

# Çözünmüş oksijen değişiminin Yapay Sinir Ağları ile belirlenmesi: Kızılırmak Nehri örneği

Oktay ÖZKAN\*, Cumali KINACI, Şeref SAĞIROĞLU

İTÜ İnşaat Fakültesi, Çevre Mühendisliği Bölümü, 34469, Ayazağa, İstanbul

## Özet

*Bu çalışmada nehirlerdeki çözünmüş oksijen konsantrasyonunun değişiminin modellenmesinde yapay sinir ağlarına (YSA) dayanan yeni bir yaklaşım sunulmuştur. Genişletilmiş delta-bar-delta ile geriyayılım öğrenme algoritmaları bu ağları eğitmede kullanılmıştır. Bu uygulama için en basit YSA yapısını oluşturmada 5 farklı veri yapısı ve 2 farklı transfer fonksiyonu test edilmiştir. Elde edilen sonuçlar, YSA'nın çözünmüş oksijen konsantrasyonunu belirlemede başarılı bulunmuştur. İşlemlerin hızlı hesaplanması, basit yapıda olmaları, matematiksel modellemesinin çıkarılması zor problemlere kabul edilebilir sonuçlar sunmaları, su kalite modellemesinde ekonomik çözümler sunmaları bu zeki yaklaşımın karşılaşılan üstünlükleridir.*

**Anahtar Kelimeler:** Çözünmüş oksijen, Kızılırmak Nehri, modelleme, yapay sinir ağları.

## Determining dissolved oxygen change using artificial neural networks: An example of Kızılırmak River

### Abstract

*In this study, a new approach based on artificial neural networks (ANN) to determine dissolved oxygen concentration change in rivers is presented. The dissolved oxygen concentration in rivers plays dominant role in determining the water quality. This parameter constitutes a significant criterion of ecological stability and activity of water. The ANN structures with the inputs of 27, 5, 4, and 3 have been constructed. The parameters that are most simplistic and easy to measure are used as inputs to the neural network structure to be able to observe the changes in the dissolved oxygen concentration in Kızılırmak River. The Multi Layer Perceptron (MLP) structure has been used in the phase of modeling. ANN models were trained with the extended delta-bar-delta and backpropagation learning algorithms. To achieve the task with simple configuration, 5 different data structures and two different transfer functions were tested. The best result of ANN applications is obtained with the neural network structure that uses the EDBD algorithm. The results obtained from the simulations have shown that, ANN models achieved the modeling of dissolved oxygen change with high accuracy. Providing fast computation, simple structure, economic and plausible solutions determine the water qualities are the advantages of ANN encountered in this work.*

**Keywords:** Dissolved oxygen, Kızılırmak River, modeling, artificial neural network.

\*Yazışmaların yapılacağı yazar: Oktay ÖZKAN. ozkan@erciyes.edu.tr; Tel: (352) 437 49 01 dahili: 32328.

Bu makale, birinci yazar tarafından İTÜ İnşaat Fakültesi'nde tamamlanmış olan "Kızılırmak Nehri'nde çözünmüş oksijen konsantrasyonunun yapay sinir ağlarıyla belirlenmesi" adlı doktora tezinden hazırlanmıştır. Makale metni 07.10.2005 tarihinde dergiye ulaşılmış, 06.12.2005 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 30.11.2006 tarihine kadar dergiye gönderilmelidir.

## Giriş

Çözünmüş oksijen konsantrasyonu, su kalitesinin belirlenmesinde önemli olduğu kadar suyun ekolojik stabilitesi ve aktivitesinin de çok önemli bir ölçütünü oluşturur. Sudaki yaşamın sürabilmesi, metabolik faaliyetler ve sentez olayı için gerekli olup kirlenmenin, alg aktivitesinin ve organik madde miktarının da aynı zamanda bir göstergesidir.

Bir su kalitesi modeli, kirliliği belirleyen parametrelerin konsantrasyonlarının zamanda ve mekandaki değişimlerini matematiksel olarak ifade edebilen bir yapıdır. Modele, bir akarsuya girdileri çıktılara dönüştüren bir sistem gözüyle bakabilir (Fleming, 1975).

Matematiksel modeller, gerçek olayın mikro düzeyde ayrıntılarına inilmeden ve doğadaki gözlemlerden hareket edilerek bulunduğu için ampirik bileşenler içermektedir. Bu tip yaklaşımlarda kullanılan sabitler daha önce o alıcı ortamlar için yapılan gözlemler yardımıyla kalibre edilir. Kalibrasyon yardımıyla elde edilen bu sabitler o alıcı ortam için model uygulamalarında kullanılır.

Stokastik (rastlantısal) modeller, deterministik modellere kıyasla matematiksel açıdan daha da karmaşıktırlar. Akarsu debilerinin, biyokimyasal olayları etkileyen sıcaklık, güneş radyasyonu gibi meteorolojik olayların, rastgele oluşumlar olduğu bilinmektedir. Bu etkenlere bağımlı olarak alıcı su ortamlarındaki kirletici konsantrasyonları değişime uğramaktadır. Tüm bu rastlansallıklar su kirliliği araştırmalarında stokastik değerlendirmeleri gerekli kılmaktadır.

Yüzeysel su kalitesinin incelenmesi için bilimsel yöntemler, 1925'lerde A.B.D. de önerilen "Streeter-Phelps Denklemleri" ile başlamıştır (Streeter ve Phelps, 1944). Bir akarsu boyunca çözünmüş oksijen ve biyokimyasal oksijen ihtiyacını parametre olarak kullanan bu yöntemler oldukça kaba basitleştirilmelerden hareket ederek, uzun yıllar boyunca su ortamlarının kalite özelliklerinin belirlenmesinde yardımcı olmuşlar ve uygulama olanağı bulmuşlardır. Elektronik bilgisayarların 1950'lerden sonra giderek

daha geniş ölçüde mühendislik çalışmalarında kullanılmaya başlaması ile kullanılan yöntemlerin daha da geliştirilmesi olanağı doğmuştur. Modellerin tarihsel gelişim süreci aşağıda kısaca özetlenmiştir.

**1925-1965:** Bu dönemde akarsu ve haliçlerde olduğu gibi tek boyutlu hareketler ve lineer süreçler (birinci derece süreçler) üzerinde çalışılmıştır. Sulara yapılan atıksu deşarjlarının içerdiği organik maddenin bakteriler tarafından ayrıştırılması ile ilişkili olarak çözünmüş oksijen modellemesi yapılmıştır (Streeter ve Phelps, 1944; O'Connell ve Thomass, 1965).

**1965-1980:** Alıcı su ortamlarında iki boyutlu (göller, körfezler) çalışılabilir hale gelmiştir. Kinetik çalışmalarına azot bileşiklerinin yükseltgenmesi de dahil edilmiştir (Williams ve Hinwood, 1976; Whitehead ve Young, 1979).

**1980-1995:** Su kalitesi modellerinin doğrulanması için çeşitli istatistiksel yöntemler kullanılmıştır (Thomann, 1982). Diferansiyel denklemlerle kurulup hızlandırılan QUAL-II modeli denenmiştir (Camara ve Randall, 1984). Su kütlesi için iki boyutlu, düşey ve boylamsal iki boyutlu hidrodinamik ve su kalitesi simülasyonları birleştirilerek, CE-QUAL-W2 modeli geliştirilmiştir (Martin, 1988). Nehirlerde su kalitesi tanımı için mevcut modelleri geliştiren tek boyutlu nümerik bir model sunulmuştur (Stamou, 1992). Bu modelde, OUICK ve QUICKSET olmak üzere iki karesel interpolasyon planı önerilmiştir. QUAL2E modelini kalibre etmek için nonlineer regresyon analizi uygulanmış ve kritik yaz ayları için çözünmüş oksijen değişimini belirlemede kullanılabileceği görülmüştür (Little ve Williams, 1992).

Bir taraftan araştırmalar devam ederken, diğer taraftan problemlerin çözümü için modeller uygulanmaya devam etmektedir. Ancak kestirimlerin güvenilirliği ve duyarlılığı konusunda farklı çalışmalara ihtiyaç duyulmaktadır. Bu arada ekosistem modellemesi de hızla gelişmektedir. Giderek daha çok zaman içinde değişken durumlar bilgisayar yardımı ile çözülebilir hale gelmektedir.

Yapay Sinir Ağları (YSA) öğrenme, genelleme yapabilme, hızlı hesaplama, donanım olarak gerçekleştirilebilme ve modellenemeyen veya modellenmesi güç olan sistemlerin modellenmesi gibi üstünlüklerinden dolayı birçok uygulamada tercih edilmektedir (Haykin, 1994). Yeraltısuyu özelliklerinin belirlenmesinde de benzer uygulamalar yapılmıştır (Rizzo ve Dougherty, 1994; Basheer ve Najjar, 1995). Göllerdeki alg patlamasının tahmini YSA ile yeni bir uygulama olarak modellenmiştir (Kenichi vd., 1997). Göl içerisindeki klorofil-a konsantrasyonunun, sıcaklık, pH, çözünmüş oksijen vb. su kalitesi parametreleri ile nasıl değiştiğini ifade eden YSA modelleri geliştirilmiştir (Karul vd., 1998). Tualatin Nehri'nde çözünmüş oksijen değişimi YSA ile modellenmiş ve bu modelde debi, sıcaklık, güneş ışığı gibi parametreler kullanılmış ve başarılı bir model gerçekleştirilmiştir (Rounds, 2002).

YSA'lar yukarıdaki bahsedilen üstünlüklerinden dolayı bu çalışmada, çözünmüş oksijen değişiminin belirlenmesi için kullanılmıştır. Çözünmüş oksijenin değişimine etki eden en uygun parametreler seçilerek, değişimin modellenmesi için en iyi yapay sinir ağı algoritması belirlenmiştir. Oluşturulan modellerin, farklı algoritmaların performanslarının denemesinde ve kurulan yapay sinir ağı modelinin eğitilmesinde daha önce Ankara Üniversitesi tarafından Kızılırmak Nehri üzerinde belirlenen su kalitesi değerlerinden yararlanılmıştır.

### Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (YSA), beynin fizyolojisinden yararlanılarak oluşturulan yapay bilgi işleme modelleridir. YSA'lar bu tür problemleri çözmede son yıllarda çok başarılı yeni yaklaşımlardandır (Haykin, 1994; Sagioglu vd., 2003). YSA'ların öğrenme özelliği, araştırmacıların dikkatini çeken en önemli özelliklerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olaylar için, önceki örneklerden çağrışım yaparak çözümler üretebilme özelliği YSA'lardaki zeki davranışın da temelini teşkil eder.

Literatürde bir çok YSA yapısı mevcuttur (Sagioglu vd., 2003). Çok katlı perseptronlar (ÇKP) uygulamalarda en çok kullanılan YSA yapısıdır (Haykin, 1994). Şekil 1'de genel bir ÇKP yapısı verilmiştir. Temel bir ÇKP, üç ana katmandan oluşur: giriş katmanı, çıkış katmanı ve gizli katmandır. Giriş katmanındaki işlem elemanları veya nöronlar (şekilde daire ile gösterilmiştir), sadece giriş sinyali  $x_i$ 'nin, gizli katmandaki nöronlara dağıtılmasını sağlayan bir tampon gibi görev yaparlar. Gizli katmanda bulunan her bir  $j$  indisli işlem elemanın çıkışı;  $x_i$  giriş sinyali ile ara katman  $w_{ji}$  ağırlıkları ile çarptıktan sonra toplamakta ve toplamın bir  $f$  fonksiyonu alınarak elde edilmektedir. Bunun çıkışı  $y_i$  ise;

$$y_i = f(\sum w_{ji}x_i) \quad (1)$$

ile hesaplanmaktadır. Burada  $f$ , sigmoidal veya hiperbolik tanjant ( $\tanh$ ) fonksiyonu gibi bir transfer veya aktivasyon fonksiyonu olabilir. Çıkış katmanındaki nöronların çıkışları da benzer şekilde hesaplanır. Bir ağı eğitme, bir öğrenme algoritması kullanılarak ağırlıkların çıkış hatasını düşürecek şekilde ayarlanmasından ibarettir. Öğrenme algoritmasıyla,  $i$  ve  $j$  nöronları arasındaki ağırlığın  $\Delta w_{ji}(k)$  değişimi bulunur. Bu çalışmada yapay sinir ağlarını eğitmede uygulamada sık karşılaşılan geriyayılım ve genişletilmiş delta-bar-delta algoritmaları kullanılmıştır. Bu algoritmalar aşağıda kısaca tanımlanmıştır.

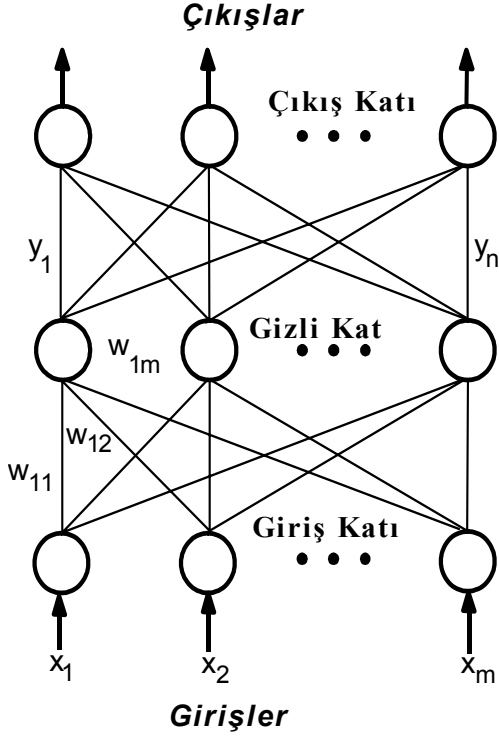
### Geriyayılım algoritması (BP)

Geriyayılım algoritması (Rumelhart ve McClelland, 1986), dereceli azalan ve ÇKP'leri öğretilmede çok kullanılan temel bir öğrenme algoritmasıdır. Bu algoritma ile,  $i$  ve  $j$  kat nöronları arasındaki ağırlık değişikliği;

$$\Delta w_{ji}(k) = \alpha \delta_j x_i + \mu \Delta w_{ji}(k-1) \quad (2)$$

ile hesaplanır. Eşitlik (2)'de  $\alpha$  öğrenme katsayısı,  $\mu$  momentum katsayısı ve  $\delta_j$  ara veya çıkış katmanındaki herhangi bir  $j$  nöronuna ait bir faktördür. Çıkış katmanı için bu faktör,

$$\delta_j = \frac{\partial f}{\partial \text{net}_j} (y_j^t - y_j) \quad (3)$$



Şekil 1. Çok katlı perseptronların genel yapısı

Burada,  $\text{net}_j \equiv \sum_i x_i w_{ji}$  ve  $y_j^t$  ise  $j$  nöronunun hedef çıkışıdır. Ara katmanlardaki nöronlar için  $\delta_j$  faktörü,

$$\delta_j = \left( \frac{\partial f}{\partial \text{net}_j} \right) \sum_q w_{jq} \delta_q \quad (4)$$

formülü ile hesaplanır.

Ara katmanlardaki nöronlar için herhangi bir hedef çıkış olmadığından, (3) No.lu eşitlik yerine (4) No.lu eşitlik kullanılır. Bu duruma bağlı olarak çıkış katmanından başlayarak  $\delta_j$  faktörü, bütün katmanlardaki nöronlar için hesaplanır. (2) No.lu eşitliğe bağlı olarak ağırlıkların güncelleştirilmesi böylece gerçekleştirilir.

### Genişletilmiş delta-bar-belta (Extended DBD)

Genişletilmiş Delta-Bar-Delta (EDBD) öğretim algoritması, eğitimde belirli bir anda çıkış hatasını hesaplayarak hata düzeltme özelliğine sa-

hiptir. Belirli bir andaki ölçülen hata, bir önceki adımda bulunan hatadan büyük ise ağırlıkları bir önceki ağırlık değerlerini alır (Neuralware Handbook, 1996). Her adımda (epok) hatayı test etmek yerine daha önce iyileştirilme işlemi yapıldığından hata,  $n$  periyotta test edilir.

EDBD’de, her bir bağlantıdaki momentum katsayısı  $\mu(k)$  ve öğrenme katsayısı  $\alpha(k)$  zamanla değişmektedir. EDBD için değişken öğrenme ve değişken momentum katsayıları aşağıdaki gibi elde edilebilir. Ağırlıklar,

$$\Delta w(k+1) = \alpha(k) \delta(k) + \mu(k) \Delta w(k) \quad (5)$$

değerinin önceki ağırlık değerine eklenmesiyle

$$w(k+1) = w(k) + \Delta w(k+1) \quad (6)$$

bulunur. Burada,  $\mu(k)$   $k$  zamanındaki ağırlık momentum katsayısıdır. Momentum  $\mu(k)$  ve öğrenme  $\alpha(k)$  katsayıları aşağıdaki kurallara göre benzer şekilde değiştirilmektedir. EDBD için öğrenme hızı değişimi (7) nolu eşitliktedir

$$\Delta \alpha(k) = \begin{cases} \kappa_\alpha \exp(-\gamma_\alpha |\bar{\delta}(k)|), & \text{eğer } \bar{\delta}(k-1) \delta(k) > 0 \\ -\varphi_\alpha \alpha(k), & \text{eğer } \bar{\delta}(k-1) \delta(k) < 0 \\ 0 & \text{diğer durumda} \end{cases} \quad (7)$$

Burada  $\exp$ , üstel fonksiyonunu,  $\kappa_\alpha$ , sabit öğrenme skala faktörünü  $\varphi_\alpha$ , sabit öğrenme azaltma faktörü ve  $\gamma_\alpha$ , sabit öğrenme üstel faktörünü göstermektedir. Benzer şekilde,  $k$  zamanındaki momentum değişimi,

$$\Delta \mu(k) = \begin{cases} \kappa_\mu \exp(-\gamma_\mu |\bar{\delta}(k)|) & \text{eğer } \bar{\delta}(k-1) \delta(k) > 0 \\ -\varphi_\mu \mu(k) & \text{eğer } \bar{\delta}(k-1) \delta(k) < 0 \\ 0 & \text{diğer durumda} \end{cases} \quad (8)$$

ifadesinden bulunabilir. Burada,  $\kappa_\mu$ , sabit momentum skala faktörünü  $\varphi_\mu$ , sabit momentum

azaltma faktörü ve  $\gamma_{\mu}$ , sabit momentum üstel faktörünü göstermektedir. EDBD'nin düzeltme özellikli hafızası kullanıldığı zaman, eğitme verilerinin sunumu her iterasyondan sonra değerlendirilir. Hata,  $E(k)$ , bir önceki minimum hatadan küçük ise ağırlıkları o anki en iyiler olarak hafızada saklanır. Düzeltme tolerans parametresi  $\lambda$ , düzeltme sürecini kontrol eder. O andaki hata önceki minimum hatayı aşarsa, yani

$$E(k) > E_{\min} \lambda \quad (9)$$

olursa, tüm bağlantı ağırlıkları, hafızada saklı olan en iyi değerlerle değiştirilir. Ayrıca, öğrenme ve momentum hızları, düzeltmeyi iyileştirmek için azaltılır.

### YSA ile modelleme uygulamaları

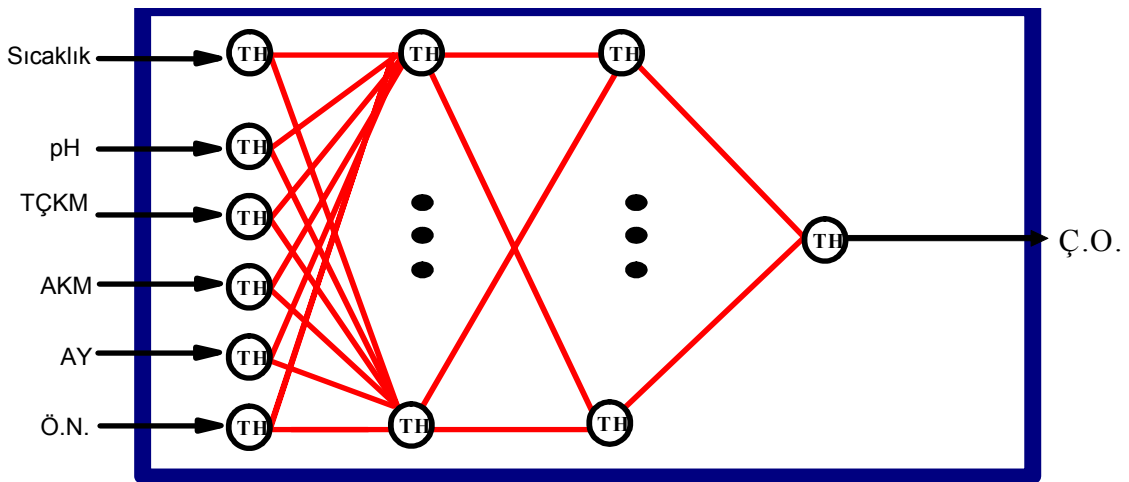
Bu çalışmada, ÇO parametresinin değişimi ile diğer su kalite parametreleri arasındaki ilişkinin belirlenebilmesinde YSA'lar kullanılmıştır.

Model için Kızılırmak Nehri üzerinde Ankara Üniversitesi'nin 9 ay süreyle 10 ayrı noktada yaptığı su kalitesi değerleri kullanılmıştır. Bu veri kümesinde toplam 90 örnekte 2700 adet veri bulunmaktadır.

Nehirdeki ÇO değişiminin nasıl gerçekleştiğini görmek amacı ile faktör analizi kullanılarak en aza indirilmiş temel ve ölçülmesi çok kolay pa-

rametreler ÇKP-YSA yapısında giriş olarak kullanılmıştır. Online olarak da ölçülebilen bu parametrelerle nehir üzerinde belirlenen ölçüm istasyonlarında yapılan ölçümler bir ağ yapılması içerisinde merkezi bir sistemde birleştirilerek bütün ölçüm sonuçları burada toplanabilecektir. Bu online ölçüm değerleri sistem içerisinde, geliştirilen nöro model yardımı ile hesaplanarak ÇO değeri tahmin edilebilecektir. Sonuçta ölçülen parametre sayısı en aza indirilmiş olacak, zaman ve ekonomik olarak tasarruf sağlanacaktır.

Toplam 28 parametre (27 giriş ve 1 çıkış) ve 2700 verinin bulunduğu küme ÇO değişimini elde etmede kullanılmıştır. En iyi sonucu en basit yapı ve an az girişle elde etmek için, 27, 7, 6, 5 ve 4 girişli farklı veri kümeleri oluşturulmuştur. 6 girişli ve 1 çıkışlı YSA yapısı Şekil 2'de verilmiştir. Sırasıyla K#27, K#7, K#6, K#5 ve K#4 veri kümeleri 27, 7, 6, 5 ve 4 girişli YSA yapılarını ifade etmektedir. Tablo 1'de bu veri kümelerinin giriş ve çıkış parametrelerinin neler olduğu verilmiştir. Veri kümeleri oluşturulurken ölçümü en kolay olan parametrelerin sistemde giriş olarak kullanılmasına dikkat edilmiştir. Çalışmanın ilk aşamasında test verisi seçilmeden farklı girişlere sahip 5 YSA-ÇKP yapısı oluşturulmuştur. Bu YSA yapılarında EDBD ve BP olmak üzere iki farklı öğrenme algoritması ve iki ayrı transfer fonksiyonu kullanılmıştır.



Şekil 2. 6 Giriş -1 çıkışlı ÇKP-YSA yapısı

Bunun amacı ise en yüksek performansı veren en basit YSA yapılarını/yapısını elde etmektir. 5 farklı YSA yapısından farklı öğrenme algoritması ve transfer fonksiyonları uygulamalarından elde edilen eğitim ortalama mutlak hata (OMH) cinsinden sonuçlar Tablo 2’de verilmiştir. Tablo 2’de görüldüğü gibi verilerin tümünün eğitilmesiyle oluşturulan ÇKP-YSA yapısı için en iyi sonuç EDBD algoritması ve tanh transfer fonk-

siyonu ile elde edilmiştir. Çalışmanın ikinci aşamasında, verilerin içerisinde 10 adet rasgele test verisi seçilerek T1# veri kümesi oluşturulmuştur. Oluşturulan bu veri kümesi, yine BP ve EDBD öğrenme algoritmaları ile tanh ve sigmoid fonksiyonları kullanılarak, 27, 7, 6, 5 ve 4 girişli ÇKP-YSA yapıları için ayrı ayrı eğitim ve test yapılmıştır. T1# veri kümesi için elde edilen OMH değerleri Tablo 3’te verilmiştir.

Tablo 1. ÇO değişimini belirlemek için oluşturulan YSA-ÇKP yapıları

Veri Kümesi İsmi	Girişler	Çıkış
K#27	Sıcaklık, pH, KOİ, TÇKM, AKM, Ay, Ölçüm Noktası, TC, FC, BOİ <sub>5</sub> , Cl <sup>-</sup> , SO <sub>4</sub> , NH <sub>4</sub> -N, NO <sub>3</sub> -N, TKN, PO <sub>4</sub> , Yağ, Fenol, Bor, Na <sup>+</sup> , Mg <sup>++</sup> , Cu, Cr, Zn, Fe, Mn, S,	ÇO
K#7	Sıcaklık, pH, KOİ, TÇKM, AKM, Ay, Ölçüm Noktası	ÇO
K#6	Sıcaklık, pH, TÇKM, AKM, Ay, Ölçüm Noktası (Ö.N.)	ÇO
K#5	Sıcaklık, pH, TÇKM, Ay, Ölçüm Noktası	ÇO
K#4	Sıcaklık, pH, Ay, Ölçüm Noktası	ÇO

Tablo 2. Eğitim seti OMH değerleri

VERİ KÜMESİ	YSA		ÖĞRENME ALGORİTMASI	AKTİVASYON FONKSİYONU	EĞİTİM OMH
	Giriş	Çıkış			
K#27	27	1	BP	Sigmoid	0.4890
K#27	27	1	BP	Tanh	0.0260
K#27	27	1	EDBD	Tanh	0.0009
K#7	7	1	BP	Tanh	0.1762
K#7	7	1	EDBD	Sigmoid	0.0450
K#7	7	1	EDBD	Tanh	0.0055
K#6	6	1	BP	Tanh	0.1731
K#6	6	1	EDBD	Tanh	0.0016
K#5	5	1	BP	Sigmoid	0.1160
K#5	5	1	EDBD	Tanh	0.0043
K#4	4	1	BP	Sigmoid	1.1010
K#4	4	1	EDBD	Tanh	0.0112

Tablo 3. T1# veri kümeleri için eğitim ve test OMH Değerleri

VERİ KÜMESİ	YSA GİRİŞ SAYISI	ÖĞRENME ALGORİTMASI	AKTİVASYON FONKSİYONU	EĞİTİM OMH	TEST OMH
T1#27	27	BP	Tanh	0.0145	2.2272
T1#27	27	BP	Sigmoid	0.5069	1.3829
T1#27	27	EDBD	Tanh	0.0009	2.1663
T1#27	27	EDBD	Sigmoid	0.1197	1.9153
T1#7	7	BP	Tanh	0.1084	1.9676
T1#7	7	BP	Sigmoid	0.7060	1.3734
T1#7	7	EDBD	Tanh	0.0049	1.8755
T1#7	7	EDBD	Sigmoid	0.0481	1.0712
T1#6	6	BP	Tanh	0.0854	0.1192
T1#6	6	BP	Sigmoid	0.6838	1.2808
T1#6	6	EDBD	Tanh	0.0288	2.2666
T1#6	6	EDBD	Sigmoid	0.2316	0.2553
T1#5	5	BP	Tanh	0.1479	0.1421
T1#5	5	BP	Sigmoid	1.0900	1.3574
T1#5	5	EDBD	Tanh	0.0134	1.3949
T1#5	5	EDBD	Sigmoid	0.1302	1.3779
T1#4	4	BP	Tanh	0.3924	1.1172
T1#4	4	BP	Sigmoid	1.0773	1.2567
T1#4	4	EDBD	Tanh	0.0478	1.6694
T1#4	4	EDBD	Sigmoid	0.4297	1.6737

Tablo 3'te görüldüğü gibi T1# veri kümesinin eğitilmesi sırasında en iyi sonucu EDBD algoritması tanh transfer fonksiyonu vermiştir.

Çalışmanın üçüncü aşamasında ise farklı test kümeleri içinde performansı görmek amacı ile 6 ayrı test veri kümesi daha oluşturulmuştur. Bu test veri kümelerinden T2#, T3#, T4# ve T6# da 10 test verisi, T5# de 20, T7# de ise 40 test verisi bulunmaktadır. T1# veri kümesinde en iyi sonuç EDBD algoritması ve tanh fonksiyonu ile elde edildiği için, diğer test verileri içinde oluşturulan 5 farklı ÇKP-YSA yapısı aynı algoritma ve fonksiyonla eğitilmiştir. Tablo 4'de T1#, T2#, T3#, T4#, T5#, T6# ve T7# test veri kümelerinin EDBD algoritması ile eğitilmesi sonucu elde edilen OMH değerleri verilmiştir.

### Sonuçlar ve tartışma

Çözünmüş oksijen parametresinin değişimini elde etmek için YSA temelli yeni bir yaklaşım başarıyla sunulmuştur. Burada ÇO ile diğer su kalite parametreleri arasındaki ilişkinin belirle-

nebilmesinde YSA tabanlı bir model oluşturulmuştur. Oluşturulan model Kızılırmak Nehri için geçerli bir modeldir.

T1#, T2#, T3#, T4#, T5#, T6# ve T7# test kümelerinin, EDBD öğrenme algoritmasında tanh transfer fonksiyonu kullanılarak yapılan, 5 farklı ÇKP-YSA yapısı için eğitimleri sırasında en iyi sonucu T7# test kümesinin vermiş olduğu görülmüştür. Bunun için, 27, 7, 6, 5 ve 4 girişli ÇKP-YSA yapıları için sırasıyla eğitim OMH değerleri; 0.00001, 0.00001, 0.0001, 0.00005 ve 0.00008 yine test OMH değerleri ise 1.7275, 1.1686, 1.1443, 1.3946 ve 1.8311 olarak bulunmuştur.

Bu çalışmada sunulan nöro modeller, yapı olarak basit, hesaplama hızları yüksek ve kabul edilebilir ölçüde başarılı sonuçlar vermişlerdir. YSA modelleri ile matematiksel olarak modellenmesi son derece zor olan su kalite modellenmesi YSA ile daha kolay ve kısa sürede gerçekleştirilmiştir.

Tablo 4. Test veri kümelerinin EDBD algoritması ve tanh transfer fonksiyonu ile eğitilmesi sonucu elde edilen OMH değerleri

VERİ KÜMESİ	YSA		EĞİTİM SETİ	TEST SETİ	EĞİTİM OMH	TEST OMH
	Giriş	Çıkış				
K#27	27	1	90	-	0.0009	-
T1#27	27	1	80	10	0.0009	2.1663
T2#27	27	1	80	10	0.0016	1.2103
T3#27	27	1	80	10	0.0017	1.0627
T4#27	27	1	80	10	0.0012	1.3004
T6#27	27	1	80	10	0.0002	1.4605
T5#27	27	1	60	20	0.00007	1.6292
T7#27	27	1	50	40	0.00001	1.7275
K#7	7	1	90	-	0.0055	-
T1#7	7	1	80	10	0.0049	1.8755
T2#7	7	1	80	10	0.0098	1.4999
T3#7	7	1	80	10	0.0034	1.3086
T4#7	7	1	80	10	0.0146	1.7757
T6#7	7	1	80	10	0.0024	1.9098
T5#7	7	1	60	20	0.0013	1.5001
T7#7	7	1	50	40	0.00001	1.1686
K#6	6	1	90	-	0.0016	-
T1#6	6	1	80	10	0.0288	2.2626
T2#6	6	1	80	10	0.0174	1.4665
T3#6	6	1	80	10	0.0022	1.3413
T4#6	6	1	80	10	0.0028	1.3897
T6#6	6	1	80	10	0.0043	2.0598
T5#6	6	1	60	20	0.0005	1.4161
T7#6	6	1	50	40	0.0001	1.1443
K#5	5	1	90	-	0.0043	-
T1#5	5	1	80	10	0.0134	1.3949
T2#5	5	1	80	10	0.0113	1.2903
T3#5	5	1	80	10	0.0108	0.9244
T4#5	5	1	80	10	0.0017	2.3600
T6#5	5	1	80	10	0.0023	1.6117
T5#5	5	1	60	20	0.0002	1.4689
T7#5	5	1	50	40	0.00005	1.3706
K#4	4	1	90	-	0.0112	-
T1#4	4	1	80	10	0.0478	1.6694
T2#4	4	1	80	10	0.0208	1.1532
T3#4	4	1	80	10	0.0108	1.4193
T4#4	4	1	80	10	0.0339	2.3607
T6#4	4	1	80	10	0.0087	2.0315
T5#4	4	1	60	20	0.0115	1.5545
T7#4	4	1	50	40	0.00008	1.8147

Çözünmüş oksijen parametresinin değişimi ile ilgili geliştirilen bu YSA modeli ile, ÇO'ne etki eden parametrelerin en aza indirilerek zaman ve ekonomik olarak en iyi çözümün bulunmasına çalışılmıştır. Sıcaklık, pH, Toplam Çözünmüş Katı Madde (TÇKM), Ay, Ölçüm Noktası gibi

temel parametreler kullanılarak ÇO'nin belirlenmesi sağlanmıştır. Nehirdeki ÇO değişiminin nasıl gerçekleştiğini görmek amacı ile en aza indirilmiş temel ve ölçülmesi çok kolay parametreler ÇKP-YSA yapısında giriş olarak kullanılmıştır. Bu parametreler online olarak da ölçü-



lebilecek nitelikte parametrelerdir. Bu online ölçüm değerleri sistem içerisinde, geliştirilen nöro model yardımı ile hesaplanarak çözünmüş oksijen değeri tahmin edilebilecektir. Böylelikle ölçülen parametre sayısı en aza indirilmiş olacak, birçok parametrenin ölçülmesi için zaman kaybedilmeyecek ve aynı zamanda da analiz maliyetleri olmayacağı için ekonomik olarak büyük tasarruf sağlanacaktır.

Burada sunulan modelin, sadece Kızılırmak Nehri için değil ülkemizdeki bir çok su kalitesi probleminin çözümleri için de kolayca kullanılabilmesi değerlendirilmektedir.

### Semboller

$w_{ij}$	: katlar arasındaki $i$ ve $j$ nöronları arasındaki ağırlık değeri
$\theta$	: eşik değeri
$\alpha$	: öğrenme katsayısı
$\delta_j$	: ara veya çıkış katındaki herhangi bir $j$ nöronuna ait bir faktör
$y_j^{(t)}$	: $t$ katındaki $j$ işlemci elemanının hedef çıkışı
$\bar{\delta}(k)$	: ağırlıklı ortalama
$\kappa$	: öğrenme katsayısı arttırma faktörü
$\varphi$	: öğrenme katsayısı azaltma faktörü
$\mu(k)$	: momentum hızı
$\kappa_\alpha$	: sabit öğrenme hızı skala faktörü
$\varphi_\alpha$	: sabit öğrenme hızı azaltma faktörü
$\gamma_\alpha$	: sabit öğrenme hızı üstel faktörü
$\kappa_\mu$	: sabit momentum hızı skala faktörü
$\varphi_\mu$	: sabit momentum hızı azaltma faktörü
$\gamma_\mu$	: sabit momentum hızı üstel faktörü

### Kaynaklar

Basheer, I.A. ve Najjar, Y.M., (1995). A Neural-network for soil compaction, *Proc. 5th Int. Symp. Numerical Models in Geomechanics*, Davos, Switzerland (eds. Pande, G.N. & Pietruszczak, S.), Rotterdam: Balkema, 435-440.

Camara, AS. ve Randall, C.W., (1984). The QUAL II Model, *Journal of Environmental Engineering*, **110**, 993-996.

Fleming, G., (1975). *Computer Simulation Techniques in Hydrology*, Elsevier, 319, New York.

Haykin, S., (1994). *Neural Networks, A Comprehensive Foundation*, MacMillan College Publishing Comp. Inc., New York.

Karul, C., Soyupak, S. ve Germen E., (1998). A new approach to mathematical water quality modeling reservoirs: Neural Network, *International Review of Hydrobiology*, **83**, 689-696.

Ken-ichi Y., Masaaki H. and Akihiko M., (1997). Novel application of a back-propagation artificial neural network model formulated to predict algal bloom, *Water Science and Technology*, **36**, 89-97.

Little, K.W., Williams, R.F., (1992). Least-Squares Calibration of QUAL2E, *Water Research*, **64**, 179-185.

Martin, J.L., (1988). Application of Two Dimensional Water Quality Model, *Journal of Environmental Engineering*, **114**, 317-336.

Neuralware Handbook, (1996). Neural Computing: A Technology Handbook for Professional II/PLUS and NeuralWorks Explorer, Pittsburg, USA.

O'Connell, R., Thomass, N.A., (1965). Effects of Benthic Algae on Stream Dissolved Oxygen, *Journal of the Sanitary Engineering*, ASCE, **91**, No:SA3.

Rizzo, D.M. ve Dougherty, D.E., (1994). application of artificial neural networks for site characterization using hard and soft information, *Proc. 10th Int. Conf. Computational Methods in Water Resources*, Heidelberg (eds. Peters, A., Wittum, G., Herrling, B., Meissner, U., Brebbia, C.A., Gray, W.G. & Pinder, G.F.), Dordrecht: Kluwer Academic, **12**, 793-799.

Rounds, S. A., (2002). Development of a neural network model for dissolved oxygen in the Tualatin River, Oregon, *In Proceedings of the Second Federal Interagency Hydrologic Modeling Conference*, Las Vegas Nevada.

Rumelhart, D E., McClelland, J. L., (1986). *Parallel Distributed Processing: Explorations in the microstructure of Cognition*, MIT Press, Cambridge, Massachusetts.

Sağiroğlu, Ş., Beşdok, E. ve Erler, M., (2003). Mühendislikte yapay zeka uygulamaları I: Yapay Sinir Ağları, Ufuk Kitap Kırtasiye-Yayıncılık Tic.Ltd.Şti., Kayseri.

Stamou, A.I., (1992). Improving the numerical modeling of river water quality by using high order difference schemes, *Water Research*, **26**, 1563-1570.

Streeter, H., Phelps, E., (1944). *Stream Sanitation*, John Wiley and Co., Newyork.

Thomann, R. V., (1982). Verification of water quality models, *ASCE Journal of the Environmental Engineering Division*, **108**, 923-940.

Whitehead, P. ve Young, P., (1979). Water quality in river systems: Monte Carlo Analysis, *Water Research*, **15**, 451-459.

Williams, B.J. ve Hinwood, J.B., (1976). Two dimensional mathematical water quality model, *ASCE Journal of the Environmental Engineering Division*, **102**, 149-163.