

BİYOLOJİK ATIKSU ARITMA TESİSLERİNDE KARBON VE AZOT GİDERİM VERİMLERİNİN TAHMİNİ AMACIYLA YAPAY SİNİR AĞLARININ KULLANIMI

Neslihan MANAV DEMİR (ORCID: 0000-0002-6050-6308)*

Çevre Mühendisliği Bölümü, İnşaat Fakültesi, Yıldız Teknik, İstanbul, Türkiye

Geliş / Received: 16.12.2016

Düzeltilmelerin gelişi / Received in revised form: 18.05.2017

Kabul / Accepted: 23.05.2017

ÖZ

Biyolojik azot giderimi gerçekleştirilen atıksu arıtma proseslerinin (AO prosesi) modellenmesi amacıyla Aktif Çamur Modeli No. 1 (ASM1) kullanılmıştır. Bu modelde ihtiyaç duyulan girdi parametrelerinin tahmin edilmesi çok zaman almaktadır. Bu çalışma kapsamında, ASM1 kadar detaylı girdi verisi gerektirmeyen geri beslemeli yapay sinir ağlarının (BPANN) AO proseslerindeki kimyasal oksijen ihtiyacı (KOİ), toplam Kjeldahl azotu (TKN) ve toplam azot (TN) giderim verimlerinin tahminindeki performansı test edilmiştir. Bu amaçla BPANN'de dört farklı aktivasyon fonksiyonu kullanılmıştır. Elde edilen sonuçlar, AO proseslerindeki KOİ, TKN ve TN giderim verimlerinin BPANN ile yüksek doğrulukta tahmin edilebildiğini göstermiş; en iyi öğrenme ve tahmin yeteneği ise Sinc fonksiyonu ile elde edilmiştir. Sinc-BPANN ile elde edilen ortalama kare hatalar KOİ giderim verimi için $2,50 \cdot 10^{-4}$, TKN giderim verimi için $4,15 \cdot 10^{-4}$, TN giderim verimi için ise $2,65 \cdot 10^{-4}$ olarak hesaplanmıştır. Buna göre Sinc-BPANN AO proseslerindeki KOİ, TKN ve TN giderim verimlerinin doğrusal olmayan doğasını ASM1'e nazaran çok daha az girdi parametresiyle açıklayabilmektedir.

Anahtar Kelimeler: ASM1, yapay sinir ağları, karbon giderimi, azot giderimi, aktivasyon fonksiyonu

USE OF ARTIFICIAL NEURAL NETWORKS AS A TOOL TO PREDICT CARBON AND NITROGEN REMOVAL EFFICIENCIES IN BIOLOGICAL WASTEWATER TREATMENT PLANTS

ABSTRACT

Although Activated Sludge Model No. 1 (ASM1) was used for modelling biological nitrogen removal processes, estimation of input parameters required to run this model necessitates complicated laboratory analyses. In this study, the performance of Backpropagation Artificial Neural Networks (BPANN), which requires considerably less numbers of input parameters, in predicting chemical oxygen demand (COD), total Kjeldahl nitrogen (TKN), and total nitrogen (TN) removal efficiencies was tested. For this purpose, four activation functions were employed in BPANN. Results suggested that COD, TKN, and TN removal efficiencies in AO processes can be accurately estimated using BPANN, with the highest learning and prediction capacity when Sinc function is employed. The mean square errors (MSEs) with Sinc-BPANN were calculated as $2.50 \cdot 10^{-4}$ for COD removal efficiency, $4.15 \cdot 10^{-4}$ for TKN removal efficiency, and $2.65 \cdot 10^{-4}$ for TN removal efficiency. Therefore, the Sinc-BPANN is concluded to be an efficient tool for estimating nonlinear nature of COD, TKN, and TN removal efficiencies in AO processes using considerably less numbers of input parameters.

Keywords: ASM1, Artificial Neural Networks, Carbon Removal, Nitrogen Removal, activation function

*Corresponding author / Sorumlu yazar. Tel.: +90 212 383 5397; e-mail / e-posta: nmanav@yildiz.edu.tr

1. GİRİŞ

Birleşmiş Milletler tarafından 2015 yılında yayınlanan rapora göre, 2010-2015 yılları arasında dünyadaki nüfus artış oranı ortalama olarak %1,18 seviyesinde gerçekleşmiştir [1]. Aynı rapora göre Umman %8,45'lik artış oranıyla nüfusun en hızlı arttığı ülke olurken, Türkiye'de 2010-2015 yılları arasında ortalama nüfus artış oranı %1,69 olarak rapor edilmiş olup Türkiye'deki nüfus artış hızı dünya ortalamasıyla kıyaslanabilir seviyededir. Dünya nüfusunun sürekli olarak artmasıyla birlikte atıksuların artırılması da özellikle çevre mühendisleri açısından önemli bir sorun olarak ortaya çıkmaktadır.

Atıksuların artırılmasıyla ilgili olarak 20. yüzyılın başlarından itibaren çok sayıda proje yürütülmüş ve bu amaçla birçok farklı arıtma sistemi geliştirilmiştir [2]. Bunların en iyi bilinen bazıları AO (Anoksik/Oksik) prosesi, A²O (Anaerobik/Anoksik/Oksik) prosesi, UCT (University of Cape Town) prosesi ve Bardenpho prosesi olarak sayılabilir. Bugün bu atıksu arıtma proseslerinin tasarımı ve işletilmesine dair detaylı bilgi birikimi mevcuttur. Ne var ki, nüfus artışının sürekli olması ve atıksu miktar ve karakterizasyonunun da buna bağlı olarak gündün güne değişmesi sebebiyle, halihazırda kurulu bulunan tesislerin sürekli olarak izlenmesi ve atıksu özelliklerindeki değişime cevap verebilecek şekilde prosesin veya işletme parametrelerinin güncellenmesi bir gereklilik haline almıştır. Günümüzde atıksu arıtma tesislerinde tecrübeye dayalı varsayımlar veya matematiksel modellere dayalı yaklaşımlar kullanılarak atıksu özellikleri ve çevre şartlarının günlük veya mevsimlik değişimlerine karşı bazı işletme tedbirleri alınabilmekte olsa da bu yaklaşımlar atıksu arıtma tesislerinde eşzamanlı olarak gerçekleşen karmaşık biyokimyasal prosesleri açıklayamamaktadır. Bu sebeple atıksu arıtma tesisinin performansını etkileyen girdiler ve işletme parametrelerine bağlı olarak gerçekleşen karmaşık prosesleri açıklayabilen modellere ihtiyaç duyulmaktadır.

Atıksu arıtma sistemlerindeki karmaşık biyokimyasal prosesleri tarif etmeyi amaçlayan bir model Henze ve ark. [3] tarafından geliştirilmiş olup, Aktif Çamur Modeli No. 1 (ASM1) olarak yayınlanmıştır. Geliştirilen model, atıksulardan karbon ve azot giderimi yapılan biyolojik atıksu arıtma tesislerinde (AO prosesi) gerçekleşen aerobik oksidasyon, nitrifikasyon ve denitrifikasyon proseslerini muhtelif hız denklemleriyle açıklayabilmekte ve bu hız denklemlerini genelleştirici kütle bilançosu denklemleriyle birleştirilerek AO proseslerinde atıksudaki kirletici parametrelerin konsantrasyonlarını tahmin etmek üzere kullanılabilmektedir. İlk modelden sonra biyolojik fosfor giderimi ve eşzamanlı nitrifikasyon-denitrifikasyon prosesleri ile ilgili hız denklemlerini de içeren ASM2, ASM2d ve ASM3 modelleri de [4-6] yayınlanmış olmakla birlikte bu çalışma ASM1 modeli üzerine yoğunlaşmaktadır.

Aktif Çamur Modeli No. 1 (ASM1), AO proseslerinde kimyasal oksijen ihtiyacı (KOİ), toplam azot (TN) ve toplam Kjeldahl azotu (TKN) konsantrasyonlarını çözülmüş ve partiküler formda bulunan toplam 12 kirlilik parametresi ile tanımlanmaktadır. Bunlara ek olarak, gerçekleşen prosesler üzerindeki etkileri ihmal edilmeyecek şekilde, sadece proses içindeki değişimlerini gözlemleyebilmek amacıyla alkalinite de bir değişken olarak modele eklenmiştir. Bu kirletici parametrelerin proses içindeki değişimlerini açıklamak üzere aerobik heterotrofik büyüme, anoksik heterotrofik büyüme, aerobik ototrofik büyüme, heterotrofik hücre ölümü, ototrofik hücre ölümü, çözülmüş organik azotun amonyağa dönüşmesi, partiküler formdaki organiklerin hidrolizi ve partiküler formdaki azotun hidrolizi olmak üzere 8 adet proses ve bunlara ait hız denklemleri tanımlanmıştır.

Aktif çamur proseslerine ilişkin modeller Hug ve ark. [7] tarafından prognostik, diagnostik ve eğitim amaçlı modeller olarak sınıflandırılmaktadır. Bugüne kadar aktif çamur modelleri ile ilgili birçok çalışma yapılmış olmakla birlikte bunların büyük bir bölümü aktif çamur modellerinin biyolojik arıtma sistemlerine entegrasyonu ve bu sistemlerin geliştirilmesi/optimizasyonu ile ilgilidir [8-13]. Atıksulardan biyolojik karbon ve azot giderimini amaçlayan tesislerin tasarımı, işletilmesi ve optimizasyonu hususunda geçerliliğini kanıtlamış olmakla birlikte, ASM1 modelinin kullanımına dair muhtelif zorluklar da bulunmaktadır. Bunlardan en önemlisi atıksu karakterizasyonu olarak göze çarpmaktadır. ASM1'de, atıksudaki özellikle KOİ ve TN konsantrasyonlarının belirli fraksiyonlarını içeren, inert veya biyoparçalanmayan ve partiküler veya çözülmüş formda kirletici parametreler kullanılmakta; bu kirletici parametrelerin belirlenmesi amacıyla yapılan laboratuvar çalışmaları ise zaman kaybına yol açmakta ve çalışmanın maliyetini artırmaktadır. ASM1 modelinin uygulanmasıyla ilgili diğer bir husus da model denklemlerinin karmaşık olmasıdır. ASM1 modelinde her bir kirletici parametrenin her bir reaktördeki konsantrasyonlarını tahmin etmek amacıyla kütle dengesi denklemlerine dayanan ve karmaşık reaksiyon hız denklemlerini de içeren çok sayıda diferansiyel denklemin eşzamanlı çözümü için uygun bir araç gerekmektedir. Bu noktada, aktif çamur sistemlerinin modellenmesi amacıyla kullanılacak daha basit, daha hızlı ve daha ucuz araçlara da ihtiyaç duyulmaktadır. Yapay sinir ağları (ANN) bu ihtiyaca cevap verebilecek niteliktedir.

Yapay sinir ağı, nöron adı verilen bir dizi işlem elemanını içeren ve toplu olarak karmaşık ve doğrusal olmayan ilişkileri, insanlara ait öğrenme yeteneğini taklit ederek öğrenip tekrarlayabilen bir model yaklaşımıdır. Yapay sinir ağlarındaki nöronlar sıralı bir şekilde düzenlenerek her bir nöronun ürettiği sinyalin bir sonraki kademede

BİYOLOJİK ATIKSU ARITMA TESİSLERİNDE KARBON VE AZOT GİDERİM VERİMLERİNİN TAHMİNİ AMACIYLA YAPAY SİNİR AĞLARININ KULLANIMI

bulunan nöron için girdi değeri teşkil etmesi sağlanır. Nöronlar arasındaki bağlantı, ağırlık olarak anılan katsayılarla gerçekleştirilir. Bu sayede, sıralı kademelerde üretilen sinyal çıktı katmanına aktarılarak bağımlı değişken değerinin tahmin edilmesi için kullanılır. Nöronlar arasındaki bağlantılara (ağırlıklar) ek olarak, yapay sinir ağlarının belkemiğini oluşturan bir diğer parametre de aktivasyon fonksiyonudur. Aktivasyon fonksiyonu, bir nörona gelen girdi sinyalini, çıktı sinyaline dönüştüren matematiksel bir fonksiyondur ve yapay sinir ağının tahmin yeteneğini iyileştirmek için farklı aktivasyon fonksiyonları arasında en uygun olanının seçilmesi gerekir.

Hava kirliliğinden su ve toprak kirliliğine kadar birçok alanda muhtelif prosesleri öğrenip modellemek için kullanılan yapay sinir ağları [14-20], biyolojik atıksu arıtma proseslerinin modellenmesi amacıyla da uygulanmıştır [21-23]. Ne var ki biyolojik atıksu arıtma proseslerinin yapay sinir ağları ile modellenmesi amacıyla gerçekleştirilen çalışmaların çoğu ağ topolojisinin kurulması üzerine odaklanmış; ağda kullanılan aktivasyon fonksiyonları geri planda kalmıştır. Örneğin, Moral ve ark. [23], yaptıkları çalışmada toplam 9 adet giriş ve çıkış suyu parametresinin farklı kombinasyonlarını kullanarak çıkış suyunda çözünmüş formdaki substrat konsantrasyonunu tahmin etmişler ve 0,8'lere varan korelasyon katsayıları (determinasyon katsayısı yaklaşık 0,64 olacaktır) elde etmişlerdir. Çalışmanın önemli bir ayağı optimum nöron sayısının belirlenmesini içermekte olup, aktivasyon fonksiyonu olarak sadece lojistik ve hiperbolik tanjant fonksiyonları kullanılmıştır. Bir başka çalışmada Hamed ve ark. [21] çıkış suyunda biyokimyasal oksijen ihtiyacını (BOİ) tahmin etmek için giriş suyundaki BOİ ve askıda katı madde (AKM) konsantrasyonlarını hiperbolik tanjant fonksiyonu ile kullanmışlar ve determinasyon katsayıları 0,665 değerlerine kadar yükselmiştir. Bu çalışmada da ilk adım optimum ağ topolojisinin belirlenmesi olup, en iyi aktivasyon fonksiyonunun seçimi ele alınmamıştır. Biyolojik atıksu arıtma proseslerinin yapay sinir ağı ile modellenmesi çalışmalarına ilişkin bir diğer husus da bu çalışmaların özellikle KOİ veya BOİ bazlı karbon giderim verimlerinin tahmin edilmesiyle sınırlı kalmış olmalarıdır ki azot gideriminin yapay sinir ağları ile tahmin edilmesine ilişkin bilgi birikimi zenginleşmemiştir. Ayrıca yapılan çalışmalarda determinasyon katsayıları kabul edilebilir olsa da nispeten düşük kalmıştır. Bunun en temel nedenlerinden biri de kullanılan aktivasyon fonksiyonlarının, atıksu arıtma proseslerinin doğrusal olmayan doğasını açıklayamıyor olmasıyla özetlenebilir.

Biyolojik atıksu arıtma proseslerinin performansını tahmin etmek amacıyla yapay sinir ağlarının güvenli bir yaklaşım olarak kullanılabilmesi için öncelikle, bu prosesler için en uygun aktivasyon fonksiyonlarının belirlenmesi bir gerekliliktir. Bu çalışmanın temel amacı, BPANN'de farklı aktivasyon fonksiyonları kullanılarak biyolojik karbon ve azot giderme proseslerini en iyi temsil eden aktivasyon fonksiyonunun belirlenmesidir ki bu çalışmayı diğerlerinden ayıran en önemli özelliğidir. Bu kapsamda, bir AO prosesi için çamur yaşı (θ_s), aerobik tankta hidrolik bekletme süresi (θ_h), geri devir oranı (R_s), iç geri devir oranı (R_n), aerobik tanktaki çözünmüş oksijen konsantrasyonu (C) ve giriş suyunda KOİ-TN konsantrasyonlarının farklı değerlerinden oluşan 972 farklı senaryo için Aktif Çamur Modeli No.1 (ASM1) kullanılarak KOİ, TKN ve TN giderim verimleri hesaplanmış; daha sonra bu değerler BPANN'de girdi olarak kullanılarak ve BPANN'nin, verilen aktivasyon fonksiyonlarıyla KOİ, TKN ve TN giderim verimlerinin tahmin edilmesindeki performansı değerlendirilmiştir.

2. MATERYAL VE METOT

2.1. Proses Konfigürasyonu

Çalışma kapsamında bir adet anoksik tank, bir adet aerobik tank ve bir çöktürücüden oluşan AO prosesi kullanılmıştır. Prosese ait akım şeması Şekil 1'de verilmiştir. Sistemde giriş suyunun tamamı (Q_0) ve geri devir çamuru (Q_5) anoksik tanka beslenmektedir. Ayrıca, aerobik tank çıkışından alınan iç geri devir hattı (Q_3) anoksik tank girişine verilmektedir. Aerobik tankın çıkış suyu (Q_2) çöktürücüye beslenmekte ve fazla çamur (Q_6) çöktürücü tabanından çekilmektedir.

Aerobik tankta hidrolik bekletme süresinin (θ_h) arıtma performansı üzerindeki etkilerini modellemek amacıyla, giriş suyu debisi sabit tutularak aerobik tankın hacmi değiştirilmek suretiyle farklı θ_h değerleri kullanılmıştır. Verilen bir θ_h değeri için çamur yaşı (θ_s), fazla çamur debisi (Q_6) değiştirilerek ayarlanmıştır. Çalışma kapsamında kullanılan parametre değerleri Tablo 1'de özetlenmiştir.


2.2. Aktif Çamur Modeli

Daha önceki bir çalışmada MS Excel Visual Basic for Applications (VBA)'da yazılmış olan Aktif Çamur Modeli No. 1 (ASM1), bu çalışmada da kullanılmıştır. Kullanılan MS Excel aracı, sistem konfigürasyonu, giriş suyu özellikleri ve sisteme ait tasarım parametrelerini kullanıcıdan alıp ASM1 model denklemlerini kurarak

N. MANAV DEMİR

çözen bir algoritmaya sahiptir. MS Excel aracı çöktürme tankı için Takacs modelini kullanmakta olup bu modelin detayları önceki çalışmalarda [24, 25], modelin farklı yaklaşımlarla kıyaslanması ve performans değerlendirmesi ise Holenda ve ark. [26] tarafından verilmiştir.

ASM1 model denklemlerinin çözümü için adım boyu 30 sn olarak alınmış; 7 adet değişkenin (Tablo 1) farklı değerlerinden oluşan toplam 972 senaryo için çalıştırılarak kararlı durumdaki KOİ, TKN ve TN giderim verimleri hesaplanmıştır. Program, Intel Core i5 3,3 GHz işlemci ve 2133 MHz 16 GB DDR3 RAM belleğe sahip bir bilgisayarda her bir veri seti için ortalama 10 dakikada hesaplamaları tamamlamıştır. Elde edilen sonuçlar, yapay sinir ağının karbon ve azot giderimi yapılan biyolojik atıksu arıtma tesislerindeki KOİ, TKN ve TN giderim verimlerinin tahmin edilmesi hususundaki performansını test etmek amacıyla kullanılmıştır.



Q_0 = Giriş suyu debisi; Q_1 = Anoksik tank çıkış debisi ($Q_0 + Q_3 + Q_5$); Q_2 = Aerobik tank çıkış debisi ($Q_1 - Q_3$);
 Q_3 = İç geri devir debisi ($Q_1 - Q_2$); Q_4 = Çıkış suyu debisi ($Q_0 - Q_6$); Q_5 = Geri devir debisi;
 Q_6 = Fazla çamur debisi

Şekil 1. Arıtma prosesine ait akım şeması


Tablo 1. İşletme senaryolarında kullanılan değer aralıkları

Bağımsız Değişken	Değer Aralığı	Notlar
Çamur yaşı (θ_s)	5 – 15 gün	3 farklı değer (5, 10, 15 gün) Atık çamur debisi (Q_6) değiştirilerek istenen değere ayarlanmıştır.
Hidrolik bekleme süresi (θ_h)	4 – 8 sa	3 farklı değer (4, 6, 8 sa) Aerobik tank hacmi değiştirilerek istenen değere ayarlanmıştır.
Geri devir oranı (R_s)	0.75 – 1.00	2 farklı değer (0.75, 1.00) Geri devir debisi (Q_5) değiştirilerek istenen değere ayarlanmıştır.
İç geri devir oranı (R_n)	2 – 4	3 farklı değer (2, 3, 4) İç geri devir debisi (Q_3) değiştirilerek istenen değere ayarlanmıştır.
Aerobik tankta çözülmüş oksijen konsantrasyonu (C)	2 – 3 mg/L	2 farklı değer (2, 3 mg/L)
Giriş suyu kimyasal oksijen ihtiyacı (KOİ)	400 – 600 mg/L	3 farklı değer (400, 500, 600 mg/L)
Giriş suyu toplam azot (TN) konsantrasyonu	60 – 90 mg/L	3 farklı değer (60, 75, 90 mg/L)

2.3. Yapay Sinir Ağı

Geri beslemeli yapay sinir ağı (BPANN) için bir Excel Visual Basic for Applications (Excel VBA) programı kullanılmıştır [19, 20]. BPANN’de girdi katmanı olarak çamur yaşı (θ_s), aerobik tankta hidrolik bekleme süresi (θ_h), geri devir oranı (R_s), iç geri devir oranı (R_n), aerobik tanktaki çözülmüş oksijen konsantrasyonu (C) ve giriş suyunda KOİ konsantrasyonu ve giriş suyunda TN konsantrasyonu olmak üzere 7 adet nöron kullanılmıştır. BPANN’de 10 nöron içeren bir adet gizli katman ve 1 adet nöron içeren bir çıktı katmanı kullanılmıştır. Öğrenme hızı 0,75, epoch sayısı 2000 alınmıştır. Kullanılan yapay sinir ağının topolojisi Şekil 2’de verilmiştir.

BİYOLOJİK ATIKSU ARITMA TESİSLERİNDE KARBON VE AZOT GİDERİM VERİMLERİNİN TAHMİNİ AMACIYLA YAPAY SİNİR AĞLARININ KULLANIMI



Şekil 2. Kullanılan geri beslemeli yapay sinir ağının yapısı

Toplam 972 adet veri setinin her bir denemede rastgele seçilen %70’i eğitim amacıyla, kalan %30’u ise validasyon amacıyla kullanılmıştır. Maliyet fonksiyonu olarak ortalama kare hata (MSE) kullanılmıştır. Her bir denemede ağırlıklar için rastgele başlangıç noktaları seçilmiş; bu sebeple denemelerde küresel minimuma yaklaşıldığından emin olmak amacıyla 25 farklı deneme yapılmış ve bu denemelerde elde edilen MSE değerlerinin ortalamaları rapor edilmiştir.

En iyi aktivasyon fonksiyonunun tespit edilmesi amacıyla BPANN’de 4 farklı aktivasyon fonksiyonu kullanılmıştır. Kullanılan aktivasyon fonksiyonlarına ait bilgiler Tablo 2’de verilmiştir. Tüm denemeler için girdi parametreleri 0–1 aralığında normalize edilmiştir. KOİ, TKN ve TN giderim verimleri ise tüm denemelerde, kullanılan fonksiyonun tarama aralığına göre normalize edilmiştir. BPANN uygulamasından sonra sonuçlar denormalizasyon yapılarak rapor edilmiştir.

Tablo 2. Yapay sinir ağında kullanılan aktivasyon fonksiyonları

Fonksiyon Adı	Matematiksel İfade	Türev İfadesi	Tarama Aralığı
Lojistik	$y = \frac{1}{1 + e^{-x}}$	$\frac{dy}{dx} = y(1 - y)$	$0 < y < 1$
Hiperbolik tanjant	$y = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$\frac{dy}{dx} = 1 - y^2$	$-1 < y < 1$
Elliot	$y = \frac{0.5x}{1 + x } + 0.5$	$\frac{dy}{dx} = \frac{1}{2(1 + x)^2}$	$0 < y < 1$
Sinc	$y = \begin{cases} 1 & \Leftrightarrow x = 0 \\ \frac{\sin x}{x} & \Leftrightarrow x \neq 0 \end{cases}$	$y = \begin{cases} 0 & \Leftrightarrow x = 0 \\ \frac{\cos x}{x} - \frac{\sin x}{x^2} & \Leftrightarrow x \neq 0 \end{cases}$	$-0.2172 \leq y \leq 1$

3. BULGULAR VE TARTIŞMA

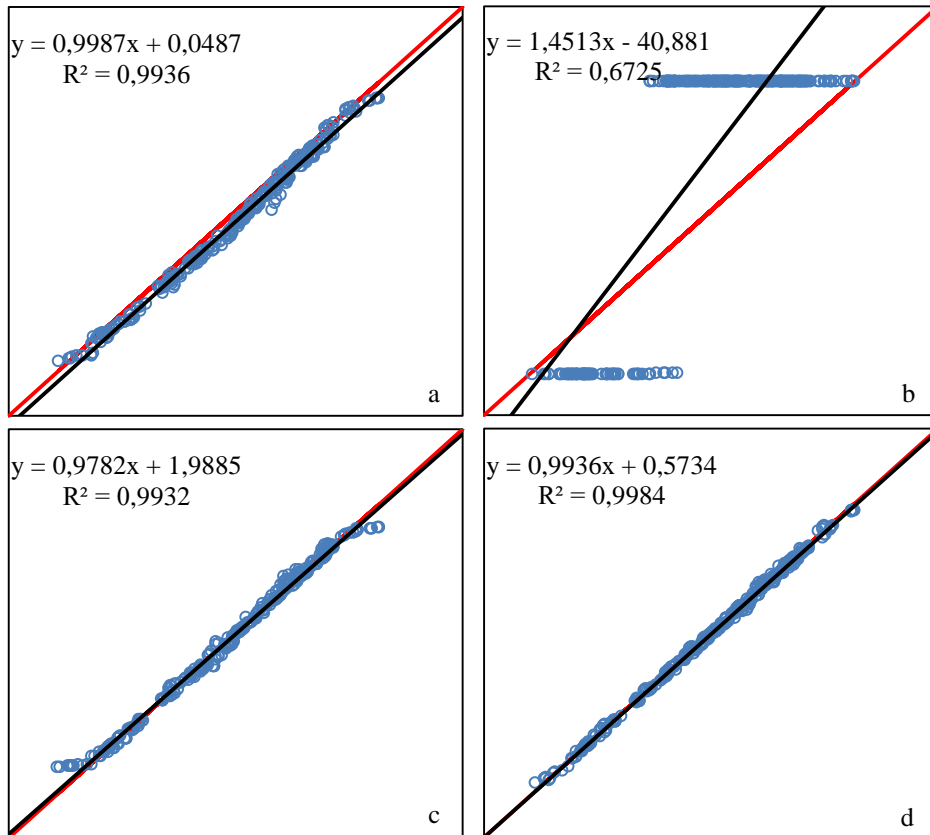
Yapılan çalışma iki adımdan oluşmaktadır. İlk adımda, karbon ve azot giderimi yapılan bir AO prosesinde (Şekil 1) ASM1 model denklemleri, 7 farklı tasarım ve işletme parametresine (Tablo 1) bağlı olarak oluşturulan, toplamda 972 adet veri seti için eşzamanlı olarak çözülmüştür. Çalışma sonucunda elde edilen KOİ giderim verimleri %90,3-92,4 arasında değişirken ortalama KOİ giderim verimi %91,5±0,5 olarak hesaplanmıştır. Ortalama TKN giderim verimi %95,9±1,7 olup, TKN giderim verimleri %89,2 ile %98,1 arasında değişmiştir. Hesaplanan en düşük ve en yüksek TN giderim verimleri sırasıyla %46,1 ile %85,2 olurken ortalama TN giderim verimi %69,9±10,0 olarak bulunmuştur.

Çalışmanın ikinci adımında ise ASM1 ile elde edilen veriler farklı aktivasyon fonksiyonları ile BPANN’de kullanılarak BPANN’nin AO prosesindeki KOİ, TKN ve TN giderim verimlerini tahmin yeteneği değerlendirilmiştir.

3.1. KOİ Giderim Verimi

Kullanılan her bir aktivasyon fonksiyonu için hesaplanan MSE değerinin küresel minimum olduğundan emin olmak amacıyla BPANN rastgele başlangıç noktasından başlayarak rastgele seçilen eğitim verileriyle 25 defa çalıştırılmıştır. Her bir aktivasyon fonksiyonu için elde edilen MSE değerlerinin aritmetik ortalamaları hesaplanmış olup, ortalama MSE değerleri lojistik fonksiyonu için $7,18 \cdot 10^{-4}$, hiperbolik tanjant fonksiyonu için $5,45 \cdot 10^{-1}$, Elliot fonksiyonu için $6,08 \cdot 10^{-4}$, Sinc fonksiyonu için ise $2,50 \cdot 10^{-4}$ 'tür. Hesaplanan ortalama MSE değerlerine bakılarak Sinc fonksiyonunun AO prosesinde KOİ giderim verimini en küçük hatayla temsil eden fonksiyon olduğu görülmektedir. BPANN'nin ASM1 sonuçlarını temsil yeteneğini daha iyi görebilmek için ASM1'de elde edilen KOİ giderim verimlerine karşı her bir aktivasyon fonksiyonu için BPANN ile elde edilen KOİ giderim verimleri arasında korelasyon grafikleri çizilmiş olup Şekil 3'te verilmiştir. Şekilde mavi noktalar ASM1 ve ANN ile elde edilen KOİ giderim verimlerini, siyah çizgi bu değerlerle elde edilen regresyon denklemini, kırmızı çizgi ise ASM1-ANN birebir değerlerini temsil etmektedir.


Şekil 3'te verilen korelasyon grafikleri, 25 denemede elde edilen en iyi sonuçları göstermektedir. Buna göre, hiperbolik tanjant fonksiyonu (Şekil 3b) haricindeki aktivasyon fonksiyonları için BPANN'nın biyolojik atıksu arıtma sistemlerinde KOİ giderimini etkileyen mekanizmaların doğrusal olmayan karakterini kabul edilebilir seviyede temsil edebileceği görülmektedir. Lojistik fonksiyonu kullanıldığında (Şekil 3a) ASM1 ve BPANN sonuçları arasında 0,9968'e varan ($R^2 = 0,9936$) korelasyon katsayıları görülmektedir. Bununla birlikte, Elliot fonksiyonu (Şekil 3c) için korelasyon katsayıları 0,9966'ya kadar ($R^2 = 0,9932$) çıkmaktadır. Sinc fonksiyonuna (Şekil 3d) bakıldığında ise en yüksek korelasyon katsayısının 0,9992 ($R^2 = 0,9984$) olduğu görülmektedir. Şekil 3'e bakarak da Sinc fonksiyonun AO prosesindeki KOİ giderim verimini en iyi temsil yeteneğine sahip olan aktivasyon fonksiyonu olduğu görülmektedir. Hiperbolik tanjant fonksiyonunun, Tablo 1'de verilen tasarım ve işletme parametreleri ile KOİ giderim verimi arasındaki bu doğrusal olmayan ilişkiyi öğrenmedeki yetersizliğinin muhtemel sebebi BPANN'de diklik katsayısına yer verilmemesi olarak açıklanabilir. Bu hususta ek bir çalışma yapılmamış olup, diklik katsayısının kullanımı ve optimum değerinin belirlenmesi ile ilgili reçete Demir ve ark. [19]'da açıklanmıştır.



Şekil 3. ASM1 ve BPANN kullanılarak elde edilen KOİ giderim verimleri arasındaki korelasyon grafikleri. **a.** Lojistik fonksiyonu, **b.** Hiperbolik tanjant fonksiyonu, **c.** Elliot fonksiyonu, **d.** Sinc fonksiyonu

BİYOLOJİK ATIKSU ARITMA TESİSLERİNDE KARBON VE AZOT GİDERİM VERİMLERİNİN TAHMİNİ AMACIYLA YAPAY SİNİR AĞLARININ KULLANIMI

BPANN ile KOİ değerlerinin tahmininde performans açısından dikkat edilmesi gereken bir diğer husus ise öğrenme yeteneğinin ne kadar istikrarlı olduğudur. Daha önce de bahsedildiği gibi BPANN ağırlıklarının her biri için rastgele başlangıç değerleri seçilmiş olup, BPANN her zaman küresel minimuma ulaşmamaktadır. Çoğu durumda, seçilen başlangıç değerleri maliyet fonksiyonunun bir yerel minimum değerine yaklaşmakta ve bu hallerde BPANN'nin öğrenme ve tahmin yeteneği kısıtlı kalmış olmaktadır. BPANN'deki her bir fonksiyonun ne kadar istikrarlı olduğunu görmek için her bir fonksiyonla elde edilen MSE değerlerinin dağılımı grafiklendirilmiştir (Şekil 4). Şekilde kutuların orta noktası medyan değeri, alt ve üst sınırları ise sırasıyla birinci ve üçüncü çeyrek değerleri temsil etmektedir. Kutu-bıyık grafiğinde bıyıklar ise sırasıyla hesaplanan MSE'lerin en küçük ve en büyük değerlerine karşılık gelmektedir. Açıkça görüldüğü gibi hiperbolik tanjant fonksiyonu kullanıldığında MSE değerleri daima yüksek olmaktadır. Lojistik ve Elliot fonksiyonları ile elde edilen MSE değerlerinin ortalaması küçük olsa da, maksimum MSE değerleri oldukça yüksek görünmekte; yani bu fonksiyonlar her zaman çok iyi temsil yeteneğine sahip olamamaktadır. Buna karşın Sinc fonksiyonu ile elde edilen MSE değerleri çok küçük olmakta ve ortalama MSE değerleri etrafında küçük salınımlar göstermektedir. Bu sonuçlar, Sinc fonksiyonunun öğrenme ve tahmin yeteneğinin oldukça yüksek olduğunu göstermektedir.



Şekil 4. BPANN ile KOİ tahmininde elde edilen MSE değerlerinin dağılımı

3.2. TKN Giderim Verimi

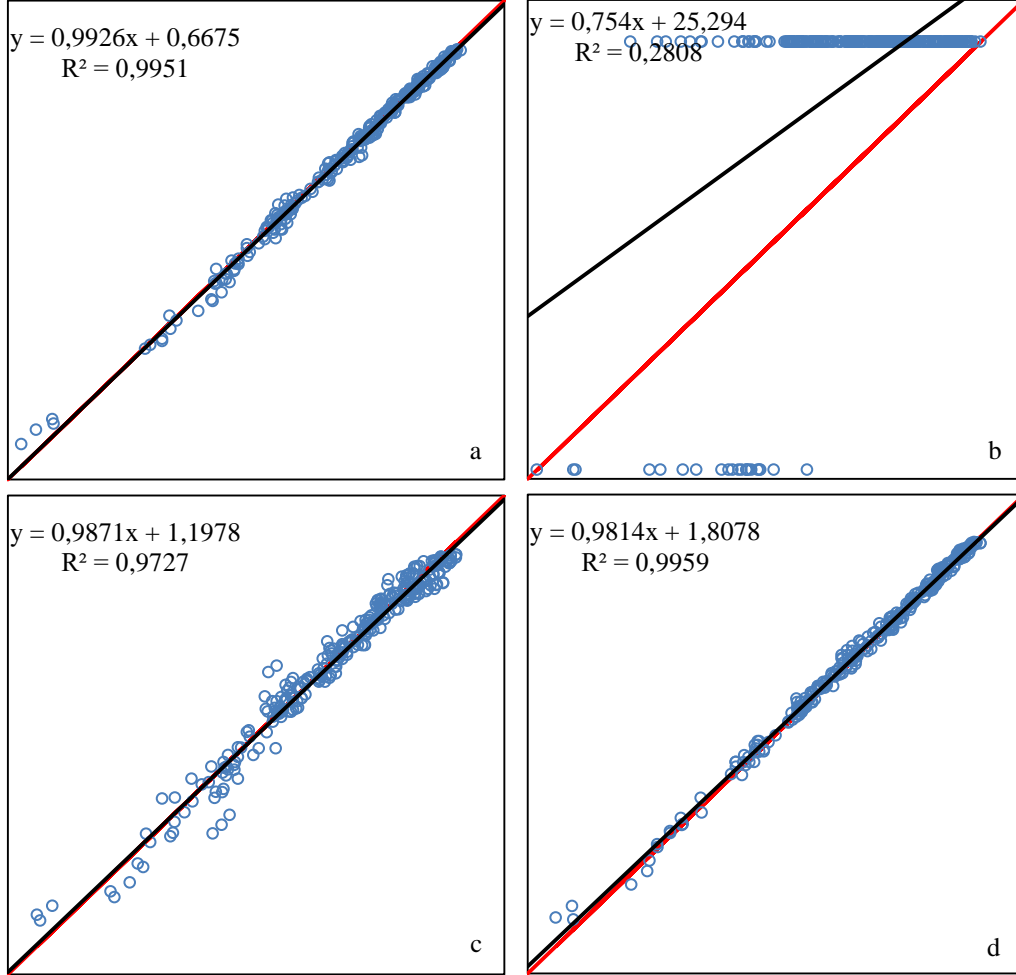
TKN giderim verimini tahmin etmek için farklı aktivasyon fonksiyonlarının her biri ile yapılan 25 denemenin sonunda elde edilen MSE değerlerinin ortalamaları lojistik fonksiyonu için $4,11 \cdot 10^{-4}$, hiperbolik tanjant fonksiyonu için $3,53 \cdot 10^{-1}$, Elliot fonksiyonu için $8,57 \cdot 10^{-4}$, Sinc fonksiyonu için ise $4,15 \cdot 10^{-4}$ olarak hesaplanmıştır. Hesaplanan ortalama MSE değerlerine bakılarak lojistik ve Sinc fonksiyonlarının AO prosesinde TKN giderimi verimini en küçük hatayla tahmin eden fonksiyonlar olduğu görülmektedir. Bununla birlikte, BPANN'de kullanılan fonksiyonların tahmin yeteneğinin hangi seviyede olduğunu görmek amacıyla validasyon verileri için ASM1 ve BPANN ile elde edilen TKN giderim verimleri arasında (en iyi BPANN sonuçları için) korelasyon grafikleri hazırlanmış ve Şekil 5'te verilmiştir. Şekilde mavi noktalar ASM1-ANN ile elde edilen TKN giderim verimlerini, siyah çizgi bu değerlerle elde edilen regresyon denklemini, kırmızı çizgi ise ASM1-ANN birebir değerlerini temsil etmektedir.

Şekil 5b'de açıkça görüldüğü gibi hiperbolik tanjant fonksiyonu mevcut haliyle aktivasyon fonksiyonu olarak kullanıldığında BPANN'nin öğrenme yeteneğini önemli ölçüde kısıtlamaktadır. Buna karşın, lojistik fonksiyonu kullanıldığında ASM1 ve BPANN ile elde edilen TKN giderim verimleri arasında $0,9975$ 'e varan ($R^2 = 0,9951$) korelasyon katsayıları elde edilmiştir (Şekil 5a). Elliot fonksiyonu (Şekil 5c) için korelasyon katsayısı $0,9863$ ($R^2 = 0,9757$), Sinc fonksiyonu (Şekil 5d) için ise $0,9979$ ($R^2 = 0,9959$) olarak hesaplanmıştır. Bu sonuçlara bakıldığında en güvenilir sonuçların lojistik ve Sinc fonksiyonu ile edildiği görülmektedir.

BPANN ile TKN giderim verimi tahmininde elde edilen MSE değerlerinin dağılımı Şekil 6'da verilmiştir. Yine hiperbolik tanjant fonksiyonu kullanıldığında elde edilen MSE değerleri her zaman yüksektir. Lojistik ve Sinc fonksiyonları ise KOİ tahmininde olduğu gibi TKN tahmininde de çok küçük MSE değerleri ile

N. MANAV DEMİR

sonuçlanmıştır. Bunların arasında, lojistik fonksiyonu ile elde edilen MSE değerleri Sinc fonksiyonu ile elde edilen değerlere nazaran daha geniş bir salınım göstermekte olup, Sinc fonksiyonunun istikrarlı bir şekilde en küçük MSE değerlerini ürettiği açıkça görülmektedir.




Şekil 5. ASM1 ve BPANN kullanılarak elde edilen TKN giderim verimleri arasındaki korelasyon grafikleri. **a.** Lojistik fonksiyonu, **b.** Hiperbolik tanjant fonksiyonu, **c.** Elliot fonksiyonu, **d.** Sinc fonksiyonu

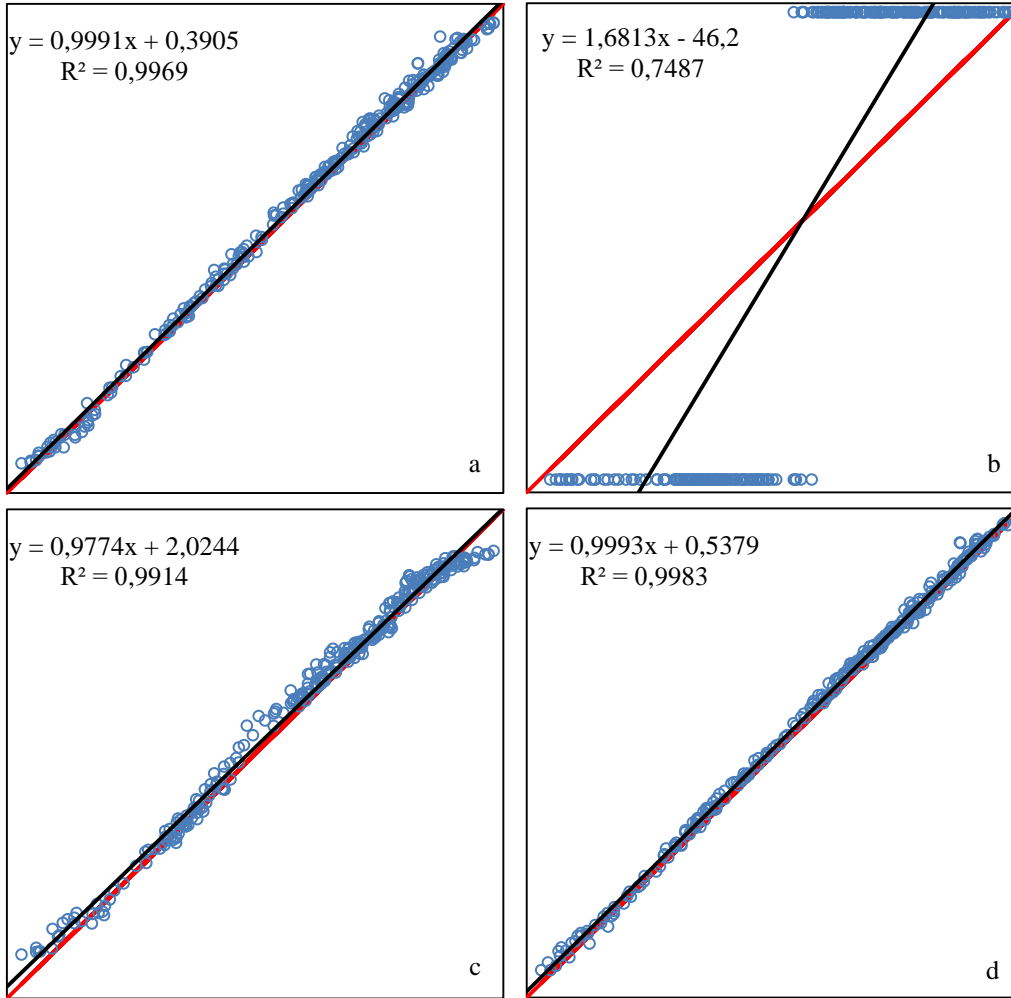
3.3. TN Giderim Verimi

Her bir aktivasyon fonksiyonu ile yapılan 25 denemenin sonunda elde edilen MSE değerlerinin ortalamaları lojistik fonksiyonu için $5,10 \cdot 10^{-4}$, hiperbolik tanjant fonksiyonu için $3,31 \cdot 10^{-1}$, Elliot fonksiyonu için $6,45 \cdot 10^{-4}$, Sinc fonksiyonu için ise $2,65 \cdot 10^{-4}$ olarak hesaplanmıştır. Hesaplanan ortalama MSE değerlerine bakılarak Sinc fonksiyonunun AO prosesinde TN giderimi verimini en küçük hatayla tahmin eden fonksiyon olduğu görülmektedir. ASM1 ve BPANN ile elde edilen TN giderim verimleri arasındaki (en iyi BPANN sonuçları için) korelasyon grafikleri Şekil 7'de verilmiştir. Şekilde mavi noktalar ASM1-ANN ile elde edilen TKN giderim verimlerini, siyah çizgi bu değerlerle elde edilen regresyon denklemini, kırmızı çizgi ise ASM1-ANN birebir değerlerini temsil etmektedir. Mevcut haliyle kullanıldığında hiperbolik tanjant fonksiyonu (Şekil 7b), TN giderim veriminin açıklanması hususunda da iyi bir performans sergileyememiştir. Buna karşın, kullanılan diğer aktivasyon fonksiyonları TN giderim verimini iyi açıklayabilmektedir. Lojistik fonksiyonu (Şekil 7a) için hesaplanan korelasyon katsayısı 0,9984 ($R^2 = 0,9969$), Elliot fonksiyonu (Şekil 7.c) için hesaplanan korelasyon katsayısı 0,9957 ($R^2 = 0,9914$), Sinc fonksiyonu (Şekil 7d) için hesaplanan korelasyon katsayısı ise 0,9992'dir. ($R^2 = 0,9983$). Elde edilen korelasyon katsayılarına göre AO prosesinde TN giderim verimini en iyi temsil eden aktivasyon fonksiyonu Sinc fonksiyonu olarak görülmektedir.

BİYOLOJİK ATIKSU ARITMA TESİSLERİNDE KARBON VE AZOT GİDERİM VERİMLERİNİN TAHMİNİ AMACIYLA YAPAY SİNİR AĞLARININ KULLANIMI




Şekil 6. BPANN ile TKN tahmininde elde edilen MSE değerlerinin dağılımı



Şekil 7. ASM1 ve BPANN kullanılarak elde edilen TN giderim verimleri arasındaki korelasyon grafikleri. **a.** Lojistik fonksiyonu, **b.** Hiperbolik tanjant fonksiyonu, **c.** Elliot fonksiyonu, **d.** Sinc fonksiyonu

N. MANAV DEMİR

BPANN ile TN giderim verimini tahmin etmek amacıyla, her bir fonksiyon kullanılarak 25 denemenin sonunda elde edilen MSE değerlerinin dağılımı Şekil 8’de verilmiştir. Lojistik, Elliot ve Sinc fonksiyonları kullanıldığında BPANN ile yüksek doğrulukta TN tahminleri yapılabilmekte; MSE değerleri küçük olmaktadır. Bunların arasında lojistik ve Sinc fonksiyonları ile elde edilen ortalama MSE değerleri düşük olmakla birlikte, lojistik fonksiyonu kullanıldığında BPANN her zaman en iyi sonuçları üretmemekte; bazen MSE değerleri yüksek hesaplanmaktadır (Şekil 8). Buna karşın Sinc fonksiyonuyla elde edilen MSE değerleri çok küçük bir ortalama değer etrafında çok küçük salınımlar göstermekte ve Sinc-BPANN TN tahmininde istikrarlı bir grafik çizmektedir.



Şekil 8. BPANN ile TN tahmininde elde edilen MSE değerlerinin dağılımı

4. SONUÇLAR

Bu çalışmada geri beslemeli yapay sinir ağının (BPANN) atıksulardan karbon ve azot giderimi amacıyla kullanılan AO prosesindeki KOİ, TKN ve TN giderim verimlerinin tahminindeki performansını test etmek amacıyla, çamur yaşı (θ_s), aerobik tankta hidrolik bekleme süresi (θ_h), geri devir oranı (R_s), iç geri devir oranı (R_n), aerobik tanktaki çözünmüş oksijen konsantrasyonu (C) ve giriş suyunda KOİ-TN konsantrasyonları olmak üzere 7 farklı tasarım ve işletme parametresinin toplamda 972 adet farklı değerlerinden oluşan bir veri seti BPANN’de girdi olarak kullanılmıştır. Veri setindeki KOİ, TKN ve TN giderim verimleri, daha önceden geçerliliğini ispatlamış olan Aktif Çamur Modeli No.1 (ASM1) kullanılarak hesaplanmıştır. Yapay sinir ağı, farklı aktivasyon fonksiyonlarıyla birlikte bu veri setine uygulanarak BPANN ve ASM1’de elde edilen KOİ, TKN ve TN giderim verimleri kıyaslanmıştır. Çalışma sonucunda elde edilen verilere dayanarak aşağıdaki çıkarımları yapmak mümkündür:

- Karbon ve azot giderimi yapılan bir biyolojik atıksu arıtma tesisindeki KOİ, TKN ve TN giderim verimleri BPANN kullanılarak kabul edilebilir doğrulukla tahmin edilebilmektedir. ASM1 modelini kullanarak KOİ, TKN ve TN giderim verimlerini tahmin etmek için atıksu karakterizasyonunun detaylı yapılması gerekirken, aynı işlevi yerine getiren BPANN uygulamasında bu derece detaylı atıksu karakterizasyonuna ihtiyaç duyulmamaktadır. Bu açıdan bakıldığında KOİ, TKN ve TN giderim verimlerini tahmin etmek amacıyla BPANN kullanılması analiz maliyetleri ve modelleme süresi açısından büyük tasarruf sağlamaktadır.
- BPANN ile KOİ giderim veriminin tahmininde aktivasyon fonksiyonu olarak lojistik, Elliot ve Sinc fonksiyonlarının kullanımını uygun olmakla birlikte Sinc fonksiyonunun en iyi öğrenme kapasitesine sahip olduğu görülmektedir.
- TKN giderim veriminin tahmininde en uygun fonksiyon Sinc fonksiyonu olarak görülmektedir. Bununla birlikte lojistik fonksiyonu da kabul edilebilir doğrulukta tahminler yapabilmektedir.

BİYOLOJİK ATIKSU ARITMA TESİSLERİNDE KARBON VE AZOT GİDERİM VERİMLERİNİN TAHMİNİ AMACIYLA YAPAY SİNİR AĞLARININ KULLANIMI

- TN giderim verimini BPANN ile tahmin etmek için en uygun fonksiyonların lojistik ve Sinc fonksiyonları olduğu görülmektedir.
- KOİ, TKN ve TN giderim verimlerini tahmin etmek için ise ortak olarak Sinc fonksiyonunun kullanılması uygun görülmektedir. BPANN'yi daha yüksek performansla çalıştırabilmek için aktivasyon fonksiyonlarının ölçeklendirilmesi amacıyla kullanılan diklik katsayılarının en yüksek performans için optimize edilmesi gerekebilir.
- Bu çalışmada kullanılan ASM1 modeli 8 proses ve 13 bileşenden oluşan bir model olup, biyolojik atıksu arıtma tesisindeki her bir proses tankı için 13 adet diferansiyel denklemin eşzamanlı çözümünü gerektirmektedir. Ayrıca bu denli karmaşık bir matematiksel problemin çözümü basit sonlu fark yaklaşımı ile yapıldığında çözümün kararlılığı tehlikeye girmekte; bu sebeple daha ileri integrasyon tekniklerine ihtiyaç duyulmaktadır. Bir diğer husus ise bu modelin lisanslı yazılımlarda kullanılmasıdır. Bu açıdan bakıldığında, ASM1 modelinin hem detaylı atıksu karakterizasyonu gerektirmesi ve hem de çok pahalı yazılımlara ihtiyaç duyulması sebebiyle çok daha düşük fiyatlarla MS Excel eklenti paketi olarak temin edilebilen yapay sinir ağlarının atıksu arıtma tesislerindeki KOİ, TKN ve TN giderim verimlerinin doğrusal olmayan doğasının modellenmesi için daha kolay ve daha ucuz bir çözüm olduğunu söylemek mümkündür. BPANN'de ihtiyaç duyulan eğitim verileri biyolojik atıksu arıtma tesislerinde rutin olarak yapılan KOİ, TN ve debi ölçümleriyle elde edilebilir.
- Bu çalışmada elde edilen sonuçlara dayanarak BPANN'nin fosfor gideriminin de gerçekleştirildiği biyolojik nütrient giderme proseslerinin performansını tahmin etmek için kullanılabileceği anlamı çıkarılmamalıdır. Fosfor giderim prosesleri ASM2 ve ASM2d modellerinde mevcut olup, giriş suyu parametrelerine göre doğrusal olmayan fosfor giderim verimini tahmin etmek için bu modellerin kullanıldığı ileri çalışmalara ihtiyaç vardır.

KAYNAKLAR

- [1] <https://esa.un.org/unpd/wpp/Download/Standard/Population/#> (erişim tarihi 15.12.2016).
- [2] MANAV DEMİR, N., "İleri Biyolojik Arıtma Proseslerinde Nütrient Giderimi ve Mikroorganizma Türlerinin İncelenmesi", Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye, 2012.
- [3] HENZE, M., GRADY, C.P.L., GUJER, W., MARAIS, G.V.R., MATSUO, T., Activated Sludge Model No. 1. In M. HENZE, W. GUJER, T. MINO, M.V. LOOSDRECHT (Eds.), Activated Sludge Models ASM1, ASM2, ASM2d and ASM3 (pp. 1-37), IWA Publishing, London, UK, 2007.
- [4] HENZE, M., GUJER, W., MINO, T., MATSUO, T., WENTZEL, M.C., MARAIS, G.V.R., Activated Sludge Model No. 2. In M. HENZE, W. GUJER, T. MINO, M.V. LOOSDRECHT (Eds.), Activated Sludge Models ASM1, ASM2, ASM2d and ASM3 (pp. 39-73), IWA Publishing, London, UK, 2007.
- [5] HENZE, M., GUJER, W., MINO, T., MATSUO, T., WENTZEL, M.C., MARAIS, G.V.R., "Activated Sludge Model No. 2d", Water Science and Technology, 39, 165-182, 1999.
- [6] GUJER, W., HENZE, M., MINO, T., VAN LOOSDRECHT, M.C.M., "Activated Sludge Model No. 3", Water Science and Technology, 39, 183-193, 1999.
- [7] HUG, T., BENEDETTI, L., HALL, E.R., JOHNSON, B.R., MORGENROTH, E., NOPENS, I., RIEGER, L., SHAW, A., VANROLLEGHEM, P.A., "Wastewater Treatment Models in Teaching and Training: The Mismatch between Education and Requirements for Jobs", Water Science and Technology, 60, 1721-1729, 2009.
- [8] COPP, J.B., MURPHY, K.L., "Estimation of the Active Nitrifying Biomass in Activated Sludge", Water Research, 29, 1855-1862, 1995.
- [9] SMETS, I.Y., HAEGEBART, J.V., CARETTE, R., VAN IMPE, J.F., "Linearization of the Activated Sludge Model ASM1 for Fast and Reliable Predictions", Water Research, 37, 1831-1851, 2003.
- [10] MULLER, A., WENTZEL, M.C., LOEWENTHAL, R.E., EKAMA, G.A., "Heterotroph Anoxic Yield in Anoxic Aerobic Activated Sludge Systems Treating Municipal Wastewater", Water Research, 37, 2435-2441, 2003.
- [11] SONG, Y., XIE, Y., YUDIANTO, D., "Extended Activated Sludge Model No. 1 (ASM1) for Simulating Biodegradation Process Using Bacterial Technology", Water Science and Engineering, 5, 278-290, 2012.
- [12] JANUS, T., ULANICKI, B., "ASM1-Based Activated Sludge Model with Polymer Kinetics for Integrated Simulation of Membrane Bioreactors for Wastewater Treatment", Procedia Engineering, 119, 1318-1327, 2015.

N. MANAV DEMİR

- [13] CRUZ, J.A.S., MUSATTI, S.F., SCENNA, N.J., GERNAEY, K.V., MUSATTI, C.M., “Reaction Invariant-Based Reduction of the Activated Sludge Model ASM1 for Batch Applications”, *Journal of Environmental Chemical Engineering*, 4, 3654-3664, 2016.
- [14] ZHAO, B., SU, Y., “Artificial Neural Network-Based Modeling of Pressure Drop Coefficient for Cyclone Separators”, *Chemical Engineering Research and Design*, 88, 606-613, 2010.
- [15] AGHAV, R.M., KUMAR, S., MUKHERJEE, S.N., “Artificial Neural Network Modeling in Competitive Adsorption of Phenol and Resorcinol from Water Environment Using Some Carbonaceous Adsorbents”, *Journal of Hazardous Materials*, 188, 67-77, 2011.
- [16] HERNANDEZ-RAMIREZ, D.A., HERRERA-LOPEZ, E.J., RIVERA, A.L., DEL REAL-OLVERA, J., “Artificial Neural Network Modeling of Slaughterhouse Wastewater Removal of COD and TSS by Electrocoagulation”, *Studies in Fuzziness and Soft Computing*, 312, 273-280, 2014.
- [17] SAMLI, R., SIVRI, N., SEVGEN, S., KIREMITCI, V.Z., “Applying Artificial Neural Networks for the Estimation of Chlorophyll-*a* Concentrations along the Istanbul Coast”, *Polish Journal of Environmental Studies*, 23, 1281-1287, 2014.
- [18] BAYRAM, A., KANKAL, M., “Artificial Neural Network Modeling of Dissolved Oxygen Concentrations in a Turkish Watershed”, *Polish Journal of Environmental Studies*, 24, 1507-1515, 2015.
- [19] DEMİR, S., KARADENİZ, A., MANAV DEMİR, N., “Using Steepness Coefficient to Improve Artificial Neural Network Performance for Environmental Modeling”, *Polish Journal of Environmental Studies*, 25, 1467-1477, 2016.
- [20] DEMİR, S., KARADENİZ, A., MANAV DEMİR, N., “Artificial Neural Network Simulation of Cyclone Pressure Drop: Selection of the Best Activation Function”, *Polish Journal of Environmental Studies*, 25, 1891-1899, 2016.
- [21] HAMED, M.M., KHALAFALLAH, M.G., HASSANIEN, E.A., “Prediction of Wastewater Treatment Plant Performance Using Artificial Neural Networks”, *Environmental Modeling and Software*, 19, 919-928, 2004.
- [22] MJALLI, F., AL-ASHEH, S., ALFADALA, H.E., “Use of Artificial Neural Network Black-Box Modeling for the Prediction of Waterwater Treatment Plants Performance”, *Journal of Environmental Management*, 83, 329-338, 2007.
- [23] MORAL, H., AKSOY, A., GOKCAY, C.F., “Modeling of the Activated Sludge Process by Using Artificial Neural Networks with Automated Architecture”, *Computers and Chemical Engineering*, 32, 2471-2478, 2008.
- [24] TAKACS, I., PATRY, G.G., NOLASCO, D., “A Dynamic Model of the Clarification-Thickening Process”, *Water Research*, 25, 1263-1271, 1991.
- [25] TAKACS, I., “Experiments in Activated Sludge Modeling”, PhD Thesis, Ghent University Applied Biological Sciences, Belgium, 2008.
- [26] HOLENDA, B., PASZTOR, I., KARPATI, A., REDEY, A., “Comparison of One Dimensional Secondary Settling Tank Models”, *E-Water*, 06, 1-17, 2006.