1.29	1.05	0.66	0.22	0.27	0.190
5	0.25	0.17	0.56	14.0	2.2	3.2	1.20	0.98	0.52	0.22	0.22	0.190
6	0.25	0.37	0.52	11.5	2.0	2.9	1.10	0.93	0.48	0.25	0.190	0.170
7	0.25	0.37	0.52	14.0	1.75	2.8	1.23	0.88	0.44	0.25	0.190	0.140
8	0.25	0.37	0.48	8.0	1.55	2.5	1.20	0.88	0.44	0.25	0.190	0.140
9	0.25	0.31	0.44	8.8	1.35	2.4	1.10	0.83	0.44	0.22	0.22	0.140
10	0.25	0.33	0.44	4.8	1.30	3.1	1.05	0.78	0.44	0.22	0.22	0.140
11	0.33	0.44	0.44	3.0	1.25	13.0	0.98	0.78	0.44	0.22	0.190	0.140
12	0.27	0.13	0.44	2.2	7.3	10.	1.10	0.78	0.44	0.33	0.190	0.37
13	0.25	0.78	0.44	1.75	33.	8.0	3.0	0.71	0.44	0.33	0.190	0.37
14	0.23	0.81	0.44	1.40	7.2	5.7	2.5	0.68	0.40	0.22	0.190	0.40
15	0.44	0.56	0.44	1.35	3.9	9.2	1.65	0.68	0.37	0.22	0.22	0.75
16	3.9	0.44	0.40	1.25	2.8	6.2	2.2	0.68	0.37	0.22	0.22	0.40
17	2.2	0.52	0.40	1.25	16.0	4.5	2.7	0.64	0.37	0.22	0.190	0.30
18	0.98	0.48	0.40	1.65	36.	4.2	2.8	0.68	0.37	0.190	0.190	0.27
19	0.64	0.44	0.40	16.5	7.8	5.5	2.4	0.4	0.37	0.140	0.190	0.25
20	0.60	0.52	0.44	20.	4.6	4.7	1.90	0.64	0.40	0.140	0.190	0.25
21	0.56	0.44	0.60	11.5	3.4	3.4	1.65	0.60	0.36	0.140	0.190	0.25
22	0.56	0.44	0.48	6.2	3.0	2.8	1.40	0.56	0.40	0.140	0.170	0.25
23	1.30	0.40	0.78	3.7	2.3	2.4	1.30	0.52	0.40	0.140	0.170	0.25
24	0.68	0.17	1.23	2.8	3.5	2.2	1.25	0.32	0.37	0.140	0.170	0.25
25	0.88	0.93	0.83	4.0	14.5	2.1	1.40	0.52	0.40	0.120	0.170	0.25
26	7.8	18.0	0.64	7.2	33.	1.90	3.7	0.32	0.52	0.140	0.140	0.23
27	1.90	4.2	1.25	4.5	11.0	1.73	3.4	0.60	0.40	0.190	0.140	0.25
28	0.91	1.65	3.5	3.2	6.2	1.65	2.4	0.83	0.37	0.22	0.140	0.25
29	0.68	1.05	2.2	13.0		1.55	1.80	1.23	0.13	0.22	0.140	0.25
30	0.60	0.83	2.0	17.5		1.40	1.40	1.10	0.30	0.190	0.140	0.25
31	0.52		2.2	7.6		1.13		0.83		0.190	0.170	
<b>Akım (P m<sup>3</sup>)</b>	2.51	3.22	2.21	18.6	19.1	11.1	4.37	2.15	1.18	0.56	0.51	0.67
<b>Max.   Q m<sup>3</sup>/s</b>	18.0	39.	4.3	54.	68.	18.	4.8	1.30	1.10	0.44	0.44	1.10
<b>On  </b>	0.23	0.33	0.40	1.25	1.23	1.33	0.98	0.32	0.10	0.100	0.120	0.140
<b>Lu/infkm<sup>2</sup></b>	0.936	1.243	0.825	6.927	7.907	4.877	1.764	0.803	0.435	0.209	0.196	0.257
<b>mm</b>	3.26	4.33	2.87	24.1	27.3	17.0	6.14	2.80	1.59	0.73	0.68	0.40
	8.74	11.2	7.70	64.8	66.5	49.6	15.9	7.49	4.11	1.95	1.85	2.13

## ÖZGEÇMİŞ

**Ad-Soyad** : Uğur Akbulut

### Öğrenim Durumu

**Yüksek Lisans:** : İstanbul Aydın Üniversitesi  
Fen Bilimler Enstitüsü, Bilgisayar Mühendisliği

**Lisans:** : Kırgızistan Türkiye Manas üniversitesi  
Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

**Ön Lisans:** : İnönü Üniversitesi  
Teknik Programlar Bölümü, Bilgisayar Programcılığı

### Mesleki Deneyim

**Duamme Bilişim** : Yazılım Uzmanı-İş analisti  
**Üsküdar Üniversitesi** : Yazılım Eğitmenliği  
**Smartpro Bilgisayar Akademisi** : Yazılım Eğitmenliği  
**Learnsis Yazılım** : Yazılım Uzmanı  
**Alfan Ltd.Şti.** : Yazılım Uzmanı

### Yayınlar

**9th International Congress on Fundamental and Applied Sciences Bildirisi**, İleri Veri İşlem Yöntemleri İle Yağış Miktarı Ve Akım Hızının Modellenmesi, İklim Değişiminin Rolü

**Aksaray University Journal Of Science And Engineering**, İleri Veri İşlem Yöntemleri ile Su Kaynaklarının Kullanımı ve Planlanmasının Optimizasyonu

**Applied Sciences**, Hybrid Modeling for Stream Flow Estimation: Integrating Machine Learning and Federated Learning