



Aylık Su Talebinin Tahmininde Veri Büyüklüğünün Etkisinin Değerlendirilmesi; Ankara (Etimesgut) Örneği [*]

Kamil AYBUĞA^{1*},

Aysel Gamze YÜCEL İŞİLDAR²

¹ Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Çevre Bilimleri Ana Bilim Dalı, Ankara, Türkiye

² Gazi Üniversitesi, Mimarlık Fakültesi, Şehir ve Bölge Planlama Bölümü, Ankara, Türkiye

Received: 15.06.2024

Accepted: 03.10.2024

Published: 31.12.2024

Atf yapmak için: Aybuğa, K. & Yücel İşildar, A.G. (2024). Aylık Su Talebinin Tahmininde Veri Büyüklüğünün Etkisinin Değerlendirilmesi; Ankara (Etimesgut) Örneği. *Anadolu Çev. ve Hay. Dergisi*, 9(4), 660-668. <https://doi.org/10.35229/jaes.1447207>

How to cite: Aybuğa, K. & Yücel İşildar, A.G. (2024). Evaluation of the Effect of Data Size on Monthly Water Demand Estimation; Ankara (Etimesgut) Case Study. *J. Anatolian Env. and Anim. Sciences*, 9(4), 660-668. <https://doi.org/10.35229/jaes.1447207>

* <https://orcid.org/0000-0003-0523-807X>
<https://orcid.org/0000-0001-8528-1806>

*Sorumlu yazar:

Kamil AYBUĞA

Gazi Üniversitesi, Fen Bilimleri Enstitüsü,
Çevre Bilimleri Ana Bilim Dalı, Ankara,
Türkiye

✉: kamilaybuga@gmail.com

Öz: Kentsel su yönetiminin planlama ve işletme süreçlerine yönelik en önemli adımı, su talep tahminidir. Su talebinin tahmini, birbirinden çok farklı yöntemlerle ortaya konulabilen bir dizi kestirimden oluşmaktadır. Genel olarak literatürde pek çok yöntem ile karşılaşılmaktadır. Ancak bu yöntemlerin kestirim gücü ve açıklayıcılık düzeyi verilerin miktarı ve zamansal çözünürlüğü gibi unsurlarla ilişkili biçimde değişkenlik göstermektedir. Özellikle tek değişkenli (sadece zaman serisi kullanılan) analizlerde uygun miktarda verinin kullanılması gerekmektedir.

Bu çalışmada, zaman serisi analizinde veri ön işleme ve kestirim yöntemi olarak da kullanılabilen veri düzleştirme (smoothing) yöntemlerinin aylık su talebinin tahminindeki etkinliği ve doğru tahminler üretilmesi için gerekli veri büyüklüğü ele alınmıştır. Bu maksatla, Ankara İline ait aylık su tüketim verileri üzerinden; "Ağırlıklı Hareketli Ortalama", "Üssel Hareketli Ortalama", "Doğrusal Eğilim Projeksiyonu", "İkinci Dereceden Eğilim Projeksiyonu", "Holt Çifte Üssel Düzleştirme" yöntemleri uygulanarak tahmin konusundaki etkinlikleri değerlendirilmiştir. Elde edilen bulgulara göre, aylık düzeyde su talebinin tahmininde Holt Çifte Üssel Düzleştirme yönteminin ortalama %3,1 hata değeriyle veri setindeki varyansı tahmin etme konusunda en iyi yöntem olduğu anlaşılmaktadır.

Anahtar kelimeler: Ankara, aylık su tüketimi, konut su tüketimi, tahmin, zaman serisi analizi.

Evaluation of the Effect of Data Size on Monthly Water Demand Estimation; Ankara (Etimesgut) Case Study

Abstract: One of the most crucial steps in urban water management planning and operation is demand forecasting. Forecasting water demand consists a series of predictions that can be made using various methods. However, the predictive power and explanatory level of these methods vary depending on factors such as the amount of data and temporal resolution. Especially in univariate analyzes (using only time series), to reach a satisfying level of predictive power, appropriate amount of data should be benefited.

In this research, the effectiveness and the required data size of data smoothing methods, which can also be employed as pre-processing and forecasting methods in time series analysis, is discussed. For this purpose, Weighting Moving Average, Exponential Moving Average, Linear Trend Projection, Quadratical Trend Projection, Holt Double Exponential Smoothing methods were applied to monthly water consumption data of a selected district of Ankara Province and their effectiveness in prediction was evaluated. According to the findings, it is understood that the Holt's DES is the best method in estimating the variance in the data set with an average error value of 3.1% in estimating monthly water demand.

Keywords: Ankara, demand forecasting, residential water demand, smoothing, time-series analysis.

GİRİŞ

Kentsel su yönetiminin planlama ve işletme süreçlerine yönelik en önemli adımı, talebin tahminidir. Su talebinin tahmini, gelecekteki su ihtiyaçlarının tahmin edilmesini ifade etmektedir ve birbirinden çok farklı

yöntemlerle gerçekleştirilebilmektedir. Bu tahminler, pek çok planlama ve optimizasyon stratejisinin üretilmesi için gereklidir. Zamansal ölçekte değerlendirildiğinde su talebi uzun dönem, orta vadeli ve kısa dönem projeksiyonlar

[*] Bu çalışma, Kamil Aybuğa'nın doktora tezinden üretilmiştir.

This study was produced from the PhD thesis prepared by Kamil Aybuğa.

olarak sınıflandırılabilir. Uzun vadeli projeksiyonlar yeni bir sistemin planlama ve tasarımında veya mevcut bir su sistemi için genişletme planları için kullanılırken kısa dönem projeksiyonlar, mevcut sistemlerin işletiminde ve yönetiminde tercih edilmektedir (Jain 2001). Genel olarak, doğru bir tahmin; talebi karşılamak için ihtiyaç duyulan su miktarını ve suyun toplanması, arıtılması ve dağıtılması gibi işletim süreçlerinde kullanılan enerjinin azaltılmasına olanak tanımaktadır (Ponte vd., 2015). Bunun yanı sıra suyun depolanması için ihtiyaç duyulan depolama ve dağıtım sistemlerinin optimum tasarım kriterlerinin geliştirilmesi gibi çeşitli faydalar sağlayabilmektedir. Halihazırda su talebinin tahminine ilişkin çalışmaların genel olarak zaman serisi analizi, yapay zekâ gibi birbirinden farklı nitelikteki bir dizi yöntem ile gerçekleştirilmektedir. Ancak veri büyüklüğünün tahmin doğruluğuna olan etkisinin değerlendirildiği bir yaklaşım bulunmamaktadır. Bu bağlamda bu çalışmada, aylık su tüketim verilerinin tahmini konusunda veri büyüklüğünün etkisi değerlendirilmiştir. Bu amaçla zaman serisi analizinde hem veri ön işleme hem de tahmin geliştirme amacıyla kullanılabilen hareketli ortalama yöntemleri kullanılarak, bu yöntemlerin eldeki serinin tamamına ait varyansı açıklama oranı değerlendirilmiştir. Böylelikle spesifik olarak veri büyüklüğünün tahmin doğruluğu üzerindeki etkisini tespit etmek üzere; hareketli ortalama yöntemlerinin mevcut verideki varyasyonu bütüncül olarak tahmin etme düzeyi belirlenmiştir.

Kavramsal çerçeve: Bu çalışmanın temel hedefi, zaman serisi analizinde veri ön işleme ve kestirim yöntemi olarak da kullanılabilen veri düzleştirme (smoothing) yöntemleri kullanılarak doğru tahminler üretilmesi için gerekli veri büyüklüğünün tespit edilmesidir. Su talebinin tahmini doğası gereği karmaşık bir süreçtir (Donkor vd., 2014; Hanif vd., 2013; House-Peters & Chang, 2011). Konutlardan kaynaklanan su talebi; insanlar ve kentsel doğal sistemler arasındaki bireysel, evsel, bölgesel ve ulusal ölçekli etkileşimler ile mekânsal ve zamansal ilişkilerin bir sonucu olarak ortaya çıkmaktadır (House-Peters & Chang, 2011). Birçok durumda elde çok değişkenli analiz yapmaya elverişli ve yeterli çözünürlükte veri bulunmadığında ilk akla gelen araçlar, zaman serisi analizi gibi tek değişkenli (univariate) analize imkân sağlayan yöntemlerdir. Bir tahmin geliştirilmesi konusunda ilk akla gelen çözüm ise bir önceki verinin tahmin olarak kullanılmasıdır (Naïve yaklaşım). Bu basit yaklaşımın daha derinlemesine detaylandırılması ise belli sayıda geçmiş verisinin tahmin için kullanılması (Moving Average), bunların kendi aralarında (Weighted Moving Average-WMA) veya üssel olarak ağırlıklandırılması (Exponensial Moving Average-EMA), trendin doğrusal veya doğrusal olmayan bir

projeksiyon yöntemine uydurulması (Lineer Trend Projection-LTP / Quadratic Trend Projection-QTP) ve bir önceki tahminin hata düzeyinin bir sonraki tahmin için bir katsayı haline getirilmesi (Holt DES gibi) gibi yöntemleri/araçları ortaya çıkarmıştır. Bu yöntemlerle eldeki verilerin niteliğine göre farklılaşan düzeyde tahmin doğruluğuna ulaşılabilmektedir. Bu yöntemlerden etkin biçimde yararlanılması için her birinin verilere uygunluk durumunun iyi biçimde analiz edilmesi gerekmektedir.

Su talebi tahmininde zaman serisi analizi, zaman içinde su talebinin değişmesine katkıda bulunan çeşitli bileşenlerin istatistiksel olarak betimlenmesine dayanmaktadır. Bir zaman serisi, belirli bir değişkene ilişkin kronolojik bir gözlem dizisinden oluşmaktadır. Bir zaman serisi modeli, uzun vadeli bir eğilim bileşeni, bir dögüsel bileşen ve bir varyans bileşeninden oluşmaktadır. Zaman serisi tahminin temel zorluklarından biri, verilerin gidişatında artış veya azalış olarak kendini gösteren eğilimin (trend) yakalanmasıdır. Düzleştirme (smoothing) yöntemleri ile verideki genel eğilim gecikmeli şekilde yakalanabilmektedir. Genel olarak eğer veri setinde mevsimsel etki ve trend etkisi olmadığı ve tahmin ufkunun çok uzak olmadığı durumlarda WMA, EMA, LTP, QTP, Holt DES gibi veri düzleştirme yöntemlerinin elverişli araçlar olduğu değerlendirilmektedir. Bu doğrultuda bu çalışmada adı geçen yöntemlere ilişkin bir uygulama yapılarak özellikle veri büyüklüğüyle ilişkili biçimde kestirim doğruluklarının nasıl değişim gösterdiği araştırılmıştır.

Literatür araştırması: Bu çalışma kapsamında kentsel su tüketiminin tahminine yönelik olarak literatürde yer alan zaman-serisi analizi ve veri düzeltme (smoothing) yöntemlerini kullanan araştırmalar değerlendirilmiştir.

Kentsel su talebiyle ilgili tahmin yöntemi olarak zaman serisi analizinin kullanıldığı bir dizi araştırma (Maidment vd., 1985) bulunmaktadır. Birçok çalışmada ((Billings & Jones, 1996; Froukh, 2001; Hartley & Powell 1991), çeşitli matematiksel, sezgisel, kişi başı su tüketimi ve birim su tüketimi temelli kısa dönem kestirim yöntemlerinin kullanıldığı görülmektedir. Bu çalışmalardan elde edilen sonuçlar, tek başına talep verisinin kendisinin kullanarak da oldukça doğru tahminler üretmenin mümkün olduğunu göstermektedir (Msiza vd., 2008). Ancak 2000'li yıllardan itibaren zaman serisi modellerinin yapay sinir ağları gibi yöntemlerle karşılaştırılması gibi yenilikçi yaklaşımlar görülmeye başlanmıştır (Adamowski vd., 2012). Bu dönemde birçok araştırmacı tarafından çeşitli hibrit yaklaşımların kullanılmaya başlandığı görülmektedir (Niknam vd., 2022; Suhartono vd., 2018). Konuyla ilgili en yeni yaklaşımlar, derin öğrenme (Namdari vd., 2024), makine öğrenmesi (ML) modellerinin karşılaştırılması (Wewer & Taormina, 2024), destek vektör makinesi, genetik algoritmalar,

evrimsel sinir ağları, LSTM ağları ve rastgele orman modelleri gibi hibrit yöntemleri kapsamaktadır.

Su talebinin çok değişkenli doğrusal regresyon ve otoregresif hareketli ortalamalar (Du vd., 2020; Xu vd., 2018; Zubaidi vd., 2018; Zubaidi vd., 2019) kullanılarak modellenmesine yaygın bir uygulamadır. Chen ve Boccelli, (2014), orta ölçekli bir su tedarik sisteminin saatlik/çeyrek saatlik talepleri için entegre bir zaman serisi tahmin çerçevesi geliştirmişlerdir. Okeya vd., (2014), bir su dağıtım sistemindeki gerçek zamanlı su tüketim tahminini ve sistemin gerçek durumuna ilişkin daha iyi bilgiler üretmek üzere, 15 dakikalık aralıklarla su taleplerini tahmin edilmesine dayalı bir TS modeli kullanmışlardır. Arandia vd., (2016) hem çevrimiçi hem de çevrimdışı modlar için su talebini tahmin etmek için bir SARIMA modeliyle birleştirilmiş bir Kalman filtresi kullanarak, çeşitli zaman çözünürlüklerinde (üç aylık, saatlik ve günlük) su taleplerine ilişkin tahminlerde bulunmuşlardır.

Fullerton vd., (2016), aylık su talebini simüle etmek için lineer transfer fonksiyonu üzerinden geliştirilmiş bir (ARIMA) zaman serisi modeli kullanmışlardır. Karamaziotis vd., (2020) ARIMA, üstel yumuşatma ve çok katmanlı algılayıcılar dahil olmak üzere çeşitli metodolojileri incelemişlerdir. Ristow vd., (2021), Brezilya'nın Joinville şehrinde konut, ticari, endüstriyel ve kamu dahil olmak üzere dört tüketim kategorisinin yanı sıra toplam tüketimin aylık su talebini tahmin etmek için zaman serisine dayalı iki model geliştirmişlerdir.

Su talebinin tahmini konusunda Türkiye'de yürütülen çalışmalar birbirinden farklı zamansal çözünürlükteki veriler üzerinden ve otoregresif hareketli ortalama (ARIMA), çoklu lineer regresyon (MLR) ve adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS), yapay sinir ağları (ANN), kaskad korelasyon sinir ağı (CCNN), genelleştirilmiş regresyon sinir ağları (GRNN), ileri besleme sinir ağları (FFNN), radyal temel sinir ağları (RBNN) ve destek vektör makinesi (SVM) gibi yapay sinir ağları ve zaman serisi analizi temelli hibrit yöntemlerden faydalandığı görülmektedir. Altunkaynak vd. (2005), zaman serisi analizinde Markov ve ARIMA modelleri kullanarak gelecek aylık su tüketimi tahmininde bulanık mantık yaklaşımını esas alarak geliştirdikleri ve durağanlık ve ergodisite varsayımlarına ihtiyaç duyulmayan yöntemlerinde tüketimin %10 hata ile tahmin edilebileceğini göstermişlerdir. Yurdusev & Fırat (2009), İzmir verileri için su tüketimi modellemesinde sosyo-ekonomik ve iklimsel faktörleri dikkate alan ANFIS yöntemini kullanarak, su tüketimi modellemesinde başarıyla kullanılabildiğini ifade etmişlerdir. Fırat vd. (2010), çeşitli ANN teknikleri kullanarak, modellerin performansını karşılaştırmışlar ve CCNN modelinin daha düşük NRMSE değerine sahip olduğunu bulmuşlardır.

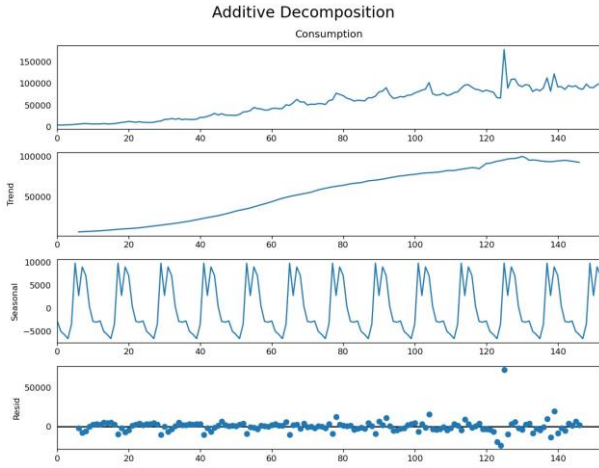
Yaşar vd. (2012) tarafından Adana ili su tüketim verilerine uyarladıkları doğrusal olmayan regresyon modeli için en iyi bağımsız değişkenlerin seçimini konu alan araştırmalarında, kademeli regresyon yönteminin NLR modeli için en iyi bağımsız değişkenleri seçmede başarılı olduğunu tespit etmişlerdir. Yalçıntaş vd. (2015) ARIMA yöntemini kullandıkları araştırmalarında İstanbul için konut suyu talebinin toplam su kullanımının % 80'ini oluşturduğunu tespit etmişlerdir. Altunkaynak & Assefa (2017), ANN ve dalgacık dönüşüm modeli kullanımının su tüketimi tahminindeki doğruluğun artırılmasındaki önemine vurgu yapmaktadır. Taştan (2018), İstanbul'da su talebinin arka planındaki faktörleri incelediği araştırmasında farklı su fiyatlandırma rejimlerinin etkinliğini analiz etmiştir. Bulgulara göre İstanbul'da su talebinin fiyat elastik olmadığı değerlendirilmiştir.

Genel olarak, kentsel su talebinin tahmini konusundaki çalışmalar 20. Yüzyılın ortalarından başlayan bir zamansal perspektifte ortaya çıkarak günümüze değin gelişim göstermiştir. Bu bağlamda kentsel su talebinin tahmini konusunun etraflıca değerlendirildiği görülmektedir. Ancak genel olarak kentsel su talebinin tahmininde, spesifik olarak ise konutlar düzeyinde su talebinin tahmini konusunda literatürde veri varlığının tahmin doğruluğuna olan etkisine yönelik bir bakış açısı bulunmamaktadır.

MATERYAL VE YÖNTEM

Bu araştırmanın amacı hem veri ön işleme hem de veri modelleme aracı olarak kullanılabilen hareketli ortalama yöntemleri kullanılarak, veri miktarının, bir veri kümesindeki varyansın açıklanması üzerine etkisinin araştırılmasıdır. Bu nedenle verilerin bir eğitim veya test serisine bölünmesi yerine, her bir yöntemin tüm veri seti üzerindeki tahmin başarısı belirlenmiştir. Bu maksatla 2010 ve 2021 yıllarını kapsayan aylık su tüketim verilerinin miktarı artırılarak (1 yıllık, 2 yıllık, 3 yıllık, 4 yıllık ... şeklinde) ağırlıklı ortalama yöntemlerinin tahmin yüzdeleri belirlenmiştir. Bu şekilde her bir yöntemin aynı veri seti üzerindeki toplam tahmin düzeyi elde edilebilmektedir. Veri büyüklüğünün tahmin doğruluğu üzerindeki etkisi kullanılan yöntemle ilişkili biçimde değişiklik göstermektedir. Bu çalışmada zaman serisi analizinin su talebinin tahminindeki etkinliği veri büyüklüğünün sürece etkisi özelinde değerlendirilmiştir. Bu maksatla Ankara şehir şebekesine bağlı 2023 yılı itibarıyla nüfusu 33 bin olan Ahimesut Mahallesinin 2010 ve 2021 yıllarını kapsayan su tüketim verileri (Şekil 1) kullanılarak hareketli ortalama yöntemleri ile tahmin yöntemi uygulanmıştır. Veriler Ankara Su ve Kanalizasyon İdaresi Genel Müdürlüğü'ne yapılan şahsi başvuru neticesinde temin edilmiş ve kişisel düzeyde bir bağlama sahip olmadığından herhangi bir etik ihlal riski barındırmamaktadır.

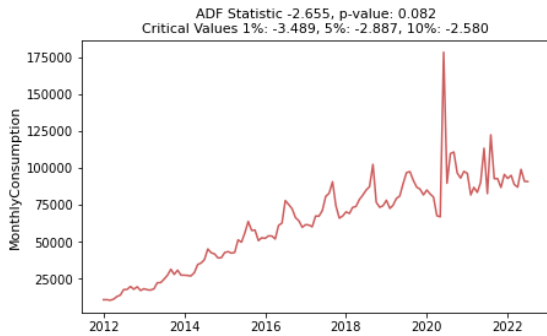
Zaman serisi analizi ile kestirim yönteminde, tahminlerin temeli literatürde sıklıkla karşılaşılan, Naïve yöntem, doğrusal veya üstel ağırlıklandırılmış ortalama, doğrusal ve doğrusal olmayan trend projeksiyonu gibi yöntemlerden oluşmaktadır. Zaman serisi analizi, verinin mevsimsel değişimler ve trend arz eden kısımlarının ayrıştırılmasına ve bir modele uygunluğu konusunda yorum yapılmasına olanak tanıdığından bu çalışmada çeşitli zaman serisi düzeltme yöntemleri kullanılarak verilerin doğrusal veya doğrusal olmayan çeşitli modellere uygunluk durumu test edilmiştir. Bu maksatla ilk olarak verilerin eğilim, mevsimsellik bileşenleri ve hata dağılımını elde etmek üzere toplamsal dekompozisyon yöntemi (Şekil 1) uygulanarak kalıntı (residual) değerlerinin dağılım durumu kontrol edilmiştir.



Şekil 1. Ankara Ahimesut Mahallesi su tüketimi zaman serisi dekompozisyonu.

Figure 1. Time-series decomposition of monthly water consumption data.

Zaman serilerinin analizinde serinin durağan olması şartı sadece AR, MA, ARMA veya ARIMA modelleri için geçerli bir koşuldur. Bununla birlikte, bu çalışmada kullanılan verilerin zaman serisi analizine elverişli veriler olup olmadığının değerlendirilmesi amacıyla, serinin durağanlık durumunu kontrol etmek üzere ADF (Augmented Dickey Fuller) testi uygulanmıştır (Şekil 2).



Şekil 2. Su tüketimi zaman serisinin ADF testi sonucu.

Figure 2. Test result for the Augmented Dickey-Fuller Test

Durağan bir seri elde etmek üzere kullanılan yöntemlerden olan ardışık verilerin farkının alınmasıyla


üretilen farklar serisi üretilerek verilerin durağan hale getirilmesi sağlanmıştır (Şekil 3).



Şekil 3. Su tüketiminin birinci derece (altta) fark serisi yöntemi ile üretilen zaman serileri.

Figure 3. Time series of first order differencing of monthly water consumption data.

Son olarak verilerin WMA, EMA, LTP, QTP, Holt DES gibi yöntemlerle tahmin edilmesi mümkün olup olmadığını tespit etmek üzere otokorelasyon fonksiyonu belirlenerek (Şekil 4) veri ön işleme aşaması tamamlanmıştır.



Şekil 4. Su tüketiminin otokorelasyon (üstte) ve kısmi otokorelasyon (altta) fonksiyonları.

Figure 4. Auto-correlation and partial auto-correlation functions of water consumption data.

Araştırmada kullanılan projeksiyon yöntemlerine (WMA, EMA, LTP, QTP, Holt DES) ilişkin detaylar Tablo 1'de verilmiştir. Zaman serisi tahminindeki temel hipotez niteliğindeki Naïve kestirim yönteminde, en son veri bir sonraki tahmin olarak alınmaktadır.

Basit hareketli ortalama, geçmişteki tüm değerlerin her birinin eşit ağırlıklı olarak hesaplandığı bir parametredir. Bu haliyle aslında her bir girdinin ağırlığının "1" olarak alındığı, ağırlıklı hareketli ortalamasının özel bir halidir. Ağırlıklı hareketli ortalama ise örneğin daha güncel verilerin ağırlığı daha yüksek alınarak, üretilen serideki etkisi artırılabilir.

Üstel hareketli ortalama Naïve yaklaşım veya WMA gibi hareketli ortalama ölçülerinden farklı olarak hesaplamalar, önceki tahminler de hesaba katılarak gerçekleştirilmektedir. Bu yöntemde, bir önceki zaman aralığına ait gerçek veri ve tahmin değerleri, ikisinin toplamı 1 olacak şekilde ağırlıklandırılmaktadır.

Doğrusal Trend Projeksiyonu yaklaşımında bütün veri setindeki genel eğilim belirlenerek, bu genel eğilimin devam edeceği varsayımıyla bir tahminde

bulunmaktadır. Doğrusal modelde temel varsayım, her bir (t) zamanda ölçümlenen değerin belirli bir miktar artması veya azalmasıdır. Bu yöntem ağırlıklı ortalama gibi yöntemlere kıyasla bir modelleme tekniği olarak ifade edilebilecek en temel yöntemidir.

Doğrusal olmayan modelde verilerin, (t) zaman artışında eğri üzerinde ölçümlenen değerinin belirli bir miktar değişimi esas alınmaktadır. Doğrusal olmayan trend projeksiyonu, doğrusal trend testinde aşırı yüksek hata değeri elde edildiğinde uygulanabilecek bir yöntemdir. Doğrusal trend projeksiyonu gibi doğrusal olmayan projeksiyonlarda da veriye aşırı uyumlanma (overfitting) söz konusu olabilmektedir.

Tablo 1. Projeksiyon (düzleştirme) yöntemleri.

Yöntem	Açıklama	Formülasyon
Naïve yaklaşım	$Y_{(t+1)}$ tahmini, Y_t ise son veriyi göstermek üzere;	$Y_{(t+1)} = Y_t$
Ağırlıklı hareketli ortalama (WMA)	N periyodu (zaman penceresi), Y_i veriyi, W_i ise bu veriye ait ağırlık oranını göstermek üzere;	$Y_{(t+1)} = \frac{\sum_{i=1}^N W_i * Y_i}{\sum_{i=1}^N W_i}$
Üstel hareketli ortalama (EMA)	EMA; $Y_{(t+1)}$ tahmini, Y_t önceki t zamanındaki tahmini, α ağırlıklandırma faktörünü, Y_t ise son veriyi göstermek üzere	$Y_{(t+1)} = \alpha Y_t + (1 - \alpha)F_t$
Doğrusal trend projeksiyonu (LTP)	Y_t tahmin değeri, ($0 \leq \alpha \leq 1$) eğim ve ($0 \leq \beta \leq 1$) kesme noktası olmak üzere;	$Y_t = \alpha(t) + \beta$
Doğrusal olmayan trend projeksiyonu (QTP)	Y_t tahmin değeri, ($0 \leq \alpha \leq 1$) doğrusal terim, ($0 \leq \beta \leq 1$) kuadratik terim ve ($0 \leq \gamma \leq 1$) sabit değer olmak üzere;	$Y_t = \alpha(t) + \beta(t)^2 + \gamma$
Holt ikili üstel projeksiyon (Holt DES)	S_t t zamanı için düzeltilmiş seviye (level) bileşeni ve T_t t zamanı için düzeltilmiş eğilim (trend) bileşeni üzerinden;	$S_{(t+1)} = \alpha Y_t + (1 - \alpha)(S_{t-1} + T_{t-1})$ $T_{(t+1)} = \beta (S_t + S_{t-1}) + (1 - \beta)(T_{t-1})$ $Y_{t+k} = S_t + kT_t$

Holt İkili Üstel Projeksiyon yönteminde düzeltme yöntemleriyle hesaba katılmayan eğilim (trend) bileşeni de hesaplamaya katılmaktadır. ($0 \leq \alpha \leq 1$) seviye bileşeni için ve ($0 \leq \beta \leq 1$) eğilim bileşeni için düzeltme faktörü olmak üzere Holt DES yönteminde eğilim bileşeni (t) zamanındaki düzeltilmiş seviye (smoothed level) bileşeninin, (t-1) zamanındaki düzeltilmiş seviye (smoothed level) bileşeni ve eğilim (trend) bileşeni arasındaki fark olarak hesaplanmaktadır. Nihai durumda ise (t+ 1) zamanı için tahmin değeri (t) zamanına ait düzeltilmiş seviye ve düzeltilmiş eğilim değerleriyle hesaplanmaktadır. Bu yöntemde α ve β katsayılarının değişimi S_t ve T_t bileşenlerinin birbirinden farklı bileşenlere dönüşmesine yol açmaktadır. $\alpha = 0$ olması durumunda S_t bileşeni F_t bileşenine (t zamanındaki tahmin değeri) eşit hale gelirken, $\alpha = 1$ olması durumunda S_t bileşeni Y_t bileşenine (t zamanındaki gerçek değere) eşit olmaktadır. Benzer şekilde $\beta =$

0 durumunda T_t bileşeni $T_{(t-1)}$ yani (t-1) zamanındaki eğilim (trend) bileşenine eşit olurken, $\beta = 1$ olması T_t bileşenini ($S_t + S_{t-1}$) t ve t-1 zamanındaki seviye (level) bileşenlerinin toplamına dönüştürmektedir.

Model hata raporlaması ve performans ölçüleri:

Veri analizi ve modelleme süreçlerinin nihai noktası elde edilen modeller ile üretilen çıktıların hata düzeyinin raporlanmasıdır. Bu çalışmada birden fazla hata ölçüsüyle raporlama yapılması tercih edilmiştir. Bunun temel nedeni ise raporlanan bilgilerin anlamlılık düzeyiyle birlikte çalışmada kullanılan projeksiyon setinin de birden fazla hata ölçüsü kullanımını gerektirmesidir. Örneğin Naïve yaklaşım temel karşılaştırma kriteri olarak belirlendiğinden, MASE hata ölçüsünün kullanılması da zorunlu hale gelmektedir. Çünkü MASE hata ölçüsü, Naïve yaklaşım için "1" kabul edilerek diğer projeksiyonların başarımı da Naïve kestirime oranı üzerinden değerlendirilmektedir. Örneğin 1'den büyük MASE değeri, projeksiyonun Naïve yaklaşıma göre hata oranının yüksek olduğunu göstermektedir. Bu durumda, projeksiyon yönteminin veri setini tahmin konusunda Naïve yaklaşımdan daha az başarılı olduğu değerlendirilmektedir. Hata değeri (e); F_t tahmini, Y_t ise veriyi temsil etmek üzere ($e = Y_t - F_t$) formunda gösterilmektedir. Bu çalışmada kullanılan hata ölçüleri Tablo 2'de verilmektedir.

Tablo 2. Hata Ölçüleri.

Table 2. Error estimation units.

Ölçü	Açıklama	Formülasyon
MAE	Mean Absolute Error (Ortalama Mutlak Hata)	$MAE = \frac{\sum_{i=1}^n e_i }{n}$
RMSE	Root Mean Square Error (Ortalama Hata Kare Kökü)	$RMSE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}}$
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)	$MAPE = \frac{\sum_{i=1}^n \left \frac{e_i}{Y_i} \right * 100}{n}$
sMAPE	Symmetric Mean Absolute Percentage Error (Simetrik Ortalama Mutlak Yüzde Hata)	$sMAPE = \frac{1}{n} \sum_{i=1}^n \frac{ F_t - Y_t }{(Y_t + F_t)} * 100$
MASE	Mean Absolute Scaled Error (Ortalama Mutlak Ölçekli Hata)	$MASE = \frac{1}{n} \sum_{i=1}^n \frac{ Y_t - F_t }{MAE_{Naive}}$

BULGULAR

Su talebinin tahmini konusunda literatürde yer alan birçok çalışmada günlük, haftalık, aylık ve yıllık düzeyde tahminlerin gerçekleştirildiği görülmektedir. Şekil 1'de 153 adet aylık su tüketimi verisinden oluşan zaman serisinin dekompozisyonu verilmiştir.

Buradan su tüketiminin trend ve mevsimsel bileşenlere sahip olduğu görülmektedir. Ayrıca zaman serilerinin durağanlığının test edildiği ADF testinin sonuçları Şekil 2’de verilmiştir. Serilerin durağan karakteristikte olmadığı buradaki test sonucu (p-value) ile açık biçimde görülmektedir. Durağan bir seri elde edilebilmesi için uygulanan farklar alınması yöntemiyle üretilen seriye ait grafikler Şekil 3’te verilmiştir.

Veri büyüklüğünün aylık su talebinin tahminine olan etkisinin değerlendirilmesi, bu konuda hali hazırda mevcut bulunan bilimsel sistematikte ilişkili biçimde yürütülmesi gereken bir görevdir. Bu bağlamda, birer zaman serisi analizi aracı olarak tüm hareketli ortalama yöntemleri, veriler arasında bir otokorelasyon olduğu varsayımından hareketle tahmine elverişli araçlar olabilmektedir. Otokorelasyon fonksiyonu bir verinin kendinden önceki N adet veri ile arasındaki korelasyonu göstermektedir. Otoresif modellerin kullanılması için otokorelasyon fonksiyonunun (ACF) kademeli olarak azalması ve kısmi otokorelasyon fonksiyonunun (PACF) de anlamlı birkaç terim sonrasında keskin biçimde düşmesi beklenir. Hareketli ortalamaya (MA) karar verilmesi içinse tam tersi durum geçerlidir. Şekil 4’e göre verilerin WMA, EMA, LTP, QTP, Holt DES gibi yöntemlerle tahmin edilmesi mümkün görünmektedir.

Bu doğrultuda WMA, EMA, LTP, QTP, Holt DES yöntemlerinin, Ankara İli Ahimesut Mahallesi’ne ait 2010 ve 2022 yıllarını kapsayan aylık su tüketim verilerini tahmin konusundaki başarımlarını test edilmiş olup, başarımlarını Tablo 3’te verilmiştir. Tabloda her bir yöntemin veri büyüklüğüyle ilişkili biçimde tahmin hata oranının kendi içindeki değişimi mavi, sarı ve kırmızı renklerle işaretlenmiştir. Buna göre tahmin hata oranları en düşük olan bölümler mavi, en yüksek olan bölümler kırmızı ile işaretlenmiştir. Sarı renkli alanlar ise orta düzeyde hatayı işaret etmektedir. MASE ölçütü Naïve yöntemin diğer yöntemlerle kıyaslanmasında kullanıldığından, bu yöntem altındaki MASE değerleri 1 şeklinde (turkuaz renkle) verilmiştir. Diğer taraftan EMA yönteminin MASE değerleri de 1,0 civarında değişim gösterdiğinden (gösterimde tutarlılık sağlanması bakımından) turkuaz renkle işaretlenmiştir.

Genel olarak veri setinin tamamı için Holt’s DES ve EMA yöntemlerinin Naïve yöntemle kıyasla daha iyi sonuçlar verdiği (bkz: MASE hata ölçütü) görülmektedir. Diğer taraftan tüm hata ölçütleri göz önüne alındığında Holt’s DES yönteminin tüm diğer düzeltme yöntemlerine kıyasla en düşük hata değerlerine sahip olduğu görülmektedir.

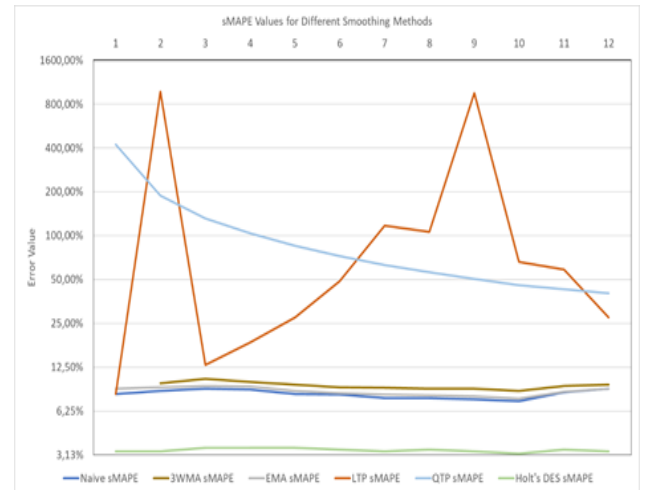
Bu araştırmanın temel hedefi doğrultusunda nihai olarak, düzeltme yöntemlerinin başarımlarının, veri büyüklüğüyle ilişkili değişiminin belirlenmesine ihtiyaç duyulmaktadır. Zaman serisi düzeltme (smoothing)

yöntemlerinin başarımlarının veri büyüklüğüyle ilişkisi Tablo 3’te bunlara ilişkin hata oranları bir arada verilmiştir. Mavi ve yeşil renkle işaretlenen hata değerleri, yatay eksen boyunca artan veri büyüklüğü doğrultusunda en az hata gerçekleşen veri aralıklarını temsil etmektedir. Tablo 3’te yer alan bilgilerden hareketle, Naïve yaklaşım ve EMA yöntemlerinin MASE ölçütleri haricinde tüm düzeltme yöntemleri için hata değerlerinin oldukça değişken olduğu değerlendirilmektedir.

Farklı hata ölçütleri düzeyinde değerlendirildiğinde, her bir hata ölçütünün kendine özgü hesaplama yöntemi nedeniyle sonuçların birbirinden oldukça farklılaşabildiği görülmektedir. Diğer taraftan tüm hata ölçütleri için Holt’s DES düzeltme yönteminin diğerlerine kıyasla tutarlı biçimde en düşük hata oranını verdiği görülmektedir. Tüm yöntemlerin zaman içerisindeki hata değerlerinin genel gidişatının değerlendirildiğinde, Holt’s DES yöntemi için MAE dışındaki tüm hata ölçütlerinin tutarlı biçimde tüm veri seti boyunca stabil kaldığı görülmektedir.

Ayrıca MAE ve RMSE hata değerlerinin veri sayısı arttıkça artma eğiliminde olduğu ve diğer hata ölçütlerinden büyük oranda ayrıştıkları görülmektedir. Bu doğrultuda tüm projeksiyon yöntemleri için en tutarlı hata değerlerinin sMAPE hata ölçütü tarafından verildiği değerlendirilmektedir.

Şekil 5’te 2010-2022 yıllarına ait su tüketiminin tüm projeksiyon yöntemleri için sMAPE hata ölçütünün değişimi görülmektedir. LTP ve QTP yöntemlerinin yüksek hata düzeyine sahip olduğu ve veri büyüklüğünden bağımsız biçimde mevcut verilerin tahmini konusunda yetersiz olduğu değerlendirilmektedir.



Şekil 5. Düzeltme yöntemlerinin veri büyüklüğüne bağlı hata oranlarının değişimi.

Figure 5. Change of error values with data size for different smoothing methods.

Tablo 3. Verilerin yıllara sâri olarak artırılması durumunda hata değerleri.
Table 3. Prediction errors in case of gradual increase of data size.

YÖNTEM	Veri Büyüklüğü												
	12	24	36	48	60	72	84	96	108	120	132	144	
Naïve	MAE	509,8	713,2	960,8	1267,5	1433,7	1828,2	2146,7	2507,6	2855,3	2986,9	4737,1	5526,4
	RMSE	580,4	819,9	1230,3	1683,1	2026,2	2715,3	3337,6	3957,4	4796,7	4793,4	13497,9	14050,3
	MAPE	8,1	8,4	8,7	8,6	8	7,8	7,6	7,5	7,4	7,2	8,3	8,8
	MASE*	1	1	1	1	1	1	1	1	1	1	1	1
	sMAPE	8,20%	8,60%	8,90%	8,80%	8,20%	8,10%	7,70%	7,70%	7,50%	7,30%	8,40%	8,90%
3WMA	MAE		960,9	1306,2	1601,1	1918,2	2318,5	2808,4	3342,3	3793,3	3980,6	5257,5	5823,3
	RMSE		1220,6	1648	2096,7	2612,4	3303,5	4132,1	4891,5	5554,5	5632,3	11904,2	12148,6
	MAPE		9,2	9,9	9,5	9	8,7	8,6	8,6	8,6	8,3	8,9	9,2
	MASE		1,3	1,3	1,2	1,3	1,2	1,3	1,3	1,3	1,3	1,1	1,1
	sMAPE		9,70%	10,40%	9,90%	9,50%	9,10%	9,00%	8,90%	8,90%	8,60%	9,30%	9,50%
EMA	MAE	554,8	742,2	1002,2	1295,4	1497,9	1844,6	2186,6	2588,8	2967,5	3136,5	4631,7	5315,3
	RMSE	626,1	876,3	1264,9	1697,5	2098,1	2760,2	3431,7	4084,7	4829,9	4869,9	12365,6	12793,9
	MAPE	8,6	8,8	9	8,9	8,3	8	7,8	7,7	7,7	7,4	8,3	8,7
	MASE*	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
	sMAPE	8,90%	9,10%	9,30%	9,20%	8,60%	8,30%	8,10%	8,00%	7,90%	7,60%	8,50%	8,90%
Hata Ölçütü	MAE	528,4	802,8	1320,9	2018,6	2950,8	3958,8	4606,6	4915,6	5077,1	5153,6	6315,2	6757,1
	RMSE	593,2	971,1	1619,4	2536,9	3631,3	4980,8	5797,8	6170,4	6435,2	6560,7	10381,5	10696,7
	MAPE	8,3	9,8	13,1	17,8	22,8	28,4	30	28,6	26,2	23,2	22,6	20,2
	MASE	1,03	1,1	1,3	1,5	2	2,1	2,1	1,9	1,8	1,7	1,3	1,2
	sMAPE	8,20%	9,70%	13,00%	18,50%	27,40%	48,80%	117,30%	105,90%	95,50%	66,10%	58,60%	27,40%
QTP	MAE	8099,8	4642,1	4945,3	5497,1	5565,2	5369,7	5483,3	5610	5648,9	5636,7	6605,9	6909,6
	RMSE	8444,6	6074,1	5969,9	6418,7	6479,1	6294	6587,8	6904,8	7154	7140,1	10932,7	11027
	MAPE	137,9	75,3	63,6	56,1	48,6	41,9	37,2	33,6	30,6	28,2	27	25,6
	MASE	15,8	6,5	5,1	4,3	3,8	2,9	2,5	2,2	2	1,9	1,4	1,25
	sMAPE	420,50%	187,90%	131,40%	103,80%	85,40%	72,10%	62,80%	55,90%	50,30%	45,80%	43,00%	40,20%
Holt's DES	MAE	237,3	307,5	432,9	568,7	710,1	859	1017,3	1217,1	1363,8	1443,3	1717,2	1818,5
	RMSE	317	441,8	621,9	817,3	1039,9	1256,2	1536,5	1782,4	1929,1	2007,7	2871,2	2895
	MAPE	3,4	3,4	3,6	3,7	3,6	3,5	3,4	3,4	3,4	3,3	3,4	3,4
	MASE	0,4	0,4	0,4	0,4	0,4	0,4	0,5	0,5	0,5	0,5	0,4	0,3
	sMAPE	3,30%	3,30%	3,50%	3,50%	3,50%	3,40%	3,30%	3,40%	3,30%	3,20%	3,40%	3,30%

TARTIŞMA VE SONUÇ

3WMA ve EMA yöntemlerinin ise bir tahmin yönteminden ziyade karşılaştırmaya bir temel oluşturması bakımından araştırma kapsamına alınan Naïve yaklaşımın çok az üzerinde bir genel hata ortalamasına sahip olduğu görülmektedir (Tablo 3). İstatistiksel anlamda tutarlı ve kabul edilebilir hata değerleri ise ancak Holt's DES yönteminde yakalanabilmektedir.

Bu durumun, su tüketim verilerinin genel karakteristiğinin (sigmoid fonksiyon olarak da adlandırılan) trend bileşenine (Şekil 1) sahip olmasından kaynaklandığı değerlendirilmektedir. Sigmoid eğriler, yavaş başlayıp, sonrasında dönüşümlü olarak lineer ve üstel gelişim gösteren ve genellikle bir tüketimin söz konusu olduğu süreçlerin temsilinde etkili bir matematiksel model sunmaktadır. Tablo 3'ten de görüldüğü üzere, bu çalışmada ele alınan tüm düzleştirme yöntemlerinin hata değerleri veri setinin başlangıç, orta veya son bölümlerinde düşmektedir. Bu durum, kullanılan yöntemlerin tahmin başarısının veri büyüklüğüyle birlikte, su tüketiminin genel karakteristiği ile de ilişkili biçimde değiştiğini göstermektedir. QTP yöntemi başlangıçta yüksek hata değerleri üretirken, veri büyüklüğü arttıkça toplam hata değerinin ortalaması da azalmaktadır. 3WMA ve EMA yöntemlerinin ise veri artışıyla birlikte değişen hata değerleri üretmediği görülmektedir.

Bu çalışmada zaman serisi analizinde modelleme ve verilerin ön analizi gibi süreçlerde yaygın biçimde kullanılan düzleştirme (smoothing) yöntemlerinin tahmin doğruluğunun veri büyüklüğüyle nasıl değiştiği analiz edilmiştir. Araştırmanın tam bir tahmin ya da kestirimde bulunmak gibi bir amacı bulunmadığından, esas olarak verilerin hangi matematiksel fonksiyona uygunluk gösterdiğinin analizi yapılmamış, verilerden hareketle bir model oluşturulmamıştır. Ayrıca literatürde aylık su tüketim verilerinin tahmini konusunda düzleştirme yöntemlerinin etkinliğinin veri büyüklüğüne bağlı olarak analiz edildiği bir çalışma ile karşılaşılmadığından, doğrudan bir karşılaştırma yapmak mümkün olmamıştır. Ancak zaman serilerinin analizi konusunda veri büyüklüğünün yeri ve önemine ilişkin mevcut araştırmalar ışığındaki değerlendirmeler aşağıdaki şekildedir:

Literatürde kullanılan birçok su talebi tahmin modelinde, zaman serileri bir saatlik zaman dilimi kullanılarak incelenmektedir (Alvisi vd., 2007; Dos Santos & Pereira Filho, 2014; Homwongs vd., 1994; Jowitt & Chengchao 1992). Bu araştırmalarda kullanılan zamansal ölçekler, 15 dakikalık zamansal aralıklardan günlük/aylık zaman dilimlerine uzanan geniş bir yelpazede dağılım göstermektedir (Miaou 1990; Smith 1998). Dolayısıyla klasik zaman serisi analiziyle üretilen tahminlerin etkinliği

de hem zamansal ölçek hem de veri büyüklüğüyle ilişkili biçimde değişkenlik göstermektedir. Bu çalışmada yalnızca aylık zamansal çözünürlükteki veriler kullanılmış olsa da elde edilen bulgular, sonuçların doğruluğunda veri büyüklüğünün önemli bir yeri olduğunu göstermektedir.

Bu çalışmanın metodolojik dayanağı, mevsimsel ve trend bileşenlerine sahip veriler üzerinden SARIMA olarak adlandırılan, bütünleşik mevsimsel otoregresif hareketli ortalama modelinin kurgulanmasına uygun veri ön işlem yönteminin uygulanmasıdır. Bu yöntemle ilişkin temeller Ristow vd., (2021) tarafından gerçekleştirilen çalışmada belirtilen hususlar temelinde şekillendirilmiştir. Çalışmada aylık su talebinin tahmininde üstel yumuşatma modeli (ETS) ile mevsimsel ARIMA modeli karşılaştırılmıştır. Yöntemsel olarak otokorelasyonun kontrolü için otokorelasyon fonksiyonu (ACF) grafiği kullanılırken, kabul edilen anlamlılık düzeyi (α) %5 olarak alınmıştır, hata değerlerinin gösteriminde temel ölçüt olarak MAPE kullanılmıştır (Ristow vd., 2021). Bu çalışmada SARIMA modeli dışında benzer metodoloji kullanılarak, ETS yönteminin yanı sıra WMA, LTP, QTP ve Holt DES yöntemlerinin veri büyüklüğüyle ilişkili başarımları araştırılmış, MAPE ölçütünün yanı sıra literatürde yoğun biçimde kullanılan hata ölçütlerinden MAE, RMSE, sMAPE ve MASE kullanılmıştır. sMAPE ölçütü MAPE'nin yüzde cinsinden ifadesi olduğundan çoğunlukla tutarlı sonuçlar elde edildiği görülmüştür.

Günümüzde zaman serilerinin analizinde daha karmaşık yöntemler kullanılmakta ve bu yöntemlerin uygulanması daha büyük veri gerektirmektedir (Sardinha-Lourenço, vd., 2018). Raporlamada çok çeşitli hata ölçütleri kullanılmaktadır. Hangi ölçütlerin seçileceği genel olarak verilerin niteliği ve sunulan çıktıların anlamlılık durumuna bağlı olarak değişkenlik göstermektedir. Verinin birimi, hata ölçüsünün ölçeği, yüzde gibi spesifik oransal büyüklükler göstermesi, seçilen hata ölçüsünün anlamlı sonuçlar verme durumunu etkilemektedir.

Sonuç olarak, aylık su tüketim verilerinin tahmininde, veri büyüklüğünün ve eldeki verilerin uyumlandığı matematiksel fonksiyonun tahmin doğruluğunu etkileyen faktörler olduğu değerlendirilmektedir.

KAYNAKLAR

Altunkaynak, A., Özger, M. & Çakmakci, M. (2005). Water Consumption Prediction of Istanbul City by Using Fuzzy Logic Approach. *Water Resources Management* **19**(5), 641-654. DOI: [10.1007/s11269-005-7371-1](https://doi.org/10.1007/s11269-005-7371-1)

Altunkaynak, Abdusselam & Assefa, Tewodros. (2017). Monthly Water Consumption Prediction Using Season Algorithm and Wavelet Transform-Based

Models. *Journal of Water Resources Planning and Management*. **143**(6), 04017011. DOI: [10.1061/\(ASCE\)WR.1943-5452.0000761](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000761)

Alvisi, S., Franchini, M. & Marinelli, A. (2007). A short-term, pattern-based model for water-demand forecasting. *Journal of Hydroinformatics*, **9**(1), 39-50. DOI: [10.2166/hydro.2006.016](https://doi.org/10.2166/hydro.2006.016)

Arandia, E., Ba, A., Eck, B. & McKenna, S. (2016). Tailoring seasonal time series models to forecast short-term water demand. *Water Resources Planning and Management*, **142**(3), 04015067. DOI: [10.1061/\(ASCE\)WR.1943-5452.0000591](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000591)

Bata, M., Carriveau, R. & Ting, D S. (2020). Short-term water demand forecasting using hybrid supervised and unsupervised machine learning model. *Smart Water*, **5**, 2 (2020). DOI: [10.1186/s40713-020-00020-y](https://doi.org/10.1186/s40713-020-00020-y)

Billings, B. & Jones, C. (1996). *Forecasting Urban Water Demand*, American Water Works Association, Denver, 179p.

Chen, J. & Boccelli, D. (2014). Demand forecasting for water distribution systems. *Procedia Engineering*, **70**, 339-342. DOI: [10.1016/j.proeng.2014.02.038](https://doi.org/10.1016/j.proeng.2014.02.038)

Donkor, E., Mazzuchi, T., Soyer, R. & Roberson, J. (2014). Urban water demand forecasting: a review of methods and models. *Journal of Water Resources Planning and Management*, **140**(2), 146-159. DOI: [10.1061/\(ASCE\)WR.1943-5452.0000314](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000314)

Du, H., Zhao, Z. & Hui-feng, X. (2020). ARIMA-M: A New Model for Daily Water Consumption Prediction Based on the Autoregressive Integrated Moving Average Model and the Markov Chain Error Correction. *Water*, **12**(3), 760, DOI: [10.3390/w12030760](https://doi.org/10.3390/w12030760)

Firat, M., Turan, M. E., & Yurdusev, M. A. (2010). Comparative analysis of neural network techniques for predicting water consumption time series. *Journal of Hydrology*, **384** (1-2), 46-51. DOI: [10.1016/j.jhydrol.2010.01.005](https://doi.org/10.1016/j.jhydrol.2010.01.005)

Froukh, M.L. (2001). Decision-Support System for Domestic Water Demand Forecasting and Management. *Water Resources Management*, **15**, 363-382. DOI: [10.1023/A:1015527117823](https://doi.org/10.1023/A:1015527117823)

Fullerton, T. J., Ceballos, A. & Walke, A. (2016). Short-term forecasting analysis for municipal water demand. *Journal of American Water Works Association*, **108**(1), 27-38. DOI: [10.5942/jawwa.2016.108.0003](https://doi.org/10.5942/jawwa.2016.108.0003)

Hanif, H., Rasmani, K. & Ramli, N. (2013). Challenges in determining attributes to generate models for estimation of residential water consumption based on consumer data. *AIP Conference. Proceedings*, 22 April 2013, Putrajaya, Malaysia, DOI: [10.1063/1.4801281](https://doi.org/10.1063/1.4801281)

Hartley, J. & Powell, R. (1991). The Development of a Combined Water Demand Prediction Systems. *Civil Engineering Systems*, **8**(4), 231-236. DOI: [10.1080/02630259108970631](https://doi.org/10.1080/02630259108970631)

Homwongs, C., Satsri, T. & Foster, J.W. (1994). Adaptive forecasting of hourly municipal water consumption. *Journal of Water Resources Planning & Management*, **120**(6), 888-905. DOI: [10.1061/\(ASCE\)0733-9496\(1994\)120:6\(888\)](https://doi.org/10.1061/(ASCE)0733-9496(1994)120:6(888))

- House-Peters, L. & Chang, H. (2011).** Urban water demand modeling: review of concepts, methods, and organizing principles. *Water Resources Research*, *47*(5), W05401. DOI: [10.1029/2010WR009624](https://doi.org/10.1029/2010WR009624)
- Jain, A., Varshney, A. & Joshi, U. (2001).** Short-Term Water Demand Forecast Modelling at IIT Kanpur Using Artificial Neural Networks. *Water Resources Management*, *15*, 299-321. DOI: [10.1023/A:1014415503476](https://doi.org/10.1023/A:1014415503476)
- Jowitt, P.W. & Chengchao, X. (1992).** Demand Forecasting for Water Distribution Systems. *Civil Engineering Systems*, *70*(2014), 105-121. DOI: [10.1016/j.proeng.2014.02.038](https://doi.org/10.1016/j.proeng.2014.02.038)
- Karamaziotis, P., 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. DOI: [10.1016/j.ijforecast.2019.07.009](https://doi.org/10.1016/j.ijforecast.2019.07.009)
- Maidment, D.R., Miaou, S. & Crawford, M.M. (1985).** Transfer Function Models of Daily Urban Water Use. *Water Resources Research*, *21*(4), 425-432. DOI: [10.1029/wr021i004p00425](https://doi.org/10.1029/wr021i004p00425)
- Miaou, S.P. (1990).** A class of time series urban water demand models with nonlinear climatic effects. *Water Resources Research*, *26*(2), 169-178. DOI: [10.1029/WR026i002p00169](https://doi.org/10.1029/WR026i002p00169)
- Msiza, I., Nelwamondo, F. & Marwala, T. (2008).** Water demand prediction using artificial neural networks and support vector regression. *Journal of Computation*, *3*(11), 1-8. DOI: [10.4304/jcp.3.11.1-8](https://doi.org/10.4304/jcp.3.11.1-8)
- Namdari, H., Ashrafi, S.M. & Haghighi, A. (2024).** Deep learning-based short-term water demand forecasting in urban areas: a hybrid multichannel model. *AQUA - Water Infrastructure, Ecosystems and Society*, *73*(3), 380-395. DOI: [10.2166/aqua.2024.200](https://doi.org/10.2166/aqua.2024.200)
- Niknam, A., Zare, H., Hosseini-Nasab, H., Mostafaeipour, A. & Herrera, M. (2022).** A Critical Review of Short-Term Water Demand Forecasting Tools-What Method Should I Use? *Sustainability*, *14*(9), 5412. DOI: [10.3390/su14095412](https://doi.org/10.3390/su14095412)
- Okeya, I., Kapelan, Z., Hutton, C. & Naga, D. (2014).** Online modelling of water distribution system using data assimilation. *Procedia Engineering*, *70*, 1261-1270. DOI: [10.1016/j.proeng.2014.02.139](https://doi.org/10.1016/j.proeng.2014.02.139)
- Ponte, B., de la Fuente, D., Pino, R. & Rosillo, R. (2015).** Real-Time Water Demand Forecasting System through an Agent-Based Architecture. *International Journal of Bio-Inspired Computation*, pp. 147-156. DOI: [10.1504/IJBIC.2015.069559](https://doi.org/10.1504/IJBIC.2015.069559)
- Sardinha-Lourenço, A., Andrea-Campos, A., Antunes, A. & Oliveira, M. (2018).** Increased performance in the short-term water demand forecasting through the use of a parallel adaptive weighting strategy. *Journal of Hydrology*, *558*, 392-404. DOI: [10.1016/j.jhydrol.2018.01.047](https://doi.org/10.1016/j.jhydrol.2018.01.047)
- Smith, J., (1998).** A model of daily municipal water use for short-term forecasting. *Water Resources Research*, *24*(2), 201-206. DOI: [10.1029/WR024i002p00201](https://doi.org/10.1029/WR024i002p00201)
- Suhartono, S., Isnawati, S., Salehah, N A., Prastyo, D D., Kuswanto, H. & Lee, M H. (2018).** Hybrid SSA-TSR-ARIMA for water demand forecasting. *International Journal of Advances in Intelligent Informatics*, *4*(3), DOI: [10.26555/ijain.v4i3.275](https://doi.org/10.26555/ijain.v4i3.275)
- Taştan, H. (2017).** Estimation of dynamic water demand function: the case of Istanbul. *Urban Water Journal*, *15*(1), 75-82. DOI: [10.1080/1573062X.2017.1395899](https://doi.org/10.1080/1573062X.2017.1395899)
- Tillman, D., Larsen, T A., Pahl-Wostl, C. & Gujer, W. (1999).** Modeling the actors in water supply systems. *Water Science & Technology*, *39*(4). DOI: [10.1016/s0273-1223\(99\)00055-4](https://doi.org/10.1016/s0273-1223(99)00055-4)
- Tiwari, M. & Adamowski, J. (2013).** Urban water demand forecasting and uncertainty assessment using ensemble wavelet-bootstrapneural network models. *Water Resources Research*, *49*(10), 6486-6507. DOI: [10.1002/wrcr.20517](https://doi.org/10.1002/wrcr.20517)
- Wewer, C. & Taormina, R. (2024).** Conformal Prediction Intervals For Water Demand Forecasting. *EGU General Assembly 2024, 14-19 April 2024*, Vienna, Austria, EGU24-8166. DOI: [10.5194/egusphere-egu24-8166](https://doi.org/10.5194/egusphere-egu24-8166)
- Xu, Y., Zhang, J., Long, Z. & Chen, Y. (2018).** A new hybrid approach for short-term water demand time series forecasting. *2018 13th World Congress on Intelligent Control and Automation (WCICA), 04-08 July 2018*, Changsha, China, 534-539, DOI: [10.1109/wcica.2018.8630722](https://doi.org/10.1109/wcica.2018.8630722)
- Yalçıntaş M, Bulu M, Küçükvar M, Samadi H. (2015).** A Framework for Sustainable Urban Water Management through Demand and Supply Forecasting: The Case of Istanbul. *Sustainability*; *7*(8),11050-11067. DOI: [10.3390/su70811050](https://doi.org/10.3390/su70811050)
- Yasar, A., Bilgili, M., & Simsek, E. (2012).** Water Demand Forecasting Based on Stepwise Multiple Nonlinear Regression Analysis. *Arabian Journal for Science and Engineering*, *37*(8), 2333-2341. DOI: [10.1007/s13369-012-0309-z](https://doi.org/10.1007/s13369-012-0309-z)
- Yurdusev, M. A. & Firat, 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. DOI: [10.1016/j.jhydrol.2008.11.036](https://doi.org/10.1016/j.jhydrol.2008.11.036)
- Zubaidi, S L., Al-Bugharbee, H., Muhsen, Y R., Hashim, K., Alkhaddar, R. & Hmeesh, W H. (2019).** The Prediction of Municipal Water Demand in Iraq: A Case Study of Baghdad Governorate. *2019 12th International Conference on Developments in eSystems Engineering (DeSE)*, Kazan, Russia, 07-10 October 2019, 274-277. DOI: [10.1109/dese.2019.00058](https://doi.org/10.1109/dese.2019.00058)
- Zubaidi, S L., Kot, P., Alkhaddar, R., Abdellatif, M. & Al-Bugharbee, H. (2018).** Short-Term Water Demand Prediction in Residential Complexes: Case Study in Columbia City, USA., *11th International Conference on Developments in eSystems Engineering (DeSE)*, 02-05 September 2018, Cambridge, UK, 31-35, DOI: [10.1109/dese.2018.00013](https://doi.org/10.1109/dese.2018.00013)