



Comparison of different machine learning techniques in river flow prediction

Uğur Akbulut^{1*}, Mehmet Akif Çifçi^{2,3,4}, Buket İşler⁵, Zafer Aslan⁶

¹Istanbul Aydın University, Graduate School Computer Engineering, 34295, İstanbul, Türkiye

²The Institute of Computer Technology, Tu Wien University, 1040, Vienna, Austria;

³Bandırma Onyedi Eylül University, Computer Engineering, 10200, Balıkesir, Türkiye

⁴Engineering and Informatics Dept, Klaipėdos Valstybinė Kolegija/Higher Education Institution, 92294, Klaipėda, Lithuania

⁵Topkapi University, Computer Engineering, 34398, İstanbul, Türkiye

⁶Istanbul Aydın University, Computer Engineering, 34295, İstanbul, Türkiye

Highlights:

- Water
- Machine Learnings
- Wavelet
- River flow forecasting

Keywords:

- Flow Estimation
- Temperature
- Precipitation
- Regression
- Wavelet Transform

Article Info:

Research Article

Received: 23.06.2023

Accepted: 23.02.2024

DOI:

10.17341/gazimmfd.1318906

Correspondence:

Author:

Uğur Akbulut

e-mail: akugur@hotmail.com

phone: +90 538 640 1474

Graphical/Tabular Abstract

Water has a complex relationship with agricultural activities, economy, health, use of energy resources and hygiene. In parallel with climate change and population growth, the inadequacy of our water resources in the coming years is one of the major problems we are likely to face. Estimating how much of the available water can be used and how much the water potential will change in the future can enable more accurate water planning. The average flow, total precipitation and average temperature values of Tagar Stream Küçükkuşluk and Porsuk Stream Porsuk Çiftliği Station were analyzed together and the river flow rate was estimated. Linear Regression, Support Vector, Decision Trees, Random Forest and Extra Trees methods were applied for flow estimation. In order to improve the performance of each of the applied models, a hybrid method was developed using Wavelet Transform.

Table A. Comparison of Model Results

Model	Stations	Method Inputs	Most Successful Method	RMSE	R2(%)
LR-SVR-DT-RF-ETR	Porsuk Çiftliği	A _{ort} , Y _{topl} , S _{ort}	ETR	53.8	67.67
	Tagar (Küçükkuşluk)	A _{ort} , Y _{topl} , S _{ort}	ETR	178.43	70.8
W-LR-SVR-DT-RF-ETR	Porsuk Çiftliği	Wavelet-A _{ort} , Y _{topl} , S _{ort}	W-ETR	13.58	91.46
	Tagar (Küçükkuşluk)	Wavelet-A _{ort} , Y _{topl} , S _{ort}	W-ETR	132.24	86.39

Purpose: River flow forecasting to ensure optimized use of water planning in future years

Theory and Methods: In this study, a hybrid model was obtained and analysed by comparing the analysis of machine learning methods with a single model. Daily river flow rate, temperature and precipitation data were analysed using only machine learning methods (Linear Regression, Support Vector Regression, Decision Trees, Random Forest and Extra Trees Regression) by applying standardised pre-processing method and then wavelet model and machine learning methods were applied together.

Results: Wavelet method was applied to hydrological data as a hybrid of flow detail data and machine learning algorithms and 15% and 25% more successful results were obtained at Küçükkuşluk and Porsuk Çiftliği stations, respectively. Higher success rates were obtained in Random Forest and Extra Trees models from machine learning algorithms. It was observed that the combination of machine learning and wavelet transform method was effective in the results and increased the model and model success. When the observation and model results are compared at Porsuk Çiftliği station, the correlation coefficients are calculated as 67.67% for ETR. With the application of the wavelet transform method (D-ETR), the correlation coefficient increased to 91.46% and RMSE decreased from 53.8 to 13.58. For Küçükkuşluk, the coefficient of association calculated as 70.8% with the ETR method increased to 86.39% with the effect of wavelet transform method (D-ETR) and RMSE decreased from 178.43 to 132.24 (Table A).

Conclusion: In the course of this research, a detailed investigation of river flow estimation has been carried out based on rich data from two leading river flow measurement stations in Turkey. These stations are located in different regions of Turkey. One is Küçükkuşluk Streamflow Observation Station D21A228 for Tagar Stream in the Upper Euphrates Basin and the other is Porsuk Çiftliği Streamflow Observation Station D12A033 for Porsuk Stream in the Sakarya Basin. Our study aims to build a robust river flow prediction model by integrating daily average flow, daily average air temperature and daily total precipitation data. In our research, different machine learning algorithms are used to predict daily streamflow and hybrid models supported by wavelet transform are also developed. The results obtained on two rivers are compared. As a result of this comparison, it was observed that the success rates obtained at Porsuk Çiftliği Station were higher than Küçükkuşluk Station. Among the machine learning algorithms, higher success rates were obtained in RF and ETR models. In particular, the inclusion of WT in the machine learning framework led to a significant improvement in the results. This new approach improved the prediction accuracy by approximately 10% and better explained the complexity of time series and irregular data.



Mühendislik Mimarlık Fakültesi Dergisi

Journal of The Faculty of Engineering
and Architecture of Gazi University

Elektronik / Online ISSN : 1304 - 4915
Basılı / Printed ISSN : 1300 - 1884

Makine öğrenme yöntemleriyle nehir akım tahmininde farklı tekniklerinin karşılaştırılması

Uğur Akbulut^{1*}, Mehmet Akif Çifçi^{2,3,4}, Buket İşler⁵, Zafer Aslan⁶

¹İstanbul Aydın Üniversitesi, Bilgisayar Mühendisliği, 34295, İstanbul, Türkiye

²The Institute of Computer Technology, Tu Wien University, 1040 Vienna, Austria;

³Bandırma Onyedi Eylül Üniversitesi, Bilgisayar Mühendisliği, 10200 Balıkesir, Türkiye

⁴Engineering and Informatics Dept, Klaipėdos Valstybinė Kolegija/Higher Education Institution, 92294 Klaipėda, Lithuania

⁵Topkapı Üniversitesi, Bilgisayar Mühendisliği Bölümü, 34398, İstanbul, Türkiye

⁶İstanbul Aydın Üniversitesi, Bilgisayar Mühendisliği Bölümü, 34295, İstanbul, Türkiye

Ö N E Ç İ K A N L A R

- Meteorolojik veriler kullanarak nehir akım tahmini
- Dalgacık modeli ile tahmin başarı oranını arttırma
- Gelecek yıllara yönelik nehir akım tahmini

Makale Bilgileri

Araştırma Makalesi

Geliş: 23.06.2023

Kabul: 23.06.2024

DOI:

10.17341/gazimmfd.1318906

Anahtar Kelimeler:

Akış tahmini,
sıcaklık,
yağış,
regresyon,
dalgacık dönüşümü

ÖZ

Su tarımsal faaliyetlerle, ekonomiyle, sağlıkla, enerji kaynaklarının kullanımı ve hijyen gibi unsurlarla karmaşık bir ilişki içindedir. İklim değişiklikleri ve artan nüfus ile paralel olarak gelecek yıllarda su kaynaklarımızın yetersiz kalması, yaşanması olası başlıca büyük problemlerdendir. Mevcut suyun ne kadarının kullanılabilirliğini ve gelecekte su potansiyelinin ne derece değişeceğini tahmin etmek, su planlamasının daha doğru yapılmasına olanak sağlayabilir. İnceleme bölgesi olarak Tagar Çayı Küçükkuşluk ile Porsuk Çayı Porsuk Çiftliği İstasyonu'na ait ortalama akım, toplam yağış ve ortalama sıcaklık değerleri birlikte analiz edilmiş ve nehir akım hızı tahmini yapılmıştır. Akış tahmini için Lineer Regresyon, Destek Vektör, Karar Ağaçları, Rasgele Orman ve Ekstra Ağaçlar yöntemleri uygulanmıştır. Uygulanan modellerin her birinin başarı performansını artırmak amacıyla Dalgacık Dönüşümü kullanarak hibrit bir yöntem geliştirilmiştir. Veri setinin yaklaşık %65'i eğitim, %15'i doğrulama ve %20'si test verisi olarak ayrılmıştır. Tagar Çayı Küçükkuşluk için %70,8 ve Porsuk Çayı Porsuk Çiftliği için %67,67 oranıyla ETR en başarılı tahmin yöntemi olarak saptanmıştır. Geliştirilen hibrit model bütün yöntemler için başarı oranını artırmış; en yüksek artış Küçükkuşluk için %20,82, Porsuk Çiftliği için %30,64 oranında artarak SVR yönteminde elde edilmiştir. En başarılı yöntem ETR yönteminde %91,46 ve %86,39 oranlarında elde edilmiştir.

Comparison of different machine learning techniques in river flow prediction

H I G H L I G H T S

- River flow forecasting using meteorological data
- Increasing the prediction success rate with the Wavelet model
- River flow forecasting for future years

Article Info

Research Article

Received: 23.06.2023

Accepted: 23.02.2024

DOI:

10.17341/gazimmfd.1318906

Keywords:

Flow estimation,
temperature,
precipitation,
regression,
wavelet transform

ABSTRACT

Water has a complex relationship with agricultural activities, economy, health, use of energy resources and hygiene. In parallel with climate change and population growth, the inadequacy of our water resources in the coming years is one of the major problems we are likely to face. Estimating how much of the available water can be used and how much the water potential will change in the future can enable more accurate water planning. The average flow, total precipitation and average temperature values of Tagar Stream Küçükkuşluk and Porsuk Stream Porsuk Çiftliği Station were analyzed together and the river flow rate was estimated. Linear Regression, Support Vector, Decision Trees, Random Forest and Extra Trees methods were applied for flow estimation. In order to improve the performance of each of the applied models, a hybrid method was developed using Wavelet Transform. Approximately 65% of the dataset is divided into training, 15% validation and 20% test data. ETR was found to be the most successful prediction method with 70.8% for Tagar Stream Küçükkuşluk and 67.67% for Porsuk Stream Porsuk Farm. The developed hybrid model increased the success rate for all methods; the highest increase was obtained in SVR method with 20.82% for Küçükkuşluk and 30.64% for Porsuk Farm. The most successful method was obtained in the ETR method with 91.46% and 86.39%.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *ugurakbulut1@stu.aydin.edu.tr, akif.cifci@tuwien.ac.at, buketisler@topkapi.edu.tr, zaferaslan@aydin.edu.tr, / Tel: +90 538 640 1474

1. Giriş (Introduction)

Dünya üzerinde yaşam olduğu sürece su, canlılar için hem çözüm hem sorun olmaya devam edecektir. Suyu mümkün olduğu kadar sorun noktasından çıkararak çözüm seçenekleri sunmak sublim biliminin görevlerinden biridir. Bu bilimin gelişmesinde insanlığın tarih boyunca başvurduğu, su kaynaklarını verimli kullanma yöntemleri önemli rol oynamaktadır. Hidrolojik döngü nedeniyle tekrar yeryüzüne ulaşan su miktarının değişiminin tahmin edilmesi planlama çalışmalarına katkı sağlamaktadır. Doğa olayları çevre koşullarından etkilenmektedir. Bu etkiler, insan müdahalesi veya atık kaynaklı etkiler sonucunda akarsuların akış yönü üzerinde değişikliklere yol açmaktadır. Sonuç olarak akarsu akış hızının tahmini zorlaşmaktadır. Özellikle sanayileşmenin ve sektör çeşitliliğinin fazla olduğu ülkelerde nüfus artışının etkisiyle kentleşme faaliyetleri, dolayısı ile insan faktörü, yerel havzalara ait hidrolojik dengeyi etkilemektedir [1, 2]. Günümüzde, su kaynaklarının canlıların gereksinimlerini karşılamak için yeterli olduğu düşünülse de iklim değişikliğinin etkisi ve artan nüfus yoğunluğu nedeniyle su krizi, küresel ölçekte bir sorun hâline gelmektedir [3-6]. Dünyada yaklaşık 1384,12 milyon km³ civarında su bulunmaktadır. Bu suyun 1348 milyon km³lük yani yaklaşık %97'lik kısmını denizler, kalan kısmın 27,82 milyon km³ünü buzullar ve 8,062 milyon km³ünü ise yeraltı suları oluşturmaktadır [7]. Canlıların ulaşabilecekleri yerüstü suları ise 0,0225 milyon km³ civarındadır. Ayrıca atmosferde suyun 0,013 milyon km³lük kısmı su buharı olarak bulunmaktadır [8]. Dünyada 884 milyon insan temiz suya erişmemektedir. Bununla beraber 2 milyondan fazla insan güvenli içilebilecek kaliteli sudan mahrum kalmaktadır [9]. Türkiye'ye yıllık ortalama olarak 574 milyar m³ yağış düşmekte olup bu değer yılda ortalama 450 milyar m³ suya karşılık gelmektedir [10, 11]. Toprak ve su yüzeyinden buharlaşan su miktarı 274 milyar m³ civarındadır. Ayrıca akarsularımızdan 158 milyar m³ su akmaktadır. Komşu ülkelerden doğan akarsularla ülkemize 7 milyar m³ su gelmektedir. Ülkemizin yıllık kullanılabilir su potansiyeli 112 milyar m³ olmasına karşın bunun ancak 95 milyar m³lük kısmı verimli olarak kullanılabilir [12]. Kullanılabilir yerüstü suyu yılda ortalama 98 milyar m³ olup bunun yaklaşık 14 milyar m³ü ise yeraltı suyu potansiyeli olarak tahmini hesaplanmaktadır [13]. Ülkemizde 25 su havzası bulunmaktadır ve mevcut su potansiyelleri her bölge için eşit dağılmamaktadır. Ayrıca her havzanın farklı dinamikleri ve sorunları bulunmaktadır. Buna örnek vermek gerekirse Büyük Menderes ve Ergene havzaları kirlilik sorunuyla karşı karşıyadır [14]. Türkiye'de kişi başına düşen yıllık su miktarı ortalaması 2000 yılında 1652 m³, 2009 yılında 1544 m³, 2020 yılında ise 1346 m³ olup bu oran giderek azalmaktadır ve bu değer Türkiye'nin kullanılabilir kaynak bakımından su zengini bir ülke olmadığını, aksine su stresi yaşayan bir ülke olduğunu açıkça göstermektedir [15,16]. Verilerden hareketle dünyada ve ülkemizde kullanılabilir su kaynaklarının verimli kullanımının artırılmasına yönelik çalışmalar yapılması gerekmektedir. Su kaynaklarından canlılar için maksimum fayda sağlanması gerekmektedir. Suyun dinamik yapısı incelenerek ileriye dönük su potansiyeli tahminlerinin yapılması ile kentsel su yönetimi için hayati önerilerde bulunabilir. Su kaynaklarıyla ilgili çalışmalarda su ve atmosfer verileri (yeraltı ve yerüstü akım, rüzgâr, nem, sıcaklık, yağış vb.) farklı karşılaştırmalarla incelenerek anlamlı sonuçlar elde edilebilir. Araştırmacılar son yıllarda yeraltı suyu seviyelerini tahmin etmek için farklı matematiksel modeller de kullanmaktadır [17, 18]. Bu modeller, girdi ve yapısal parametrelerin çokluğu, çeşitli ölçümleme gibi nedenlerle su seviyelerini tahmin etmenin zorluklarını çözecek şekilde oluşturulmuştur [19, 20]. Zaman serileri belirli süre içinde tekrar eden farklı değişken değerlerine ait gözlemlerin belli dönemlerle yapıldığı sayısal değerlerdir. Zaman serileri içerisindeki değerler birbiri ile bağlantılı değişim gösterir [21]. Serinin içindeki değerlerden hareketle en anlamlı bilgiyi çıkarmaya ve gelecekte oluşacak değerleri tahmin etmeye çalışılmaktadır. Zaman, frekans

ortamında analizler yapılabilir [22]. Aynı bölgelerdeki geçmiş yıllara ait veriler birleştirilerek regresyon ve zaman serileri yöntemi dalgacık modeli yardımıyla geçmiş yıllardaki belirli aralıklarla tekrar eden olayları saptayabilir. Yerel ve zamansal olarak ileriye dönük tahmin sonuçları elde edilebilir. Yapılacak bu tahminlerin sonucunda suyun nerelerde ve nasıl kullanılacağı konusunda planlamalar yapılabilir. Suyun uygun ve verimli kullanımını sağlayacak alanlar ve kullanım şekilleri belirlenebilir [23, 24]. Regresyon modellerinin, su kaynakları ve hidrolojik verilerin tahmininde kullanıldığı çok sayıda araştırma bulunmaktadır. Bir başka çalışmada Fırat havzasında eksik akım verileri, regresyon modelleri ve debi verileri kullanılarak tahmin edilmeye çalışılmıştır. Sonuç olarak her iki yöntemle iyi sonuçlar elde edilmiş, ancak regresyon modellerinin daha başarılı sonuçlar verdiği belirtilmiştir [25, 56]. Ayrıca eksik verilerin tamamlanmasında da regresyon analizi yaygın olarak kullanılmaktadır [26, 27].

Yeraltı su kaynaklarının tahmini için kullanılan Destek Vektör Regresyonu (SVR), Decision Tree (DT) gibi en uygun şekle sokma algoritmalarına dayalı diğer istatistiksel veya geliştirilmiş modeller, yeraltı suyu seviyelerini tahmin etmede yüksek başarı oranlarına sahiptir [28-30]. Makine öğrenme modeli olan Random Forest (RF) algoritması da yüksek tahmin performansına sahip basit ve hızlı bir algoritma olduğu için su kaynaklarının tahmin çalışmalarında sıkça kullanılmaktadır [31-33]. Makine öğrenmesi yöntemleri kullanılarak yapılan tahminlerin performansını artırmak için veri ön işleme teknikleri kullanılabilir [57, 58]. Wavelet Transform (WT) bu tekniklerden biridir. WT, hem frekans hem de zaman alanında eşzamanlı olarak zaman serilerini analiz etmektedir [59]. Durağan olmayan zaman serileri için en iyi tekniklerden biri olan dalgacık dönüşümü, verinin farklı frekans bantlarına ayrılması, zaman diliminde bölümler oluşturulması ve böylece kendi frekans içeriklerinin analiz edilmesine olanak tanıyan bir yöntemdir [60]. Dalgacık dönüşüm tekniği ile su kaynakları alanında bilinen ilk çalışma 1993 yılında Kumar ve Foufoula-Georgiou (1993) tarafından yağış verileri üzerine uygulanmıştır [61]. Nehir-akarsu akım analizlerinde de birçok çalışmada kullanılan WT tekniği ile daha başarılı sonuçlar alınmaktadır [34, 35].

Bu çalışma, su kaynaklarının yönetimi ve sürdürülebilir kullanımı açısından büyük bir öneme sahiptir. Su, yaşamın temel taşıdır ve tüm canlı organizmalar için vazgeçilmez bir gerekliliktir. Ancak, son yıllarda artan nüfus, hızla ilerleyen sanayileşme, iklim değişikliği ve doğal kaynakların aşırı kullanımı, dünya genelinde su kaynakları üzerinde büyük baskılara neden olmaktadır. Bu faktörler, su kaynaklarının sınırlı olduğu gerçeğini daha da önemli hale getirirken, suyun etkin bir şekilde yönetilmesi ve gelecek nesiller için korunması gerekmektedir. Özellikle son yıllarda artan nüfus, sanayileşme ve iklim değişikliği gibi etkenler, su kaynaklarının yönetimini zorlaştırmış ve su krizlerinin küresel ölçekte artmasına neden olmuştur. Su krizleri, temiz içme suyu eksikliği, sulama için yetersiz su kaynakları ve çevresel bozulma gibi ciddi sorunlara yol açmaktadır. Bu krizler, sadece insan sağlığına değil, aynı zamanda tarım, sanayi ve ekosistemlere de zarar vermektedir. Dünya genelinde su kaynaklarının durumu da endişe vericidir. Dünya üzerindeki suyun %97'si denizlerde bulunurken, tatlı su kaynakları sadece %3'lük bir paya sahiptir. Bu tatlı su kaynaklarının bir kısmı buzullarda ve yeraltı sularında saklıdır. Diğer bir sorun da su kaynaklarının dağılımının eşitsiz olmasıdır. Bazı bölgeler su zenginiyken diğerleri kuraklıkla mücadele etmek zorundadır. Bu nedenle, su kaynaklarının sürdürülebilir bir şekilde yönetilmesi ve dağıtılması kritik bir öneme sahiptir. Türkiye gibi su kaynaklarının önemli bir rol oynadığı ülkeler, suyun etkin bir şekilde yönetilmesi gereken bölgelerdir. Türkiye'ye yıllık ortalama olarak 574 milyar m³ yağış düşmekte olup bu değer yılda ortalama 450 milyar m³ suya karşılık gelmektedir. Ancak, bu suyun verimli bir şekilde kullanılması gerekmektedir. Ülkemizin

yıllık kullanılabilir su potansiyeli 112 milyar m³ olmasına rağmen bunun ancak 95 milyar m³lük kısmı verimli olarak kullanılabilmektedir. Su kaynakları, Türkiye'nin ekonomik kalkınması ve insanların yaşam kalitesi için hayati bir öneme sahiptir. Bu çalışma, yeraltı su seviyelerinin tahmin edilmesi ve su kaynakları yönetimine ilişkin olarak yapılan bu tür araştırmaların önemini vurgulamakta ve yerel ve ulusal düzeyde su kaynaklarının daha etkili ve sürdürülebilir bir şekilde yönetilmesine yardımcı olabilir. Araştırmacılar, suyun dinamik yapısını inceleyerek ileriye dönük su potansiyeli tahminlerinin yapılması ve kentsel su yönetimi için önemli önerilerde bulunabilirler. Ayrıca bu çalışma, farklı su ve atmosfer verilerinin analiz edilmesiyle anlamlı sonuçlar elde edilmesine katkı sağlayabilir.

Bu çalışmada LR, SVR, DT, RF, Extra Tree Regressor (ETR) algoritma performansları karşılaştırılarak yeraltı suyu akış tahmini yapılmıştır. İnceleme bölgesi olarak Yukarı Fırat Havzası Tagar Çayı Küçükkuşluk ve Sakarya Havzası Porsuk Çayı Porsuk Çiftliği istasyonları seçilmiştir. Akım miktarının tahmini için günlük ortalama akım, bölgeye ait günlük toplam yağış miktarı ve günlük ortalama hava sıcaklığı parametreleri kullanılmıştır. Farklı girdi parametreleri birleşimleri oluşturularak yöntem sonuçları karşılaştırılmıştır. Ayrıca yöntemlerin tahmin performanslarının iyileştirilmesi amacıyla her bir algoritma için dalgacık analizi kullanılarak hibrit bir yöntem geliştirilmiştir. Hibrit modelden elde edilen sonuçlardan yararlanarak Üstel düzleştirme yöntemi, mevsimsellik dikkate alınarak ileri dönük olarak 2030 yılına kadarki tahmin değerleri elde edilmiştir. (Tablo 1)

2. Veri ve Deneysel Yöntem (Material and Experimental Method)

2.1. Çalışma Alanı (Study Area) ve Veri Seti (Dataset)

Fırat Havzası D21A228 numaralı Tagar Çayı Küçükkuşluk akım gözlem istasyonuna ait akım verileri ele alınmış ve analiz edilmiştir. Şekil 1'de istasyonun yeri kırmızı ile belirtilmiştir. D21A228 Numaralı Tagar Çay Küçükkuşluk akım gözlem istasyonunun 2014-2021 su yılları arası günlük ortalama akım verileri kullanılmıştır. Yağış ve sıcaklık verileri Meteoroloji Genel Müdürlüğü aynı dönem 17165 Numaralı Tunceli sahası istasyonu kayıtlarına dayalıdır.

Sakarya Havzasında Kütahya Porsuk çayı Porsuk Çiftliği D12A033 numaralı Porsuk çayı Porsuk Çiftliği akım gözlem istasyonu ait akım verileri kullanılmış ve analiz edilmiştir. Şekil 2'de kırmızı olarak belirtilmiştir. Kütahya-Afyon Yolunun 10 Km'sinden sağa ayrılan Gediz yolunun 1,5 km'sindeki köprüünün yakınındadır. D12A033 numaralı Porsuk çayı Porsuk Çiftliği akım gözlem istasyonuna ait 2014-2021 su yılları arası günlük ortalama akım verileri kullanılmıştır. Kütahya sahası 2014-2021 yılları arası yağış ve sıcaklık verileri 17155 numaralı istasyon günlük verileri kullanılmıştır.

2.2. Metodoloji (Methodology)


Çalışmada hibrit model elde edilmiş makine öğrenmesi yöntemlerinin tek bir modelle yapılan analizler karşılaştırılarak incelenmiştir.

Tablo 1. Literatürdeki çalışmaların kapsamlı özetleri (Comprehensive summaries of studies in the literature)

Kaynak	Başlık	Açıklama
[1, 2]	Sanayileşme ve Nüfus Artışının Hidrolojik Dengeye Etkisi	Bu çalışma, sanayileşmenin ve nüfus artışının hidrolojik denge üzerindeki etkilerini araştırıyor.
[3-6]	Su Kaynakları ve Su Krizi	Küresel ölçekte su krizinin, artan nüfus ve iklim değişikliği nedeniyle bir sorun haline geldiğini belirtiyor.
[5-7]	Dünya ve Türkiye'deki Su Kaynakları İstatistikleri	Dünya su kaynaklarının istatistiklerini sunuyor; denizler, buzullar, yeraltı suları ve yerüstü sularının miktarlarını içeriyor.
[8, 9]	Temiz Su Erişimi ve Kaliteli Su Eksikliği	Dünya genelinde temiz su erişiminin sınırlı olduğu ve birçok insanın kaliteli su eksikliği yaşadığına dikkat çekiyor.
[10, 11]	Türkiye'nin Yağış ve Su Kaynakları	Türkiye'nin yıllık yağış miktarını ve su kaynaklarını detaylı bir şekilde sunuyor.
[15, 16]	Kişi Başına Düşen Yıllık Su Miktarı	Türkiye'de kişi başına düşen yıllık su miktarının azaldığını gösteriyor ve ülkenin su stresi yaşadığını vurguluyor.
[17]	Su Yönetimi ve Planlaması İçin Önem	Su kaynaklarının etkili ve sürdürülebilir bir şekilde yönetilmesi gerektiğini vurguluyor.
[18,20]	Yeraltı Su Seviyelerinin Tahmin Edilmesi	Araştırmacıların yeraltı su seviyelerini tahmin etmek için matematiksel modelleri kullandığını açıklıyor.
[21]	Zaman Serileri ve Tahminler	Zaman serilerinin gelecekteki su potansiyeli tahminleri için önemli olduğunu belirtiyor.
[22]	Su Kaynaklarının Bölgesel Farklılıkları	Türkiye'deki su havzalarının farklı dinamiklere ve sorunlara sahip olduğunu ve her havzanın ayrı değerlendirilmesi gerektiğini vurguluyor.
[23-27]	Regresyon Modelleri ve Su Verileri	Regresyon modellerinin su kaynakları ve hidrolojik verilerin tahmininde kullanıldığını ve iyi sonuçlar verdiğini belirtiyor.
[28-30]	Yeraltı Su Seviyelerini Tahmin Etme Algoritmaları	Yeraltı su seviyelerini tahmin etmek için kullanılan SVR, DT, ve RF algoritmalarının yüksek başarı oranlarına sahip olduğunu açıklıyor.
[29]	Makine Öğrenme ve Su Tahminleri	Makine öğrenme yöntemlerinin su tahminlerinin performansını artırmak için kullanılabileceğini belirtiyor.
[30]	Dalgacık Dönüşümü ve Su Kaynakları Analizi	Dalgacık dönüşümünün zaman serilerini analiz etmek için etkili bir teknik olduğunu vurguluyor.
[31-33]	Türkiye'deki Su Akışı Tahmini	Bu çalışma, Türkiye'deki farklı bölgelerdeki su akışlarını tahmin etmek için LR, SVR, DT, RF ve ETR algoritmalarını kullanıyor.
[34]	Hibrit Model ve Su Tahmin Performansı	Hibrit bir modelin kullanılarak su tahmin performansının iyileştirildiğini açıklıyor.
[35]	İleriye Dönük Tahminler ve Su Kullanımı	Üstel düzleştirme yöntemi kullanılarak suyun gelecekteki kullanımını tahmin etmek için 2030 yılına kadar uzanan değerler sunuyor.



Şekil 1. Çalışma alanı (D21A228) Tagar Çayı Küçükkuşluk akım gözlem istasyonu konumu
(Study Area alanı (D21A228) Tagar Stream Küçükkuşluk current observation station location) [36].



Şekil 2. Çalışma alanı (D12A033) Porsuk Çayı Porsuk Çiftliği akım gözlem istasyonu konumu
(Study Area alanı (D12A033) Porsuk Çayı Porsuk Çiftliği current observation station location) [37].


Çalışmada izlenen yöntem ve işlem adımları Şekil 3'te akış diyagramı olarak sunulmuştur. Günlük nehir akım hızı, sıcaklık ve yağış verileri standartlar önileme yöntemi uygulanarak yalnız makine öğrenme yöntemleri (Lineer Regresyon, Destek Vektör Regresyonu, Karar Ağaçları, Rasgele Orman ve Ekstra Ağaçlar Regresyon) kullanarak sonrasında dalgacık modeli ile makine öğrenme yöntemleri birlikte uygulanarak akım hızı tahmin karşılaştırması yapılmıştır.

Şekil 3'te görüldüğü üzere sadece incelenen akım gözlem istasyonu verileri değil günlük iklim verileri ile de çalışılmıştır. Akım hızını tahmin etmek için akım gözlem istasyonundan alınan verilerle yağış ve sıcaklık verileri birlikte analiz edilmiştir. Veriler elde edildikten sonra yapılan ilk işlem, eksik verilerin tamamlanması ve verilere ön işlem uygulaması olmuştur. Ardından veriler normalize edilmiştir. Normalizasyon işlemi ile program çalışma hızı artırılmış ve bellek ekonomisi sağlanmıştır [38]. Bu çalışmada veriler [0,1] aralığına

normalize edilmiştir. Veri ön işlemeden sonra tanımlayıcı istatistiksel analizler kullanılarak veriler arasında ilişkilerin bulunulması hedeflenmiştir. Sonuçları yorumlarken tanımlayıcı istatistiksel analizlerden de faydalanılmıştır. Sonraki adımda ise veriler 5 farklı makine öğrenme algoritması ile analiz edilmiştir. Tahmin performansını artırmak üzere düşünülen Dalgacık Dönüşümü yöntemi kullanılarak hibrit bir yöntem geliştirilip veriler tekrar analiz edilmiştir. En son aşamada tahmin performansları karşılaştırılmış ve ileriye yönelik nehir akış tahmin sonuçları açıklanmıştır.

2.3. Korelasyon, Determinasyon ve Ortalama Hata Karekökü (Correlation, Determination and Root Mean Square Error)

İki veya daha fazla değişkenler arasındaki ilişkinin şiddeti, yönü hakkında bilgi veren bağıntıya korelasyon analizi denir. Değişkenler arasında neden sonuç ilişkisi olmasına gerek yoktur. Korelasyon



Şekil 3. Geliştirilen Modelin Akış diyagramı (Flowchart of the architecture)

katsayısı değişkenler arasındaki ilişki derecesi korelasyon katsayısını belirler. Değişkenler arasında ters orantı varsa negatif, doğru orantılı bir ilişki varsa pozitif yönlü bir korelasyon mevcuttur. Korelasyon katsayısı genel olarak 'R' harfi ile gösterilir [65]. Determinasyon katsayısı korelasyon katsayısının karesine eşittir. Çıkan sonuçların determinasyon katsayısına uyumu çözümün doğruluğunu, veri noktasının çokluğu ise güvenilirliğini gösterir. Determinasyon katsayısı 'R²' ile gösterilir. Edilen tahmin sonuçlarının gerçek verilerin oluşturduğu eğriye dik uzaklıklarının toplamının karekökü Ortalama Hata Karekökü (RMSE) değerini verir. Düşük RMSE değeri modelin verilere uyum sağladığını doğru tahminler oluştuğunun ispatıdır.[66]

2.4. Yöntem (Method)

Kullanılan makine öğrenme algoritmalarını seçmemin temel nedeni, bu algoritmaların farklı tipteki verilerdeki ilişkileri modelleme yetenekleri ve geniş uygulama alanlarıdır. Lineer Regresyon, veriler arasındaki doğrusal ilişkileri modeller ve bu ilişkileri açıkça ifade edebilir. Bu nedenle, veriler arasındaki basit ve açık doğrusal ilişkileri anlamak ve tahminlerde bulunmak için tercih edilir. Özellikle, bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini anlamak istediğinizde bu algoritma çok kullanışlıdır. Öte yandan, SVR, doğrusal olmayan veri ilişkilerini modelleme yeteneği sunar. Bu algoritma, veriler arasındaki karmaşık ve doğrusal olmayan ilişkileri ele alabilir, bu nedenle daha esnek bir tahmin yapma yeteneğine sahiptir. Özellikle regresyon görevlerinde, veriler arasındaki non-lineer ilişkileri anlamak ve tahmin etmek istediğinizde SVR kullanmak daha uygundur. Bu iki algoritma, veri setinin yapısına ve analiz gereksinimlerine bağlı olarak kullanılabilir güçlü araçlardır.

Lineer Regresyon, basit ve doğrusal veri ilişkilerini anlamak için en uygun çözüm iken, SVR, daha karmaşık ve non-lineer veri yapılarını ele almak için daha uygundur. Bu nedenle, her iki algoritmayı seçmek, verilerin özelliklerine ve analiz hedeflerine uygun bir yaklaşımın benimsenmesini sağlar.

2.4.1. Makine öğrenmesi algoritmaları (Machine learning algorithms)

Makine Öğrenmesi, ham veya işlenmiş veri üzerinden bilgi elde eden ve hesaplama yöntemleri geliştiren, sürekli olarak öğrenerek ve bu verilere göre tahminler yapan, ardından özel modeller oluşturabilen yapay zekânın bir alt kategorisidir [39]. Makine öğrenmesi yöntemleriyle, geçmişteki veriyi kullanarak uygun modeller oluşturur ve tahmin yöntemleri geliştirilebilir [40, 41].

Lineer İlişki (Lineer Regression): İki değişken arasındaki doğrusal ilişkiyi inceleyen istatistiksel yöntemle doğrusal ilişki ve basit doğrusal regresyon denilir. Makine öğrenmesinde doğrusal (lineer) model Eş 1'de belirtildiği gibi hesaplanır. Bağımsız değişken (x), bağımlı değişken (y) ile ifade edilmektedir [42].

$$y = a + bx + \epsilon \quad (1)$$

Eşitlikte verilen a değeri, doğrunun y eksenini kestiği noktayı (y-kesişim) temsil ederken analitik yöntemde sabit hata ölçüsüdür. Öte yandan, b olarak gösterilen değer regresyon katsayısını (eğim) gösterir. Analitik yöntemde oransal (proporsiyonel) hata ölçüsüdür.

Destek Vektör Regresyonu (Support Vector Regression): Evrensel ileri beslemeli ağların bir çeşidi olan SVR, sinir ağlarının geleneksel


denetimli öğrenme yöntemleri ile karşılaştırıldığında, sadece deneysel ölçüm hatasını (Empirical risk minimization) değil, aynı zamanda genelleme hatasının üst sınırını da azaltmayı amaçlayan yapısal riski minimuma indirme (Structural risk minimization) ilkesini kullanır [43]. Şekil 4'te görseli paylaşılmıştır. Sınıflandırma yöntemlerindeki amaç bir sonraki değerin hangi sınıfa ait olduğuna karar vermektir. Bu sınıflandırmanın yapılabilmesi için şekilde verildiği üzere iki sınıfı ayıran bir doğru çizilmektedir. Çizilen doğrunun ± 1 arasında kalan bölgeye marjın denilmektedir. Marjın ne kadar geniş ise sınıflar arasında ayrışma o kadar fazla olmaktadır.

Karar Ağacı (Decison Tree): Karar Ağaçları, tahmin ve sınıflandırma problemlerinde en yaygın kullanılan makine öğrenimi yöntemlerinden biridir, çünkü kolayca anlaşılabilirler. Girdi verileri kümeleme algoritmalarıyla gruplara ayrılır ve ardından bu gruplar tekrar tekrar Test_ort_hata edilerek sonuçta bir karar ağacı oluşturulur [44]. Şekil 5'te bu konsepti gösteren bir görsel bulunmaktadır. Bir karar ağacı, tipik olarak bir ağaç yapısına sahiptir, bu da kök, dallar ve yapraklardan oluşur. Karar ağacı, her iç düğümde bir özellik


(öznitelik) Test_ort_hata edildiği, Test_ort_hata sonucunun bir dalda ve sonunda bir yaprak düğümünde sonuçlandığı bir yapıya sahiptir [3]. Kök düğüm, ağacın en üst düğümüdür ve diğer düğümlerin atasıdır. Bir karar ağacı, her düğümün bir özellik (öznitelik) temsil ettiği, her bağlantının (dal) bir karar (kural) içerdiği ve her yaprağın bir sonuç (kategorik veya sürekli bir değer) sunduğu bir ağaçtır [4]. Karar ağaçları, insan düşünme sürecini taklit ettiği için verileri anlamak ve anlamlı yorumlar yapmak için oldukça basittir. Temel fikir, tüm veriler için bu tür bir ağaç oluşturmak ve her yaprak düğümünde tek bir sonuca ulaşmaktır.

Rastgele Orman (Random Forest): Rastgele Orman, eğitilmiş karar ağaçlarından oluşan denetimli öğrenme algoritmasıdır. Birden fazla karar ağacından oluşan rastgele orman sınıflandırma ve regresyon problemlerinin çözümünde kullanılabilir [44]. Şekil 6'da görseli paylaşılmıştır.

Ekstra Ağaçlar (Extra Trees): Ekstra Ağaçlar, Rastgele Orman ile benzer yapıya sahiptir. Sınıflandırma kararı, ağaç topluluğunda



Şekil 4. Örnek bir dağılım grafiği için SVR yönteminde eşik ve hata tanımı (Similar and error definition in SVR method for an example scatter plot) [45]



Şekil 5. Karar Ağacı (Decision Tree)[47]

çoğunluğa göre verilir. Dğümleri ayırmak için rastgele kesme noktaları seçilir. Ekstra ağaçlar girdi verisi olarak orijinal örneğin tamamını kullanır [50]. Şekil 7’de görseli paylaşılmıştır.

2.4.2. Dalgacık dönüşümü (Wavelet transform)


Zaman serileri her ne kadar karmaşık görünse de belli bir matematik kurala dayandırılabilir [63]. Dalgacık dönüşümü sinyallerin frekans ve zaman ortamında gözlemlemek ve tanımlamak için kullanılan modellerdendir. Ardışık ve durağan olmayan sinyallerin değişimini inceleyerek dalgacık dönüşüm zaman serisini bölerek analiz edilen zaman serisinin tekrarlarını ve zaman içinde nasıl değiştiğini gösterir [45, 46, 64]. Çalışma kapsamında seçilen verilerin kaotik yapısı nedeniyle tahmin edilmesi zordur. WT yönteminin iklim verileri üzerinde yapılan tahmin çalışmalarında başarılı sonuçlar verdiği literatür taramalarında görülmüştür [50, 51]. Bu yöntem, analizde kullanılan yöntemlerin başarısını arttıracakı düşünülerek çalışmada kullanılmıştır. WT için birçok dalgacık fonksiyonları kullanılabilmektedir. Bu çalışmada Daubechies dalgacık ailesi kullanıldı. Nehir akım hızı tahmininde daha başarılı sonuçlar elde edilmiştir. Nehir akımı mevsimsel belli trendler oluştursa da günlük ölçümler farklı frekanslarda akımlar oluşturmamasından Daubechies’e daha uygun sonuçlar ortaya koymuştur [67]. Çalışmada, ortalama akım hızı, toplam yağış ve ortalama sıcaklık verileri ile dalgacık dönüşümü analizi uygulanarak orijinal veriler alt bileşenlerine

ayrılmıştır. Elde edilen yeni verilerle orijinal akım verisi arasındaki ilişki katsayısı toplanmış, akım verisi üzerinde etkili olduğu saptanan ayrıntı katsayıları ile hibrit yöntem geliştirilmiş ve akım tahmini yapılmıştır.


3. Deneysel Sonuçlar (Computational Results)

3.1. İstatistiksel Sonuçlar (Statistical Results)

Bu çalışmada, Sakarya Havzası, D12A033 numaralı Porsuk Çayı Porsuk Çiftliği akım gözlem istasyonu için 01 Ekim 2014-30 Eylül 2021 tarihleri arası Günlük Ortalama Akım, Günlük Ortalama Yağış, Günlük Ortalama hava sıcaklığı verileri kullanılmıştır. Toplam 2556 adet günlük verilere ait istatistiksel değerler Tablo 2’de gösterilmektedir. 01 Ekim 2014 – 30 Eylül 2020 yılları arası 2191 adet günlük veri eğitim için, 01 Ekim 2020-30 Eylül 2021 yılları arasındaki 365 adet günlük veri Test_ort_hata için kullanılmıştır. Yukarı Fırat havzası, D21A228 Numaralı Tagar Çayı Küçükumluk akım gözlem istasyonu 01 Şubat 2014- 30 Eylül 2021 tarihleri arası Günlük Ortalama Akım, Günlük Ortalama Yağış, Günlük Ortalama hava sıcaklığı verileri kullanılmıştır. Toplam 2799 adet günlük verilere ait istatistiksel değerler 3’te gösterilmektedir. 01 Şubat 2014- 30 Eylül 2020 yılları arası 2432 adet günlük veri eğitim için, 01 Ekim 2020-30 Eylül 2021 yılları arasındaki 365 adet günlük veri Test_ort_hata için kullanılmıştır.



Şekil 6. Rastgele Orman modelinin genel yapısı (Random Forest Classifier (RFC)) [48]



Şekil 7. Ekstra Ağaçlar (Extra Tree) [49]

Tablo 2 ve Tablo 3'ü karşılaştırdığımızda Küçükkuşluk istasyonu ortalama akım değerinin Porsuk Çiftliği istasyonundan yaklaşık iki katı kadar yüksek olduğu saptanmıştır. Porsuk Çiftliği istasyonunda toplam yağış miktarı düşük ve Küçükkuşluk istasyonunda maksimum yağış miktarının %25 oranda daha yüksek olduğu belirlenmiştir.

3.2. Makine Öğrenmesi Uygulamaları (Machine Learning Applications)

Çalışma kapsamında kullanılan verileri üzerinde beş farklı makine öğrenmesi yaklaşımıyla analiz yapılmıştır. Porsuk Çiftliği ve Küçükkuşluk akım gözlem istasyonlarına ait günlük ortalama akım, bölgeye ait günlük toplam yağış miktarı ve günlük ortalama hava

sıcaklığı değerleri kullanılmış ve akım tahmini yapılmıştır. Analiz sonuçları Porsuk Çiftliği için Tablo 4 ve Şekil 8'de verilmiştir. İncelemelere göre gözlem ve model sonuçları arasında en yüksek R2 Test_ort_hata değeri sırasıyla ETR ve RF yöntemleriyle %67,7 ve %65,6 bulunmuştur ($\alpha=0,01$).

Çalışmada göz önüne alınan diğer bir inceleme bölgesi olan Küçükkuşluk istasyonu için makine öğrenmesiyle yapılan analiz sonucunda performans karşılaştırılması Tablo 5 ve Şekil 9'da verilmiştir. Analiz sonuçlarına göre tahminde en yüksek başarı gösteren yöntemler RF, ETR ve SVR algoritmaları olmuştur. Tahmin ve gözlem değerleri arasındaki ilişki katsayısı başarı oranı RF için %69,9, ETR için %70,8 bulunmuştur ($\alpha=0,01$).

Tablo 2. Porsuk Çiftliği veri kümesine ait istatistiksel değerler (Statistical values of Porsuk Çiftliği dataset)


Veri Tipi	Ortalama	Min	Maks	Standart Sapma	Çarpıklık	Değişinti	Mod (En Çok Tekrar)	Medyan (Ortanca)
Günlük Ortalama Akım(m ³ /sn)	2,93	0,11	28,7	3,22	2,72	10,37	0,19	2,2
Günlük Toplam Yağış(mm=kg/m ²)	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

Tablo 3. Küçükkuşluk veri kümesine ait istatistiksel değerler (Statistical values of Küçükkuşluk dataset)

Veri Tipi	Ortalama	Min	Maks	Standart Sapma	Çarpıklık	Değişinti	Mod (En Çok Tekrar)	Medyan (Ortanca)
Günlük Ortalama Akım (m ³ /sn)	7,67	0,98	72,80	9,85	2,51	97,04	1,45	3,20
Günlük Toplam Yağış(mm=kg/m ²)	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

Tablo 4. Porsuk Çiftliği akım hızı (m³/sn) eğitim ve Test_ort_hata sonuçları karşılaştırılması (Comparison of Porsuk Çiftliği training and Test_ort_hata results)

Model	R2_train %	R2_Test_ort_hata %	Bağıl Mutlak Hata (RAE) Eğitim ort_hata %	Bağıl Mutlak Hata (RAE) Test_ort_hata %	rmse_train %	rmse_Test_ort_hata %
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 8. Porsuk Çiftliği akım hızı eğitim ve Test ortalama hata sonuçları (Porsuk Çiftliği training and test absolute error results)

3.3. Dalgacık- Makine Öğrenmesi Uygulamaları (Wavelet -Machine Learning Applications)


Analizde kullanılan makine öğrenme yöntemlerinin sonuçlarını iyileştirmek için dalgacık dönüşümü uygulanarak hibrit yöntemler geliştirilmiş ve oluşturulan yeni hibrit modellerle veriler tekrar analiz edilmiştir. Porsuk çayı Porsuk Çiftliği akım gözlem istasyonlarına ait karşılaştırmalı sonuçlar Tablo 6 ve Şekil 10'da verilmiştir. Dalgacık dönüşüm kullanılarak yapılan analizde en iyi performans gösteren iki yöntemin R2_Test_ort_hata değeri RF ve ETR için sırasıyla %90,38, %91,46 bulunmuştur, ($\alpha=0,01$). Porsuk Çiftliği dalgacık analizine ait 1-D ve Continuous 1-D grafikleri Şekil 11 ve Şekil 12'de paylaşılmıştır. Hibrit yöntemle başarısı en çok artan yöntem SVR yöntemi olmuş ve artış oranı %23,79 olarak saptanmıştır. El -Nino, La-Nina yılları ile akım değerleri arasındaki ilişki aşağıdaki gibi saptanmıştır, [52]. Yapılan gözlemlere göre, 2014-2015 dönemi, zayıf, 2015-2016 dönemi kuvvetli El-Nino dönemlerine karşı gelmektedir (Hava sıcaklığı ve aylık toplam yağışların ortalamalar üzerinde olduğu dönemler). 2016-2017 ve 2017-2018 yılları Zayıf La-Nina Dönemi olarak kaydedilmiştir. Soğuk olan bu dönemlerde Türkiye genelinde yıllık toplam yağış miktarı ortalamasının altında kaydedilmiştir. 2018-2019 dönemi, El-Nino yılı olarak kaydedilmiş olup, (sıcak), yağış miktarının ortalamaların üstünde kaydedildiği dönemlere karşı gelmektedir. 2020-2021 ve 2021-2022 dönemleri orta şiddette La-Nina dönemi olarak kayıtlara geçmiştir [52, 53]. Şekil

12'de ilk iki yıl, (2014-15) El-Nino yılı ile yüksek yağış ve akım değerleri gözlenmiştir. 2016-18 dönemi zayıf La-Nina dönemine karşı gelmekte olup, düşük yağış miktarı ile ilişkili olarak düşük akım değerleri kaydedilmiştir. Şekil 15'e göre, Tagar Akım İstasyonu ve civarında, ilk 3 yıl, (2014-16) El-Nino yılında, yüksek yağışa bağlı, yüksek akım değerleri birlikte gözlenmiştir. 2017-18 dönemi zayıf La-Nina nedeni ile ortalamasının altında yağış kaydedilmiş, 2018-19 döneminde tekrar El-Nino nedeni ile ortalamasının üzerinde yağış ve yüksek akım değerleri gözlenmiştir.

Şekil 11 ve Şekil 12'de Porsuk Çiftliği istasyonu akım verilerine dayalı olarak, 1D-Wavelet ve 1D-Continuous Wavelet analizleri sunulmaktadır. Yüksek akım değerleri yüksek d1 (büyük ölçekli), d2 (orta ölçekli) ve d3 (büyük ölçekli) ayrıntıları ile ilişkili olmaktadır. Her üç ölçeğin katkısı birbirine benzer olarak yorumlanabilir. Yüksek akım değerleri, bir ay ile 4 ay arasında değişen tekrarlanma periyoduna sahiptir. Hibrit yöntem uygulanan Küçükkuşluk için analiz sonuçları Tablo 7 ve Şekil 11'de verilmiştir. Küçükkuşluk dalgacık analizine ait 1-D ve Continuous 1-D grafikleri Şekil 14 ve Şekil 15'te paylaşılmıştır. R2_Test_ort_hata sonuçlarına göre en başarılı iki yöntem RF ve ETR algoritmaları olmuştur. Gözlem ve model arasında sırasıyla %84,41 ve %86,39 bulunmuştur. Hibrit yöntem uygulandıktan sonra başarı oranı en fazla yükselen yöntem SVR, %20,82 oranında daha fazla başarı göstermiştir.

Tablo 5. Küçükkuşluk eğitim ve Test_ort_hata sonuçları karşılaştırılması
(Comparison of Küçükkuşluk training and Test_ort_hata results)


Model	R2_train %	R2_Test_ort_hata %	Bağıl Mutlak Hata (RAE) Eğitim ort_hata %	Bağıl Mutlak Hata (RAE) Test ort_hata %	rmse_train %	rmse_Test_ort_hata %
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 9. Küçükkuşluk eğitim ve Test_ort_hata sonuçları (Küçükkuşluk training and Test_ort_hata results)

Tablo 6. Dalgacık Dönüşümü Porsuk Çiftliği eğitim ve Test_ort_hata sonuçları karşılaştırılması
(Comparison of Wavelet Transform Porsuk Çiftliği training and Test_ort_hata results)

Model	R2_train %	R2_Test_ort_hata %	Bağıl Mutlak Hata (RAE) Eğitim ort_hata %	Bağıl Mutlak Hata (RAE) Test ort_hata %	rmse_train %	rmse_Test_ort_hata %
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 10. Dalgacık Dönüşümü Porsuk Çiftliği eğitim ve Test_ort_hata sonuçları
(Wavelet Transform Porsuk Çiftliği training and Test_ort_hata results)



Şekil 11. Porsuk Çiftliği Günlük Ortalama Akım Dalgacık 1-D Db, Level 3
(Porsuk Farm Daily Average Flow Wavelet 1-D Db, Level 3)

Şekil 14 ve Şekil 15 de Küçükkumluk için akım değerlerinin 1D Wavelet ve 1D Continuous Wavelet analizleri sunulmaktadır. Yüksek akım değerleri üzerinde d1-d3 ayrıştırma bileşenleri ortak etki göstermekle beraber, büyük ölçekli olayların rolünün (d3 genlikleri) daha fazla olduğu vurgulanabilir. Şekil 15'e göre büyük ölçekli olayların (lacivert, fuşya 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. Büyük ölçekli olaylar, Porsuk Çiftliğine göre, Küçükkumluk ve civarında daha fazla etkin rol oynamaktadır. Porsuk Çiftliği için Günlük Ortalama Akım Hızı (Test_ort_hata verileri) Tahmini Dağılım Grafiği(Daily average Flow Rate (Test_avg_error data) Estimated Scatter Plot for Porsuk Farm) Şekil


16'da gösterilmektedir. Porsuk Çiftliği istasyonu akım tahmin uygulamasında, Şekil 16'da (i-l) ETR RF modellerinde gerçekleştirilen hibrit yaklaşımın başarı üzerinde belirgin bir olumlu etkisi olduğu gözlenmektedir. Bu etki, dalgacık transformasyonunun bu modellerle birleştirilmesiyle daha kesin ve güvenilir tahminlerin yapılabildiğini vurgular. ETR ve RF modelleri, bu hibrit yaklaşımla birlikte, akım hızı tahmini konusunda daha yüksek doğruluk sağlamaktadır. Bu sonuçlar, akım tahmin uygulamalarında Hibrit modelleme yöntemlerinin potansiyelini ve veri dönüşümünün önemini vurgular niteliktedir. Akım tahmininde kullanılan bu gelişmiş yöntemler, su kaynaklarının sürdürülebilir yönetimi ve çevresel etkilerin minimize edilmesi gibi çeşitli uygulamalarda önemli rol oynamaktadır.



Şekil 12. Porsuk Çiftliği Günlük Ortalama Akış, Wavelet Continuous 1-D
(Porsuk Farm Average Daily Flow, Wavelet Continuous 1-D)

Tablo 7. Dalgacık Dönüşümü Küçükkumluk eğitim ve Test_ort_hata sonuçları karşılaştırılması
(Comparison of Wavelet Transform Küçükkumluk training and Test_ort_hata results)


Model	R2_train %	R2_Test_ort_hata %	Bağıl Mutlak Hata (RAE)Eğitim_ort_hata %	Bağıl Mutlak Hata (RAE)Test_ort_hata %	rmse_train %	rmse_Test_ort_hata %
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 13. Dalgacık Dönüşümü Küçükkumluk eğitim ve Test_ort_hata sonuçları
(Wavelet Transform Küçükkumluk training and Test_ort_hata results)

Küçükkumluk için Günlük Ortalama Akım Hızı (Test_ort_hata verileri) Tahmini Dağılım Grafiği(Daily average Flow Rate (Test_avg_error data) Estimated Scatter Plot for Kucukumluk) Şekil

17'de gösterilmektedir. Küçükkumluk istasyonu akım tahmin uygulaması, Şekil 17'de (i-l) ETR ve RF modellerinde hibrit uygulamanın başarı seviyesini önemli ölçüde artırdığını




Şekil 14. Küçükkuşluk Günlük Ortalama Akım Hızı Dalgacık 1-D Db, Level 3
(Küçükkuşluk Daily Average Current Velocity Wavelet 1-D Db, Level 3)




Şekil 15. Küçükkuşluk Günlük Ortalama Akım Hızı Wavelet Continuous 1-D
(Küçükkuşluk Daily Average Current Velocity Wavelet 1-D Db, Level 3)

göstermektedir. Bu grafik, akım tahmininin etkinliği açısından değerli bilgiler sunmaktadır. Özellikle dikkat çeken bir nokta, Porsuk Çiftliği istasyonu için elde edilen sonuçlarla Küçükkuşluk istasyonu için elde edilen sonuçlar arasındaki farklılıklardır. Porsuk Çiftliği istasyonu için, Hibrit yaklaşımın daha yüksek bir başarı oranı sağladığı belirtilmiştir. Bu, Dalgacık Transformasyonu ile kullanılan modellerin Porsuk Çiftliği istasyonundaki akım tahmininde daha

etkili olduğunu göstermektedir. Ancak, Küçükkuşluk istasyonunda da Hibrit uygulamanın başarıyı artırdığı açıkça görülmektedir. Bu, Hibrit yaklaşımın sadece Porsuk Çiftliği değil, farklı istasyonlarda da olumlu sonuçlar verdiğini vurgulamaktadır. İstasyonlar arasındaki başarı farklılıkları, coğrafi ve çevresel farklılıklardan kaynaklanabilir ve bu, akım tahmini modellerinin yerel koşullara nasıl adapte edilebileceği konusunda önemli bir bulgudur.



Şekil 16. Porsuk Çiftliği için Ortalama Akım Hızı Tahmini Dağılım Grafiği (a) Makine Öğrenmesi modelleri b) Dalgacık Transformasyonu ve Makine öğrenmesi modelleri (Hibrit) c) Lineer Regresyon d) Dalgacık Transformasyonu ve Lineer Regresyon (Hibrit) e) Support Vector Regresyon f) Dalgacık Transformasyonu ve SVR (Hibrit) g) Decision Tree h) Dalgacık Transformasyonu ve Decision Tree (Hibrit) i) Random Forest j) Dalgacık Transformasyonu ve Random Forest (Hibrit) k) Extra Trees l) Dalgacık Transformasyonu ve Extra Trees (Hibrit)) (Scatter Plot of Average Flow Rate Prediction for Posuk Farm (a) Machine Learning models b) Wavelet Transform and Machine Learning models (Hybrid) c) Linear Regression d) Wavelet Transform and Linear Regression (Hybrid) e) Support Vector Regression f) Wavelet Transform and SVR (Hybrid) g) Decision Tree h) Wavelet Transform and Decision Tree (Hybrid) i) Random Forest j) Wavelet Transform and Random Forest (Hybrid) k) Extra Trees l) Wavelet Transform and Extra Trees (Hybrid))



Şekil 17. Küçükkuşluk için Ortalama Akım Hızı Tahmini Dağılım Grafiği (a) Makine Öğrenmesi modelleri b) Dalgacık Transformasyonu ve Makine öğrenmesi modelleri (Hibrit) c) Lineer Regresyon d) Dalgacık Transformasyonu ve Lineer Regresyon (Hibrit) e) Destek Vektör Regresyon f) Dalgacık Transformasyonu ve SVR (Hibrit) g) Karar Ağacı h) Dalgacık Transformasyonu ve Karar Ağacı (Hibrit) i) Rastgele Orman j) Dalgacık Transformasyonu ve Rastgele Orman (Hibrit) k) Ekstra Ağaçlar l) Dalgacık Transformasyonu ve Ekstra Ağaçlar (Scatter Plot of Mean Current Velocity Estimation for Küçükkuşluk (a) Machine Learning models b) Wavelet Transform and Machine Learning models (Hybrid) c) Linear Regression d) Wavelet Transform and Linear Regression (Hybrid) e) Support Vector Regression f) Wavelet Transform and SVR (Hybrid) g) Decision Tree h) Wavelet Transform and Decision Tree (Hybrid) i) Random Forest j) Wavelet Transform and Random Forest (Hybrid) k) Extra Trees l) Wavelet Transform and Extra Trees)

3.4. Gelecek Tahmin Senaryoları (Future Prediction Scenarios)


Üstel düzeltirme yöntemi ve gözlemlenen verilerinden yararlanarak bilinmeyen parametreler için yeni değerler elde edebilir. Zaman serisi verilerinin üstel düzeltilmesi ile eski verilere daha az ağırlık ve yeni verilere daha fazla ağırlık verilir. Değişim ve sıçramalarda dikkate alınarak tahminlerin oluşturulduğu yöntemdir [54]. Bu yöntem sonucunda 2030 yılına kadar tahmin grafiği Şekil 18’de (Porsuk Çiftliği), Şekil 19’da (Küçükkumluk) sunulmuştur. İstatistiksel tabanlı yöntemler, mevcut tüm verilere göre bir tahmin eğrisine uymaya çalışır. Oluşan eğrinin uzantısı gelecek tahminini oluşturur. Tahmin eğrisinin belli bir trend oluşturması geçmiş yıllardaki istatistiklerden kaynaklanır [55]. Mevsimselliğin dikkat edildiği Porsuk Çiftliği ve Küçükkumluk için oluşturulan tahmin değerlerinde artan bir eğilim olacağı saptanmıştır. Akım değerlerinde 2030 yılına kadar artış olacağı tahmin edilmektedir. Her iki istasyonda akım değerlerinde beklenen artış karşılaştırıldığında, Küçükkumluk istasyonu için Porsuk Çiftliği göre %1-%5 güvenle %10 daha fazla artış beklenebileceği söylenebilir.

4. Tartışmalar (Discussions)


Çalışmada Sakarya Havzası Porsuk Çayı alt havzasına ait D12A033 numaralı Porsuk Çayı Porsuk Çiftliği akım gözlem istasyonu ve Yukarı Fırat Havzası, D21A228 numaralı Tagar Çayı Küçükkumluk Akım Gözlem İstasyonu “günlük ortalama akım”, “günlük ortalama hava sıcaklığı”, “günlük toplam yağış” verileri kullanılmıştır. Türkiye’deki iki akarsu üzerinde akım gözlem istasyonlarında

kaydedilen verilerden faydalanılarak akarsu akım tahmin modeli oluşturulmaya çalışılmıştır. Günlük akım, sıcaklık ve yağış verileri ile farklı makine öğrenmesi algoritmaları kullanılarak akım tahmini yapılmış, dalgacık modeliyle hibrit model oluşturularak modellerin başarıları artırılmıştır. Ayrıca beş farklı makine öğrenmesi yönteminin başarı oranları karşılaştırılmıştır. Dalgacık yönteminde akım ayrıntı verileri ile makine öğrenmesi algoritmaları hibrit olarak hidrolojik verilere uygulanmış ve Küçükkumluk ile Porsuk Çiftliği istasyonlarında sırası ile %15 ve %25 daha başarılı sonuçlar elde edilmiştir. Makine öğrenmesi algoritmalarından Rasgele Orman ve Ekstra Ağaçlar modellerinde daha yüksek başarı oranları elde edilmiştir. Makine öğrenmesi ve dalgacık dönüşümü yönteminin birlikte uygulanmasının (Tablo 3 ve Tablo 5’e göre) sonuçlarda etkili olduğu, model ve model başarısını yükselttiği görülmüştür. Porsuk Çiftliği istasyonunda gözlem ve model sonuçları karşılaştırıldığında, ilişki katsayıları ETR için %67,67 olarak hesaplanmıştır. Dalgacık dönüşümü yönteminin (D-ETR) uygulanması ile ilişki katsayısı %91,46’ya yükselmiş; KOKH 53,8’den 13,58’e düşmüştür. Küçükkumluk için ETR yöntemi ile %70,8 olarak hesaplanan ilişki katsayısı, dalgacık dönüşümü yönteminin etkisiyle D-ETR %86,39’a yükselmiş, KOKH 178,43’ten 132,24’e düşmüştür. Sonuçlar Tablo 8’te ayrıntılı olarak paylaşılmıştır.

Tablo 8, çalışmanın ana sonuçlarını ve farklı makine öğrenmesi algoritmalarının performansını karşılaştıran önemli bir özet sunmaktadır. Bu tablo, iki farklı akarsu istasyonu olan Porsuk Çiftliği ve Tagar (Küçükkumluk) için kullanılan beş farklı makine öğrenme yönteminin tahmin başarılarını göstermektedir. Tablonun ilk sütunu,



Şekil 18. Porsuk Çiftliği, 2022-2030 Üstel düzeltirme yöntemi akım hızı tahmini
(Porsuk Farm, 2022-2030 Exponential smoothing method flow rate estimation) ($\alpha=0,05$)



Şekil 19. Küçükkumluk, 2022-2030 Üstel düzeltirme yöntemi akım hızı tahmini
(Kucukkumluk, 2022-2030 Exponential Smoothing Method Flow Rate Estimation)($A=0,01$)

Tablo 8. Karşılaştırmalı yöntem sonuçları verileri (Comparison of Model Results)

Yöntem	İstasyonlar	Yöntem Girdileri	En Başarılı Yöntem	RMSE	R2(%)
LR-SVR-DT-RF-ETR	Porsuk Çiftliği	A _{ort} , Y _{toplam} , S _{ort}	ETR	53,8	67,67
	Tagar (Küçükkumluk)	A _{ort} , Y _{toplam} , S _{ort}	ETR	178,43	70,8
W-LR-SVR-DT-RF-ETR	Porsuk Çiftliği	Wavelet-A _{ort} , Y _{toplam} , S _{ort}	W-ETR	13,58	91,46
	Tagar (Küçükkumluk)	Wavelet-A _{ort} , Y _{toplam} , S _{ort}	W-ETR	132,24	86,39

kullanılan tahmin yöntemlerini listelemektedir. Bu yöntemler LR, SVR, DT, RF ve ETR şeklindedir. İkinci sütun, hangi istasyonlarda (Porsuk Çiftliği ve Tagar) bu yöntemlerin uygulandığını belirtmektedir. Üçüncü sütun, kullanılan girdi verilerini açıklamaktadır. Bu veriler “Aort” (günlük ortalama akım), “Ytoplam” (günlük toplam yağış), ve “Sort” (günlük ortalama hava sıcaklığı) olarak belirtilmiştir. Dördüncü sütun, her istasyon ve her yöntem için en başarılı tahmin yöntemini göstermektedir. Beşinci sütun, rmse olarak bilinen hata metriğini yansıtmaktadır. Bu değer, tahminlerin gerçek değerlerden ne kadar sapma gösterdiğini ölçmekte ve daha düşük bir rmse’nin daha iyi tahminlerin bir göstergesi olarak kabul edilmektedir. Altıncı sütunda, R-squared (R2) değerleri yer almaktadır. Bu değer, tahmin modelinin veriye ne kadar iyi uyarlandığını göstermektedir. Yüksek bir R2 değeri, modelin veriyi iyi açıkladığını göstermektedir. Tablo 8, her iki istasyon için farklı makine öğrenme yöntemlerinin performansını net bir şekilde karşılaştırarak çalışmanın ana sonuçlarını bütüncül olarak ortaya koyan önemli bir araçtır. Bu sonuçlar, dalgacık dönüşümünün (Wavelet Transform) uygulandığı hibrit yöntemlerin, geleneksel makine öğrenmesi yöntemlerine göre daha iyi performans gösterdiğini ve tahmin başarısını artırdığını göstermektedir.

Bu çalışma, Tarım ve Orman Bakanlığı çalışmalarında toprak ve su kaynaklarının korunması, geliştirilmesi, kırsal alanda su temini ve kullanılmış suların arıtılması vb. hizmetleri planlamada ve organize etmede faydalı olabilecektir. Tahmin edilen sonuçlara göre yetiştirilmesi gereken ürün seçimi, su yönetimi vb. planlamalarda daha etkin sonuçlar verecektir. Bu çalışmanın bulguları, farklı yöntem sonuçları ile yeniden analiz edilebilir. Bir sonraki araştırma çalışmasında bulanık mantık (Fuzzy Logic), ARIMA (autoregressive integrated moving average), yapay sinir ağları vb. yöntemlerin denenmesi planlanmaktadır.

5. Sonuçlar (Conclusions)

Bu araştırma sürecinde, Türkiye’nin önde gelen iki akarsu debisi ölçüm istasyonundan elde edilen zengin verilere dayanarak akarsu debisinin tahmini hakkında ayrıntılı bir inceleme gerçekleştirilmiştir. Bu istasyonlar, Türkiye’nin farklı bölgelerinde bulunmaktadır. Biri Yukarı Fırat Havzası’ndaki Tagar Çayı için D21A228 numaralı Küçükkumluk Akım Gözlem İstasyonu, diğeri ise Sakarya Havzası’nda yer alan Porsuk Çayı için D12A033 numaralı Porsuk Çiftliği Akım Gözlem İstasyonu’dur. Çalışmamız, günlük ortalama akım, günlük ortalama hava sıcaklığı ve günlük toplam yağış verilerini entegre ederek sağlam bir akarsu debisi tahmini modeli oluşturmayı amaçlamaktadır. Araştırmamızda farklı makine öğrenimi algoritmaları kullanılarak günlük akım tahminleri gerçekleştirilmiş ve ayrıca dalgacık dönüşümü ile desteklenmiş hibrit modeller geliştirilmiştir. İki akarsu üzerinde elde edilen sonuçlar karşılaştırılmıştır. Bu karşılaştırma sonucunda, Porsuk Çiftliği İstasyonu’nda elde edilen başarı oranlarının Küçükkumluk İstasyonu’ndan daha yüksek olduğu gözlemlenmiştir. Makine öğrenimi algoritmaları arasında, RF ve ETR modellerinde daha yüksek başarı oranları elde edilmiştir. Özellikle, WT makine öğrenimi çerçevesine dâhil edilmesi, sonuçlarda belirgin bir iyileşme sağlamıştır. Bu yeni yaklaşım, tahmin etme doğruluğunu yaklaşık olarak %10 artırmış ve zaman serileri ile düzensiz verilerin karmaşıklığını daha iyi açıklamıştır.

Bu çalışmanın sonuçlarının, Tarım ve Orman Bakanlığı gibi kuruluşlar için önemli olabileceği değerlendirilmektedir. Elde edilen tahminler, toprak ve su kaynaklarının korunması, su temini, kullanılmış suların arıtılması ve su yönetimi gibi alanlarda planlama ve organizasyon için değerli bilgiler sunmaktadır. Sonuç olarak bu çalışma, su kaynaklarının tahmin edilmesinde makine öğrenimi algoritmalarının ve dalgacık dönüşümünün birleşimini inceleyen bir başlangıç noktasıdır. Gelecekteki araştırmalar, yeraltı su seviyesi tahminleri ve sel tahminleri gibi alanlarda bu yöntemlerin daha fazla keşfedilmesine yönlendirebilir. Ayrıca, büyük veri kümelerinin ve bulut teknolojisinin entegrasyonu, su yönetimi paradigmasını daha da canlandırmak için önemli bir fırsat sunmaktadır. Su kullanımı ile ekonomik dinamikler arasındaki karmaşık etkileşim, keşfedilmesi gereken bir başka alan olarak öne çıkmaktadır. Bu çalışmaların sonuçları, bilimsel keşfin ve somut etki yaratmanın dinamik bir ilişkisi olan sürdürülebilir ve dirençli bir su yönetimi ethosu doğrultusunda, bilimsel keşfi ve pratik kullanımı birleştiren bütünsel su yönetimi stratejileri için aydınlatıcı bir zemin sunmaktadır.

Gelecekteki çalışmalar, bu araştırmanın bulgularını daha da genişletme potansiyeline sahiptir. İlk olarak, benzer bir metodoloji kullanarak farklı akarsu havzalarında veri toplama ve analiz yapılabilir. Bu, elde edilen sonuçların genelleştirilebilirliğini artırabilir ve Türkiye’nin farklı coğrafyalarında su yönetimi uygulamalarına daha fazla rehberlik sağlayabilir. İkinci olarak, bu çalışmanın odaklandığı akarsu debisi tahminine ek olarak, yeraltı su seviyeleri tahminleri ve sel tahminleri gibi su kaynakları yönetimi alanlarında daha fazla çalışma yapılabilir. Bu, su kaynaklarının daha geniş bir perspektiften ele alınmasını sağlar ve afet yönetimi ve su kaynaklarının sürdürülebilirliği konularında önemli katkılar sunabilir. Ayrıca, büyük veri kümelerinin ve bulut teknolojisinin entegrasyonu konusu daha fazla keşfedilebilir. Bu, veri toplama, analiz ve tahmin süreçlerini daha verimli hale getirebilir ve su yönetimi kararlarının daha hızlı ve etkili bir şekilde alınmasına yardımcı olabilir.

Sonuç olarak, bu çalışma su kaynakları yönetimi alanında önemli bir adımı temsil etmektedir, ancak gelecekteki çalışmaların bu alanda daha fazla keşfi ve inovasyonu teşvik etmesi gerekmektedir. Su kaynaklarının etkin bir şekilde yönetilmesi, çevresel sürdürülebilirlik ve toplumsal refah açısından kritik bir öneme sahiptir ve bu tür çalışmaların bu hedeflere ulaşmada önemli bir rol oynayabileceğine inanılmaktadır.

Kaynaklar (References)

- Demir V., Keskin A. Ü., Yeterince akım ölçümü olmayan nehirlerde taşkın debisinin hesaplanması ve taşkın modellemesi (Samsun, Mert Irmağı örneği), Geomatik, 7 (2), 149-162, 2022.
- Bozkurt C., Karakaya N., Genç Ö., Fidan H., Fırtına Deresi Havzasında GEFC Metodu Kullanılarak Çevresel Su İhtiyacı Tahmini, 2021.
- Ewaid S. H., Abed S. A., Al-Ansari N., Water footprint of wheat in Iraq. Water, 11 (3), 535, 2019.
- Ünlü A., Çoban F., Tunç M.S., Investigation of Lake Hazar water quality according to physical and inorganic chemical parameters, Journal of the Faculty of Engineering and Architecture of Gazi University, 23 (1), 119-127, 2013.
- Muratoğlu A., Assessment of water footprint of production: A case study for Diyarbakır province, Journal of the Faculty of Engineering and Architecture of Gazi University, 35 (2), 845-858, 2019.

6. Bulut A. P., Canbaz G. T., Sivas İlinde Buğday, Arpa, Şeker Pancarı ve Ayçiçeği Üretimi İçin Su Ayak İzini Hesaplanması. Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi, 9 (1), 249-255, 2022.
7. Yılmaz A., Küresel Isınmanın Dünya Su Rezervleri Üzerindeki Etkileri. Kent Akademisi, 8 (22), 63-72, 2015.
8. Bilgiç Y., Güneş enerjili su damıtma sistemlerinde genişletilmiş yüzeylerin ısı ve kütle transferi üzerindeki etkisi/The effect of extended surfaces in the solar distillation systems on the heat and mass transfer, 2008.
9. Gleick P. H., Water as a Weapon and Casualty of Conflict: Freshwater and International Humanitarian Law, Water Resources Management, Springer. European Water Resources Association (EWRA), 33 (5), 1737-1751, 2019.
10. Altan K., Türkiye’de yağış ve sıcaklığın su kaynakları, tarımsal ürün verimi ve su politikalarına etkisi, 2020.
11. Toprak Su Kaynakları, DSİ, (2020), <https://www.dsi.gov.tr/Sayfa/Detay/754> Erişim tarihi Kasım 11, 2021.
12. Muluk Ç.B., Kurt, B., Turak, A., Türker, A., Çalışkan, M.A., Balkız, Ö. et al., Türkiye’de suyun durumu ve su yönetiminde yeni yaklaşımlar: çevresel perspektif, İşDünyası ve Sürdürülebilir Kalkınma Derneği-Doğa Koruma Merkezi, 2013.
13. Çiçek İ., Ataoğlu, M., Türkiye’nin su potansiyelinin belirlenmesinde yeni bir yaklaşım. Coğrafi Bilimler Dergisi, 7(1), 51-65, 2009.
14. Ilgar R., Su Okuryazarlığı ve Su Ayak İzi Üzerine Yaklaşımlar, Journal of International Social Research, 13 (73), 2020.
15. Sarış F., Türkiye’de evsel su tedarik ve tüketim istatistiklerinin değerlendirilmesi. Coğrafi Bilimler Dergisi, 19 (1), 195-216, 2021.
16. Altan K., Teksoy A., Solmaz, S. K. A., Türkiye’de Yağış ve Sıcaklığın Su Kaynakları, Tarımsal Ürün Verimi ve Su Politikalarına Etkisi. Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 25 (3), 1253-1270, 2020.
17. Ehteram M., Karami H., Mousavi S. F., Farzin S., Celeste A. B., Shafie, A.-E., Reservoir operation by a new evolutionary algorithm: Kidney algorithm. Water Resources Management, 32 (14), 4681-4706, 2018.
18. Ehteram M., Singh V. P., Ferdowsi A., Mousavi S. F., Farzin S., Karami, H., et al., An improved model based on the support vector machine and cuckoo algorithm for simulating reference evapotranspiration. PLoS ONE, 14 (5), e0217499, 2019.
19. Şeker, S. E., Zaman Serisi Analizi, YBS Ansiklopedisi, 2 (4), 2015.
20. Başaran A., Dursun F., Tipi, A. F., Balıkesir’de Sürdürülebilir Kalkınmanın İncelenmesi. Anadolu Akademi Sosyal Bilimler Dergisi, 4 (1), 48-65, 2022.
21. Navarro-Hellín H., Martínez-del-Rincon J., Domingo-Miguel R., Soto-Valles F., Torres-Sánchez R. A., Decision support system for managing irrigation in agriculture. Comput. Electron. Agric, 124, 121-131, 2016.
22. González-Teruel J. D., Ruiz-Abellón M. C., Blanco V., Blaya-Ros P. J., Domingo R., Torres-Sánchez R., Prediction of Water Stress Episodes in Fruit Trees Based on Soil and Weather Time Series Data. Agronomy, 12 (6), 1422, 2022.
23. Tosunoğlu, F. İspirli, MN. Gürbüz, F. ve Şengül, S., Fırat Havzası’ndaki eksik akım verilerinin debi süreklilik çizgileri ve regresyon modelleri ile tahmin edilmesi. İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 7 (4), 85-94, 2017.
24. Bakış, R. ve 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.
25. Gyau-Boakye P., Schultz G. A., Filling gaps in runoff time series in West Africa. Hydrological sciences journal, 39 (6), 621-636, 1994.
26. Baykal, T., & Terzi, Ö. Küçük Aksu Çayı taşkın frekans analizi. Cumhuriyet Sci. J, 38 (4), 639-646. 2017.
27. Ismail WNW., Zin WZW., Estimation of rainfall and stream flow missing data for Terengganu, Malaysia by using interpolation technique methods. Malaysian Journal of Fundamental and Applied Sciences, 13 (3), 213-217. 2017.
28. Nadiri, A. A., Naderi, K., Khatibi, R., Gharekhani, M., Modelling groundwater level variations by learning from multiple models using fuzzy logic. Hydrological Sciences Journal, 64 (2), 210-226, 2019.
29. Karami H., Farzin S., Jahangiri A., Ehteram M., Kisi O., ElShafie A., Multi-reservoir system optimization based on hybrid gravitational algorithm to minimize water-supply deficiencies. Water Resources Management, 33, 1-20, 2019.
30. Bahadır Z. M., Yeraltı suyu seviye değişiminin M5 karar ağacı ve yapay sinir ağları yöntemleriyle belirlenmesi (Master's thesis, İskenderun Teknik Üniversitesi/Lisansüstü Eğitim Enstitüsü/İnşaat Mühendisliği Ana Bilim Dalı), 2021.
31. Biau G.Ä.Ş.; Scornet E., A random forest guided tour., 25, 197-227. 2016.
32. Baudron P., Alonso-Sarria F., García-Aróstegui, J.L., Cánovas-García F., Martínez-Vicente D., Moreno-Brotóns J., Identifying the origin of groundwater samples in a multi-layer aquifer system with random forest classification. J. Hydrol. 2013, 499, 303-315, 2013.
33. Tyralis, H., Papacharalampous, G., Langousis, A., A brief review of random forests for water scientists and practitioners and their recent history in water resources. Water, 11 (5), 910, 2019.
34. Bravo S., González-Chang M., Dec D., Valle S., Wendroth O., Zúñiga F., Dörner J., Using wavelet analyses to identify temporal coherence in soil physical properties in a volcanic ash-derived soil. Agricultural and Forest Meteorology, 285, 107909, 2020.
35. İşler B., Aslan Z., Modeling of vegetation cover and spatio-temporal variations, Journal of the Faculty of Engineering and Architecture of Gazi University, 36 (4), 1863-1874, 2021.
36. Yılmaz M. U., Onoz B., A Comparative Study of Statistical Methods for Daily Streamflow Estimation at Ungauged Basins in Turkey, Water 2020, 12, 459; doi:10.3390/w12020459
37. Yılmaz M. U., Onoz B., Evaluation of Statistical Methods for Estimating Missing Daily Streamflow Data, Teknik Dergi, 9597-9620, Paper 558, 2019
38. Amit Pandey, Achin Jain, Comparative Analysis of KNN Algorithm using Various Normalization Techniques, International Journal of Computer Network and Information Security (IJCNIS), 9 (11), 36-42, 2017.
39. Mehmet A.C.I., Doğan Soy G.A., Demand forecasting for e-retail sector using machine learning and deep learning methods, Journal of the Faculty of Engineering and Architecture of Gazi University, 37 (3), 1325-1340, 2022.
40. Datlıca M., Çakıt E., Estimation of clustering parameters and anomaly detection in tracking devices with changeable position time, Journal of the Faculty of Engineering and Architecture of Gazi University, 36 (1), 373-394, 2020.
41. Gökdemir A., Çalhan A., Deep learning and machine learning based anomaly detection in internet of things environments, Journal of the Faculty of Engineering and Architecture of Gazi University, 37 (4), 1945-1956, 2022.
42. S Kılıç., Doğrusal Regresyon Analizi” Journal of Mood Disorders, 3, 2, 2013.
43. Karal Ö., Compression of ECG data by support vector regression method, Journal of the Faculty of Engineering and Architecture of Gazi University, 33 (2), 743-756, 2018.
44. Ahmet S. E. L., Pandemi sürecinde altın fiyatları ile kripto para ilişkisinin makine öğrenme metodları ile incelenmesi. İstatistik ve Uygulamalı Bilimler Dergisi, 1 (2), 85-98, 2020.
45. Akbulut U., Aslan, Z., İleri Veri İşlem Yöntemleri ile Su Kaynaklarının Kullanımı ve Planlanmasının Optimizasyonu. Aksaray University Journal of Science and Engineering, 6 (2), 79-94, 2022.
46. Tarannom Parhizkar, Elham Rafeipour, Aram Parhizkar, Evaluation and improvement of energy consumption prediction models using principal component analysis based feature reduction, Journal of Cleaner Production 279 (2021) 123866
47. Bahzad Taha Jijo, Adnan Mohsin Abdulazeez, Classification Based on Decision Tree Algorithm for Machine Learning, Journal of Applied Science and Technology Trends, ISSN: 2708-0757, 2 (1), 20-28, 2021.
48. Viet-Hung Dang, Nhat-Duc Hoang, Le-Mai-Duyen Nguyen, Dieu Tien Bui and Pijush Samui, A Novel GIS-Based Random Forest Machine Algorithm for the Spatial Prediction of Shallow Landslide Susceptibility, Forests 2020, 11, 118;
49. Wu, D., Liu, S., Moayed, H., Cifci, M. A., & Le, B. N. ANN-Incorporated satin bowerbird optimizer for predicting uniaxial compressive strength of concrete. Steel and Composite Structures, An International Journal, 45 (2), 281-291, 2022.
50. Karbasi, M., Jamei, M., Ali, M., Abdulla, S., Chu, X., and Yaseen, Z. M. Developing a novel hybrid Auto Encoder Decoder Bidirectional Gated Recurrent Unit model enhanced with empirical wavelet transform and Boruta-Catboost to forecast significant wave height. Journal of Cleaner Production, 379, 134820. 2022.
51. Peng, L., Wang, L., Xia, D., and Gao, Q. Effective energy consumption forecasting using empirical wavelet transform and long short-term memory. Energy, 238, 121756. 2022.

52. Kayhan, M., ve İ. Alan, Havza Bazında Yağışın El-Nino ve La-Nina ile İlişkisi, MGM, Ankara. 2014.
53. <https://ggweather.com/enso/oni.htm> (Erişim tarihi, 31.05.2023)
54. Güngül, M., & Yenilmez, F. Üstel Düzleştirme Yöntemi ile Türkiye'nin Tarım Sektörü Dış Ticaret Dengesi Tahmini (2018-2023). Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 21 (3), 959-980, 2019.
55. Baba A., Probabilistic-Based Forecasting Method For Time Series Datasets, Düzce University Journal of Science & Technology, 11 563-573, 2023.
56. Tang, Y., Song, Z., Zhu, Y., Yuan, H., Hou, M., Ji, J., ... & Li, J., A survey on machine learning models for financial time series forecasting. Neurocomputing, 512, 363-380, 2022.
57. Baker, M. R., Mahmood, Z. N., & Shaker, E. H., Ensemble Learning with Supervised Machine Learning Models to Predict Credit Card Fraud Transactions. Revue d'Intelligence Artificielle, 36 (4), 2022.
58. Yaseen, Z. M., Naganna, S. R., Sa'adi, Z., Samui, P., Ghorbani, M. A., Salih, S. Q., & Shahid, S., Hourly river flow forecasting: application of emotional neural network versus multiple machine learning paradigms. Water Resources Management, 34, 1075-1091, 2020.
59. Du Preez, J., & Witt, S. F., Univariate versus multivariate time series forecasting: an application to international tourism demand. International Journal of Forecasting, 19 (3), 435-451, 2003.
60. Nooruldeen, O., Alturki, S., Baker, M. R., & Ghareeb, A. Time series forecasting for decision making on city-wide energy demand: A comparative study. In 2022 International Conference on Decision Aid Sciences and Applications (DASA) (1706-1710). IEEE, 2022.
61. Baker, M. R., Jihad, K. H., Al-Bayaty, H., Ghareeb, A., Ali, H., Choi, J. K., & Sun, Q., Uncertainty management in electricity demand forecasting with machine learning and ensemble learning: Case studies of COVID-19 in the US metropolitans. Engineering Applications of Artificial Intelligence, 123, 106350, 2023.
62. Üzülmöz S., Çifçi M.A., Early diagnosis of lung cancer using deep learning and uncertainty measures, Journal of the Faculty of Engineering and Architecture of Gazi University, 39 (1), 385-400, 2024.
63. Koçak, K., Şaylan, L., & Eitzinger, J., Nonlinear prediction of near-surface temperature via univariate and multivariate time series embedding. Ecological Modelling, 173 (1), 1-7, 2004.
64. Takaoğlu, M., Özyavaş, A., Ajlouni, N., & Takaoğlu, F., Highly Secured Hybrid Image Steganography with an Improved Key Generation and Exchange for One-Time-Pad Encryption Method. Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 23 (1), 101-114, 2023.
65. Sezer, Z. A. Çıplak İstatistik'e Bakış. 2023.
66. Ahmet, G. A. N. İ.; Açıkgöz, Hakan; Şekkelı, Mustafa. Fotovoltaik Sistemlerde Değişken Yük ve Güneş Işınımı Altında Sinirsel-Bulanık Denetleyici ile Maksimum Güç Noktası Takibi. Avrupa Bilim ve Teknoloji Dergisi, 19, 734-745, 2020.
67. Da Silva, P. C. L.; Da Silva, J. P.; Garcia, A. R. G. Daubechies Wavelets As Basis Functions For The Vectorial Beam Propagation Method. Journal Of Electromagnetic Waves And Applications, 33 (8), 1027-1041, 2019.

Copyright of Journal of the Faculty of Engineering & Architecture of Gazi University / Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, is the property of Gazi University, Faculty of Engineering & Architecture and its content may not be copied or emailed to multiple sites or posted to a listserv without the copyright holder's express written permission. However, users may print, download, or email articles for individual use.