

Araştırma Makalesi

Hodrick-Prescott Filtreleme ve Yapay Sinir Ağları Yöntemiyle Uzun Dönem Su Tüketim Tahmini Üzerine Türkiye Uygulaması

A Case Study on Long-Term Water Consumption Forecasting in Türkiye By Using The Hodrick–Prescott Filter and Artificial Neural Networks

Ömer Faruk BAYARSLAN Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü ofb_94@hotmail.com https://orcid.org/0000-0003-0100-206X	Onur KOYUNCU Dr. Öğr. Üyesi, Hacettepe Üniversitesi İktisadi İdari Bilimler Fakültesi okuyuncu@hacettepe.edu.tr https://orcid.org/0000-0002-5899-8841
Zehra B. KANIK Arş. Gör. Dr., Çankaya Üniversitesi İktisadi İdari Bilimler Fakültesi zbkanik@cankaya.edu.tr https://orcid.org/0000-0003-1683-060X	Mine ÖMÜRGÖNÜLŞEN Prof. Dr., Hacettepe Üniversitesi İktisadi İdari Bilimler Fakültesi mergun@hacettepe.edu.tr https://orcid.org/0000-0001-6905-1154

Makale Geliş Tarihi	Makale Kabul Tarihi
30.09.2025	09.12.2025

Öz

Kıt kaynaklara yönelik tüketim planlamasının yapılması, yeryüzündeki sınırsız istek ve ihtiyaçların karşılanmasını sağlamak açısından en önemli yaşamsal faaliyetlerden birisidir. Özellikle mevcut su kaynakları ve bunların tüketim yönetimi, ülkelerin sürdürülebilir kalkınma hedeflerinin gerçekleştirilmesi açısından önem arz etmektedir. Sınırlı ve dengesiz dağılan su kaynakları, insan faaliyetlerinden kaynaklanan kirlilik ve iklim değişikliği etkisiyle giderek daha kırılgan hale gelmekte, bu da suyun etkin yönetimini zorunlu kılmaktadır. Su dağıtım sistemlerinin güvenilir ve ekonomik şekilde çalışabilmesi için kısa ve uzun vadeli su talep tahminleri büyük önem taşımaktadır. Bu çalışmada, Türkiye'nin uzun dönem su tüketim tahminlemesini yapmak amacıyla Hodrick–Prescott (HP) Filtreleme ve Yapay Sinir Ağları (YSA) yöntemleri kullanılarak 2001-2021 yılları arasındaki su tüketim miktarını etkileyen faktörler analiz edilmiştir. Çalışmada amaç, 2030-2050 yılları için Türkiye’de su tüketim miktarına yönelik tahminlerin yapılmasıdır. Bu bağlamda, HP filtrelemesi ile veri setindeki dalgalanmalar arındırılarak eğilim ve döngüsel hareket bileşenleri oluşturulmuş; ardından bu bileşenlere YSA ve Çoklu Doğrusal Regresyon (ÇDR) yöntemleri uygulanmıştır. Bulgulara göre, 2030 yılında su tüketiminde belirgin bir artış miktarı görülmezken, 2050 yılında ciddi bir su tüketim miktar artışı yaşanacağı tespit edilmiştir. 2030 yılı tahminlerinde, sürdürülebilir kalkınma hedefleri doğrultusunda su tüketimine yönelik politika müdahalelerinin etkili olacağı öngörülmüştür. Sonuçlar, gelecekte su tüketimi miktarını dengelemek için yeni su kaynakları oluşturulması, atık suyun geri dönüşümü ve su yönetimi politikalarının etkinleştirilmesi gerektiğini göstermektedir.

Anahtar Sözcükler: Su Tüketimi Tahminleme, Hodrick–Prescott Filtreleme, Yapay Sinir Ağları, Çoklu Doğrusal Regresyon, Türkiye

Abstract

Consumption planning for scarce resources is one of the most critical activities for meeting the unlimited needs and demands of humankind. In this context, the management of existing water resources and their efficient use play a vital role in achieving countries' sustainable development goals. However, water resources are becoming increasingly fragile due to their limited and uneven distribution, anthropogenic pollution, and the impacts of climate change, which makes effective water management necessary. Accurate short and long-term water demand forecasting is essential to ensure reliable and cost-efficient operation of water distribution systems. This study

Önerilen Atıf /Suggested Citation

Bayarslan, Ö.F. & Koyuncu, O., Kanık, Z.B., Ömürgönülşen, M., 2025, Hodrick-Prescott Filtreleme ve Yapay Sinir Ağları Yöntemiyle Uzun Dönem Su Tüketim Tahmini Üzerine Türkiye Uygulaması, Üçüncü Sektör Sosyal Ekonomi Dergisi, 60(4), 4611-4637.

aims to forecast Türkiye's long-term water consumption by analyzing the factors influencing water use between 2001 and 2021 using the Hodrick–Prescott (HP) filtering method and Artificial Neural Networks (ANNs). The objective is to generate water consumption forecasts for the years 2030 and 2050. In this context, HP filtering is first employed to remove short-term fluctuations and extract the trend and cyclical components of the data. These components are then modeled by using ANN and Multiple Linear Regression (MLR) methods. According to the findings, while no significant increase in water consumption is projected for 2030, a substantial rise is expected by 2050. The 2030 forecasts indicate that policy interventions targeting water consumption, aligned with the Sustainable Development Goals, will be effective. Overall, the results suggest the need to develop new water resources, enhance wastewater recycling, and strengthen water management policies to balance future water demand with supply.

Keywords: Water Consumption Forecasting, Hodrick–Prescott Filtering, Artificial Neural Networks, Multiple Linear Regression, Türkiye

1. Giriş

Günümüzde hızla artan dünya nüfusu, kentleşme, sanayileşme ve teknolojiye bağlı üretim faaliyetleri, küresel ölçekte suya olan talebi önemli ölçüde arttırmaktadır. Bu artışa karşılık iklim değişikliğinin etkileriyle birlikte yağış rejimlerinde görülen bozulmalar, aşırı sıcaklıklar, buzulların erimesi, orman alanlarının tahribi ve yer altı su kaynaklarının azalması gibi çevresel faktörler, su kaynakları üzerinde ciddi bir baskı oluşturmaktadır. Yaşanan bu gelişmeler, suya erişimi güçleştirmekte ve su kıtlığı riskini gün geçtikçe daha görünür bir hale getirmektedir. Nitekim çeşitli bölgelerde kuraklık ve su temininde yaşanan zorluklar, bu sürecin yalnızca teorik bir tehlike olmadığını açıkça ortaya koymaktadır (Ghalekhondabi vd., 2017).

Su tüketimi içme, kullanma, tarımsal sulama ve sanayi gibi çok çeşitli alanlarda gerçekleştirilmekte olup, ilgili alanların her geçen gün gelişmesiyle su tüketim miktarı da doğrudan artmaktadır. Özellikle sanayi sektöründe ürünlerin üretimi, soğutulması ve temizlenmesi gibi süreçlerde yoğun su kullanımına ihtiyaç duyulmaktadır. Sanayide tüketilen suyun yaklaşık %75'i enerji sektöründe kullanılmaktadır (Hakyemez, 2019).

Türkiye'deki su tüketimi alanlarına bakıldığında ise, Türkiye İstatistik Kurumu (TÜİK) 2020 verilerine göre, kullanılan toplam suyun %71'i tarımsal sulamada, %10'u içme ve kullanma amacıyla, %19'u ise sanayi, maden işletmeleri ve termik santrallerde tüketilmektedir. Aynı kaynaklara göre, 2008 yılında 44 milyar m³ olan toplam su tüketimi, 2020 yılı itibarıyla 64 milyar m³'e ulaşmıştır. Artan nüfus ve tüketim eğilimleri, Türkiye'nin 2030 yılı itibarıyla ciddi bir su kıtlığıyla karşı karşıya kalabileceğine işaret etmektedir (Pegram vd., 2014).

Yaşamsal faaliyetlerde hayati öneme sahip olan su kaynaklarının sınırlı ve düzensiz dağılımı, insan kaynaklı kirlilik ve iklimsel etkilerle her geçen gün daha da kırılgan hâle gelmekte; bu durum da etkili bir su yönetimi ihtiyacını gündeme getirmektedir. Aküzüm vd. (2010) tarafından yapılan çalışmada, Türkiye'de kişi başına düşen tatlı su miktarının 2000 yılında 1652 m³'ten 2020 yılında 1346 m³'e düştüğü belirtilmiştir. Bu durum, Türkiye'nin artık su zengini olmayan ülkeler arasında yer aldığını ve Türkiye'de mevcut su kaynaklarının verimli bir şekilde yönetilebilmesi için etkili planlama araçlarına ihtiyaç duyulduğunu göstermektedir. Su dağıtım sistemlerinin güvenilir ve ekonomik biçimde işletilebilmesi için kısa ve uzun vadeli su talep tahminlerinin yapılması büyük önem arz etmektedir.

Türkiye'nin hızla artan nüfusu, kentleşme oranı ve sanayi faaliyetleri dikkate alındığında, ülkenin su kaynakları üzerindeki baskının daha da artacağı öngörülmektedir. Özellikle kuraklık riski taşıyan bölgelerin varlığı ve düzensiz yağış rejimi, Türkiye'yi su yönetimi açısından kırılgan ülkelerden biri hâline getirmektedir (Msiza vd., 2008; Zubaidi vd., 2020). Bu bağlamda, Türkiye'nin su talebi tahminine dayalı politikalar geliştirmesi, sürdürülebilir kaynak yönetimi açısından kritik önemdedir. Bu nedenle, çalışmada Türkiye örneği seçilerek su tüketim tahminlerinin modellenmesi amaçlanmıştır.

İlgili literatür incelemeleri, su talep tahmininde geleneksel yöntemlerin yaygın olarak kullanıldığını, ancak bu yöntemlerin dinamik ve çok değişkenli çevresel koşulları yeterince yansıtmadığını göstermektedir. Bu çalışmada, Hodrick–Prescott (HP) filtreleme yöntemi veri ön işleme aracı olarak kullanılarak su tüketimi ve etkileyen faktörler trend ve döngüsel bileşenlerine ayrıştırılmıştır. Elde edilen bileşenler üzerinde hem Çoklu Doğrusal Regresyon (ÇDR) hem de Yapay Sinir Ağları (YSA) yöntemleri uygulanmış, ayrıca farklı model kombinasyonları denenerek en düşük hata oranını veren yaklaşım belirlenmiştir.

Literatürde ÇDR, su talebi ile nüfus, sıcaklık, yağış, gelir düzeyi gibi çoklu bağımsız değişkenler arasındaki doğrusal ilişkileri modelleme, kolay uygulanabilirlik ve yorumlanabilir katsayılar sunması nedeniyle yaygın olarak tercih edilmektedir (Adamowski vd., 2012). HP filtresi, zaman serisi verilerinde

uzun dönemli eğilimleri kısa dönemli dalgalanmalardan ayırarak veri setini daha istikrarlı hale getirmekte ve tahmin modellerinin doğruluğunu artırıcı bir ön işleme tekniği olarak kullanılmaktadır (Harvey & Jaeger, 1993). YSA ise doğrusal olmayan karmaşık ilişkileri öğrenebilme ve yüksek öngörü kapasitesi sayesinde, özellikle çevresel ve sosyoekonomik faktörlerin etkilerini modellemede güçlü bir yöntem olarak öne çıkmaktadır (Maier & Dandy, 2000). Bu yaklaşımların bir arada uygulanması, hem verinin yapısal özelliklerinin dikkate alınmasını hem de doğrusal ve doğrusal olmayan ilişkilerin bütüncül biçimde modellenmesini sağlayarak uzun dönemli su talep tahmininde daha sağlam ve çok boyutlu bir öngörü sunmaktadır. Bu çalışmada sunulan 2030 ve 2050 projeksiyonları, veri setinin uzun dönem trend bileşenlerinden hareketle oluşturulmuş senaryo tabanlı tahminlerdir. 2030 yılı Birleşmiş Milletler'in Sürdürülebilir Kalkınma Amaçları kapsamında, temiz suya erişimin iyileştirilmesi için belirlenen politika hedefi olması nedeniyle çalışmada kritik bir referans yılında seçilmiştir. Benzer şekilde 2050 yılı, Türkiye'nin taraf olduğu Paris İklim Anlaşması kapsamında öngörülen net sıfır karbon hedefi ile ilişkilidir. Dolayısıyla bu iki yıl, Türkiye'nin uzun vadeli sürdürülebilirlik gündemiyle uyumlu bir çerçeve sunmaktadır.

Çalışmanın takip eden bölümleri şu şekildedir: İkinci bölümde ilgili literatür incelemeleri sunulmaktadır. Üçüncü bölüm yöntem ve vaka çalışması uygulamasını ele almaktadır. Son bölümde ise sonuç ve önerilere yer verilmektedir.

2. Literatür Taraması

Su talebi tahminlemesi üzerine yapılan çalışmaları daha bütüncül bir bakış açısıyla ele alabilmek adına ilgili literatür taraması iki başlık altında incelenmiştir. İlk olarak, farklı ülkelerde ve bölgelerde yapılmış su tüketimi tahminleme çalışmalarına odaklanan genel literatür taraması sunulmuştur. İkinci olarak ise, su talebi tahminlemesinde yaygın olarak kullanılan yöntemlere odaklanılmış ve özellikle YSA gibi yapay zekâ temelli yaklaşımların etkinliği incelenmiştir. Bu iki aşamalı yapı sayesinde hem literatürdeki genel eğilimler hem de bu çalışmanın temelini oluşturan yöntemsel tercihler derinlemesine ele alınmıştır. Böylelikle hem çalışmanın teorik temelleri kuvvetlendirilmiş hem de yöntem seçiminde izlenen yol gerekçelendirilmiştir.

2.1. Farklı Ülke ve Bölgelerde Yürütülen Su Tüketimi Tahminleme Araştırmalarına Yönelik Literatür Taraması

Farklı ülke ve bölgelerde yürütülen su tüketimi tahminleme araştırmalarına odaklanan ilk literatür taraması sürecinde, ScienceDirect ve Web of Science veri tabanları kullanılmıştır. Literatür taraması kapsamında, “*water consumption forecasting (su tüketimi tahmini)*”, “*water forecasting (su tahmini)*”, “*water consumption forecasting with machine learning (makine öğrenmesi ile su tüketimi tahmini)*”, “*water demand forecasting (su talebi tahmini)*” ve “*water consumption forecasting with artificial neural network (yapay sinir ağları ile su tüketimi tahmini)*” anahtar kelimeleriyle toplam 412 makaleye ulaşılmıştır. Bu makaleler, konuya uygunluk, yöntemsel açıklık ve veri kullanılabilirliği kriterleri doğrultusunda incelenmiş ve nihai olarak 2000-2022 yılları arasında yayınlanan, 37 çalışma detaylı analize dahil edilmiştir. İlgili makaleler yazar(lar) ve yayın yılı, çalışmanın yürütüldüğü ülke, tahminin yapıldığı zaman aralığı, uygulanan metodoloji, kullanılan bağımsız değişkenler ve kıtasal konum kriterlerine göre Tablo 1’de sınıflandırılmıştır.

Tablo 1: Farklı Ülke ve Bölgelerde Yürütülen Su Tüketimi Tahminleme Çalışmaları


Yazar / Yıl	Ülke	Periyot	Metodoloji	Değişkenler	Kıta	Yazar / Yıl	Ülke	Periyot	Metodoloji	Değişkenler	Kıta
Zhou vd. (2000)	Avusturalya-Melbourne	Günlük	ZS	Su tüketimi, Maksimum sıcaklık, Yağış, Buharlaşma	Diğer	Walker vd. (2015)	Yunanistan-İWIDGET Projesi	Haftalık	İM, YSA	Haftalık su tüketimi	Avrupa
Jain vd. (2001)	Hindistan-Teknoloji Enstitüsü	Haftalık	YSA, ZS, ÇDR	Su tüketimi, Yağış, Sıcaklık	Asya	Vijayalakshmi & Babu (2015)	Hindistan-Hogenakkal	Günlük	Uyarlamalı ATBC	Su talebi	Asya
Jain & Ormsbee (2002)	ABD-Lexington	Günlük	YSA, YZ, US, Regresyon	Su tüketimi, Yağış, Maksimum Sıcaklık	Amerika	Yalçıntaş vd. (2015)	Türkiye-İstanbul	Günlük-Aylık	BOHO	Su talebi, Saglanan Su	Asya
Liu vd. (2003)	Çin- Weinan	Günlük	YSA	Su fiyatı, Evin alanı, Su tüketimi, Evin geliri	Asya	Peña-Guzmán vd. (2016)	Kolombiya-Bogota	Yıllık	EKK-DVM	Aylık su tüketimi, Kullanıcı sayısı, Toplam faturası	Amerika
Altunkaynak vd. (2005)	Türkiye-İstanbul	Aylık	BM	Su talebi	Asya	Pacchin vd. (2017)	İtalya-Castelfranco Emilia	Günlük	KP	Ortalama su talebi	Avrupa
Adamowski (2008)	Kanada-Ottawa	Günlük	YSA, DR, ZS	Maksimum su tüketimi, Sıcaklık, Yağış	Amerika	Anele vd. (2017)	İspanya- Bir şehir	Saatlik	ZS, YSA, Regresyon, HM	Günlük ortalama su tüketimi	Avrupa
Msiza vd. (2008)	Güney Afrika-Gauteng	Günlük	YSA, DVR	Su Talebi, Yıllık tahmini popülasyon	Diğer	Gagliardi vd. (2017)	İngiltere-Yorkshire	Saatlik	Markov Zinciri	Su talebi	Avrupa
Fırat vd. (2009)	Türkiye- İzmir	Aylık	YSA	Su faturası, Nüfus, Ortalama	Asya	Ghalekhondabi vd. (2017)	Belirli Bölge Yok	Kısa-Uzun Dönem	YSA, BA, DVM, BOHO	Su tüketimi, Sıcaklık, Yağış	Diğer

				sıcaklık, Gayri safi Yurtiçi hasıla							
Yurdusev & Fırat (2009)	Türkiye- İzmir	Aylık	Uyarlamalı Sinirsel BM	Aylık su faturası, Nüfus, Hane sayısı, Enflasyon, GSYİH	Asya	Duerr vd. (2018)	ABD- Florida	Aylık	İM, MÖ	Aylık tüketimi su	Amerika
Herrera vd. (2010)	İspanya- Hidrolik Bölgesi	Saatlik	MÖ	Saatlik su tüketimi, Günlük sıcaklık, Rüzgâr hızı, Yağış, Basınç	Avrupa	Vijai & Sivakumar (2018)	Avrupa Bölgesi	Saatlik, Günlük	YSA, EKK-DVM, EÖM	Su tüketimi, Sıcaklık, Nem, Nüfus, Rüzgâr hızı	Avrupa
Li & Huicheng (2010)	Çin -Dalian	Yıllık	BSA, ÇDR	Nüfus, GSYİH, Yeşil alan, Sıcaklık, Su tüketimi	Asya	Gharabaghi vd. (2019)	Kanada- Guelph	Günlük	DOZS	Su tüketimi, Sıcaklık, Yağış	Amerika
Adamowski & Karapataki (2010)	Kıbrıs- Lefkoşa	Haftalık	MLR, EGY, LM	Su tüketimi, Maksimum Sıcaklık, Toplam Yağış	Asya	Benítez vd. (2019)	İspanya-3 bölgesi	Haftalık	ÖBT	Dakikalık su akımı	Avrupa
Nasseri vd. (2011)	İran- Tahran	Aylık	KF, GP	Aylık su tüketimi	Asya	Muhammad vd. (2019)	Belirli Bölge Yok	Kısa- Uzun Dönem	YSA, Bulanık DVM, BOHO	Su tüketimi, Sıcaklık, Yağış, Nüfus, Rüzgâr hızı	Diğer
Adamowski vd. (2012)	Kanada- Montreal	Günlük	Dalgali YSA, BOHO, YSA, ÇDR	Su talebi, Yağış, Sıcaklık	Amerika	Karamaziotis vd. (2020)	Yunanistan- Atina	Aylık	MÖ	Aylık tüketimi, Su sayacı	Avrupa
Yaşar vd. (2012)	Türkiye- Adana	Aylık	SÇR	Ortalama fatura, Toplam abone, Sıcaklık, Nem Yağış, Rüzgâr hızı	Asya	Zubaidi vd. (2020)	Irak- Bağdat	Aylık	Otoregresif	Su tüketimi	Asya
Sampathirao vd. (2014)	İspanya- Barcelona	Günlük	Sezonlar BOHO, BCD, DVM	Su talebi	Avrupa	Boudhaouia & Wira (2021)	Belirli Bölge Yok	Saatlik	KUDH, GYSA	Su tüketimi	Diğer
Bakker vd. (2014)	Hollanda-6 bölgesi	Günlük	Uyarlanabilir SM, STM, ÇDR	Su talebi, Sıcaklık	Avrupa	Hao vd. (2022)	İtalya- Milano	Günlük, Haftalık	BOHO, YSA, MÖ, STM, DS	Su tüketimi, Ortalama sıcaklık, Maksimum sıcaklık, Yağış	Avrupa
Huang vd. (2014)	Çin -Dalian	Yıllık	DD, Kernel Parçalı EKK	Yıllık su tüketimi	Asya	Liu vd. (2023)	Birleşik Krallık	Saatlik	OEHO, YSA, RO, Prophet	Talep, Tüketim	Avrupa
Tiwari & Adamowski (2015)	Kanada- Cagary	Haftalık, Aylık	Dalgacık ön YSA	Toplam yağış, Maksimum sıcaklık, Toplam talep	Amerika	Iwakin & Moazeni (2024)	Telford Borough, Pennsylvania	Saatlik	KR, KÇKA, KGARA, KKR-KDA, OA, MA	Sıcaklık, Yağış, Nem, Basınç, Saat, Su talebi	ABD
Candelieri vd. (2015)	İtalya- Milano	Günlük	ZS, DVM	Saatlik su tüketimi, Günlük	Avrupa	Devianto vd. (2025)	Endonezya, Jakarta	Aylık	YSA	Su üretimi	Asya
Bu çalışma	Türkiye	Yıllık	YSA, filtreleme, HP ÇDR	Su tüketimi, Nüfus, Ortalama Sıcaklık, İhracat	Asya						

ZS: Zaman Serisi, YSA: Yapay Sinir Ağları, MÖ: Makine Öğrenmesi, DVM: Destek Vektör Makinesi, YZ: Yapay Zekâ, ÇDR: Çoklu Doğrusal Regresyon, EKK: En Küçük Kareler, US: Uzman Sistem, DD: Dalgacık Dönüşümü, BOHO: Bütünleşik Otoregresif Hareketli Ortalama, STM: Sönümsüz Transfer Model, DS: Dalgacık Serisi, SM: Sezgisel Model, GYSA: Geri Yayılım Sinir Ağları, KUDH: Kısa Uzun Dönem Hafıza, İM: İstatistiksel Metot, BSA: Bulanık Sinir Ağları, DVR: Destek Vektör Regresyonu, EÖM: Ekstrem öğrenme makineleri, HM: Hibrit Model, DOZS: Doğrusal olmayan zaman serisi, ÖBT: Örnek Benzetim Tekniği, LM: Levenberg-Marquardt, KF: Kalman Filtresi, GP: Genetik Programlama, SÇR: Stepwise-Çoklu Regresyon, BCD: Box-Cox Dönüşümü, BA: Bulanık Ağ, BM: Bulanık Mantık, ATBC: Ağ Tabanlı Bulanık Çıkarım, KP: Kayan Pencere, DR: Doğrusal Regresyon, OEHO: Otokorelasyonlu Entegre Hareketli Ortalama Modeli, RO: Rastgele Orman, KR: Kantil Regresyonu, KÇKA: Kantil Çok Katmanlı Algılayıcı, KGARA: Kantil Gradyan Artırmalı Regresyon Ağları, KKR-KDA: Konformal Kantil Regresyonu – Kosullu Dönüşüm Ağı, OA: Ortalama Ansambıl, MA: Medyan Ansambıl


Tablo 1 incelendiğinde, su tüketimi tahminlemesi üzerine yazılan makalelerin en çok 2015 yılında yazıldığı, 2004 ve 2013 yıllarında hiç makale yazılmadığı görülmektedir. Tablo 1’de verilerden oluşturulan Şekil 1’de ise incelenen makalelerin uygulama yapılan ülkelere göre dağılımı verilmiştir. Buna göre, en fazla çalışmanın 2005 ve 2015 yıl aralığında değişmekle birlikte, Türkiye’de yürütülmüş olduğu görülmekte, onu Kanada ve İspanya takip etmektedir. Bu durum, su tüketimi tahmini konusunda Türkiye’de artan araştırma ilgisini göstermektedir.

Şekil 1: Ülkelere Göre Yazılan Makale Sayısı




Şekil 2 ise literatürde yer alan su tüketimi tahminleme çalışmalarının tahmin dönemlerine göre dağılımını sunmaktadır. Elde edilen bulgulara göre, çalışmaların %37'lik oranla önemli bir kısmı günlük tahminlemelere odaklanmakta olup, bu yönelimi %25 ile aylık tahminler takip etmektedir. Bu sonuç, su yönetiminde kısa vadeli tahminlerin öncelikli bir gereklilik olarak değerlendirildiğini ve karar alma süreçlerinde daha sık başvurulmuş bir veri kaynağı olduğunu ortaya koymaktadır. Kısa vadeli tahminlerin uzun vadeli tahminlere göre daha fazla tercih edilmesi, hem veri erişimi ve model doğruluğu açısından yaşanan zorluklara hem de kısa dönemli operasyonel planlamaların daha kritik görülmesine bağlanabilir.

Şekil 2: Tahmin Periyoduna Göre Yazılan Makalelerin Yüzdelik Dağılımı




Şekil 3, su tüketimi tahminlemesi alanında kullanılan yöntemlerin sıklık dağılımını göstermektedir. Şekil 3'e göre incelenen çalışmaların büyük çoğunluğunda birden fazla yöntemin birlikte kullanıldığı, böylece yöntemlerin tahmin başarısı açısından karşılaştırıldığı görülmektedir. YSA ve bu yöntemden türeyen modeller, açık ara en çok tercih edilen yaklaşım olarak öne çıkmaktadır. Bu durum, YSA'nın doğrusal olmayan karmaşık ilişkileri modellemedeki güçlü yapısından kaynaklanmaktadır. Zaman serisi analizleri ile makine öğrenmesi tabanlı yöntemler ise literatürde benzer düzeyde ilgi görmektedir. Bu yöntemler, özellikle geçmiş tüketim verilerinin istatistiksel örüntülerini yakalama veya veri içinden öğrenme temelli yaklaşımlarla öne çıkmaktadır. Öte yandan, destek vektör makineleri ve bulanık mantık tabanlı yaklaşımlar, görece daha az sayıda çalışmada yer almaktadır.

Şekil 3: Kullanılan Yöntemlere Göre Makale Sayısı



Şekil 4, su tüketimi tahminleme çalışmalarında kullanılan bağımsız değişkenlerin dağılımını sunmaktadır. İncelenen tüm makalelerde su tüketimi verisi bağımlı değişken olarak kullanılmıştır. Bunun yanında, özellikle sıcaklık, yağış miktarı ve nüfus değişkenleri, tahmin modellerinde en yaygın biçimde yer verilen bağımsız değişkenler arasında öne çıkmaktadır. Bu durum, söz konusu değişkenlerin su talebini doğrudan etkileyen çevresel ve demografik etmenler olmasıyla açıklanabilir. Daha az sıklıkla kullanılan değişkenler arasında fatura tutarları, hane halkı gelir düzeyi, rüzgâr hızı, ev büyüklüğü ve buharlaşma oranları gibi faktörler yer almaktadır.

Şekil 4: Kullanılan Bağımsız Değişkenlere Göre Makale Sayısı



İlgili literatür taramasının genel bir değerlendirmesi yapıldığında, günlük tahmin dönemi en yaygın biçimde kullanılan unsur olup, su talebinin kısa vadeli planlamalarla yönetilmeye çalışıldığını göstermektedir. Yöntemsel açıdan ise, yapay sinir ağları ve bu yaklaşımdan türetilmiş modeller en çok tercih edilenler arasında yer alırken, destek vektör makineleri, zaman serisi analizleri ve bulanık mantık temelli yöntemler sınırlı sayıda çalışmada kullanılmaktadır. Değişken kullanımı açısından, sıcaklık ve yağış gibi meteorolojik veriler en yaygın bağımsız değişkenler arasında yer alırken, ekonomik ve demografik değişkenlerin daha az kullanıldığı görülmektedir. Bu analiz, özellikle mevcut çalışmaların kısa dönemli ve veri odaklı modellere eğilimli olduğunu, gelişmekte olan ülkelerde yürütülen uygulamalı analizlerin sınırlı kaldığını ve politik/stratejik önerilerden çok tahmine odaklı olduğunu ortaya koymaktadır. Ayrıca, literatürde uzun dönemli tahminler, karar destek sistemlerine bütünleşmiş modeller ve veri çeşitliliği olan uygulamalar gibi konularda önemli boşluklar bulunmaktadır. Bu durum, ileride yapılacak çalışmalarda yeni veri kaynaklarının kullanılması, alternatif yöntemlerin test edilmesi ve daha bütüncül modelleme yaklaşımlarının geliştirilmesi gerekliliğine işaret etmektedir.

Literatürde yöntemlerin sıklık dağılımı ve değişken çeşitliliğine ilişkin bulgular, su talebi tahmin çalışmalarının büyük kısmında kısa dönemli verilerle sınırlı kaldığını ve çoğunlukla tek veya az sayıda bağımsız değişken kullanıldığını ortaya koymaktadır. Bu durum, uzun dönemli ulusal ölçekte tutarlı projeksiyonlar üretmeyi güçleştirmekte ve özellikle Türkiye gibi hem iklimsel hem sosyoekonomik açıdan hızlı değişen ülkelerde model doğruluğunu sınırlamaktadır. Bu nedenle mevcut literatürün yöntemsel ve değişkenlerle ilgili sınırlılıkları, Türkiye'nin 2030 ve 2050 yıllarına yönelik toplam su tüketiminin, HP filtreleme ile ayrıştırılmış uzun dönem trend bileşenleri ve çok değişkenli yapay zekâ modelleri kullanılarak daha güvenilir bir şekilde tahmin edilip edilemeyeceği sorusuna zemin hazırlamaktadır. Bu bağlamda çalışma, yöntem sıklığı ve değişken seçimi konusundaki literatür bulgularını başlangıç noktası olarak kullanarak daha kapsamlı ve uzun vadeli bir tahmin modeli geliştirmeyi amaçlamaktadır.

2.2. Su Talebi Tahminlemesinde Yapay Sinir Ağları Kullanan Çalışmalara Yönelik Literatür Taraması

Bu çalışmanın ikinci literatür taramasında, YSA yönteminin kullanıldığı su tüketimi ve su talebi tahminleme çalışmaları sistematik biçimde incelenmiştir. Bu kapsamda, ScienceDirect ve Web of Science veri tabanlarında; “*artificial neural network for water consumption forecasting (su tüketimi tahmini için yapay sinir ağı)*”, “*water demand prediction using ANN (yapay sinir ağı kullanılarak su*

talebi tahmini”, “*water use forecasting with ANN (yapay sinir ağları ile su kullanımı tahmini)*” gibi anahtar kelimelerle yürütülen tarama sonucunda elde edilen çalışmalar değerlendirilmiştir.

İncelenen makaleler; yazar(lar) ve yayın yılı, uygulama yeri, tahmin dönemi, uygulanan YSA modeli, kullanılan açıklayıcı değişkenler, performans ölçütleri ve temel bulgular esas alınarak sınıflandırılmıştır. Tablo 2, farklı bölgelerde uygulanan YSA tabanlı tahmin modellerinin yapılarını karşılaştırmalı olarak sunmakta; yöntemin doğruluk, esneklik ve uygulama yaygınlığı açısından literatürdeki yerini somutlaştırmaktadır.

Tablo 2: Su Talebi Tahminlemesinde Yapay Sinir Ağları Kullanan Çalışmalar

Yazar/Yıl	Şehir	Periyot	Yöntem	Değişkenler	Performans Ölçütü	Sonuç
Jain vd. (2001)	Hindistan,Kanpur	Haftalık	YSA, Çoklu Doğrusal Regresyon, Zaman Serisi	Su tüketimi, maksimum sıcaklık, yağış,	Eşik Değer, Bağlı Hata	Yapay sinir ağları en iyi sonuç veren yöntemdir.
Jain & Ormsbee (2002)	ABD-Lexington	Günlük	YSA, Yapay Zekâ, Uzman Sistem, Regresyon	Su tüketimi, Yağış, Maksimum Sıcaklık	Ortalama Bağlı Hata, Eşik Değer	Yapay zekâ yöntemlerinin geleneksel yöntemlere göre daha iyi sonuç verdiği bulunmuştur.
Liu vd. (2003)	Çin- Weinan	Günlük	YSA	Su fiyatı, Evin alanı, Su tüketimi, Evin geliri	Korelasyon katsayısı, R ² , Artık Değer	Yapay sinir ağları metodunun tahminleme için uygun bir yöntem olduğu görülmüştür.
Adamowski (2008)	Kanada- Ottawa	Günlük	YSA, Çoklu Doğrusal Regresyon, Zaman serisi analizi	Maksimum su tüketimi, Sıcaklık, Yağış	Ortalama Bağlı Hata, R ²	Yapay sinir ağlarının diğer yöntemlere göre tahminlemede daha iyi sonuçlar verdiği görülmüştür.
Msiza vd. (2008)	Güney Afrika- Gauteng	Günlük	YSA, Destek Vektör Regresyonu	Su Talebi, Yıllık tahmini popülasyon	Yüzde Doğruluk, Hata	Yapay sinir ağları metodu destek vektör regresyonundan daha iyi performans göstermiştir.
Yurdusev & Fırat (2009)	Türkiye- İzmir	Aylık	Uyarlanalı Sinirsel Bulanık Mantık	Aylık su faturası, Nüfus, Hane sayısı, Enflasyon, GSYİH	Korelasyon katsayısı, Verimlilik, Karekök Ortalama Hata Karesi (RMSE)	Tek bir girdiyle yapılan tahminlemeye göre birden fazla girdi verisiyle daha iyi sonuç elde edilmiştir.
Fırat vd. (2009)	Türkiye- İzmir	Aylık	YSA	Su faturası, Nüfus, Ortalama sıcaklık, GSYİH	Korelasyon katsayısı, Verimlilik, RMSE	Birden fazla yapay sinir ağları yöntemi arasından geliştirilmiş regresyon yönteminin daha iyi sonuç verdiği görülmüştür.
Li & Huicheng (2010)	Çin -Dalian	Yıllık	Bulanık Sinir Ağları, ÇDR	Nüfus, GSYİH, Yeşil alan, Sıcaklık, Su tüketimi	Ortalama Bağlı Hata	Veriler ön işleme tabi tutulduğunda model kombinasyonlarıyla etkili sonuçlar doğurmuştur.
Adamowski vd. (2012)	Kanada- Montreal	Günlük	Dalgalı yapay sinir ağları, ARIMA, YSA, Çoklu Doğrusal Regresyon	Su talebi, Yağış, Sıcaklık	R ² , RMSE, Verimlilik	Hibrit bir model oluşturarak diğer metotlara göre daha iyi bir sonuç elde edilmiştir.
Walker vd. (2015)	Yunanistan- IWIDGET Projesi	Haftalık	İstatistiksel Metot, YSA	Haftalık su tüketimi	Korelasyon	Kurulan model çok yüksek tüketimlerde doğru sonuç veremeyerek başarısız olmuştur.
Ghalekhondabi vd. (2017)	Belirli Bölge Yok	Kısa- Uzun Dönem	YSA, Bulanık Ağ, Destek Vektör Makinesi, ARIMA	Su tüketimi, Sıcaklık, Yağış	Bağlı Hata, Hız, Verimlilik	Kullanım amacına göre en iyi modelin değiştiği görülmüştür.
Anele vd. (2017)	İspanya- Bir şehir	Saatlik	Zaman Serisi, YSA, Regresyon, Hibrit model	Günlük ortalama su tüketimi	RMSE, Mutlak Ortalama Yüzde Hata (MAPE)	Otoregresif hareketli ortalamalar modelinin daha iyi sonuç verdiği görülmüştür.
Vijai & Sivakumar (2018)	Avrupa Bölgesi	Saatlik- Günlük	YSA, En küçük kareler DVM, Ekstrem öğrenme makineleri	Su tüketimi, Sıcaklık, Nem, Nüfus, Rüzgâr hızı	RMSE, MSE, R ² , Hesaplama Hızı	Yapay sinir ağları daha iyi sonuç vermesine karşın, en küçük kareler metodunun daha hızlı tahminleme yaptığı görülmüştür.
Muhammad vd. (2019)	Belirli Bölge Yok	Kısa- Uzun Dönem	YSA, Bulanık Ağ, Destek Vektör Makinesi, ARIMA	Su tüketimi, Sıcaklık, Yağış, Nüfus, Rüzgâr hızı	RMSE, MSE, MAPE, Ortalama Mutlak Hata (MAE)	Gerçekleştirdikleri derleme çalışmasında dalgacık dönüşüm algoritmasının iyi performans gösterdiğini belirtmiştir.
Hao vd. (2022)	İtalya- Milano	Günlük Haftalık	ARIMA, YSA, ÇDR, Sönümsüz transfer model, Dalgacık serisi	Su tüketimi, Ortalama sıcaklık, Maksimum sıcaklık, Yağış	RMSE, MAPE, R ² , MAE	Günlük tahminleme için yapay sinir ağları, haftalık tahminlemeler için dalgalı uzun kısa bellek metodu daha etkili sonuçlar vermiştir.
García-Soto vd. (2024)	Murcia-İspanya	Saatlik	DNN, KNN, Random Forest, XGBoost, SARIMA	Su tüketimi	MAPE	Derin öğrenme modeli diğer tüm yöntemlerden daha iyi performans göstermiştir; yaklaşık %3 hata ile kısa dönem öngörü başarıları yüksektir.
Bakshpour vd. (2024)	Belirli Bölge Yok	Saatlik	Topluluk makine öğrenmesi modeli	Su tüketimi, Takvim değişkenleri, Bölgesel göstergeler, Tatil bilgisi	MAE	Topluluk makine öğrenmesi modeli, tüm bölgelerde en düşük hata değerlerini vermiş ve diğer modellerin tamamını geride bırakarak en iyi performansı göstermiştir.
Seo vd. (2025)	Joinville, Brezilya	Aylık	Çok katmanlı yapay sinir ağı	Su tüketimi, Sıcaklık, Yağış, Abone/Konut sayısı, Gecikmeli değişkenleri	MAPE	Yapay sinir ağları modelleri su talebi tahmininde oldukça başarılı bulunmuştur.
Estrada vd. (2025)	Seul, Güney Kore	Aylık	Bayesian YSA	Ortalama sıcaklık	RMSE	Bayesian YSA modeli, tahmin belirsizliğini içermesi sayesinde uzun dönem iklim senaryolarında daha güvenilir sonuçlar vermiştir.
<i>Bu çalışma</i>	<i>Türkiye</i>	<i>Yıllık</i>	<i>HP filtreleme, YSA, ÇDR</i>	<i>Su tüketimi, Nüfus, Ortalama Sıcaklık, İhracat</i>	<i>MAPE, R², Düzeltmiş R², F-testi, p-değerleri</i>	<i>2030'da sınırlı, 2050'de ise belirgin bir su tüketim artışı öngörülmektedir.</i>

İlgili literatür taramasında yer alan çalışmalarda genellikle birden fazla yöntem bir arada kullanılmış ve sonuçlar karşılaştırmalı olarak analiz edilmiştir. Örneğin, Jain vd., (2001) Hindistan'daki bir çalışmada YSA'yı regresyon ve zaman serisi yöntemleriyle karşılaştırmış; ortalama bağlı hata (OBH) ve belirlilik katsayısı (R²) gibi performans ölçütlerine göre YSA'nın daha üstün sonuçlar verdiğini ortaya koymuştur. Benzer şekilde Jain & Ormsbee (2002), ABD'nin Lexington şehrinde gerçekleştirdikleri günlük tahminleme çalışmasında, geleneksel regresyon ve zaman serisi yöntemlerine kıyasla YSA ve uzman sistemlerin daha iyi performans sunduğunu raporlamıştır.

YSA'nın farklı coğrafi ve sosyoekonomik bağlamlarda da başarıyla uygulandığı görülmektedir. Liu vd. (2003) Çin'in Weinan kentinde gerçekleştirdikleri çalışmada, su fiyatı, hane geliri ve hane büyüklüğü gibi değişkenleri dikkate alarak günlük su tüketimi tahmini yapmış ve YSA'nın yeterince doğru sonuçlar verdiğini doğrulamıştır. Adamowski (2008) Kanada-Ottawa'da günlük en yüksek su talebini tahmin ettiği çalışmada, YSA'nın çoklu doğrusal regresyon ve zaman serisi analizine göre daha başarılı

olduğunu saptamıştır. Güney Afrika'dan Msiza vd. (2008) ise destek vektör regresyonuyla karşılaştırmalı analizinde YSA'nın daha isabetli çıktılar ürettiğini vurgulamıştır.

Türkiye özelinde yapılan çalışmalarda da benzer sonuçlar gözlemlenmiştir. Yurdusev & Fırat (2009), İzmir kenti için yürüttükleri çalışmada uyarlamalı sinirsel bulanık mantık yöntemini kullanmış, çoklu bağımsız değişken kullanımının tahmin performansını artırdığını göstermiştir. Fırat vd. (2009) ise yine İzmir için gerçekleştirdikleri çalışmada, genelleştirilmiş regresyon sinir ağı yaklaşımıyla en başarılı sonuca ulaştıklarını belirtmişlerdir. YSA'nın hibrit modellerle birlikte kullanımının da etkinliğini artırdığı bulgulanmıştır. Adamowski vd. (2012), Montreal için dalgacık dönüşümü ile entegre ettikleri YSA modelinde tahmin hatalarının en düşük seviyeye indiğini ortaya koymuştur. Hao vd. (2022), İtalya-Milano'da farklı yöntemlerle yürüttüğü çalışmada, günlük tahminlemede YSA'nın, haftalık tahminlemede ise uzun-kısa vadeli bellek ağlarının daha başarılı olduğunu belirtmiştir.

Diğer yandan, nesnelerin interneti destekli uygulamalarda da YSA'nın performansı test edilmiştir. Vijai & Sivakumar (2018), anlık olarak topladıkları çoklu çevresel ve demografik verilerle yürüttükleri çalışmada, YSA'nın farklı sektörlerdeki su tüketimini başarıyla modellediğini göstermiştir. Literatür taraması odaklı çalışmalarda ise (Ghalekhondabi vd., 2017; Muhammad vd., 2019), YSA ve diğer yapay zekâ tabanlı algoritmaların kullanım alanları ve başarı düzeyleri değerlendirilmiş; özellikle dalgacık dönüşümü gibi tekniklerle birlikte kullanıldığında YSA'nın performansının arttığı vurgulanmıştır.

Son yıllarda yapılan çalışmalar, derin öğrenme ve hibrit makine öğrenmesi modellerinin talep tahmininde önemli kazanımlar sağladığını göstermektedir. 2023–2024 döneminde gerçekleştirilen araştırmalarda, derin sinir ağlarının kısa dönem tahminlerde yüksek doğruluk elde ettiği görülmüştür (García-Soto vd., 2024). Ayrıca, farklı kent bölgelerinden elde edilen su talebi serilerini topluluk makine öğrenmesi yöntemleriyle tahmin eden yeni çalışmalarda (Bakhshipour vd., 2024), model çeşitliliğinin tahmin performansını artırdığı gösterilmiştir. 2025 yılında yayımlanan çalışmalarda ise özellikle belirsizlik içeren iklim senaryoları altında su talebi tahmini öne çıkmaktadır. Seo vd. (2025), Seul için gerçekleştirdikleri analizde Bayesgil Yapay Sinir Ağları (BNN) kullanarak sıcaklık senaryolarına dayalı su tüketimi projeksiyonları üretmiş ve BNN modellerinin belirsizliği içselleştirme kapasitesi sayesinde uzun dönemli tahminlerde daha güvenilir çıktılar verdiğini göstermiştir. Bu çalışma, makine öğrenmesi tabanlı su talebi modellerine “olasılık temelli tahmin ve belirsizlik değerlendirme” perspektifinin eklenmesine katkı sağlayarak literatürde önemli bir boşluğu tamamlamaktadır.

Her iki literatür taraması birlikte değerlendirildiğinde, su talebi tahminine yönelik çok sayıda çalışma bulunduğu; ancak bu çalışmaların büyük ölçüde belirli ülkelerde ve kısa dönemli uygulamalarda yoğunlaştığı görülmektedir. Özellikle yapay sinir ağları yönteminin doğruluk oranları nedeniyle yaygın olarak tercih edildiği anlaşılmakla birlikte, Türkiye özelinde gerçekleştirilen çalışmaların sayıca sınırlı kaldığı dikkat çekmektedir. Ayrıca, birçok çalışmanın değişken seçiminde önemli sosyoekonomik ya da çevresel göstergelerin göz ardı edildiği tespit edilmiştir. Bu bağlamda, Türkiye gibi hem kuraklık riski taşıyan hem de nüfus, kentleşme ve sanayi faaliyetlerinin hızla arttığı ülkelerde, kapsamlı veri kümeleriyle geliştirilecek tahmin modellerine ihtiyaç duyulmaktadır. Çalışma bu motivasyonla, Türkiye genelini kapsayan bir veri setiyle, farklı yöntemleri karşılaştırmalı olarak analiz etmeyi ve yapay zekâ temelli tahmin modellerinin uygulanabilirliğini test etmeyi amaçlamaktadır.

3. Amaç ve Yöntem

Bu çalışmada, Türkiye'deki toplam su tüketiminin kısa dönemli tahminine yönelik olarak, Hodrick–Prescott (HP) filtreleme yöntemi ile ön işleme tabi tutulmuş veriler kullanılarak iki farklı modelleme yöntemi uygulanmıştır. Bunlar; Yapay Sinir Ağları (YSA) ve Çoklu Doğrusal Regresyon (ÇDR)'dur. Literatürde öne çıkan ve doğrusal olmayan yapıları başarılı şekilde modelleme yeteneği nedeniyle YSA tercih edilmiştir. Alternatif olarak, istatistiksel doğruluk ve açıklanabilirlik açısından yaygın kullanılan bir yaklaşım olan ÇDR yöntemiyle karşılaştırma yapılması uygun görülmüştür. Böylece, farklı yapıda iki yöntemin su tüketim tahminindeki başarıları karşılaştırmalı biçimde değerlendirilmiştir.

Modellerde bağımlı değişken olarak Türkiye'nin yıllık toplam su tüketimi (m^3), bağımsız değişkenler olarak ise ortalama yıllık sıcaklık ($^{\circ}C$), yıllık toplam yağış miktarı (kg/m^2) ve ihracat verisi kullanılmıştır. Bu değişkenler hem literatürde sıkça yer almaları hem de su tüketimi üzerinde doğrudan etkili olmaları nedeniyle tercih edilmiştir. Söz konusu veriler 2001–2021 dönemine ait olup Türkiye İstatistik Kurumu (TÜİK) ve Meteoroloji Genel Müdürlüğü (MGM) gibi kurumsal kaynaklardan temin edilmiştir. Eğitim ve test süreçlerinde verinin %80'i modelin öğrenme süreci için, kalan %20'si ise

performans testleri için ayrılmıştır. Modelleme süreçleri Excel ortamında ön işleme, Matlab programında *nnntool* araç takımı kullanılarak gerçekleştirilmiştir.

3.1. Değişkenler

Su tüketimini etkileyen çok sayıda faktör bulunmakla birlikte, bu çalışmada literatürde sıkça kullanılan ve verisine güvenilir biçimde erişilebilen üç temel bağımsız değişken dikkate alınmıştır. Bunlar nüfus, ortalama yıllık sıcaklık ve ihracattır. Bu değişkenlerin seçiminde hem su tüketimi üzerindeki etkileri hem de sürdürülebilir planlamalarda kullanılabilirlikleri belirleyici olmuştur.

Nüfus, doğrudan su talebini artıran temel değişkenlerden birisidir. Ortalama sıcaklık ise buharlaşma, tarımsal sulama ve içme-kullanma amaçlı tüketimi etkileyerek su talebi üzerinde belirgin bir rol oynamaktadır. İhracat ise, ülkedeki üretim hacmi ve endüstriyel faaliyetlerle doğrudan ilişkili olup, dolaylı biçimde su tüketiminde artışa neden olmaktadır. Öte yandan, literatürde yer alan yağış ve gayri safi yurt içi hasıla gibi değişkenler, veri tutarlılığı ve erişilebilirlik açısından yeterli bulunmadığından bu çalışmaya dahil edilmemiştir. Özellikle yağış verilerine güvenilir ve düzenli şekilde ulaşılamaması, bu değişkenin modele dâhil edilmesini engellemiştir. Gayrisafi yurt içi hasıla verileri ise yalnızca Türk lirası cinsinden bulunabilmiş, enflasyonist koşullar altında sağlıklı bir ölçüt olmamıştır. Ayrıca bu değişkenlere ilişkin güvenilir uzun dönem tahmin verilerinin mevcut olmaması da çalışmaya dâhil edilmemelerinin bir diğer nedeni olmuştur.

Kullanılan değişkenlerin kısa açıklamaları ve modeldeki gösterimleri, Tablo 3'te sunulmaktadır.

Tablo 3: Notasyon Tablosu

Sembol	Açıklama
ST	Su Tüketimi
N	Nüfus
IH	İhracat
S	Sıcaklık
ST ^T	Su Tüketimi Eğilim Bileşeni
ST ^C	Su Tüketimi Döngüsel Hareket Bileşeni
YSA	Yapay Sinir Ağları
ÇDR	Çoklu Doğrusal Regresyon
HP Filtreleme	Hodrick-Prescott Filtreleme

Bu bağlamda, çalışmada kullanılan su tüketim tahmin modeli Denklem (1) ile gösterilmektedir:

$$ST = f(N, IH, S) \quad (1)$$

3.2. Veri Seti

Modellemede kullanılan veriler, 2001–2021 dönemini kapsayan yıllık verilerden oluşmaktadır. Bağımsız değişkenler olan nüfus, ihracat ve yıllık ortalama sıcaklık ile bağımlı değişken olan toplam su tüketimi verileri, aşağıda belirtilen ulusal kurumsal kaynaklardan temin edilmiştir:

- Nüfus ve ihracat verileri, Türkiye İstatistik Kurumu (TÜİK) tarafından sağlanmıştır.
- Ortalama sıcaklık verileri, Meteoroloji Genel Müdürlüğü (MGM)'nden alınmıştır.
- Toplam su tüketimi verileri, TÜİK'in belediyelerden temin ettiği içme ve kullanma suyu istatistiklerinden elde edilmiştir.

2001–2006 yılları arasındaki nüfus verileri doğrudan mevcut olmadığından, bu dönem için eksik değerler ağırlıklı ortalama yöntemi ile tahmin edilerek tamamlanmıştır. Böylece zaman serisi bütünlüğü korunmuş ve modelin sağlıklı biçimde işlemesi sağlanmıştır.

3.3 Yöntem

2001–2021 dönemine ait zaman serisi verileri, tahminleme işlemi öncesinde durağanlaştırılmıştır. Zaman serisi verilerinin durağanlaştırılmasının temel nedeni, seride yer alan dalgalanmaların ve geçici etkilerin düzleştirilerek daha durağan bir yapıya kavuşturulmasıdır. Durağan hale getirilen veri setleri uzun dönemli tahminlemelerde daha sağlıklı sonuçlar verdiğinden bu işlem uygulanmıştır. Zaman serisi bileşenlerini (trend ve döngüsel hareket) ayırtmak amacıyla kullanılan yöntemler arasında HP (Hodrick–Prescott) filtreleme, Baxter-King filtresi, Christiano-Fitzgerald filtresi ve Beveridge-Nelson ayrışımı gibi teknikler yer almaktadır.

Bu çalışmada, yaygın kullanımı ve hesaplama kolaylığı nedeniyle HP filtreleme yöntemi tercih edilmiştir. Böylece verilerin uzun dönemli eğilim (trend) ve döngüsel hareket (cyclical component)

bileşenleri ayrıştırılmıştır. Elde edilen bu bileşenler hem ÇDR hem de YSA modellerine ayrı ayrı girdi olarak verilmiş ve farklı kombinasyonlar denenerek en başarılı tahminleme çıktısı hedeflenmiştir.

3.3.1. HP Filtreleme

HP filtreleme yöntemi, zaman serisi verilerinden uzun dönemli eğilim (trend) bileşenini ayıklamak için kullanılan yaygın bir düzleştirme tekniğidir (Hodrick & Prescott, 1997). Bu yöntem ile ham zaman serisi verileri, kısa dönemli dalgalanmalardan arındırılarak eğilim ve döngüsel hareket (cycle) bileşenlerine ayrıştırılır. Elde edilen eğilim bileşeni, uzun dönemli tahminlemelerde; döngüsel bileşen ise orta dönemli dalgalanmaların analizinde kullanılabilir.

Bu çalışmada, Türkiye'nin yıllık toplam su tüketimi verisi ST_t , HP filtreleme ile iki bileşene ayrıştırılmıştır. HP filtreleme optimizasyon problemi Denklem (2)'de tanımlandığı üzere, orijinal seri ile eğilim bileşeni arasındaki farkların kareleri toplamını en aza indirmeyi, aynı zamanda eğilim bileşeninin ikinci farkındaki dalgalanmaları cezalandırmayı amaçlamaktadır.

$$\min \left\{ \sum_{t=1}^N (ST_t - ST_t^T)^2 + \lambda \sum_{t=2}^{N-1} [(ST_{t+1}^T - ST_t^T) - (ST_t^T - ST_{t-1}^T)]^2 \right\} \quad (2)$$

N örneklem büyüklüğünü göstermektedir. λ düzgünleştirme parametresidir ve sıfırdan büyüktür. Bu parametre, eğilim bileşenindeki devingenliği cezalandırarak daha durağan bir trend elde edilmesini sağlamaktadır.

Döngüsel hareket bileşeni ise Denklem (3)'te gösterildiği gibi, orijinal seriden eğilim bileşeninin çıkarılmasıyla elde edilir.

$$ST^C = ST - ST^T \quad (3)$$

Döngüsel hareket bileşeni toplamdan eğilim bileşeninin çıkarılmasıyla bulunur. Bu yüzden eğilim bileşeni ne kadar büyük olursa diğer bileşen o kadar küçük olur. λ değeri büyüdükçe ceza artmaktadır.

3.3.2. Çoklu Doğrusal Regresyon (ÇDR)

Çoklu doğrusal regresyon analizi, birden fazla bağımsız değişkenin bağımlı değişken üzerindeki doğrusal etkisini modelleyerek tahminleme yapılmasına olanak tanımaktadır. (Gujarati & Porter, 2009). Bu çalışmada su tüketimi, nüfus (N), ihracat (IH) ve ortalama sıcaklık (S) değişkenlerine bağlı olarak modellenmiştir. Regresyon denkleminde göre:


$$ST = c_0 + c_1 N + c_2 IH + c_3 S \quad (4)$$

Burada ST su tüketimini, c_0 sabit terimi, c_1, c_2, c_3 ise her bir bağımsız değişkenin etkisini ifade eder. Katsayılar hesaplanarak hem eğilim hem de döngüsel bileşenler için tahminleme yapılmıştır.

3.3.3. Yapay Sinir Ağları (YSA)

YSA, insan beyninin öğrenme ve genelleme yeteneklerini taklit eden matematiksel modellerdir (Öztürk&Şahin). YSA, girdi ve çıktı arasındaki karmaşık ilişkileri öğrenerek tahminleme yapabilir. YSA yapısı giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç temel katmandan oluşmaktadır. Yapay sinir ağları mimarisi Şekil 5'te yer almaktadır.


Şekil 5: Yapay Sinir Ağı Mimarisi Kaynak: Kabalcı, 2014



Şekil 5'te gösterilen ağ yapısına göre, girdi verileri, X_{ij} giriş katmanında ilgili ağırlıklar w_{ik} ile çarpılarak gizli katmana aktarılır. Bu veriler, bir toplama fonksiyonundan geçtikten sonra aktivasyon fonksiyonu ile işlenir. Aktivasyon fonksiyonu, özellikle doğrusal olmayan ilişkileri modellemek amacıyla yaygın olarak sigmoid fonksiyonu olarak seçilir (Öztemel, 2003). Sigmoid fonksiyonu, küçük girişler için 0'a, büyük girişler için 1'e yaklaşan S-şeklinde bir eğriye sahiptir.

YSA'nın bu çalışmada kullanılan çeşidi, geri yayımlı yapay sinir ağıdır. Bu ağda, hedef ile tahmin arasındaki hata (loss) hesaplanarak ağırlıklar güncellenir (Öztürk & Şahin, 2018). Geri yayılım algoritması sayesinde ağ, en uygun ağırlıkları öğrenerek minimum hataya ulaşmayı hedefler. Öğrenme süreci tamamlandıktan sonra, test verileri ile modelin tahmin gücü değerlendirilir. Şekil 6'da örnek model gösterilmiştir.

Şekil 6: Yapay Sinir Ağı Çalışma Yöntemi Kaynak: Kabalcı, 2014




Bu süreç sonunda, model her bir bağımsız değişkenin çıktıya olan katkısını öğrenmiş olur ve tahminleme amacıyla kullanılabilir hale gelir.

3.4. Bulgular

Su tüketimi ve tüketimi etkileyen veri setlerinin içerisindeki dalgalanmaların arındırılması için HP filtreleme metodu uygulanmıştır. Böylece düzeltme işlemi gerçekleştirilmiştir. Oluşan döngüsel hareket bileşen serileri C sembolü ile, eğilim bileşeni serileri T sembolü gösterilmiştir. Şekil 7 ihracata, ortalama sıcaklığa, nüfusa ve yıllık su tüketimine ait 2001 ile 2021 yılları arasındaki orijinal, döngüsel hareket ve eğilim bileşenleri veri setlerini grafiksel olarak göstermektedir. Şekil 7'deki grafiklerin sağ dikey eksenini döngüsel hareket bileşen değerlerini gösterirken, sol dikey eksenini eğilim bileşeni ve orijinal veri seti değerlerini göstermektedir.

Şekil 7: HP Filtrelenmiş İhracat, Ortalama Sıcaklık, Nüfus ve Su Tüketimi



Çıkan eğilim ve döngüsel hareket bileşenleri sonuçlarının birbirleriyle ilişkileri yoktur. Yıllık tekrar eden döngüsellik arındırarak yeni veri setleri oluşturmuştur. Şekil 7’de verilen ihracat ve ortalama sıcaklık verilerinin HP filtrelemesi yapıldıktan sonra orijinal veri setinden döngüsellik düzeltilirdikten sonra eğilim bileşeni düzgün artan bir hale gelmiştir.

Korelasyon ilişkileri Tablo 4 ve Tablo 5’te gösterilmiştir.

Tablo 4: Su Tüketimi ve Etkileyen Faktörler Arasındaki Korelasyon Katsayısı

Korelasyon Katsayısı	Su tüketimi	Nüfus	Ortalama sıcaklık	İhracat
Su tüketimi	1			
Nüfus	0,89471556	1		
Ortalama sıcaklık	0,51084305	0,20178710	1	
İhracat	0,72874702	0,241489061	0,27291096	1

Tablo 5: HP Filtreleme Öncesi ve Sonrası Su Tüketimi ve Etkileyen Faktörler Arasındaki Korelasyon Katsayısı

Etkenler	ST ile Korelasyon Katsayısı	ST ^T ile Eğilim Bileşeni Korelasyon Katsayısı	ST ^C ile Döngüsel Hareket Bileşeni Korelasyon Katsayısı
Nüfus	0,8947156	0,94909	0,0369833
İhracat	0,72874702	0,85858908	-0,3072229
Ortalama Sıcaklık	0,510843059	0,974582921	-0,234599092

Tablo 4 ve 5’e göre, nüfus ile su tüketimi arasındaki ilişki oldukça güçlüdür. Ortalama sıcaklığın etkisi daha zayıf, değişkenler arasındaki korelasyon ise düşük düzeyde olduğundan çoklu doğrusal bağlantı sorunu bulunmamaktadır. HP filtre uygulandıktan sonra nüfus, ihracat ve sıcaklıkla su tüketimi arasındaki korelasyon 0,85’in üzerine çıkmıştır. Bu da uzun dönemli eğilimlerde ilişkinin güçlendiğini gösterirken, döngüsel bileşenlerdeki düşük değerler kısa dönemli dalgalanmaların etkisinin sınırlı olduğunu ortaya koymaktadır.

Oluşan bu döngüsel hareket ve eğilim bileşeni veri setlerini çoklu doğrusal regresyon modeline yüklenmiştir. Döngüsel hareket veri seti regresyon analizi sonuçları, Tablo 6’da verilmiştir.

Tablo 6: Döngüsel Hareket Regresyon Analizi Sonuçları

Regresyon İstatistikleri					
Çoklu R		R^2	Düzeltilmiş R^2	Standart Hata	Gözlem
0,392642065		0,154167791	0,004903284	1579,173023	1579,173023
ANOVA					
	df	SS	MS	F	Anlamlılık F
Regresyon	3	7727122	2575707,428	1,03285	0,403027039
Fark	17	42394386	2493787,435		
Toplam	20	50121509			
		Katsayılar	Standart Hata	t Stat	P -değeri
Kesişim		-5,97346E-10	344,6038	-1,73343E-12	1
Nüfus (C)		-1,625956114	11,81797	-0,137583378	0,892186
Ortalama Sıcaklık (C)		-762,4346118	709,9301	-1,073957337	0,29785
İhracat (C)		-0,402124484	0,289481	-1,389122537	0,182725

Tablo 6 incelendiğinde, döngüsel hareket bileşeni R² değeri 0.15, düzeltilmiş R² değeri 0.0049 olduğu görülmektedir. Bu modelde su tüketimi bağımlı değişkeni bağımsız değişkenler tarafından açıklanamadığını göstermektedir. Döngüsel hareket bileşeni F anlamlılık değeri 0,4 değerindedir. Modelleme bu veri seti için anlamlı olmadığını göstermektedir. Değişkenlerin p değerleri de 0,05’ten büyüktür. Bu durum, değişkenler ile çıktı arasında bir bağlantı bulunmadığını göstermektedir. Döngüsel hareket bileşeni regresyon analizine göre tahminleme denklemi, Denklem (5)’te gösterilmiştir.

$$ST(C) = -5,973 * 10^{-10} - 1,625 * N(C) - 0,402 * IH(C) - 762,434 * S(C) \quad (5)$$

Eğilim bileşeni veri seti sonuçları, Tablo 7’de yer almaktadır.

Tablo 7: Eğilim Bileşeni Regresyon Analizi Sonuçları

Regresyon İstatistikleri

Çoklu R	R^2	Düzeltilmiş R^2	Standart Hata	Gözlem
0,996844	0,993697	0,992585	537,8166	21
ANOVA				
	df	SS	MS	F
Regresyon	3	775216271,7	2,58E+08	893,3739
Fark	17	4917193,626	289246,7	
Toplam	20	780133465,3		
		Katsayılar	Standart Hata	t Stat
Kesişim		-48423,7	59235,91043	-0,81747
Nüfus (C)		-9,00243	2,360146526	-3,81435
Ortalama Sıcaklık (C)		11579,48	5481,775403	2,112359
İhracat (C)		0,33427	0,053426113	6,256673
				P-değeri
				0,424968
				0,001387
				0,049754
				8,69E-06


Tablo 7’de görüldüğü üzere, eğilim bileşeni için R^2 değeri 0.993 ve düzeltilmiş R^2 değeri 0.992 bulunmuştur. Bu değerler, modelin su tüketimini yüksek doğrulukla açıkladığını göstermektedir. F testinin anlamlı çıkması ve p değerlerinin de 0.05’in altında olması, bağımsız değişkenlerle su tüketimi arasında anlamlı ilişkiler olduğunu göstermektedir. Katsayılara göre nüfus artışı su tüketimini azaltıcı yönde görünse de ihracat ve sıcaklıktaki artışlar bu etkiyi dengeleyerek toplam tüketimi yükseltmektedir.

Eğilim bileşeni regresyon analizine göre tahminleme denklemi Denklem (6)’da gösterilmiştir.

$$ST(T) = -48423,7 - 9,00243 * N(T) + 11579,48 * S(T) + 0,33427 * IH(T) \quad (6)$$

İlgili analizlerin devamında YSA metodu döngüsel hareket ve eğilim bileşeni veri setlerine uygulanmıştır. Çeşitli gizli katman sayılarında 1000 iterasyon yapılarak modelleme çalıştırılmıştır. Katman sayısının 8, 10 ve 12 olarak oluşturulan modellerin regresyon değerlerinin sonuçları Şekil 8’de verilmiştir.


Şekil 8: Gizli Katman Sayısı 8, 10 ve 12 Olan YSA Sonuçları



Sonuçlar değerlendirildiğinde, en yüksek R değeri 10 gizli katmana sahip modelde elde edilmiştir. R değeri, gerçek değerler ile yapay sinir ağı modelinden elde edilen tahminler arasındaki korelasyonu göstermektedir. Başka bir deyişle, 10 gizli katmanlı modelin çıktıları ile gerçek değerler %99,9 oranında örtüşmektedir.

Çalışmanın modeli, Şekil 9'daki gibi oluşturulmuş ve Matlab programında *nnTool* araç takımı kullanılarak çalıştırılmıştır. Program girdilerin ağırlıkları güncelleyerek hata sinyali en aza indirmeye çalışmaktadır. Öğrenme işlemi ise burada gerçekleştirilmektedir.

Şekil 9: Oluşturulan Yapay Sinir Ağı Modeli




Tüm modellerin ortalama bağıl hataları Tablo 8’de yer almaktadır.

Tablo 8: Modellerin Ortalama Bağıl Hata Sonuçları

	YSA ST (C)	ÇDR ST (C)	YSA ST (T)	ÇDR ST (T)	YSA ST	ÇDR ST
Ortalama Bağıl Hata	%6,41	%259,40	%0,03	%1,06	%0,58	%3,66

Döngüsel hareket yapay sinir ağları, orijinal değer ve çoklu doğrusal regresyon uygulandıktan sonraki sonuçları ve bu sonuçların bağıl hataları, Ek 1’de yer alan Tablo 10’da gösterilmiştir. Beklenildiği gibi, döngüsel hareket bileşen su tüketiminde çoklu doğrusal regresyon sonuçları gerçek değerden uzak sonuçlar vermektedir. Yapay sinir ağlarıyla aynı tahminlemeler yapıldığında, gerçek tüketim değerlerine çok daha yakın olduğu görülmektedir. Değişkenler arasında doğrusal bir ilişki olmamasından dolayı bu durum ortaya çıkmıştır. Sonuçların grafiksel gösterimi, Şekil 10’da görülmektedir. Döngüsel hareket bileşenler için yapay sinir ağlarının ortalama bağıl hatası %6,41 olarak ölçülmüşken, çoklu doğrusal regresyon yönteminin ortalama bağıl hatası %259,4 olarak ölçülmüştür (Tablo 10).


Şekil 10: Döngüsel Hareket Bileşen Su Tüketimi Farklı Modellerle Tahminleme



Eğilim bileşeni su tüketimi yapay sinir ağları, orijinal değer ve çoklu doğrusal regresyon yöntemleri uygulandıktan sonraki sonuçları ve bu sonuçların bağıl hataları, Ek 1’de yer alan Tablo 11’de


gösterilmiştir. Ayrıca, Şekil 11’de sonuçlar grafiksel olarak ortaya koyulmuştur. Yapay sinir ağlarının ortalama bağıl hatası %0,03, çoklu doğrusal regresyonun ise %1,06 olarak ölçülmüştür.

Şekil 11: Eğilim Bileşeni Su Tüketimi Farklı Modellerle Tahminleme



HP filtreleme uygulanmamış su tüketimi verilerine yapay sinir ağları, orijinal değer ve çoklu doğrusal regresyon uygulandıktan sonraki sonuçları ve bu sonuçların bağıl hataları, Ek 1’de yer alan Tablo 12’de gösterilmiştir. Orijinal veri setindeki değişkenleri yapay sinir ağları ve çoklu doğrusal regresyon yöntemleri uygulandığında ortaya çıkan sonuçların grafiksel gösterimi Şekil 12’deki gibidir. Yapay sinir ağlarının ortalama bağıl hatası %0,58, çoklu doğrusal regresyonun bağıl hatası ise %3,66 olarak ölçülmüştür (Tablo 12).

Şekil 12: Su Tüketimi Farklı Modellerle Tahminleme




Yapay sinir ağları ve çoklu doğrusal metotları uygulanan veri setleri ayrı ayrı incelendiğinde, gerçek sonuçlara yakınlığı grafiklerden gözlenmektedir. HP filtreleme metoduyla döngüsel hareket ve eğilim bileşeni olarak ayrılan su tüketimleri HP filtreleme metodu formülüyle birbirlerine eklenerek toplam su tüketim verilerine ulaşılmıştır. Sonuçların kıyaslanması için de bağıl hatalarına bakılarak gerçek sonuçtan ne kadar uzakta olduğu gözlemlenebilmektedir. Bunun için altı farklı modelleme kombinasyonu oluşturularak bağıl hataları birbirleriyle kıyaslanabilmektedir. Bu modeller;

- Yapay sinir ağları ST(C)+ Yapay sinir ağları ST(T),
- Yapay sinir ağları ST(C)+ Çoklu doğrusal regresyon ST(T),

- Çoklu doğrusal regresyon ST(C)+ Yapay sinir ağları ST(T),
- Çoklu doğrusal regresyon ST(C)+ Çoklu doğrusal regresyon ST(T),
- Yapay sinir ağları ST,
- Çoklu doğrusal regresyon ST'dir.

Bu modellerin sonuçlarının bağıl hatalarının yüzdelik olarak gösterimi, Şekil 13'te verilmiştir.

Şekil 13: Farklı Model Kombinasyonlarının Yüzde Bağıl Hataları



HP filtreleme yöntemi, modelin duyarlılığını arttırmıştır. Çoklu doğrusal regresyonda ortalama bağıl hata %3,66 iken, HP filtrelemesi sonrasında bu değer %3'e düşmüştür. Yapay sinir ağları yöntemi ise çok daha yüksek doğruluk sağlamış; hata oranı orijinal veriyle %0,58, HP filtrelenmiş eğilim ve döngüsel bileşenlerle ise %0,24 olarak bulunmuştur.

Tüm modeller karşılaştırıldığında, en düşük hata oranını %0,24 ile HP filtrelenmiş veriye ayrı ayrı YSA uygulanarak elde edilen model vermiştir. İkinci en başarılı sonuç ise %0,58 hata oranıyla, orijinal veriye doğrudan uygulanan YSA modelidir. Değişkenlerin katkısı da ayrı analiz edilerek test edilmiş, en iyi sonuçların yine HP filtrelenmiş bileşenlere uygulanan YSA ile elde edildiği doğrulanmıştır (Tablo 9).

Tablo 9: Su Tüketimini Etkileyen Faktörlerin Modelden Çıkarılmasıyla Ortalama Bağıl Hata

YSA (T)+ YSA (C)			
	IH'siz	S'siz	N'siz
Ortalama Bağıl Hata	1,975%	1,261%	0,958%

Tüm değişkenler modele dahil olduğunda ortalama bağıl hata %0,24 çıktığı görülmüştür. İhracat çıkarıldığında ortalama bağıl hata %1,975'e; ortalama sıcaklık çıkarıldığında %1,261'e ve nüfus çıkarıldığında ise %0,958'e arttığı görülmüştür. En iyi sonucun tüm değişkenlerin modellemeye kullanıldığında elde edildiği görülmüştür. Bu da model için seçilen etkenlerin makul olduğunu göstermektedir.

3.3.4. 2030 ve 2050 Yılları İçin Su Tüketim Tahminlemesi

Günümüzde kaynakların verimli kullanılarak gelecek nesillere aktarılması kritik bir konudur. Üretim ve tüketim dengesinin korunması, sürdürülebilirlik kavramının önemini ortaya koymaktadır. Birleşmiş Milletler'in 2015 yılında ilan ettiği Sürdürülebilir Kalkınma Hedefleri, 2030 yılına kadar temiz suya erişim dâhil birçok hedefi içermektedir (Eşkinat, 2016). İklim değişikliği ve su kaynaklarının azalması nedeniyle 191 ülke tarafından kabul edilen Paris İklim Anlaşması'na Türkiye de taraf olmuş, 2050 yılına kadar sıfır karbon emisyonu hedefini benimsemiştir (Karakaya, 2016). Bu nedenle, çalışmada 2030 ve 2050 yılları temel hedef dönemleri olarak seçilmiştir.


Tahmin yapılabilmesi için gelecekteki belirleyici faktörlere ihtiyaç vardır. Ancak yıllık bazda veriler her zaman mevcut değildir. Bu nedenle uzun dönemli öngörüler kullanılmıştır. Meteoroloji Genel Müdürlüğü'nün tahminlerine göre Türkiye'de ortalama sıcaklığın 2030'da 2°C, 2050'de ise 3°C artması beklenmektedir (Akçakaya vd., 2015). Birleşmiş Milletler Ekonomik ve Sosyal İşler Bölümü'nün raporuna göre Türkiye nüfusu 2030'da 88,4 milyon, 2050'de ise 95,6 milyona ulaşacaktır. Türkiye

İhracatçılar Meclisi'nin öngörüsüne göre ihracat hacmi 2030'da 258 milyar dolar, 2050'de ise 500 milyar dolara çıkacaktır (Güler, 2021).

HP filtreleme metodu zaman serisi veri setiyle düzleştirme yaptığından dolayı, uzun dönemli filtreleme yapılamamaktadır. 2030 ve 2050 yılları için eğilim ve döngüsel hareket bileşenleri oranlama yöntemiyle bulunmuştur. Bu oranlama 2001 ve 2021 yılları için çalışma yapılan veri setinden elde edilmiştir. Türkiye nüfus verisinin nüfus eğilim bileşenine oranı %1,00084 ile %0.99009 aralığında değişmektedir. Diğer bileşenlerinin de eğilim bileşenine oranları bulunarak maksimum ve minimum eğilim bileşen değerleri elde edilmiştir. 2030 ve 2050 eğilim bileşeni veri setiyle orijinal değerden çıkarılarak döngüsel hareket bileşen değerleri de bulunmuştur.

Oluşturulan veri setiyle en iyi sonucu veren yapay sinir ağları eğilim ve döngüsel hareket bileşenleri kullanılarak su tüketim tahminlemesi yapılmıştır. Türkiye'deki su tüketiminin yıllara göre değişimi ve 2030 ve 2050 yılların tahminlemesi Şekil 14'te gösterilmiştir. Buna göre sonuç aralığı 2030 yılı için $[58.616,5762 \times 10^5 \text{ m}^3, 69.828,3102 \times 10^5 \text{ m}^3]$ ve 2050 yılı için $[64.359,7615 \times 10^5 \text{ m}^3, 84.293,90122 \times 10^5 \text{ m}^3]$ aralıkları ortaya çıkmaktadır. Ortalama yıllık su tüketimi değerleri 2030 yılı için $64.222,4432 \times 10^5 \text{ m}^3$, 2050 için $74.326,83138 \times 10^5 \text{ m}^3$ olarak bulunmuştur. Tahminleme sonucuna göre su sistemleri ve temiz su kaynaklarının planlanması konusunda kararlar verilebilir ve geleceğe yönelik bazı yatırımlar yapılabilir.

Şekil 14: Türkiye'deki İçme ve Kullanma Suyu Tüketimi ve Tahminlemesi



4. Tartışma ve Sonuç

Su, insan yaşamının en temel gereksinimlerinden biridir. Yalnızca içme amacıyla değil, tarım, hayvancılık, temizlik ve üretim faaliyetleri için de vazgeçilmezdir. Ancak küresel ısınma ve çevresel kirlilik, su kaynaklarını giderek daha kısıtlı hale getirmektedir. Bu nedenle mevcut kaynakların verimli yönetilmesi büyük önem taşımaktadır. Gelecekte su kıtlığı riskini azaltmak için stratejik planlamaların yapılması, doğru talep tahminlerine dayanmaktadır.

Bu çalışmada, Paris İklim Anlaşması ve Sürdürülebilir Kalkınma Hedefleri doğrultusunda 2030 ve 2050 yıllarına yönelik su tüketim tahminleri yapılmıştır. Analizlerde nüfus, ortalama sıcaklık ve ihracat değişkenleri kullanılmıştır. Veriler HP filtreleme yöntemiyle eğilim ve döngüsel bileşenlerine ayrılmış, ardından çoklu doğrusal regresyon ve yapay sinir ağları (YSA) yöntemleri uygulanmıştır. Bulgular, döngüsel bileşenlerde regresyon modelinin zayıf kaldığını, doğrusal olmayan ilişkilerde ise YSA'nın çok daha yüksek doğruluk sağladığını göstermektedir. Özellikle YSA eğilim ve döngüsel bileşen (YSA(T)+YSA(C)) kombinasyonu, en düşük hata oranıyla en başarılı sonuçları vermiştir.

Bu çalışmanın bulguları, literatürde tespit edilen temel boşluklarla doğrudan örtüşmektedir. Mevcut araştırmaların büyük bölümü kısa dönemli ve şehir ölçekli tahminlere odaklanırken, bu çalışma ulusal ölçekli ve uzun dönemli senaryo tahminleri üretmesi bakımından literatüre özgün bir katkı sağlamaktadır. Ayrıca, önceki çalışmalarda bağımsız değişken çeşitliliğinin sınırlı olması model

doğruluğunu azaltmakta iken, bu çalışmada nüfus, sıcaklık ve ihracat gibi Türkiye ölçeğinde anlamlı değişkenlerin birlikte ele alınması tahmin performansını artırmıştır. HP filtreleme ile trend bileşenlerinin ayrıştırılması, YSA ve ÇDR modellerinin karşılaştırmalı kullanımı da literatürdeki yöntemsel eksikliği gidermekte; böylece Türkiye için uzun dönem su tüketimi tahminlerinde daha bütüncül bir yaklaşım sunmaktadır.

Sonuçlar, 2050 yılında su tüketiminde ciddi bir artış yaşanacağını, 2030'da ise artış hızının daha sınırlı olacağını ortaya koymaktadır. Bu tahminler, Türkiye'de artan nüfus ve sıcaklık karşısında su yönetimi politikalarının kritik bir rol oynayacağını göstermektedir. Bu amaçla, talep yönetimi önlemlerinin uygulanması 2030'da su tüketim dengesini koruyabilecektir. Ancak 2050 için daha kapsamlı politikalar gereklidir. Bu tahminler uzun dönem trend bileşenlerine dayalı öngörüler olduğu için Birleşmiş Milletler'in 2030 ve Paris 2050 hedefleri doğrultusunda değerlendirilmelidir.

Elde edilen bulgular, suyun sürdürülebilir yönetimi için somut ipuçları sunmaktadır. Su tüketiminin kontrolü, atık suyun geri kazanımı, üretimde içme suyu kullanımının azaltılması ve yeni kaynakların geliştirilmesi, gelecekte su kıtlığı riskini azaltacaktır. Aksi halde, Türkiye'nin artan nüfus ve iklim değişikliği baskısı altında su tüketim yasaklarını daha sık uygulamak zorunda kalacağı öngörülmektedir. Su tüketimi üzerine yapılan çalışmalarda genel olarak kısa dönem tahminlemeler üzerine çalışmalar yapılmıştır. Verilerin ulaşılmasının kolaylığı bu duruma etki etmiştir. Yapılan çalışmalarda genel olarak birden fazla yöntem birbirleri ile kıyaslanarak en iyi tahminleme metodu üzerine çalışılmıştır. Bu çalışma ise, uzun dönem su tüketim tahminlemesi üzerine yapılmıştır. Literatürde genel olarak bir şehrin su tüketim tahminlemesi üzerine çalışma yapılmasına karşın bu çalışmada Türkiye'nin su tüketimi tahminlemesi gerçekleştirilmektedir. Yapılan çalışmalardan farklı olarak bir metodun diğerinden daha iyi tahminleme yaptığını ispatlamak yerine en iyi sonuç veren tahminleme kombinasyonunu ortaya çıkararak geleceğe dair su tüketim tahminlemesi amaçlanmıştır.

Çalışmada geçmiş verilere ulaşmakta zorluklar yaşanmıştır. Çalışmanın sadece Türkiye'de yapılması bir başka kısıttır. Uzun dönem tahminlerin doğruluğunun kısa dönem tahminlemelere daha zayıf olması, çalışmanın doğruluğunu düşürmektedir. Gelecekte daha kısa dönemli tahminlemeler yaparak modelin doğruluk derecesi artırılabilir. Gelecekte 2022 ve sonraki yılların su tüketimi, sıcaklık, nüfus ve ihracat verilerini de kullanarak veri seti genişletilerek, gerçeğe daha yakın sonuçlar elde edilebilir. Ayrıca çalışmaya daha farklı su tüketimini etkileyen faktörler eklenerek model doğruluğu daha da artırılabilir. Ayrıca, farklı tahminleme metodları kullanılarak daha kesin tahminlemelerde bulunulabilir. Su kaynakları tahminlemesi yapılarak da su tüketiminin gelecekte karşılanıp karşılanmayacağı görülebilir. Bu çalışmanın önemli bir kısıtı, analiz döneminin 2021 yılında sona ermesidir. 2022–2025 dönemi için güvenilir ve revizyondan arındırılmış ulusal su tüketim verilerine ulaşamadığı için modelin dış-örnek doğrulaması yapılamamıştır. Bu nedenle, tahminlerin 2021 sonrasındaki gerçek tüketimle ne ölçüde örtüştüğü bu aşamada test edilememiştir. Gelecekte, ilgili veriler yayımlandığında modelin doğrulaması yapılabilir ve özellikle 2021 sonrası gözlenen olası düşüşün geçici bir dalgalanma mı yoksa kuraklık ve idari kısıtlamalardan kaynaklanan yapısal bir kırılma mı olduğu araştırılabilir.

Ayrıca, 2030 yılı için yapılan değerlendirmelerin nokta tahmin olarak değil, belirli varsayımlara dayalı senaryolar şeklinde okunması gerekmektedir. Geçmişte uygulanan kısıtlamalar tüketim üzerinde baskı yaratmış, bu da seride beklenmedik düşüşlere neden olmuştur. Bu tür yerel minimumların gelecekte tekrar edip etmeyeceğini öngörmek güçtür. Bu nedenle, ileriki çalışmalarda güncel verilerle yapısal kırılma testlerinin uygulanması, senaryo temelli tahmin bantlarının oluşturulması ve ilave değişkenlerin (yağış, gelir düzeyi vb.) modele dâhil edilmesi, elde edilen sonuçların güvenilirliğini ve politika önerilerinin sağlamlığını artıracaktır. Elde edilen 2030 ve 2050 projeksiyonları, Türkiye'nin uluslararası taahhütleriyle uyumludur. Birleşmiş Milletler 2030 planı temiz suya erişimin güçlendirilmesini hedeflerken, Paris Anlaşması 2050 yılına kadar net sıfır emisyon öngörmektedir. Bu çalışma, su tüketimi projeksiyonlarını bu politika çerçeveleriyle ilişkilendirerek literatürdeki boşluğu tamamlamaktadır.

5. Kaynakça

- Adamowski, J. F. (2008). Peak daily water demand forecast modeling using artificial neural networks. *Journal of Water Resources Planning and Management*, 134(2), 119-128.
- Adamowski, J., & Karapataki, C. (2010). Comparison of multivariate regression and artificial neural networks for peak urban water-demand forecasting: evaluation of different ANN learning algorithms. *Journal of Hydrologic Engineering*, 15(10), 729-743.

- Adamowski, J., Fung Chan, H., Prasher, S. O., Ozga-Zielinski, B., & Sliusarieva, A. (2012). Comparison of multiple linear and nonlinear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada. *Water Resources Research*, 48(1).
- Akçakaya, A., Sümer, U. M., Demircan, M., Demir, Ö., Atay, H., Eskioğlu, O., ... Çukurçayır, F. (2015). *Yeni senaryolar ile Türkiye iklim projeksiyonları ve iklim değişikliği*. Ankara: Meteoroloji Genel Müdürlüğü Matbaası.
- Aküzüm, T., Çakmak, B., & Gökalp, Z. (2010). Türkiye’de su kaynakları yönetiminin değerlendirilmesi. *Tarım Bilimleri Araştırma Dergisi*, (1), 67-74.
- Altunkaynak, A., Özger, M., & Çakmakci, M. (2005). Water consumption prediction of Istanbul city by using fuzzy logic approach. *Water Resources Management*, 19, 641-654.
- Anele, A. O., Hamam, Y., Abu-Mahfouz, A. M., & Todini, E. (2017). Overview, comparative assessment and recommendations of forecasting models for short-term water demand prediction. *Water*, 9(11), 887.
- Bakhshipour, A. E., Namdari, H., Koochali, A., Dittmer, U., & Haghighi, A. (2024). An ensemble data-driven approach for enhanced short-term water demand forecasting in urban areas. *Engineering Proceedings*, 69 (1).
- Bakker, M., Van Duist, H., Van Schagen, K., Vreeburg, J., & Rietveld, L. (2014). Improving the performance of water demand forecasting models by using weather input. *Procedia Engineering*, 70, 93-102.
- Benítez, R., Ortiz-Caraballo, C., Preciado, J. C., Conejero, J. M., Sánchez Figueroa, F., & Rubio-Largo, A. (2019). A short-term data based water consumption prediction approach. *Energies*, 12(12), 2359.
- Boudhaouia, A., & Wira, P. (2021). A real-time data analysis platform for short-term water consumption forecasting with machine learning. *Forecasting*, 3(4), 682-694.
- Candelieri, A., Soldi, D., & Archetti, F. (2015). Short-term forecasting of hourly water consumption by using automatic metering readers data. *Procedia Engineering*, 119, 844-853.
- Cendere, A. (1998). *Su elemanlarının kentsel mekânlarda ve yeşil alanlarda kullanımı* (Yayımlanmamış yüksek lisans tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Devianto, D., Maiyatri, M., Afrimayani, A., Ramadani, K., Juwita, D., Almuayyar, M., & Bahari, A. (2025). The long short-term memory model as the neural networks approach in modeling water supply structural production. *Communications in Mathematical Biology and Neuroscience*, 2025(39).
- Duerr, I., Merrill, H. R., Wang, C., Bai, R., Boyer, M., Dukes, M. D., & Bliznyuk, N. (2018). Forecasting urban household water demand with statistical and machine learning methods using large space-time data: A Comparative study. *Environmental Modelling & Software*, 102, 29-38.
- Düzenli, T., Alpak, E. M., & Akyol, D. (2019). Peyzaj mimarlığında su ögesinin tarihsel süreçteki kullanım amaçları. *Sanat ve Tasarım Dergisi*, 9(1), 20-35.
- Estrada, A. V., Henning, E., Kalbusch, A., & Walter, O. M. F. C. (2025). Urban water demand forecasting via artificial neural network models: A case study in Southern Brazil. *Discover Sustainability*, 6, 1105.
- Eşkinat, R. (2016). Binyıl kalkınma hedeflerinden sürdürülebilir kalkınma hedeflerine. *Anadolu Üniversitesi Hukuk Fakültesi Dergisi*, 2(3), 267-282.
- Fırat, M., Yurdusev, M. A., & Turan, M. E. (2009). Evaluation of artificial neural network techniques for municipal water consumption modeling. *Water Resources Management*, 23, 617-632.

- Gagliardi, F., Alvisi, S., Kapelan, Z., & Franchini, M. (2017). A probabilistic short-term water demand forecasting model based on the Markov Chain. *Water*, 9(7), 507.
- García-Soto, C. G., Torres, J. F., Zamora-Izquierdo, M. A., Palma, J., & Troncoso, A. (2024). Water consumption time series forecasting in urban centers using deep neural networks. *Applied Water Science*, 14, 21.
- Ghalehkhondabi, I., Ardjmand, E., Young, W. A., & Weckman, G. R. (2017). Water demand forecasting: review of soft computing methods. *Environmental Monitoring and Assessment*, 189, 1-13.
- Gharabaghi, S., Stahl, E., & Bonakdari, H. (2019). Integrated nonlinear daily water demand forecast model (case study: City of Guelph, Canada). *Journal of Hydrology*, 579, 124182.
- Gujarati, D. N., & Porter, D. C. (2009). *Basic econometrics* (5th ed.). New York, NY: McGraw-Hill.
- Güler, İ. (2021). Gençler ve yeni projelerle geleceğe hazırlanıyoruz. *TİMREPORT*, 194, 4–5.
- Gülgün, B., Keskin, N., & Ankaya, F. Ü. (2011). Tarih Boyunca Bahçelerde Su Ögesinin Kullanımı. *Ziraat Mühendisliği*, 357, 18-23.
- Hakyemez, C. (2019). *Su: Yeni Elmas* (TSKB Ekonomik Araştırmalar Tematik Bakış). İstanbul: TSKB.
- Hao, W., Cominola, A., & Castelletti, A. (2022). Comparing predictive machine learning models for short-and long-term urban water demand forecasting in Milan, Italy. *IFAC-PapersOnLine*, 55(33), 92-98.
- Harvey, A. C., & Jaeger, A. (1993). Detrending, stylized facts and the business cycle. *Journal of applied econometrics*, 8(3), 231-247.
- Herrera, M., Torgo, L., Izquierdo, J., & Pérez-García, R. (2010). Predictive models for forecasting hourly urban water demand. *Journal of Hydrology*, 387(1-2), 141-150.
- Hodrick, R. J., & Prescott, E. C. (1997). Postwar US business cycles: an empirical investigation. *Journal of Money, Credit, and Banking*, 1-16.
- Huang, L., Zhang, C., Peng, Y., & Zhou, H. (2014). Application of a combination model based on wavelet transform and KPLS-ARMA for urban annual water demand forecasting. *Journal of Water Resources Planning and Management*, 140(8), 04014013.
- Jain, A., Kumar Varshney, A., & Chandra Joshi, U. (2001). Short-term water demand forecast modelling at IIT Kanpur using artificial neural networks. *Water Resources Management*, 15, 299-321.
- Jain, A., & Ormsbee, L. E. (2002). Short-term water demand forecast modeling techniques—Conventional methods versus AI. *Journal-American Water Works Association*, 94(7), 64-72.
- Kabalıcı, E. (2014). Yapay Sinir Ağları. Ders Notları <https://ekblc.files.wordpress.com/2013/09/ysa.pdf>
- Karakaya, E. (2016). Paris iklim anlaşması: içeriği ve Türkiye üzerine bir değerlendirme. *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 3(1), 1-12.
- Karamaziotis, P. I., Raptis, A., Nikolopoulos, K., Litsiou, K., & Assimakopoulos, V. (2020). An empirical investigation of water consumption forecasting methods. *International Journal of Forecasting*, 36(2), 588-606.
- Kurnaz, L. (2014). Drought in Turkey. İstanbul Policy Center, Sabancı Üniversitesi, İstanbul.
- Li, W., & Huicheng, Z. (2010). Urban water demand forecasting based on HP filter and fuzzy neural network. *Journal of Hydroinformatics*, 12(2), 172-184.
- Liu, J., Savenije, H. H., & Xu, J. (2003). Forecast of water demand in Weinan City in China using WDF-ANN model. *Physics and Chemistry of the Earth, Parts A/B/C*, 28(4-5), 219-224.

- Maier, H. R., & Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental modelling & software*, 15(1), 101-124.
- Martínez, A., Pérez-García, R., & Mora-Méndez, J. (2024). Predicting water distribution: Heterogeneous data modelling in large water networks. *Sustainable Cities and Society*, 103.
- Msiza, I. S., Nelwamondo, F. V., & Marwala, T. (2008). Water demand prediction using artificial neural networks and support vector regression. *Journal of Computers*, 3(11), 1-8.
- Muhammad, A. U., Li, X., & Feng, J. (2019). Artificial intelligence approaches for urban water demand forecasting: a review. In *Machine Learning and Intelligent Communications: 4th International Conference, MLICOM 2019, Nanjing, China, August 24–25, 2019, Proceedings 4*, 595-622. Springer International Publishing.
- Nasseri, M., Moeini, A., & Tabesh, M. (2011). Forecasting monthly urban water demand using extended Kalman filter and genetic programming. *Expert Systems with Applications*, 38(6), 7387-7395.
- Ndehedehe, C. E., Ferreira, V., & Elmahdy, S. I. (2023). Assessing water availability using machine learning and remote sensing datasets: A case study in Africa. *Journal of Hydrology: Regional Studies*, 45.
- Öztemel, E. (2003). *Yapay sinir ağları*. Papatya Yayıncılık, İstanbul.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekaya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Pacchin, E., Alvisi, S., & Franchini, M. (2017). A short-term water demand forecasting model using a moving window on previously observed data. *Water*, 9(3), 172.
- Pegram, G., Conyngham, S., Aksoy, A., Dıvrak, B. B., & Öztok, D. (2014). *Türkiye'nin su ayak izi raporu: Su, üretim ve uluslararası ticaret ilişkisi*. İstanbul: WWF Türkiye.
- Peña-Guzmán, C., Melgarejo, J., & Prats, D. (2016). Forecasting water demand in residential, commercial, and industrial zones in Bogotá, Colombia, using least-squares support vector machines. *Mathematical Problems in Engineering*, 2016.
- Sampathirao, A. K., Grosso, J. M., Sopasakis, P., Ocampo-Martinez, C., Bemporad, A., & Puig, V. (2014). Water Demand Forecasting for the Optimal Operation of Large-Scale Drinetworks: The Barcelona Case Study. *IFAC Proceedings*, 47(3), 10457-10462.
- Seo, Y. H., Sung, J. H., Park, J. S., Kim, B. S., & Park, J. (2025). Future residential water use and management under climate change using Bayesian neural networks. *Water*, 17, 2179.
- Meteoroloji Genel Müdürlüğü (2022). 2021 Yılı İklim Değerlendirmesi. Erişim adresi: <https://mgm.gov.tr/FILES/iklim/yillikiklim/2021-iklim-raporu.pdf>.
- Tiwari, M. K., & Adamowski, J. F. (2015). Medium-term urban water demand forecasting with limited data using an ensemble wavelet–bootstrap machine-learning approach. *Journal of Water Resources Planning and Management*, 141(2), 04014053.
- TÜİK (2009). TÜİK Veri). TÜİK Su İstatistikleri <https://data.TÜİK.gov.tr/Search/Search?text=Belediye%20Su%20%C4%B0statistikleri> [Erişim tarihi: 10 Şubat 2024].
- TÜİK (2013). TÜİK Veri Portalı: Adrese Dayalı Nüfus Kayıt Sistemi Sonuçları, <https://data.TÜİK.gov.tr/Bulten/Index?p=Adrese-Dayali-Nufus-Kayit-Sistemi-Sonuclari-2012-13425> [Erişim tarihi: 10 Şubat 2024].
- TÜİK (2020). TÜİK Veri Portalı: Kaynağına göre Çekilen Su Miktarı <https://data.tuik.gov.tr/Kategori/GetKategori?p=Cevre-ve-Enerji-103> [Erişim tarihi: 10 Şubat 2024].

- TÜİK (2021). TÜİK Veri Portalı: Belediye Su İstatistikleri <https://data.TÜİK.gov.tr/Search/Search?text=Belediye%20Su%20%C4%B0statistikleri> [Erişim tarihi: 10 Şubat 2024].
- TÜİK (2023). TÜİK Veri Portalı: Adrese Dayalı Nüfus Kayıt Sistemi Sonuçları, <https://data.TÜİK.gov.tr/Bulten/Index?p=Adrese-Dayali-Nufus-Kayit-Sistemi-Sonuc-lari-2022-49685> [Erişim tarihi: 10 Şubat 2024].
- TÜİK (2023). TÜİK Veri Portalı: Dış Ticaret İstatistikleri, <https://data.TÜİK.gov.tr/Search/Search?text=d%C4%B1%C5%9F%20ticaret%20istatistikleri> [Erişim tarihi: 10 Şubat 2024].
- Vijai, P., & Sivakumar, P. B. (2018). Performance comparison of techniques for water demand forecasting. *Procedia computer science*, 143, 258-266.
- Vijayalaksmi, D. P., & Babu, K. J. (2015). Water supply system demand forecasting using adaptive neuro-fuzzy inference system. *Aquatic Procedia*, 4, 950-956.
- Walker, D., Creaco, E., Vamvakieridou-Lyroudia, L., Farmani, R., Kapelan, Z., & Savić, D. (2015). Forecasting domestic water consumption from smart meter readings using statistical methods and artificial neural networks. *Procedia Engineering*, 119, 1419-1428.
- Yalçıntaş, M., Bulu, M., Küçükvar, M., & Samadi, H. (2015). A framework for sustainable urban water management through demand and supply forecasting: The case of İstanbul. *Sustainability*, 7(8), 11050-11067.
- Yaşar, A., Bilgili, M., & Şimşek, E. (2012). Water demand forecasting based on stepwise multiple nonlinear regression analysis. *Arabian Journal for Science And Engineering*, 37, 2333-2341.
- Yurdusev, M. A., & Fırat, M. (2009). Adaptive neuro fuzzy inference system approach for municipal water consumption modeling: An application to Izmir, Turkey. *Journal of Hydrology*, 365(3-4), 225-234.
- Zhou, S. L., McMahon, T. A., Walton, A., & Lewis, J. (2000). Forecasting daily urban water demand: a case study of Melbourne. *Journal of Hydrology*, 236(3-4), 153-164.
- Zubaidi, S. L., Al-Bugharbee, H., Muhsin, Y. R., Hashim, K., & Alkhaddar, R. (2020). Forecasting of monthly stochastic signal of urban water demand: Baghdad as a case study. In *IOP Conference Series: Materials Science and Engineering*, 888 (1) p. 012018). IOP Publishing.

EKLER

EK 1: Tablo 10: Döngüsel Hareket Sonuçları ve Bağlı Hatalar

	YSA ST (C)	Su tüketimi (C)	ÇDR ST (C)	YSA Bağlı Hata	ÇDR Bağlı Hata
2001	-1274,48	-1.280,05	-675,07	0,44%	89,62%
2002	106,69	108,32	375,99	1,53%	71,19%
2003	1.075,25	1.076,44	411,24	0,11%	161,75%
2004	1.375,07	1.373,42	266,41	0,12%	415,53%
2005	2.385,38	2.383,77	279,34	0,07%	753,35%
2006	3.406,79	3.406,80	303,02	0,00%	1024,27%
2007	2.389,91	275,24	-445,47	88,48%	161,79%
2008	-2.950,94	-2.950,95	-879,70	0,00%	235,45%
2009	-2.068,55	-2.069,76	619,59	0,06%	434,05%
2010	-1.400,23	-1.400,55	-578,09	0,02%	142,27%
2011	-1.396,86	-1.399,33	682,60	0,18%	305,00%
2012	-1.586,44	-1.642,55	-429,49	3,54%	282,44%
2013	-1.377,94	-1.378,16	-474,03	0,02%	190,73%
2014	-1.332,10	-1.332,27	-904,69	0,01%	47,26%

2015	29,75	30,57	545,85	2,72%	94,40%
2016	1.249,74	1.258,18	755,92	0,67%	66,44%
2017	1.069,32	1.165,78	690,86	9,02%	68,74%
2018	1.021,96	1.021,56	-583,69	0,04%	275,02%
2019	571,07	572,51	121,94	0,25%	369,49%
2020	149,76	108,93	861,64	27,27%	87,36%
2021	671,05	672,11	-944,17	0,16%	171,19%
			Ortalama Bağlı Hata	6,41%	259,40%

Tablo 11: Eğilim Bileşeni Sonuçları ve Bağlı Hatalar

	YSA ST(T)	Su tüketimi(T)	ÇDR ST(T)	YSA Bağlı Hata	ÇDR Bağlı Hata
2001	47.941,82	47.924,16	49.124,57	0,04%	2,44%
2002	48.001,84	48.022,65	48.490,25	0,04%	0,96%
2003	48.106,61	48.108,33	47.929,01	0,00%	0,37%
2004	48.184,79	48.169,50	47.505,56	0,03%	1,40%
2005	48.217,73	48.205,19	47.273,82	0,03%	1,97%
2006	48.228,15	48.228,20	47.266,79	0,00%	2,03%
2007	48.270,80	48.275,13	47.500,83	0,01%	1,63%
2008	48.424,79	48.416,69	47.966,45	0,02%	0,94%
2009	48.731,28	48.726,30	48.648,10	0,01%	0,16%
2010	49.233,97	49.247,89	49.484,90	0,03%	0,48%
2011	50.019,84	50.004,71	50.429,46	0,03%	0,84%
2012	51.000,50	51.005,97	51.566,98	0,01%	1,09%
2013	52.236,04	52.246,91	52.892,07	0,02%	1,22%
2014	53.713,20	53.706,34	54.377,53	0,01%	1,23%
2015	55.358,54	55.349,28	55.966,70	0,02%	1,10%
2016	57.114,56	57.127,43	57.630,87	0,02%	0,87%
2017	58.975,72	58.992,82	59.329,70	0,03%	0,57%
2018	60.936,24	60.910,02	61.032,43	0,04%	0,20%
2019	62.824,26	62.855,29	62.671,03	0,05%	0,29%
2020	64.828,66	64.815,09	64.249,95	0,02%	0,88%
2021	66.732,16	66.781,61	65.782,49	0,07%	1,52%
			Ortalama Bağlı Hata	0,03%	1,06%

Tablo 12: Ham Veri Sonuçları ve Bağlı Hatalar

	YSA ST	Su Tüketimi	ÇDR ST	YSA Bağlı Hata	ÇDR Bağlı Hata
2001	46.075,38	46.644,11	47.518,15	1,23%	1,84%
2002	48.229,56	48.130,97	48.593,50	0,20%	0,95%
2003	48.970,04	49.184,77	48.385,19	0,44%	1,65%
2004	49.689,57	49.542,92	47.768,56	0,30%	3,71%
2005	50.572,98	50.588,96	47.564,33	0,03%	6,36%
2006	51.587,28	51.635,00	47.281,24	0,09%	9,21%
2007	48.160,24	48.550,37	45.798,90	0,81%	6,01%
2008	45.811,77	45.465,74	45.582,08	0,76%	0,26%
2009	46.684,78	46.656,54	50.090,94	0,06%	6,86%

2010	47.841,46	47.847,34	50.282,58	0,01%	4,84%
2011	48.584,15	48.605,38	52.043,87	0,04%	6,61%
2012	49.361,13	49.363,42	51.527,91	0,00%	4,20%
2013	50.798,45	50.868,75	52.737,01	0,14%	3,54%
2014	54.391,73	52.374,07	53.761,01	3,71%	2,58%
2015	55.370,61	55.379,84	57.608,71	0,02%	3,87%
2016	58.383,40	58.385,61	59.666,93	0,00%	2,15%
2017	60.147,61	60.158,59	60.468,83	0,02%	0,51%
2018	61.930,81	61.931,58	60.640,28	0,00%	2,13%
2019	66.238,21	63.427,80	63.030,99	4,24%	0,63%
2020	64.919,57	64.924,02	64.732,72	0,01%	0,30%
2021	67.453,71	67.453,72	62.035,77	0,00%	8,73%
			Ortalama Bağlı Hata	0,58%	3,66%

Tablo 13: Su Tüketimini Etkileyen Faktörlerin Çıkarılarak Model Oluşturulması

YSA (T)+ YSA (C) Su tüketimi Tahminlemesi							
Yıllar	Gerçek değer	IH'sız	Bağlı hata	S'siz	Bağlı Hata	N'siz	Bağlı Hata
2001	46.644	46.754	0,235%	47.663	2,138%	46.653	0,019%
2002	48.131	49.125	2,023%	48.124	0,015%	49.061	1,895%
2003	49.185	48.998	0,381%	48.903	0,576%	49.157	0,057%
2004	49.543	49.122	0,858%	48.672	1,790%	51.560	3,912%
2005	50.589	49.256	2,705%	50.595	0,012%	50.593	0,007%
2006	51.635	48.958	5,469%	50.983	1,280%	51.614	0,040%
2007	48.550	48.386	0,340%	48.521	0,060%	48.553	0,004%
2008	45.466	47.553	4,389%	45.979	1,115%	45.485	0,042%
2009	46.657	48.723	4,242%	47.210	1,173%	47.573	1,927%
2010	47.847	47.797	0,105%	51.196	6,541%	47.853	0,012%
2011	48.605	50.592	3,927%	49.794	2,388%	48.603	0,005%
2012	49.363	51.028	3,262%	50.027	1,326%	49.361	0,004%
2013	50.869	52.583	3,260%	51.300	0,842%	50.875	0,012%
2014	52.374	52.564	0,361%	52.818	0,840%	51.377	1,941%
2015	55.380	56.267	1,577%	56.735	2,388%	55.326	0,098%
2016	58.386	57.530	1,487%	58.293	0,158%	54.188	7,746%
2017	60.159	60.074	0,140%	60.272	0,188%	60.158	0,001%
2018	61.932	60.729	1,980%	61.654	0,450%	62.149	0,349%
2019	63.428	65.419	3,044%	63.360	0,107%	62.166	2,029%
2020	64.924	66.019	1,659%	64.970	0,071%	64.925	0,002%
2021	67.454	67.470	0,025%	65.471	3,028%	67.436	0,026%
Ortalama Bağlı Hata			1,975%		1,261%		0,958%

Research Article**Hodrick-Prescott Filtreleme ve Yapay Sinir Ağları Yöntemiyle Uzun Dönem Su Tüketim Tahmini Üzerine Türkiye Uygulaması***A Case Study on Long-Term Water Consumption Forecasting in Türkiye By Using The Hodrick–Prescott Filter and Artificial Neural Networks*

Ömer Faruk BAYARSLAN Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü ofb_94@hotmail.com https://orcid.org/0000-0003-0100-206X	Onur KOYUNCU Dr. Öğr. Üyesi, Hacettepe Üniversitesi İktisadi İdari Bilimler Fakültesi okuyuncu@hacettepe.edu.tr https://orcid.org/0000-0002-5899-8841
Zehra B. KANIK Arş. Gör. Dr., Çankaya Üniversitesi İktisadi İdari Bilimler Fakültesi zbkanik@cankaya.edu.tr https://orcid.org/0000-0003-1683-060X	Mine ÖMÜRGÖNÜLŞEN Prof. Dr., Hacettepe Üniversitesi İktisadi İdari Bilimler Fakültesi mergun@hacettepe.edu.tr https://orcid.org/0000-0001-6905-1154

Extended Summary

Water is one of the most essential natural resources, forming the foundation of human life, economic activity, and social development. Beyond its direct use for drinking and sanitation, water serves as a critical input for agriculture, industry, energy production, and export-oriented value chains. However, rapid population growth, industrialization, urbanization, and the effects of climate change have placed increasing pressure on the world's freshwater resources. Türkiye, located in a semi-arid climate zone and characterized by irregular precipitation patterns, is among the countries expected to experience water stress in the near future. Therefore, developing long-term and data-driven water demand forecasting models is vital for ensuring sustainable resource planning and effective policy design.

The aim of this study is to identify the main factors influencing Türkiye's total water consumption and to produce reliable forecasts for the years 2030 and 2050. To this end, a hybrid modeling framework combining the Hodrick–Prescott (HP) filtering method, Multiple Linear Regression (MLR), and Artificial Neural Networks (ANNs) was employed. The model analyzes the relationships between Türkiye's total water consumption (dependent variable) and three key independent variables, population, average annual temperature, and exports, within both linear and nonlinear structures. By integrating statistical and machine learning techniques, the study aims to enhance forecasting precision and capture the complex interactions among demographic, climatic, and economic factors that shape national water demand.

Annual data covering the 2001–2021 period were used in the modeling process. Population and export data were obtained from the Turkish Statistical Institute (TUIK), temperature data from the General Directorate of Meteorology (MGM), and total water consumption data from TUIK's municipal drinking and utility water statistics. Because population data for 2001–2006 were unavailable, missing values were estimated using the weighted average method to preserve the integrity of the time series and ensure consistency across all variables.

The selection of variables was guided by their relevance in the literature and their measurable influence on water demand. Population directly increases water demand as a demographic indicator. Average temperature affects water consumption indirectly by influencing evaporation and irrigation needs, thus representing the climatic dimension of water use. Exports reflect industrial production and economic

activity, which are directly linked to the embodied water content in goods and the expansion of industrial water use.

To remove short-term fluctuations and seasonal irregularities, HP filtering was applied to decompose the time series into trend (long-term structural movements) and cyclical (short-term fluctuations) components. This separation enabled the isolation of persistent structural changes from temporary variations. After decomposition, both the original and filtered series were modeled using MLR and ANN techniques. While MLR captures linear relationships among variables, ANNs can model nonlinear and dynamic dependencies. Several ANN architectures with varying hidden layer sizes were tested, and all models were trained using the backpropagation algorithm. Model performance was assessed through the Mean Relative Error (MRE) and correlation coefficients, ensuring that both the magnitude and direction of prediction errors were systematically evaluated.

Correlation analysis revealed strong positive relationships between water consumption and population, temperature, and exports. After applying the HP filter, the correlation coefficients among the trend components exceeded 0.85, indicating that long-term relationships are considerably stronger than short-term fluctuations. This result implies that structural dynamics dominate the evolution of Türkiye's water demand, while short-term shocks such as droughts or temporary restrictions exert only marginal effects on the overall trajectory.

The MLR results demonstrated that the model for cyclical components had a weak explanatory power ($R^2 = 0.15$), while the model for trend components exhibited a remarkably high explanatory capability ($R^2 = 0.993$). This significant difference shows that short-term variations are largely random, whereas long-term consumption follows predictable structural trends. In other words, Türkiye's water demand is shaped mainly by persistent demographic and economic patterns rather than by short-lived anomalies.

ANN models, in contrast, outperformed the regression models by achieving substantially lower error rates and stronger correlations. The hybrid configuration, where trend and cyclical components were modeled separately and then recombined, yielded the best predictive accuracy. In this case, the mean relative error was nearly zero, and the model's fit approached perfection. The ANN applied to HP-filtered data effectively removed short-term noise, allowing the model to capture the underlying structure of water consumption more clearly. This confirms the capacity of neural networks to learn nonlinear patterns that conventional statistical models cannot represent adequately.

The comparative results revealed that exports exert the strongest influence on total water consumption, followed by temperature and population. When exports were excluded from the model, the average error increased almost eightfold, confirming the strong linkage between industrial production, trade intensity, and water use. This finding highlights that national water management must consider not only household and agricultural use but also the growing industrial and trade-related demand that accompanies economic expansion.

The long-term forecasts indicate a moderate increase in water consumption by 2030, followed by a much sharper rise by 2050. This pattern suggests that Türkiye could face growing water scarcity risks if efficiency improvements in agriculture and industry are not realized. Without structural reforms and technological interventions, the imbalance between water supply and demand is expected to widen, potentially leading to economic and social pressures.

The findings confirm that combining HP filtering and ANNs results in a more stable and accurate forecasting framework. HP filtering smooths out irregularities and enhances the interpretability of time series data, while ANNs efficiently capture complex nonlinear interactions. Together, these methods provide a comprehensive understanding of both the structural and behavioral aspects of water demand. Moreover, the results demonstrate that water consumption is not solely determined by demographic growth, but is also driven by climate variability and industrial development factors, which require coordinated policy responses.

This study is among the few to perform a national-scale long-term water demand forecast for Türkiye. While most prior studies have focused on short-term or local analyses, this research provides macro-level insights spanning more than two decades. Rather than evaluating the superiority of a single approach, it compares multiple model combinations and identifies the hybrid configuration with the lowest forecasting error and highest robustness. Such a strategy provides a more flexible and policy-relevant framework for sustainable water governance.

The analysis period was limited to 2021 due to the unavailability of revised national data for 2022-2025, which prevented out-of-sample validation. As a result, the alignment between forecasted and observed

post-2021 values has not yet been verified. Future studies can re-evaluate the model's predictive accuracy once new datasets are released, especially to determine whether post-2021 variations represent temporary fluctuations or structural breaks driven by drought conditions or regulatory interventions.

In addition, the projections for 2030 should be interpreted not as deterministic point forecasts but as scenario-based estimations dependent on several assumptions. Past water restrictions have occasionally led to abrupt declines in consumption, and it remains uncertain whether similar shocks may occur again. Incorporating additional variables, such as precipitation, income level, industrial output, and water pricing mechanisms, into future models could improve forecasting accuracy and expand the explanatory power of the model.

This study demonstrates that integrating HP filtering and artificial neural networks into a unified hybrid framework yields a highly effective tool for long-term water demand forecasting. The results provide valuable insights for formulating sustainable water management strategies and designing adaptive policies to mitigate future risks of scarcity.

At the policy level, several recommendations emerge. Priority should be given to promoting water-efficient technologies in agriculture, encouraging the reuse of treated wastewater in industrial processes, reducing leakage and loss rates in urban distribution systems, and expanding the use of smart metering infrastructure. In addition, establishing national drought early warning systems and developing AI-supported water monitoring platforms would enhance adaptive capacity and facilitate data-driven decision-making in response to changing climatic conditions.

In conclusion, this study not only makes a methodological contribution by demonstrating the effectiveness of a hybrid statistical-machine learning model but also provides a practical framework for policymakers. The integration of HP filtering and ANNs can provide a scientific foundation for Türkiye's long-term water security and climate resilience strategies, supporting evidence-based planning, the efficient allocation of resources, and the development of sustainable water governance at both national and regional scales.