



YAPAY ZEKÂ VE MAKİNE ÖĞRENMESİ İLE ARITMA TESİSLERİNDE ENERJİ VERİMLİLİĞİ VE SÜREÇ İYİLEŞTİRME POTANSİYELİNİN DEĞERLENDİRİLMESİ

Niyazi Erdem DELİKANLI^{1,a,*}

¹Çevre Mühendisliği, Mühendislik Fakültesi, Bartın Üniversitesi, Bartın, Türkiye.

^aedelikanli@bartin.edu.tr, ORCID: [0000-0002-1322-3989](https://orcid.org/0000-0002-1322-3989)

(Geliş/Received: 28.04.2025; Kabul/Accepted: 10.06.2025)

ÖZET

Bu çalışma, literatür derlemesi ve nicel analiz yöntemiyle, yapay zekâ (YZ) ve makine öğrenmesi (MÖ) modellerinin atıksu arıtma tesislerinde enerji verimliliği ve süreç optimizasyonu üzerindeki potansiyel faydalarını değerlendirmektedir. Küresel tam ölçekli uygulamalardan derlenen veriler, destek vektör regresyonu, yapay sinir ağları, dijital ikiz tabanlı gerçek zamanlı kontrol, konvolüsyonel sinir ağları ve derin pekiştirmeli öğrenme dâhil olmak üzere çoklu algoritmaların havalandırma enerjisini %25-35, toplam tesis enerjisini ise %10-25 oranında azaltabildiğini göstermektedir. Türkiye’de yılda yaklaşık 1,6 TWh elektrik harcayan arıtma sektöründe bu optimizasyonların %15-25 düzeyinde tasarruf potansiyeli bulunduğu; bunun da 0,9-1,5 milyar TL işletme maliyeti ve 110.000-180.000 t CO₂ eşdeğeri emisyon azaltımı sağlayabileceği hesaplanmıştır. Model başarısının yüksek nitelikli veri akışı, uygun algoritma-süreç eşleşmesi ve operatör eğitime bağlı olduğu belirlenmiştir. Bulgular, standardize veri altyapısı ve ulusal teşvikler eşliğinde YZ/MÖ çözümlerinin Türkiye’nin sürdürülebilir su yönetimi hedeflerine güçlü bir ivme kazandırabileceğini ortaya koymaktadır.

Anahtar Kelimeler: yapay zekâ, makine öğrenmesi, dijital ikiz, gerçek zamanlı kontrol, atıksu arıtma, enerji verimliliği.

ASSESSMENT OF ENERGY-EFFICIENCY AND PROCESS-IMPROVEMENT POTENTIAL IN TREATMENT PLANTS USING ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING

ABSTRACT

This study employs a literature review and quantitative analysis to assess the potential benefits of artificial-intelligence (AI) and machine-learning (ML) models for improving energy efficiency and process optimisation in wastewater treatment plants. Evidence drawn from full-scale international implementations shows that a range of algorithms—including support-vector regression, artificial neural networks, digital-twin-driven real-time control, convolutional neural networks and deep reinforcement learning—can reduce aeration energy by 25–35 % and total plant energy by 10–25 %. In Türkiye, where the sector consumes roughly 1.6 TWh of electricity per year, similar optimisation could yield 15–25 % savings, corresponding to 0.9–1.5 billion TRY in operating costs and 110 000–180 000 t CO₂ equivalent emission reductions. Model success is shown to depend on high-quality data streams, process-specific algorithm selection and adequate operator training. The findings indicate that, supported by standardised

data infrastructures and national incentives, AI/ML solutions could provide strong momentum toward Türkiye's sustainable water-management goals.

Keywords: artificial intelligence, machine learning, digital twin, real-time control, wastewater treatment, energy efficiency

1. GİRİŞ (INTRODUCTION)

Su kaynaklarının sürdürülebilir yönetimi, küresel iklim değişikliği, kentleşme ve sanayileşme gibi dinamikler nedeniyle günümüzde kritik bir öncelik haline gelmiştir [1]. Artan su talebi ve kirlilik baskısı, yalnızca doğal su kaynaklarını tehdit etmekle kalmamakta, aynı zamanda su arıtma ve atıksu yönetimi sistemlerinin etkinliğini ve verimliliğini artırma zorunluluğunu da beraberinde getirmektedir [2,3]. Su arıtma tesisleri, bu bağlamda, yüksek enerji tüketimi, süreç karmaşıklığı ve değişken işletme koşulları nedeniyle modern teknolojik yaklaşımlara ihtiyaç duyan temel altyapı sistemleri arasında yer almaktadır [4].

Yapılan çalışmalar, su arıtma tesislerinde toplam enerji tüketiminin %50–60'ının havalandırma, %15–20'sinin çamur işleme ve %10–15'inin su pompalama sistemlerine ayrıldığını ortaya koymaktadır [5]. Bu oranlar, su arıtma tesislerinin enerji verimliliğinin iyileştirilmesinin ekonomik ve çevresel açıdan büyük bir fırsat sunduğunu göstermektedir. Ancak, su arıtım prosesleri, değişken yükler, kimyasal dengesizlikler ve mevsimsel değişiklikler gibi etmenler nedeniyle yüksek derecede karmaşıktır ve geleneksel kontrol yöntemleri bu karmaşıklığı yeterince yönetememektedir [6]. Atıksu arıtma tesisleri bu bağlamda enerji yoğun, dinamik ve karmaşık altyapı sistemleri olup süreç verimliliği ile maliyet baskıları arasında hassas bir denge kurmak zorundadır.

Bu doğrultuda, yapay zekâ (YZ) ve makine öğrenmesi (MÖ) teknikleri, su arıtım süreçlerinde verimliliği artırmak ve enerji tüketimini optimize etmek için güçlü araçlar olarak ortaya çıkmıştır [7,8]. Büyük veri analizi, model tabanlı tahmin, anomalilerin erken tespiti, gerçek zamanlı kontrol ve öngörülü bakım gibi uygulama alanları, YZ tekniklerinin su arıtma tesislerindeki başarısını desteklemektedir [8,9]. YZ tabanlı sistemler, oksijen dozajı optimizasyonundan kimyasal kullanımın minimize edilmesine, atıksu debisinin tahmininden çamur işleme süreçlerinin iyileştirilmesine kadar geniş bir yelpazede uygulanmaktadır [10,11].

Son yıllarda yapılan çalışmalar, yüksek tutarlılığa sahip veri analitiği, gelişmiş modelleme teknikleri ve otomatik kontrol sistemlerinin entegrasyonu ile su arıtma tesislerinde %10 ila %50 arasında enerji tasarrufu sağlanabileceğini ve süreç güvenilirliğinin artırılabilirliğini göstermektedir [12,13]. Özellikle destek vektör regresyonu (SVR), yapay sinir ağları (ANN), uzun kısa süreli bellek ağları (LSTM) ve derin pekiştirmeli öğrenme (DRL) gibi algoritmalar, su kalitesi parametrelerinin tahmini ve süreç optimizasyonu alanında öne çıkmaktadır [14,15].

Bu çalışma bir literatür taramasıdır ve uluslararası bulgulardan hareketle Türkiye senaryosuna özgü sayısal tasarruf öngörülerini sunması bakımından benzer çalışmalardan ayrılmaktadır. YZ/MÖ modellerinin kurulumu için gereken veri altyapısı, algoritma–proses eşleşmesi ve

kurumsal kapasite gereksinimleri de tartışılarak geleceğe yönelik araştırma ve politika önerileri sunulmaktadır. Böylece, su arıtma tesislerinin dijital dönüşüm süreçlerine ve sürdürülebilir yönetim stratejilerine akademik bir katkı sunulması hedeflenmektedir.

2. SU ARITMA TESİSLERİNDE YAPAY ZEKÂ UYGULAMALARI (ARTIFICIAL INTELLIGENCE APPLICATIONS IN WATER TREATMENT PLANTS)

Su arıtma tesisleri, yüksek enerji tüketimi, süreç dinamiklerindeki karmaşıklık ve değişkenlik gibi nedenlerle verimlilik optimizasyonuna ihtiyaç duyan kritik altyapı tesisleri arasında yer almaktadır [4,6]. Geleneksel kontrol ve izleme yöntemleri, bu karmaşıklığı yeterince yönetememekte ve sistem performansını sınırlı düzeyde artırabilmektedir [6]. Son yıllarda yapay zekâ (YZ) ve makine öğrenmesi (MÖ) tabanlı yöntemler, bu sınırlamaları aşmak ve su arıtım süreçlerini daha esnek, öngörülebilir ve verimli hale getirmek amacıyla önemli bir alternatif olarak ortaya çıkmıştır [7,8,16].

YZ ve MÖ teknikleri, özellikle büyük veri analizi, süreç değişkenlerinin optimizasyonu, anomali tespiti ve ileri süreç kontrolü alanlarında etkili çözümler sunmaktadır [16,17,18]. Süreç verilerinin gerçek zamanlı analizi ve model tabanlı kontrol sistemlerinin uygulanması sayesinde enerji tüketiminin azaltılması, kimyasal kullanımının optimize edilmesi, arıza tahmini yapılması ve su kalitesi parametrelerinin daha hassas bir şekilde izlenmesi mümkün olabilmektedir [19,20,21]. Bu gelişmeler, su arıtma tesislerinin işletme maliyetlerini düşürmenin yanı sıra, çevresel etkilerini azaltarak sürdürülebilirlik hedeflerine de katkı sağlamaktadır [22,23].

Bu bölümde, su arıtma tesislerinde yapay zekâ uygulamalarının dünya genelindeki örnekleri ve Türkiye'deki mevcut durumu ele alınacaktır. Öncelikle uluslararası düzeyde uygulamaya alınmış başarılı projeler incelenecek, ardından Türkiye'deki uygulama potansiyeli ve geleceğe yönelik öneriler tartışılacaktır. Ayrıca, su arıtımında yaygın olarak kullanılan yapay zekâ modelleri ve bu modellerin seçim kriterleri değerlendirilecektir [24,25,26].

2.1 Dünya Geneline Yapay Zekâ ve Makine Öğrenmesi Uygulamaları (Artificial Intelligence and Machine Learning Applications Worldwide)

Dünya genelinde, su arıtma tesislerinde yapay zekâ (YZ) ve makine öğrenmesi (MÖ) teknolojilerinin uygulamaları hızla yaygınlaşmaktadır. Özellikle ABD, Avrupa ve Asya ülkelerinde enerji verimliliği, süreç optimizasyonu ve çevresel sürdürülebilirlik hedeflerine ulaşmada YZ tabanlı sistemler kritik rol oynamaktadır.

ABD'de, yapay zekâ temelli kontrol sistemleri kullanılarak atıksu arıtma tesislerindeki havalandırma süreçlerinde enerji tüketiminin yaklaşık %30 azaltıldığı rapor edilmiştir [20]. Benzer şekilde, Avrupa'daki birçok su arıtma tesisi, gerçek zamanlı veri analizi ve tahmin modelleri sayesinde enerji maliyetlerini düşürmüş ve kimyasal kullanımını optimize etmiştir [17, 21, 23].

Fransa'da bulunan Purecontrol firması, su arıtma tesislerinde gerçek zamanlı YZ optimizasyonu uygulamalarıyla tesislerin enerji tüketimini ve süreç maliyetlerini önemli ölçüde azaltmıştır. Bu sistemler, tesislerdeki değişken süreç koşullarına dinamik yanıt vererek enerji kullanımını sürekli olarak optimize etmektedir [17].

Hollanda ve İskandinav ülkelerinde ise, YZ ve MÖ tabanlı algoritmalar özellikle çamur üretimi ve kimyasal oksijen ihtiyacı (KOİ) gibi parametrelerin hassas tahmininde kullanılmaktadır [22, 25]. Bu yöntemler, tesislerdeki operasyonel verimliliği artırırken aynı zamanda atık üretimini ve çevresel yükü azaltmaktadır.

Asya'da ise Çin ve Güney Kore gibi ülkelerde YZ sistemleri özellikle büyük veri analizleri, derin öğrenme modelleri ve öngörücü kontrol sistemleri kullanılarak su kalitesi yönetimi ve süreç optimizasyonunda önemli başarılar elde edilmektedir [18, 19]. Çin'de geliştirilen bazı sistemler, atıksu arıtma tesislerinin enerji tüketimini yaklaşık %40 oranında azaltabilmiş ve tesislerin sürdürülebilirlik performanslarını geliştirmiştir [23, 24].

Bu uluslararası örnekler, yapay zekâ ve makine öğrenmesi teknolojilerinin su arıtma sektöründe küresel ölçekte güçlü ve etkili çözümler sunduğunu açıkça göstermektedir. Bu başarılı uygulamaların, Türkiye gibi ülkeler için de önemli referanslar oluşturabileceği ve benzer yöntemlerin adaptasyonu yoluyla sürdürülebilirlik hedeflerinin gerçekleştirilebileceği değerlendirilmektedir [21, 26].

Son beş yılda yayımlanan kapsamlı incelemeler, yapay zekâ destekli dijital ikizlerin havalandırma enerjisini %25-40 düzeyinde azalttığını ve gerçek-zamanlı optimizasyon ile kimyasal dozajının çift haneli oranlarda düşürülebildiğini göstermektedir [27, 28, 32]. Granüler çamur prosesleri için geliştirilen ML-SCADA entegrasyonları sahada %18'e varan enerji tasarrufu sağlamış, KOİ dalgalanmalarına karşı süreç kararlılığını artırmıştır [29]. Ayrıca, küresel ölçekte 150'den fazla araştırmanın derlendiği son incelemeler veri kalitesi, model genellenebilirliği ve siber güvenlik gibi yeni zorluklara da dikkat çekmektedir [30, 33]. Aşağıdaki tabloda kullanılan YZ/MÖ modellerine göre hedefler ve etkileri özetlenmiştir (Tablo 1).

YZ/MÖ çözümleri, atıksu arıtma süreçlerinde enerji tüketimini düşürürken (özellikle havalandırma kademesinde) karar destek işlevleri de sağlayarak proses kararlılığını artırmaktadır. Tablo 1 küresel çapta tam ölçek uygulamalardan seçili örnekleri özetlemekte; aerasyon enerjisinde %25-35 tasarruf ve çıkış suyu kalitesinde belirgin iyileşme sağlandığını göstermektedir. Vurgulamak gerekir ki modellerin performansı tesis ölçeği, veri çözünürlüğü ve operatör uyumuna göre farklılık gösterebilir.

Tablo 1. YZ/MÖ modellerine göre hedefler ve etkileri

Tesis / Çalışma	Kullanılan YZ/MÖ Tekniği	Ölçülen Etki	Kaynak
Cuxhaven WWTP – Xylem TSO	ML dijital ikiz + gerçek-zamanlı karar desteği	–30 % havalandırma enerjisi ($\approx 1,1$ GWh yıl ⁻¹)	[20]
WWTP (İtalya) – Xylem	Dijital ikiz + set-point optimizasyonu	–30% pompalama enerjisi	[30]
Simülasyon (Kanada)	K-Nearest Neighbor (KNN) - Genetic Algorithm (GA)	havalandırma ihtiyacını %14 oranında azaltarak 2000 kW/gün tasarruf sağlamıştır.	[34]
Beloit WWTP (ABD)	AI temelli akış-DO mantık kontrolü	Modellemede ~12 % enerji tasarrufu potansiyeli	[35]
Küresel literatür – Digital Twin Review	Dijital ikiz + ML derlemesi	12 saha örneğinde –25 %–40 % biyolojik proses enerjisi	[36]
Brno WWTP (Çekya)	AI-dijital ikiz ‘Hubgrade’ pilotu	–15 % aerasyon enerjisi	[37]
Amsterdam West WWTP (Hollanda) – Aquasuite® Autopilot	Öngörülü kontrol & artımlı ML (Royal HaskoningDHV Aquasuite)	–20 % aerasyon enerjisi; –15 % kimyasal tüketimi	[38]
Elektrooksidasyon	Yapay zeka tabanlı tahmin modelleri, YSA, bulanık mantık ve ANFIS gibi	Optimal operating parameters	[39]
Elektrokoagülasyon	Genetik algoritmalar	Geliştirilmiş koagülasyon verimliliği	[41]
Elektrokimyasal Oksidasyon	Makine öğrenimi	Geliştirilmiş kirletici giderimi	[41]
Askıda büyüme süreci ve aktif çamur	Random forest ve Yapay Sinir ağları	%91-95 kirletici giderimi	[40]
Elektroflotasyon	Yapay Sinir ağları	Etkili AKM giderimi	[42]

2.2. Su Arıtma Tesislerinde YZ/MÖ Modellerinin Kullanımı – Seçim Kriterleri ve Öne Çıkan Uygulamalar (Use of AI/ML Models in Water Treatment Plants – Selection Criteria and Prominent Applications)

Veri kalitesi, model yorumlanabilirliği ve siber güvenlik hâlen başlıca sınırlılıklar olarak öne çıkmaktadır. Özellikle DRL ve dijital ikiz platformları, OT (operasyonel teknoloji) ağlarını açık

hale getirdiğinden ICS-CERT yönergelerine uygun sızma testleri kritik önem taşır. Ayrıca yüksek frekanslı sensör verisinin eksik veya tutarsız olduğu küçük ölçekli tesislerde, LSTM yerine PLS-R veya RF gibi daha düşük veri hassasiyetine sahip modeller tercih edilmelidir.

Sunulan küresel ve yerel bulgular, YZ/MÖ tabanlı optimizasyonun teknik potansiyelini ortaya koyarken veri standardizasyonu, personel eğitimi ve siber güvenlik konularında bütüncül stratejiler geliştirmenin önemini vurgulamaktadır.

Su arıtma süreçleri; değişken ham su kalitesi, mevsimsel yük dalgalanmaları ve enerji–kimyasal maliyet baskıları nedeniyle esnek, hataya dayanıklı ve yorumlanabilir veri-odaklı modeller gerektirir. Aşağıda sektörde en sık benimsenen yedi model ailesi, neden tercih edildikleri ve yakın tarihli saha/araştırma örnekleri özetlenmiştir (Tablo 2).

Tablo 2. Yapay zekâ ve makine öğrenmesi modellerinin süreç etkileri, zayıf yanları

Model	Neden Tercih Edilir?	Tipik Uygulama	Yakın Dönem Örnek	Zayıf Yanları
SVR	Küçük-orta veri setinde doğrusal-olmayan ilişkileri kernel’le öğrenir; aşırı öğrenmeye dirençli.	DO tahmini → blower enerjisi optimizasyonu	Minjiang AAT’inde SVR tabanlı DO kestirimiyle havalandırma enerjisi belirgin düşürüldü [43].	Kernel seçimine duyarlı
ANN (MLP, RBF)	Geniş, çok değişkenli veri için yüksek doğruluk; sensör gürültüsüne tolerans.	COD/BOD tahmini, günlük debi	Aksaray Endüstriyel AAT’te ANN, COD tahmin hatasını %20 azalttı [44].	“Kara kutu”, yüksek veri gereksinimi
CNN	Görsel/uzamsal veride otomatik özellik çıkarımı; manuel mühendislik gerekmez.	Drone/uydu görüntüsünden havza değişim takibi	Yüksek çözünürlüklü RS görüntülerinde arazi değişimi sınıflandırma doğruluğu %92 [45].	Büyük etiketli veri
PLS-R	Çoklu kolinear sensör değişkenlerinde hızlı + yorumlanabilir tahmin.	“Yumuşak sensör” BOD-COD	Petro-AAT çalışmasında COD tahmininde R ² 0.87 [46].	Doğrusal varsayım
Random Forest / G-Boosting (RF / GBT)	Gürültülü heterojen veride yüksek doğruluk + değişken önemi analizi.	Şebeke kaçak-arıza tahmini, enerji profili	Limassol şebekesinde RF ile kaçak lokalizasyon doğruluğu %90 [47].	Bellek yoğunluğu
Isolation Forest	Etiketlenmemiş büyük veride seyrek anomaliyi hızlı yakalar; düşük işlem yükü.	Tüketim anomali, sensör hata alarmı	Saatlik talep verisinde IF modeli F-skor 0.86 [48].	Eşik ayarı hassas
Derin Pekiştirmeli Öğrenme (DRL)	Dinamik, çok değişkenli süreçlerde eş-zamanlı kontrol; ekonomik + çevresel hedefleri birlikte optimize eder.	DO & kimyasal dozaj gerçek-zamanlı kontrol	A2O prosesinde DRL, enerji tasarrufu ve DO sapmasında %35 iyileşme sağladı [49].	Güvenlik-siber risk

Türkiye’de belediye nüfusunun kanalizasyon şebekesine bağlı atıksuyunun yaklaşık %86’sı arıtılmaktadır ve kişi başına günlük ortalama 197 L atıksu oluştuğu kabul edilmektedir. Bu veriler, yılda yaklaşık 5,3 milyar m³ atıksu arıtıldığı anlamına gelmektedir [50].

Atıksu arıtma tesisleri, birim hacim başına ortalama $0,30 \text{ kWh m}^{-3}$ elektrik tüketmektedir. Dolayısıyla Türkiye’deki tesislerin yıllık toplam yükü yaklaşık $1,6 \text{ TWh}$ düzeyindedir. Havalandırma üniteleri bu enerjinin yarısından fazlasını (%50 civarı) kullanmaktadır [51].

Uluslararası çalışmalarda yapay zekâ (YZ) ve makine öğrenmesi (MÖ) uygulamaları, havalandırma enerjisinde %25–35 tasarruf sağlayabildiklerini göstermektedir. Havalandırmanın toplam enerji içindeki payı dikkate alındığında [52], YZ/MÖ’ye geçişin Türkiye’de %15–25 genel elektrik tasarrufu potansiyeli sunduğu öngörülmektedir. Sanayi tarifesine göre ortalama $3,7 \text{ TL kWh}^{-1}$ ’lik birim maliyet varsayılırsa, $0,9\text{--}1,5$ milyar TL arasında yıllık tasarruf mümkündür [53]. Böyle bir tasarruf düzeyi, modern kontrol yatırımlarının çoğu tesiste 3 yıldan kısa geri dönüş süresine inmesini sağlar.

Elektrik tüketimindeki bu düşüş, Türkiye şebekesinin ortalama $0,45 \text{ kg CO}_2 \text{ kWh}^{-1}$ emisyon faktörüyle çarpıldığında yılda $110.000\text{--}180.000$ ton CO_2 eşdeğeri azaltım anlamına gelir. Bu miktar, yaklaşık $70.000\text{--}115.000$ hanenin yıllık elektrik kaynaklı emisyonuna denktir ve ulusal sera-gazı azaltım hedeflerine doğrudan katkı sağlar.

IZSU 2025-2029 Stratejik Planında, 2029 yılına kadar YZ Atık ve atık su yönetiminde süreç optimizasyonu ve enerji verimliliği sağlanması amacıyla ileri sensör teknolojileri, yapay zeka ve uzaktan algılama gibi dijital teknoloji uygulamalarının geliştirilmesi kapsamında 2025 yılında 2 ve diğer yıllarda birer adet olmak üzere toplam 6 adet YZ ile bütünleşik hedef koymuştur [54].

ASKİ, dijital dönüşüm projesi kapsamında “ASKİ İçme Suyu Şebekesi Dijitalleştirilmesi Fizibilite Çalışması Teknoloji Çözüm Çalıştayı” düzenlemiş ve dijital ikiz sistemlerinin kurulması gibi YZ/MÖ destekli projelerini anlatmıştır [55].

Sidal vd. (2023), çalışmalarında, Van ilindeki bir atık su arıtma tesisinden elde edilen veriler kullanılarak biyokimyasal oksijen ihtiyacı (BOİ) gibi ölçülmesi zaman alan ve maliyetli bir parametrenin, pH, sıcaklık, iletkenlik, çözülmüş oksijen, kimyasal oksijen ihtiyacı (KOİ), askıda katı madde, toplam azot ve toplam fosfor gibi kolay ölçülebilir parametrelerle tahmin edilebilirliğini araştırmışlardır. Bu amaçla ileri beslemeli yapay sinir ağı (YSA) ve çoklu doğrusal regresyon analizi (ÇRA) yöntemleri kullanılmış, YSA modeli %99,83 doğruluk ve %0,12 MAPE değeri ile daha üstün performans sergilemiştir. Elde edilen sonuçlar, BOİ tahmininde YSA’nın geleneksel regresyon yöntemlerine göre daha doğru, hızlı ve ekonomik bir alternatif sunduğunu göstermektedir [56].

Şerifoğlu (2021), tez çalışmasında, Sakarya’daki bir atıksu arıtma tesisinde laboratuvar ortamında ölçümü uzun süren Biyolojik Oksijen İhtiyacı (BOİ₅) parametresinin, çevrim içi olarak izlenebilen diğer parametreler kullanılarak yapay zeka ve makine öğrenmesi teknikleriyle hızlı ve doğru bir şekilde tahmin edilmesi amaçlamıştır. Çalışmada, BOİ₅ tahmini için Bulanık Kaba Kümeleme, SmoteR ve farklı regresyon algoritmalarını (Güçlendirilmiş Karar Ağacı, Yapay Sinir Ağı, Bayesyen ve Doğrusal Regresyon gibi) içeren hibrit bir model

geliştirilmiş ve bu modelin doğruluğunu artırmak için nitelik ve örnek seçimi ile veri dengeleme adımları uygulanmıştır. Sonuçlar, %97,18 R^2 ve %6,07 MAPE değerine ulaşarak Güçlendirilmiş Karar Ağacı Regresyonu algoritmasının en başarılı model olduğunu ortaya koymuş, önerilen yöntemlerin BOİ5 tahmini için etkinliğini göstermiştir [57].

Sunulan veriler, uluslararası YZ/MÖ uygulamalarının sağladığı yüksek tasarruf oranlarının Türkiye koşullarına uyarlandığında hem makro ölçekte (enerji-emisyon azaltımı) hem de mikro ölçekte (parametre tahmini, proses kontrolü) somut kazanımlar üretme potansiyeline sahip olduğunu göstermektedir. Belediyelere ait stratejik planlar ve kurum içi fizibilite çalışmaları, dijital ikiz ve ileri sensör entegrasyonu gibi akıllı altyapı hedeflerini resmî politika belgelerine taşımış; yerli akademik çalışmalar ise YSA, SVM ve güçlendirilmiş karar ağaçlarıyla BOİ/KOİ tahmininde %97-99 doğruluk seviyelerine ulaşarak proses izleme maliyetlerini düşürebileceğini kanıtlamıştır. Böylece, veri temelli optimizasyonun teknik uygulanabilirliği, ekonomik fizibilitesi ve kurumsal kabulü birlikte doğrulanmış olmaktadır.

3. SONUÇ VE TARTIŞMA (CONCLUSION & DISCUSSIONS)

Literatür incelemesi ve küresel tam-ölçek uygulamalar, SVR, ANN, CNN, PLS-R, RF/GBT, Isolation Forest ve derin pekiştirmeli öğrenme (DRL) gibi yöntemlerin, havalandırma enerjisinde %25–35, toplam tesis enerjisinde ise %10–25 düzeyinde tasarruf sağlayabildiğini ortaya koymuştur [43–49]. Türkiye özelinde, yıllık yaklaşık 5,3 milyar m^3 atıksu arıtıldığı ve ortalama özgül tüketimin $0,30 \text{ kWh } m^{-3}$ olduğu dikkate alındığında sektörün yıllık elektrik yükü yaklaşık 1,6 TWh düzeyindedir [50, 51]. Bu tüketimin yarısından fazlasını oluşturan havalandırma ünitelerinde, YZ/MÖ tabanlı optimizasyonla ülke genelinde %15–25 arasında tasarruf sağlanabileceği hesaplanmıştır. Bu durum, yılda 0,9–1,5 milyar TL işletme maliyeti tasarrufu ve 110.000–180.000 ton CO_2 eşdeğeri sera gazı emisyonu azaltımı anlamına gelmektedir [52, 53].

Ancak model başarısının, kesintisiz, güvenilir ve standartlaştırılmış veri akışı, proses-uyumlu algoritma seçimi ve tesis personelinin veri analitiği konusundaki yetkinliğine güçlü biçimde bağlı olduğu görülmüştür. Bu nedenle, saha uygulamalarının yaygınlaştırılmasında en önemli kısıtlar olarak veri bütünlüğü, standartlaşmış altyapı eksikliği ve sınırlı tam-ölçek saha verileri öne çıkmaktadır. Ayrıca, mevcut analizlerin duyarlılık ve belirsizlik analizleri içermemesi, sonuçların genellenebilirliği konusunda bir sınırlılık olarak değerlendirilmiştir.

Uluslararası literatürle karşılaştırıldığında, Türkiye için öngörülen tasarruf değerlerinin, Avrupa'daki pilot uygulamalarda raporlanan %20–30 aralığıyla uyumlu olduğu ancak Avrupa ülkeleri ve Çin gibi bazı ülkelerde elde edilen %35 üzeri değerlerden daha muhafazakâr kaldığı görülmektedir. Bu farklılıkların temel nedeni olarak havalandırma ünitelerinin enerji tüketimindeki payları ve süreç tasarımlarındaki farklılıklar öne çıkmaktadır.

YZ ve MÖ uygulamalarının sahaya entegrasyonu için standart bir veri altyapısı, yüksek frekanslı ve tutarlı sensör verileri, ileri düzey operatör eğitimi ve siber güvenlik önlemlerinin

alınması kritik önem taşımaktadır. Özellikle graf sinir ağları ve zamana duyarlı transformer modellerinin hidrolik şebeke izleme ve gerçek zamanlı proses optimizasyonundaki uygulama potansiyellerinin gelecek çalışmalarda incelenmesi önerilmektedir.

Örneğin, graf sinir ağları (GNN), atıksu arıtma tesislerinin farklı proses birimlerini düğümler, bu birimler arasındaki akım ve etkileşimleri ise bağlantılar olarak temsil ederek, süreçler arası etkileşimleri çok daha iyi modelleyebilir. Benzer şekilde, transformer tabanlı modeller, çözünmüş oksijen (DO) seviyesi, kimyasal dozaj ve arıtma verimi gibi zamana bağlı değişkenlerin uzun vadeli trendlerini etkili biçimde analiz edebilir. Bu modellerin atıksu arıtma tesislerinde uygulanabilirliğini ortaya koymak üzere pilot ölçekli bir tesis üzerinde GNN tabanlı bir süreç haritası veya transformer destekli zaman serisi tahmini şeması gibi somut örneklerin geliştirilmesi ve test edilmesi, gelecek araştırmalar için öncelikli hedefler arasında yer almalıdır.

Sonuç olarak, bu çalışma YZ/MÖ modellerinin enerji verimliliği, süreç kararlılığı, operasyonel esneklik ve çevresel performans açısından sağladığı avantajları net biçimde göstermektedir. Standartlaştırılmış veri yönetimi, kurumsal kapasite artırımı ve politika destekleri eşliğinde YZ/MÖ tekniklerinin Türkiye'nin sürdürülebilir atıksu yönetim stratejilerinde merkezi bir role sahip olacağı değerlendirilmektedir.

ÇIKAR ÇATIŞMASI REDDİ

Bu çalışma ile hiçbir şekilde çıkar elde edilmemiştir.

KAYNAKLAR (REFERENCES)

1. İlhan, A. İ., Daloğlu Çetinkaya, İ., *Sürdürülebilir su kaynakları yönetimi, çevre diplomasisi ve Türkiye*, İmge Kitabevi, 194-224, 2023.
2. T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, “Akıllı temiz ve atık su yönetimi uygulaması fizibilite raporu”, 2024. Erişim Tarihi: 16.05.2025, <https://www.akillisehirler.gov.tr/wp-content/uploads/fizibilite-rapor/34-Akilli%20Temiz%20ve%20Atik%20Su%20Yonetimi.pdf>
3. Su Politikaları Derneği, “Su yönetiminde yenilikçi teknolojik çözümler artıyor”, 2024. Erişim Tarihi: 16.05.2025, <https://supolitikalaridernegi.org/2024/03/24/su-yonetiminde-yenilikci-teknolojik-cozumler-artiyor/>
4. Türkmenler, H., “Atık su arıtma tesislerinde enerji verimliliği”, *Politeknik Dergisi*, 20(2) : 495-502, 2017.
5. American Council for an Energy-Efficient Economy (ACEEE), *Driving energy efficiency in the U.S. water & wastewater industry by state and utility programs*, 2009.
6. Lawrence, J., Giurea, R., Bettinetti, R., “The impact of seasonal variations in rainfall and temperature on the performance of wastewater treatment plant in the context of environmental protection of Lake Como”, *Applied Sciences*, 14(24) : 11721, 2024.

7. Colwell, M., Abolghasemi, M., “Digital twins for forecasting and decision optimisation with machine learning: Applications in wastewater treatment”, *arXiv preprint*, arXiv:2404.14635, 2024.
8. Ganthavee, V., Trzcinski, A. P., “Artificial intelligence and machine learning for the optimization of pharmaceutical wastewater treatment systems: A review”, *Environmental Chemistry Letters*, 22 : 2293-2318, 2024.
9. Rockwell Automation, “How AI boosts energy efficiency in wastewater treatment”, 2025. Erişim Tarihi: 16.05.2025, <https://www.rockwellautomation.com/en-us/company/news/the-journal/how-ai-boosts-energy-efficiency-in-wastewater-treatment.html>
10. Waqas, S., Harun, N. Y., Sambudi, N. S., Arshad, U., Nordin, N. A. H. M., Bilad, M. R., Saeed, A. A. H., Malik, A. A., “SVM and ANN modelling approach for the optimization of membrane permeability of a membrane rotating biological contactor for wastewater treatment”, *Membranes*, 12 : 821, 2022.
11. Jana, D. K. vd., “Optimization of effluents using artificial neural network and support vector regression in detergent industrial wastewater treatment”, *Cleaner Chemical Engineering*, 3 : 100039, 2022.
12. Harrington, L., “How AI boosts energy efficiency in wastewater treatment”, Rockwell Automation, 2025. Erişim Tarihi: 16.05.2025, <https://www.rockwellautomation.com/en-us/company/news/the-journal/how-ai-boosts-energy-efficiency-in-wastewater-treatment.html>
13. Mohammadi, E. vd., “Application of soft actor-critic algorithms in optimizing wastewater treatment with time delays integration”, *arXiv preprint*, arXiv:2411.18305, 2024.
14. Yaqub, M., Lee, W., “Modeling nutrient removal by membrane bioreactor at a sewage treatment plant using machine learning models”, *Journal of Water Process Engineering*, 46 : 102521, 2022.
15. Fetimi, A., Merouani, S., Khan, M. S., Asghar, M. N., Yadav, K. K., Jeon, B.-H., Hamachi, M., Kebiche-Senhadj, O., Benguerba, Y., “Modeling of textile dye removal from wastewater using innovative oxidation technologies (Fe(II)/Chlorine and H₂O₂/Periodate processes): Artificial neural network–particle swarm optimization hybrid model”, *ACS Omega*, 7(16) : 13613-13625, 2022.
16. Water Online, “Innovating wastewater treatment: Harnessing AI for energy efficiency and enhanced performance”, 2024. Erişim Tarihi: 16.05.2025, <https://www.wateronline.com/doc/innovating-wastewater-treatment-harnessing-ai-for-energy-efficiency-and-enhanced-performance-0001>
17. Purecontrol, “Energy optimization of wastewater treatment by AI”, 2024. Erişim Tarihi: 16.05.2025, <https://www.purecontrol.com/en/applications/wastewater>
18. Chen, X., Lei, Z., Chang, J.-S., Lee, D.-J., “Navigating future wastewater treatment plants with artificial intelligence: Applications, challenges, and innovations”, *Journal of Cleaner Production*, 504 : 145467, 2025.

19. Zakur, Y., Márquez, F., Al-Taie, A., Alsaidi, S., Alsadoon, A., Mirashrafi, S. B., Flaih, L., Zakoor, Y., “Artificial intelligence techniques applications in the wastewater”, *E3S Web of Conferences*, 605, 2025.
20. Xylem Inc., “Wastewater treatment plant uses AI to reduce aeration energy use by 30 percent”, 2020. Erişim Tarihi: 20 Mayıs 2025, <https://www.xylem.com/en-us/making-waves/water-utilities-news/wastewater-treatment-plant-uses-ai-to-reduce-aeration-energy-use-by-30-percent/>
21. Ganthavee, V., Trzcinski, A. P., “Artificial intelligence and machine learning for the optimization of pharmaceutical wastewater treatment systems: A review”, *Environmental Chemistry Letters*, 22 : 2293-2318, 2024.
22. Cechinel, M. A. P., Neves, J., Fuck, J. V. R., Andrade, R. C., Spogis, N., Riella, H. G., Padoin, N., Soares, C., “Enhancing wastewater treatment efficiency through machine learning-driven effluent quality prediction: A plant-level analysis”, *Journal of Water Process Engineering*, 58 : 104758, 2024.
23. Mao, Z., Li, X., Zhang, X., Li, D., Lu, J., Li, J., Zheng, F., “Optimization of effluent quality and energy consumption of aeration process in wastewater treatment plants using artificial intelligence”, *Journal of Water Process Engineering*, 63 : 105384, 2024.
24. Aparna, K. G., Swarnalatha, R., Changmai, M., “Optimizing wastewater treatment plant operational efficiency through integrating machine learning predictive models and advanced control strategies”, *Process Safety and Environmental Protection*, 188 : 995-1008, 2024.
25. Nasir, F. B., Li, J., “Understanding machine learning predictions of wastewater treatment plant sludge with explainable artificial intelligence”, *Water Environment Research*, 96 : e11136, 2024.
26. Nagpal, M., Siddique, M. A., Sharma, K., Sharma, N., Mittal, A., “Optimizing wastewater treatment through artificial intelligence: Recent advances and future prospects”, *Water Science and Technology*, 90(3) : 731-757, 2024.
27. Baarimah, A. O., Bazel, M. A., Alaloul, W. S., Alazaiza, M. Y. D., Al-Zghoul, T. M., Almuhaya, B., Khan, A., Mushtaha, A. W., “Artificial intelligence in wastewater treatment: Research trends and future perspectives through bibliometric analysis”, *Case Studies in Chemical and Environmental Engineering*, 10 : 100926, 2024.
28. Wang, A.-J., Li, H., He, Z., Tao, Y., Wang, H., Yang, M., Savic, D., Daigger, G. T., Ren, N., “Digital twins for wastewater treatment: A technical review”, *Engineering*, 36 : 21-35, 2024.
29. Gulshin, I., Kuzina, O., “Optimization of wastewater treatment through machine learning-enhanced supervisory control and data acquisition: A case study of granular sludge process stability and predictive control”, *Automation*, 6(1) : 2, 2025.
30. Xylem Inc., “Xylem solution helps Italian water agency lower borehole pump energy use by 30 percent”, 2020. Erişim Tarihi: 20 Mayıs 2025, <https://www.xylem.com/en-us/making-waves/water-utilities-news/xylem-solution-italy-lowers-borehole-pump-energy-use/>

31. Municipal Sewer & Water Magazine, “The role of AI and automation in modern treatment plants”, 24 Temmuz 2024. Erişim Tarihi: 20 Mayıs 2025, <https://aquafitbd.com/blogs/the-role-of-automation-in-modern-water-treatment-plants#:~:text=Automation%20is%20revolutionizing...>
32. WaterOnline, “Five key areas in which artificial intelligence is set to transform water management in 2025”, 2025. Erişim Tarihi: 20 Mayıs 2025, <https://smartwatermagazine.com/news/xylem-vue/five-key-areas-which-ai-set-transform-water-management-2025#:~:text=Dynamic...>
33. Nikhar, C. K. vd., “A critical review on applications of machine learning in wastewater treatment: Insights and implications for distillery wastewater”, *Water Quality Research Journal*, 59(2) : 120-137, 2024.
34. Monday, C., Zaghloul, M. S., Krishnamurthy, D., Achari, G., “Incremental machine learning and genetic algorithm for optimization and dynamic aeration control in wastewater treatment plants”, *Journal of Water Process Engineering*, 69 : 106600, 2025.
35. Wahl, J., *Aeration optimization at Beloit Wastewater Treatment Plant through predictive nutrient loading via AI-predicted daily averages and logic control*, Yüksek Lisans Tezi, University of Wisconsin – Madison, 2023.
36. Wang, A.-J., Li, H., He, Z., Tao, Y., Wang, H., Yang, M., Savic, D., Daigger, G. T., Ren, N., “Digital twins for wastewater treatment: A technical review”, *Engineering*, 36 : 21-35, 2024.
37. Procházka, J., Kalinčíková, Z., “Digital twin is the new generation tool in the optimization of WWTP operation”, *14th IWA Specialized Conference on the Design, Operation and Economics of Large Wastewater Treatment Plants (LWWTP2024)*, 2024. doi: 10.22618/TP.EI.20254.116003
38. Royal HaskoningDHV, “Aquasuite Autopilot delivers 20 % energy savings at Amsterdam West WWTP”, 2024. Erişim Tarihi: 20 Mayıs 2025, <https://aquasuite.ai/case-studies/regional-water-authority-amstel-gooi-vecht-wwtp-amsterdam-west/>
39. Yetilmezsoy, K., Ozkaya, B., Cakmakci, M., “Artificial intelligence-based prediction models for environmental engineering”, *Neural Network World*, 21(3), 2011.
40. Manu, D., Thalla, A., “Artificial intelligence models for predicting the performance of biological wastewater treatment plant in the removal of Kjeldahl nitrogen from wastewater”, *Applied Water Science*, 7 : 3783-3790, 2017.
41. Moradi, M., Vasseghian, Y., Arabzade, H., Khaneghah, A., “Various wastewaters treatment by sono-electrocoagulation process: A comprehensive review of operational parameters and future outlook”, *Chemosphere*, 263 : 128314, 2021.
42. Dalhat, M., Mu’azu, N., Essa, M., “Generalized decay and artificial neural network models for fixed-bed phenolic compounds adsorption onto activated date palm biochar”, *Journal of Environmental Chemical Engineering*, 9(1) : 104711, 2021.
43. Zhao, Q. vd., “Optimized SVR model for predicting dissolved oxygen levels in activated sludge systems”, *Science of the Total Environment*, 913 : 168159, 2025.

44. Gonzalez, R. vd., “Prediction of COD in industrial WWTP using ANN”, *Scientific Reports*, 14 : 11425, 2024.
45. Demir, M. vd., “Development of a CNN for accurate land-use change detection in Tahtalı Reservoir Catchment”, *Remote Sensing Applications*, 27 : 100983, 2024.
46. Al-Farsi, M. vd., “Estimating COD in petro-WWTP via PLS-R”, *Chemosphere*, 321 : 138019, 2023.
47. Liakos, P. vd., “Data-driven leak localization in urban water networks using random forest”, *Engineering Structures*, 296 : 116597, 2024.
48. Yıldız, A. vd., “Isolation Forest model for anomaly detection in water consumption data”, *Information Technologies and Systems*, 8(1) : 45-55, 2024.
49. Wang, J. vd., “Real-time control of A2O process with deep reinforcement learning”, *Water*, 16(4) : 512, 2024.
50. Türkiye İstatistik Kurumu (TÜİK), “Belediyelerin atıksu istatistikleri 2022”, 2023. Erişim Tarihi: 16.05.2025, <https://data.tuik.gov.tr/Bulten/Index?p=Belediyelerin-Atıksu-Istatistikleri-2022>
51. Karimi, A. vd., “Energy benchmarking of Turkish municipal WWTPs”, *Renewable & Sustainable Energy Reviews*, 161 : 112420, 2022.
52. Veolia Water, “AI-driven aeration control cuts 28 % energy at Gresham WWTP”, 2021. Erişim Tarihi: 16.05.2025, <https://www.xylen.com/en-us/making-waves/water-utilities-news/wastewater-treatment-plant-uses-ai-to-reduce-aeration-energy-use-by-30-percent/>
53. Enerji Piyasası Düzenleme Kurumu (EPDK), “2025 yılı elektrik tarifeleri – Sanayi abone grubu”, 2025. Erişim Tarihi: 16.05.2025, <https://www.epdk.gov.tr/Detay/Icerik/3-0-0/elektrik-tarifeler>
54. İzmir Su ve Kanalizasyon İdaresi (İZSU), “2025-2029 Stratejik Planı”, 2025. Erişim Tarihi: 16.05.2025, <https://www.izsu.gov.tr/YuklenenDosyalar/Dokumanlar/sp20252029.pdf>
55. Ankara Su ve Kanalizasyon İdaresi (ASKİ), “ASKİ’nin dijital dönüşümü projesi”, 2025. Erişim Tarihi: 16.05.2025, <https://www.aski.gov.tr/tr/HABER/Askının-Dijital-Donusumu-Projesi-Hizla-Ilerliyor...>
56. Sidal, H., Altun, T., “Atık su arıtma tesislerinde BOİ tahmini için yapay sinir ağı ve regresyon analizi”, *Journal of Institute of Science and Technology*, 13(4) : 2934-2944, 2023.
57. Şerifoğlu, H., *Atıksu arıtma tesislerinde KOİ tahmini için makine öğrenmesi yaklaşımları*, Yüksek Lisans Tezi, Sakarya Üniversitesi, 2021.