

# Yapay Sinir Ağı Modeli Kullanılarak İleri Biyolojik Atıksu Arıtma Tesislerinde Kimyasal Oksijen İhtiyacı Çıkış Konsantrasyonlarının Tahmini

<sup>1</sup>Harun Türkmenler, <sup>2</sup>Murat Pala, <sup>\*3</sup>Ruşen Can, <sup>4</sup>Naci Çağlar

<sup>1</sup>Adıyaman Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Bölümü, Adıyaman-Türkiye

<sup>2</sup>Adıyaman Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Adıyaman-Türkiye

<sup>\*3</sup>Adıyaman Üniversitesi, Fen Bilimleri Enstitüsü, Çevre Mühendisliği Anabilim Dalı, Adıyaman-Türkiye

<sup>4</sup>Sakarya Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Sakarya-Türkiye

## Abstract

This study presents the application of Artificial Neural Network (ANN) techniques for the prediction of the performance of advanced biological wastewater treatment plants. The ANN-based model for prediction of effluent chemical oxygen demand (COD) concentrations was formed using a three-layered feed forward ANN, which used a back propagation learning algorithm (BPA). ANNs are effective in modeling and simulation of highly non-linear multivariable relationships. The plantscale data set used in this study (306 daily records of the year 2012) was obtained from a local wastewater treatment plant. Daily records of biochemical oxygen demand ( $BOD_{influent}$ ), chemical oxygen demand ( $COD_{influent}$ ), flow rate ( $Q_w$ ), suspended solid ( $SS_{influent}$ ), total nitrogen ( $TN_{influent}$ ), and total phosphorus ( $TP_{influent}$ ) are used as inputs into the ANN so as to assess the degree of effect of each of these parameters on the  $COD_{effluent}$ . The root mean square (RMS) error, the mean absolute percentage error (MAPE), and the sum of the squares error (SSE) for  $COD_{effluent}$  were employed for the evaluation accuracy of the model. The absolute fraction of variance ( $R^2$ ) values were found to be 96.88% and 96.15% for the training and testing sets of treatment plant process, respectively. The results revealed that ANN model is fairly promising approach for the prediction of the COD in the effluent of wastewater treatment plants.

**Key words:** COD prediction, wastewater treatment plant, total phosphorus, artificial neural networks, performance assessment

## Özet

Bu çalışma, ileri biyolojik atık su arıtma tesislerinin performans tahmini için Yapay Sinir Ağı (YSA) tekniklerinin uygulanmasını sunmaktadır. Çıkış kimyasal oksijen ihtiyacı (KOİ) konsantrasyonları tahmininde YSA-tabanlı model olarak geri yayılma algoritması (GYA) kullanıldı. YSA, modellemede ve yüksek derecede lineer olmayan çoklu değişkenlerin simülasyonunda oldukça etkilidir. Bu çalışmada kullanılan tesis-ölçekli veriler (2012 yılına ait 306 günlük kayıt), yerel bir atıksu arıtma tesisinden elde edilmiştir. Biyokimyasal oksijen ihtiyacı ( $BOİ_{giriş}$ ), kimyasal oksijen ihtiyacı ( $KOİ_{giriş}$ ), debi ( $Q_w$ ), askıda katı madde ( $AKM_{giriş}$ ), toplam azot ( $TN_{giriş}$ ) ve toplam fosfor ( $TP_{giriş}$ ) parametrelerinin her birinin  $KOİ_{çıkış}$  üzerindeki etkisini değerlendirmek için YSA modelinde bu parametrelerin giriş parametreleri olarak kullanıldı.  $KOİ_{çıkış}$  için, karekök ortalama hata (KOH), ortalama mutlak hata yüzdesi (OMHY) ve kareler hata toplamı (KHT), modelin doğruluğunun değerlendirilmesi için kullanılmıştır. Varyans mutlak fraksiyonu ( $R^2$ ) değerleri, arıtma tesisi prosesinin eğitim ve test setleri için sırasıyla 96.88 ve % 96.15 bulunmuştur. Sonuçlar, YSA modelinin atık su arıtma tesislerinin çıkış suları KOİ tahmini için oldukça umut verici bir yaklaşım olduğunu ortaya koymuştur.

**Anahtar kelimeler:** KOİ tahmini, atıksu arıtma tesisleri, toplam fosfor, yapay sinir ağları, performans değerlendirilmesi

## 1. Giriş

<sup>1</sup>Sorumlu yazar: Adres: Adıyaman Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Bölümü, 02040, Altınşehir, Adıyaman/Türkiye. E-mail adresi: hturkmenler@adiyaman.edu.tr, Tlf.: +904162233800/2780 Fax: +904162233809

Doğal kaynakların gerektiği gibi kullanılmaması ve bunların yenilenemez kaynakları oluşturması zaman içerisinde çevre sorunlarını ortaya çıkarmaktadır. Doğal kaynakların aşırı ve bilinçsiz bir şekilde tüketilmesi, çevre problemlerinde belirgin bir artışa neden olmaktadır. Artan nüfusa paralel olarak doğa, daha yoğun kullanılmakta ve tahrip edilmektedir. Arıtma süreci modelleri, atıksu arıtma tesislerinin düzgün çalışmasının ve daha iyi kontrolünün sağlanması için gerekli araçlardır [1].

Son yıllarda, bilgisayar tabanlı yöntemler çevresel konuların birçok alanında uygulanmıştır. YSA; insan beynindeki birçok nöronun (sinir hücresinin), ya da yapay olarak basit işlemcilerin birbirlerine değişik etki seviyeleri ile bağlanması sonucu oluşan karmaşık bir sistem olarak tanımlanabilir. YSA'ların modelleme yeteneği, doğrusal olmayan özelliklere sahip karmaşık sistemlerin biyolojik süreçlerinin modellenmesi için onları en popüler araç yapmıştır [2].

Bir biyolojik atıksu arıtma tesisinin (AAT), işlemsel kontrolü arıtma prosesinin değişen ve karmaşık yapısı nedeniyle işlenmemiş atıksu bileşimlerin, güçlü yönleri ve akış oranları değişimleri genellikle karmaşıktır [3]. Ayrıca, uygun bir işlem değişkenlerinin eksikliği atık su kalitesi etkin kontrolünü sınırlar [4]. Kimyasal olarak oksitlenebilen organik maddelerin oksijen ihtiyacı KOİ ile ifade edilir. KOİ asidik ortamda kuvvetli bir kimyasal oksitleyici (potasyum dikromat gibi) vasıtasıyla ölçülür. Kimyasal olarak oksitlenebilecek bileşikler, biyolojik olarak oksitlenebileceklerden daha fazla olduğundan, kimyasal oksijen ihtiyacı, biyolojik oksijen ihtiyacından daha büyüktür.

Biyoproseslerde kullanılan geleneksel modelleme teknikleri mikrobiyal büyüme, substratın tüketiminin ve ürünlerin oluşumu için hız eşitlikleri ile birlikte denge denklemlerine dayanmaktadır. Geleneksel deneysel teknikler kullanılarak tesis çalışma parametrelerinin tahmini zaman alıcıdır ve bu tür işlemlerin verimli ve etkin kontrolü yolunda bir engeldir [5].

YSA tabanlı modeller, AAT performansını tahmin etmek için verimli ve güçlü bir araç sağlamak için bulunmuştur [6]. YSA modelleri tek veya birden fazla giriş ve tek (veya iki) çıkışlar olarak konfigüre edilmektedir. Bu nedenle, şimdiye kadar yapılmış çalışmalar çoğunlukla iki ya da üç parametre giriş ve tek bir çıkışa dayanmaktadır.

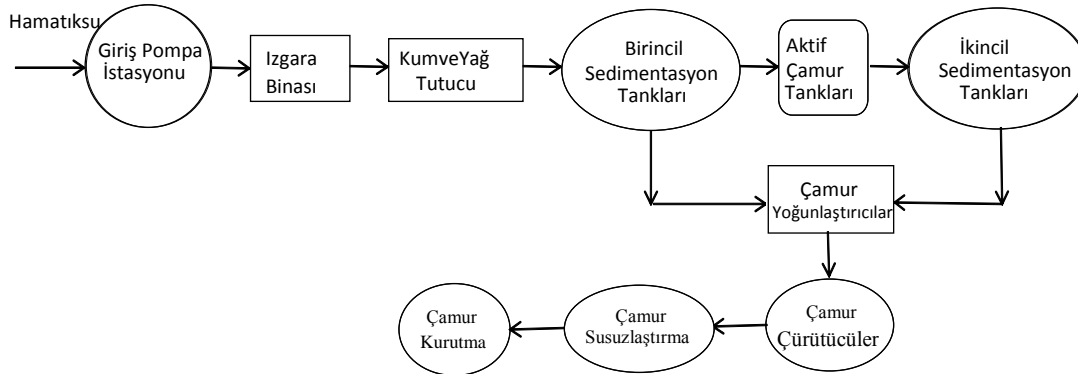
Bu çalışmada, kullanılan tesis ölçekli veri seti (2012 yılı 306 günlük kayıtlar) Ataköy İleri Biyolojik Atıksu Arıtma Tesisinden (AİBAAT) elde edilmiştir.  $BOİ_{giriş}$ ,  $KOİ_{giriş}$ , Debi,  $AKM_{giriş}$ ,  $TN_{giriş}$  ve  $TP_{giriş}$  parametrelerinin her birisinin günlük kayıtlarının  $KOİ_{çıkış}$  parametresine olan etkisini değerlendirmek üzere bu parametreler YSA modelinde girdi olarak kullanıldı. YSA tabanlı model esas alınarak  $KOİ_{çıkış}$  konsantrasyonlarının tahmini için, GYA kullanan bir üç-katmanlı ileri beslemeli YSA modeli oluşturuldu.

## 2. Materyal ve Metot

### 2.1. Gelişmiş biyolojik atıksu arıtma tesisinin genel tanımı

Tesisin amacı; Bakırköy, Bahçelievler ve Bağcılar ilçelerini tamamen ve Küçükçekmece ve Gaziosmanpaşa ilçelerini de kısmen, halihazırda Ayamama ve Tavukçu nehirlerine deşarj edilen ve böylece Marmara Denizi'ni kirleten atık suları kolektörler vasıtasıyla toplamak, bu atıksuların ileri derecede arıtılacağı yer olan AİBAAT'ye taşımak ve son olarak arıtılmış atıksuyu çevreye zararsız bir şekilde deşarj etmektir.

Arıtma tesisi 400,000 m<sup>3</sup>/gün kapasiteli karbon, azot ve fosfor giderimi yapan, 1.600.000 eşdeğer nüfus tarafından üretilen atık suyu arıtır. AİBAAT'nin akış diyagramı Şekil 1. de görülmektedir. Tesis tarafından üretilen çamur kurutucularda çevreye zararsız hale getirilir.



Şekil 1. AİBAAT akış diyagramı

Veriler,2012 yılına ait 306 günlük kayıtların İstanbul/Türkiye de bulunan AİBAAT veritabanından alınmıştır.Bu dönem,çalışılan değişkenlerdeki muhtemel tüm mevsimsel değişimleri kapsadığı için tatmin ediciydi.Model yapısını oluşturmak için, toplam 6 kritik atıksu kaliteparametreleri girdi değişkenleri olarak seçilmiştir.YSA modelinde çıkış parametresi olarak KOİ<sub>çıkış</sub> seçilmiştir. Toplam 306 veri kullanıldı ve bu verilerin 276 'sı eğitim ve 30'u test için kullanılmıştır.

## 2.2.YSA'lar

YSA, basit biyolojik sinir sisteminin çalışma şeklini benzetmek içintasarlanan programlardır. Çeşitli şekillerde birbirlerine bağlanan sinir hücreleri (nöronlar) ağıloştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarmakapasitesine sahiptir [7]. Mühendislik uygulamalarında YSA'nın geniş çaplı kullanımının en önemli nedeni, tekniklerle çözümü zor problemler için etkin bir alternatif oluşturmasıdır.YSA yaklaşımının temel düşüncesiyle, insan beyninin fonksiyonları arasında benzerlik vardır. Bu yüzden YSA sistemine insan beyninin modeli denilebilir.

YSA'nın önemli bir özelliği bilgiyi saklama şeklidir. Özetle, YSA' lar, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgileri üretebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri bilgisayarlarakazandıran sistemlerdir. Ayrıca bu yöntem genelleme yapabilme ve sınırsız sayıda değişkenleçalışabilme gibi başka özelliklere de sahiptir. Tüm bu özelliklerinden dolayı YSA' lar, kontrol,görüntü işleme, sınıflandırma, görüntü ve ses tanıma, modelleme, kalite kontrolü, kestirim vetahmin (öngörü) hesaplamaları gibi pek çok alanda kullanılmaktadır ve uygulama alanları içinbir sınırlama bulunmamaktadır[8].

YSA teknikleri karmaşık ve doğrusal olmayan modellerde etkilidir. YSA son yıllarda oldukça ilgi gören bir modelleme tekniğidir. YSA'nın kullanıldığı önemli alanlardan biri de geleceği tahmindir. YSA, veriler arasındaki bilinmeyen ve fark edilmesi güç ilişkileri ortaya çıkartabilir. YSA, günümüzde birçok probleme çözüm üretebilme yeteneğine sahiptir. YSA'

ların örnekler ile öğrenebilme ve genelleme yapabilme özellikleri onlara çok esnek ve güçlü araçlar olma özelliği sağlamaktadır.

En yaygın olarak kullanılan sinir ağı yöntemi GYA'dır. Bu öğrenme algoritması, çok katmanlı sinir ağı içerir ve bir giriş katmanı, gizli katmanlar bir çıkış katmanı içerir. Eğitim algoritmalarının çeşitli birçok tipleri mevcuttur. GYA, ileri besleme sinir ağı (İBSA) için eğitim algoritmalarının en yaygın sınıflarından biridir [9].

Model tanıma, tanımlama, sınıflandırma, konuşma, görme ve kontrol sistemleri gibi pek çok farklı uygulama alanlarıyla karşılaşılan karmaşık sorunları çözmek için YSA'lar kullanılmışlardır. Üstelik YSA'ların, artı noktalarından biri konvansiyonel yaklaşımdan farklı bu verilerin doğrudan istenen bilgileri ayıklar olmasıdır.

Bir çok-tabakalı GYA, YSA'nın temelidir ve YSA da en yaygın olarak kullanılır. Bu, bir giriş tabakası, bir çıkış tabakası ve çok sayıda gizli tabakayı içeren en az üç veya daha fazla tabaka içerir. Bir tabakadaki her nöron bitişik tabakadaki nöronlara bağlanır ve aynı tabakanın birimleri arasında hiçbir bağlantı yoktur. Probleme bağlı olarak, her tabakada nöronların sayısı değişebilir. Girdiler ve çıktılar arasındaki ilişkiler eğilimsiz ağ yerine eğilimli ağlar kullanarak daha kolay temsil edilebilmektedir. Genellikle cebirsel denklemler içeren bir transfer fonksiyonu, doğrusal ya da doğrusal olmayan olabilir [10].

### 2.3. YSA modeli

Bu çalışmada lojistik sigmoid (logsig) transfer fonksiyonuna dayalı bir formül geliştirmek için YSA kullanılmıştır. Çalışma süresince, AİBAAT'den elde edilen veriler YSA'nın eğitim ve test gereksinimlerini karşılamak için tasarlanmıştır. Düzenlenen giriş ve çıkış veri setleri eğitim ve test fazlarında kullanılmıştır. Tablo 1.'de, tesis giriş ve çıkış parametrelerinin maksimum ve minimum değerleri verilmiştir. Giriş katmanındaki altı giriş parametreleri;  $BOI_{giriş}$ ,  $KOI_{giriş}$ ,  $debi$ ,  $AKM_{giriş}$ ,  $TN_{giriş}$  ve  $TP_{giriş}$  dir (Şekil 2.). Çıkış parametresi ise  $KOI_{çıkış}$  dir.

**Tablo 1.** Parametrelerin maksimum ve minimum değerleri

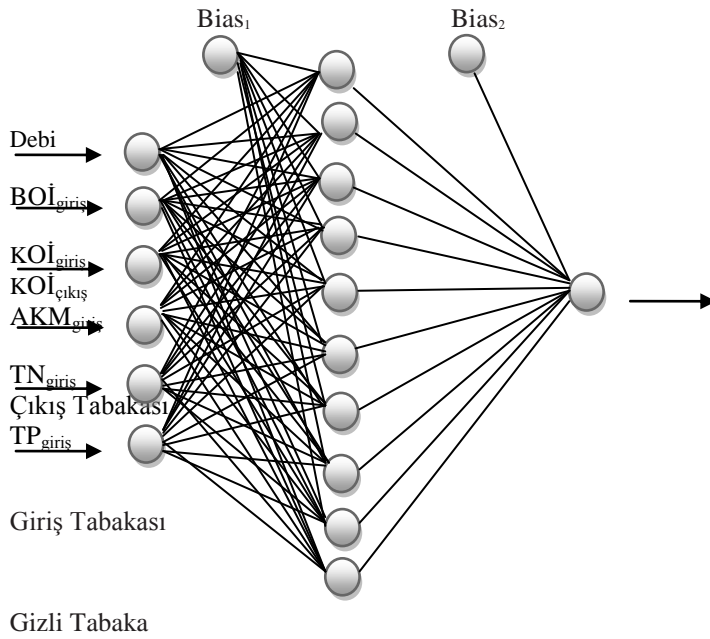
Parametreler	Maksimum ve minimum değerler
Debi ( $m^3/sn$ )	5.52-0.99
$BOI_{giriş}$ (mg/L)	560-120
$KOI_{giriş}$ (mg/L)	2352-325
$AKM_{giriş}$ (mg/L)	1744-148
Toplam- $N_{giriş}$ (mg/L)	132-26
Toplam- $P_{giriş}$ (mg/L)	25.50-4.20
$KOI_{çıkış}$ (mg/L)	115-30

Bir, ikili çift kıvrımlı transfer fonksiyonu ile seçilen ağ mimarisi 6-10-1 oldu (Şekil 2.); ölçekli bağıl gradyant [scaled conjugate gradient algorithm (SCGA)] kullanılan öğrenme algoritması oldu. Optimum sonucu bulmak için 12.000 iterasyon gerçekleştirildi.

Ağ, eğitim için varsayılan ölçekli bağıl gradyant algoritmasını kullanmaktadır. Uygulama şöyle; iki set halinde giriş vektörü ve hedef vektörleri olmak üzere rastgele böler: % 90'ı eğitim

için kullanılır; %10 u ağ genelleme olduğunu doğrulamak için ve aşırı olmadan önce eğitimi durdurmak için kullanılır.

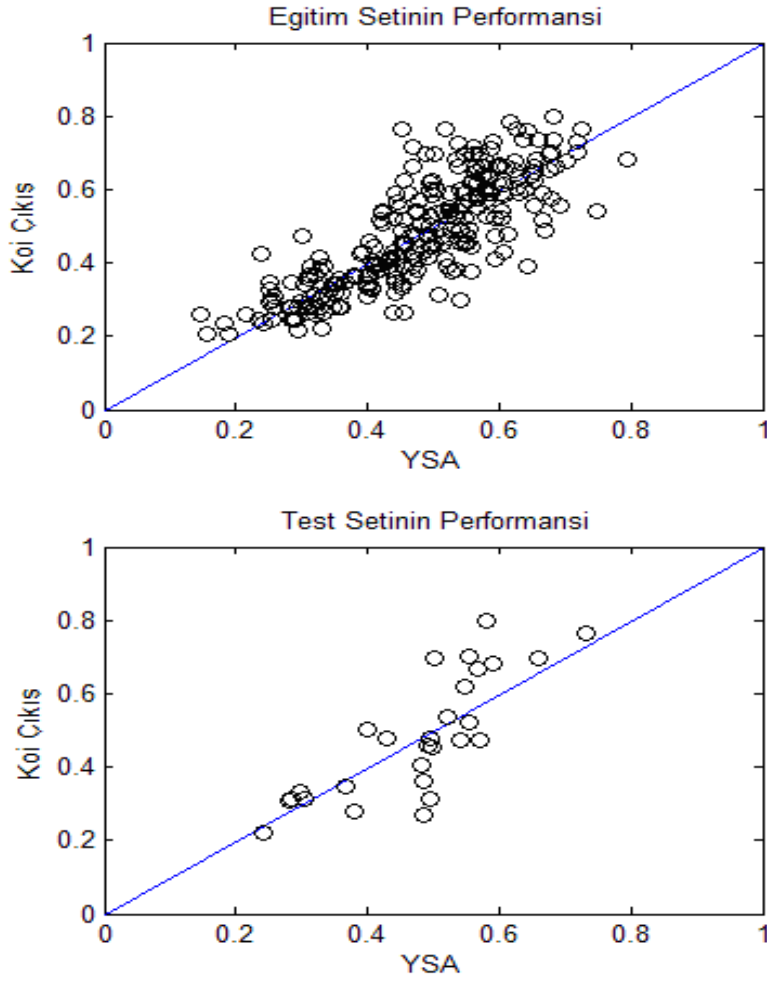
$KOI_{çıkış}$  için eğitim hataları aşağıda verilmiştir. Elde edilen bulgular, hatalar her bir durum için oldukça tatmin edici olduğu bulunmuştur. Böylece, eğitilmiş YSA'lar tatmin edici iyi sonuçlar vermiştir. Şekil 3. ve Tablo 2.'de, eğitim ve test setleri performansı ve eğitilmiş YSA istatistiksel parametreleri sırasıyla verilmiştir. Şekil 3. ve Tablo2.'de görülebileceği gibi her iki set için korelasyon faktörünün oldukça yüksek çıkması, eğitilmiş YSA modelinin yüksek doğruluğunu kanıtlamaktadır.



Şekil 2.Önerilen geri yayılma sinir ağının yapısı

Tablo 2.YSA formülasyonunun istatistiksel parametreleri

	Eğitim seti	Test seti
OMHY	15.1284	17.5874
KHT	2.0158	0.2783
KOH	0.0889	0.0997
$R^2$	0.9688	0.9615



Şekil 3.Eğitim ve test setlerinin performansı

OMHY, KHT,  $R^2$  ve KOH sırasıyla aşağıdaki gibidir:

$$OMHY = \left( \frac{0-t}{0} \right) * 100 \quad (1)$$

$$KHT = \sum_j (o_j - t_j)^2 \quad (2)$$

$$R^2 = 1 - \left( \frac{\sum_j (t_j - o_j)^2}{\sum_j (o_j)^2} \right) \quad (3)$$

$$KOH = \left( (1/p) \sum_j |t_j - o_j|^2 \right)^{1/2} \quad (4)$$

Burada;  $o$ , çıkış değeri,  $p$  numune ve  $t$  ise hedef değeridir.

KOI<sub>çıkış</sub> için, OMHY, KHT ve KOH değerleri eğitim seti için sırasıyla 15.1284, 2.0158 ve 0.0889; test seti için ise 17.5874, 0.2783 ve 0.0997 olarak elde edilmiştir. Varyans mutlak

fraksiyonu ( $R^2$ ) değerleri, arıtma tesisi prosesinin eğitim ve test setleri için sırasıyla %96,88 ve %96,15 olarak bulunmuştur. Bu durumda, ağınyanıttoldukça tatmin edicidir ve yeni girdiler girilmesi için de kullanılabilir.

YSA modelleri,  $KO\dot{I}_{\text{çıkış}}$  konsantrasyonlarının dinamik davranışını yüksek doğrulukta tahmin etti ve eğitim ve test verilerine çok iyi bir uyum sağladı (Şekil 3.). Önerilen sinir ağları prosesin davranış sürecini tatmin edici bir şekilde tanımlayabilir. Bunun bir sonucu olarak, modellerin iyi tahmin performansını öneren kısmen düşük bir KHT, OMHY ve çok yüksek  $R^2$  değerleri esas alınarak göre tahmin edilen  $KO\dot{I}_{\text{çıkış}}$  konsantrasyonları gözlemlenen konsantrasyonlarla eşleşti. Bu biyolojik proseslerin yüksek seviyede karmaşıklığı, veri aralığının genişliği ve hesaplanan hata değerleri düşünüldüğünde, bu yöntemin başarılı bir şekilde hedef çıkışını tahmin ettiği görülmektedir.

### 3. Sonuçlar

YSA, atıksu değişkenlerin tahmininde umut verici araçlardan biridir. YSA modeli, AİBAAT için  $KO\dot{I}_{\text{çıkış}}$  konsantrasyonunun tahmini için geliştirilmiştir. Bu çalışma, atıksu arıtma süreci için  $KO\dot{I}_{\text{çıkış}}$  tahmininde YSA kullanımının, geleneksel matematiksel modellemeden daha iyi bir teknik olduğunu kanıtlamıştır. İyi eğitilmiş YSA parametreleri sayesinde,  $KO\dot{I}_{\text{çıkış}}$ 'nin YSA modeli oluşturuldu. Eğitim ve test  $R^2$  değerleri, bu çalışmada kullanılan YSA'nın yüksek doğrulukta sonuçlar verdiğini gösterdi. Bu çalışmada geliştirilen model, kabul edilebilir bir genelleme yeteneğine sahiptir.  $KO\dot{I}_{\text{çıkış}}$  hesaplanması için mevcut prosedürler deneysel çalışmalara dayanmaktadır. Bu çalışma, AİBAAT performansını tahmin etmek için YSA modelinin yeteneğini doğrulamaktadır.

YSA'nın arıtma prosesinin doğrusal olmayan davranışını simüle ederek etkili bir analiz ve teşhis etme aracı olduğu ve tesis operatörleri ve karar vericiler için değerli bir performans değerlendirme aracı olarak kullanıldığı sonucuna varılmıştır.

### Teşekkür

Yazarlar, bu çalışmada kullanılan AİBAAT neait verileri tedarik etmede yardımcı olduğu için İstanbul-Türkiye'de bulunan İstanbul Su ve Kanalizasyon İdaresi'ne (İSKİ) teşekkürlerini sunarlar.

### Kaynaklar

- [1] Khataee A.R. Photocatalytic removal of C.I. Basic Red 46 on immobilized TiO<sub>2</sub> nanoparticles: Artificial neural network modeling. *Environ. Technol.* 2009;30:1155–1168.
- [2] Kardam A., Rohit Raj K, Kumar Arora J, Mohan Srivastava M, Srivastava S. Artificial neural network modeling for sorption of cadmium from aqueous system by shelled moringa oleifer seed powder as an agricultural waste. *Water Res. Pr.* 2010;2:339–344.
- [3] Hamoda M.F., Al-Gusain I.A., Hassan A.H. Integrated wastewater treatment plant performance evaluation using artificial neural network. *Water Science and Technology* 1999;40:55–69.
- [4] Harremoës P., Capodaglio A.G., Hellstrom B.G., Henze M., Jensen K.N., Lynggaard-Jensen A., Otterpohl R., Soeborg H. Wastewater treatment plants under transient loading performance, modeling and control. *Water Science and Technology* 1993;12:71–115.

- [5] Hamed M.,Khalafallah M.G., Hassanein E.A. Prediction of wastewater treatment plant performance using artificial neural network. *Environmental Modeling and Software* 2004;19;919–928.
- [6] Yurtođlu, H. (2005). Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Deđişkenler İçin Türkiye Örneđi. *Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, Uzmanlık Tezi*, 104 s., Ankara.
- [7] Öztopal, A. ve Şen, Z. (2009). Kısa Vadeli Yađış Modellemesi İçin Yapay Sinir Ağları Yaklaşımı. *İTÜ Dergisi/d Mühendislik*, 8(1), 83-94.
- [8] Demuth H., Beale M., Hagan M. *Neural Network Toolbox 5: Users Guide*. Natick. MA The MathWorks Inc. 2007.
- [9] Lu W. Neural network model for distortional buckling behaviour of coldformed steel compression members. Ph.D. thesis. Helsinki University of Technology 2000.
- [10] Berke L, Patnaik SN, Murthy PLN. Optimum design of aerospace structural components using neural networks. *Computers & Structures* 1993;48(6);1001–1010.