

GÜNLÜK ÇÖZÜNMÜŞ OKSİJEN KONSANTRASYONUNUN ÇOK DEĞİŞKENLİ UYARLANABİLİR REGRESYON EĞRİLERİ İLE TAHMİN EDİLMESİ

Sinan NACAR *^{ID}

Betül METE **^{ID}

Adem BAYRAM **^{ID}

Alınma: 10.06.2020; düzeltme: 15.09.2020; kabul: 04.12.2020

Öz: Bu çalışmada su sıcaklığı (T), özgül iletkenlik (Öİ) verilerinden hesaplanmış elektriksel iletkenlik (Eİ), pH ve debi (Q) verileri kullanılarak çok değişkenli uyarlanabilir regresyon eğrileri (MARS) ve regresyon analizi (RA) yöntemleri ile ÇO konsantrasyonunun tahmin edilmesi amaçlanmıştır. MARS yönteminde en iyi tahmin değerlerini üreten temel fonksiyonlar ve denklemler belirlenmiş, RA yöntemi doğrusal, üs, üstel ve kuadratik olmak üzere dört farklı fonksiyona uygulanmış ve bu fonksiyonlara ait katsayılar hesaplanmıştır. Modelleme çalışmalarında Amerika Birleşik Devletleri'nin Oregon eyaletinin kuzey batısında yer alan Willamette Nehri'nin yan kollarından biri olan ve yaklaşık 2435 km²'lik bir havza alanına sahip Clackamas Nehri'ne ait Eylül 2016 – Ağustos 2017 dönemi günlük ortalama verileri kullanılmıştır. Her bir su kalitesi değişkeninin ÇO konsantrasyonu tahmin performansına etkisini belirlemek amacıyla sekiz farklı model oluşturulmuştur. ÇO konsantrasyonu tahmininde kurulan modellerin ve kullanılan yöntemlerin performanslarının değerlendirilebilmesi için çeşitli istatistikler (ortalama karesel hatanın karekökü, ortalama mutlak hata, saçılım indeksi ve Nash Sutcliffe verimlilik katsayısı) kullanılmıştır. Modelleme çalışmalarından elde edilen sonuçlar irdelendiğinde, MARS yönteminin RA yönteminden daha iyi sonuçlar verdiği anlaşılmıştır. Regresyon fonksiyonları içerisinde ise en başarılı tahmin sonuçlarının kuadratik fonksiyondan elde edildikleri ve MARS yöntemi ile elde edilen değerlere de oldukça yakın oldukları görülmüştür. ÇO konsantrasyonu tahmininde etkili değişkenlerin T ve Q oldukları dolayısıyla en etkisiz değişkenlerin ise Eİ ve pH oldukları anlaşılmıştır. Model 3, Model 5, Model 7 ve Model 8'den elde edilen sonuçların birbirine çok yakın olması sebebiyle daha az değişken ile güçlü tahminler yapması ve daha sade bir model olması bakımından ÇO tahmininde Model 3'ün kullanılmasının daha avantajlı olacağı sonucuna varılmıştır.

Anahtar Kelimeler: Çok değişkenli uyarlanabilir regresyon eğrileri, Çözünmüş oksijen konsantrasyonu, Regresyon analizi

Estimation of Daily Dissolved Oxygen Concentration using Multivariate Adaptive Regression Splines Methods

Abstract: In this study, it is aimed to estimate DO concentration using the river water temperature (WT), electrical conductivity (EC) computed from specific conductance (SC), pH, and discharge (Q) data by employing multivariate adaptive regression splines (MARS) and regression analysis (RA) methods. For this purpose, the basic functions and equations, which yielded the best estimation values in the MARS method, were determined. The RA method was applied to four different functions, namely linear, power,

* Tokat Gaziosmanpaşa Üniversitesi, Mühendislik ve Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Taşlıçiftlik Yerleşkesi, 60150 Taşlıçiftlik /TOKAT

** Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Kanuni Kampüsü, 61080 Ortahisar /Trabzon

İletişim Yazarı: Sinan NACAR (sinan.nacar@gop.edu.tr)

exponential, and quadratic, and the coefficients for these functions were computed. Daily mean data for a period from September 2016 to August 2017 were used in DO modeling studies for the Clackamas River having a basin area of approximately 2435 km², which is one of the tributaries of the Willamette River located in the northwestern state of Oregon, USA. Eight different models were generated to determine the effect of each water-quality parameter on the estimation performance of the river DO concentration. In order to evaluate the performances of the methods and the models used in estimating the river DO concentration, various statistics, e.g. the root mean square error, mean absolute error, scatter index, and Nash Sutcliffe coefficient of efficiency, were used. When the results from the modeling efforts were evaluated, it was seen that the MARS method provided better results than RA method. It was also seen that the most successful estimation results were provided by quadratic function among the regression functions and were also quite close to estimation results provided by the MARS method. It was revealed WT and Q parameters were highly effective, that is to say, EC and pH parameters were highly ineffective in estimating the river DO concentration. The estimation results obtained from Model 3, Model 5, Model 7, and Model 8 were very close to each other. It was concluded that Model 3 with less parameters would be more advantageous to use in the estimation of the river DO concentration owing to being a simpler model but making strong estimations.

Keywords: Multivariate adaptive regression splines, Dissolved oxygen concentration, Regression analysis

1. GİRİŞ

Akarsularda su kalitesi takibi birçok fiziksel, kimyasal ve biyolojik değişkeni içermektedir. Bu değişkenlerden biri olan çözünmüş oksijen (ÇO) konsantrasyonu gerek su kalitesinin belirlenmesinde gerekse sudaki canlıların yaşamını sürdürebilmesi bakımından oldukça önemlidir. 1 mg/L'nin altındaki ÇO konsantrasyon değerleri hipoksik olarak kabul edilmektedir. 5 mg/L'nin altındaki değerler stres etkeni oluşturmakta ve 1-3 mg/L arası konsantrasyonun uzun süreli olarak yaşanması sucul canlılarda ölüme sebebiyet verdiği bilinmektedir. ÇO konsantrasyonunun; balıkların larvalarından çıkması için 6 mg/L, gelişimlerini sağlayabilmeleri için 7 mg/L ve popülasyonun yaşamlarını devam ettirebilmesi için 9 mg/L'den fazla olması gerekmektedir. Nehir, akarsu ve sığ sularda yaşayan canlılar 4-15 mg/L arasında ÇO'ya ihtiyaç duyarlar. Aşırı miktarda ÇO de (>15 mg/L) sucul canlılar için zararlıdır. Bu sebeple ÇO'nun belirlenmesi önem arz etmektedir (Foundriest Environmental, 2013). Rankovic ve diğ. (2010) yapmış oldukları çalışmada ÇO konsantrasyonu değerlerinin su ekosistemlerinin metabolizmaları hakkında diğer tüm tekil değişkenlerden daha fazla bilgi sağlayabileceğini ifade etmişlerdir. Ayrıca ÇO konsantrasyonunun atmosferden sağlanan oksijen ile fotosentez ve oksijen tüketen diğer metabolik süreçler arasındaki dengeyi gösteren önemli bir değişken olduğu ifade edilmektedir (Kalff, 2002). Tüm bu nedenlerle akarsularda ÇO konsantrasyonunun belirlenmesi konusu son yıllarda araştırmacıların ilgisini çekmiş (Sarkar ve Pandey, 2015), akarsu ve nehirlerdeki ÇO konsantrasyonu dinamiklerini anlamak için çok fazla araştırma yapılmıştır (Liu ve diğ., 2016; Nacar ve diğ., 2016; Murrell ve diğ., 2018; Post ve diğ., 2018). Yapılan bu çalışmalar ışığında su kalitesinin belirlenmesinde kullanılan ÇO konsantrasyonunun, yüzey sularının fiziksel, kimyasal ve biyolojik faktörlerden veya bu faktörlerin kombinasyonlarından önemli ölçüde etkilendiği belirlenmiştir (Spanou ve Chen, 2000; Mulholland ve diğ., 2005; Sanchez ve diğ., 2007; Heddam, 2016). Bayram ve Kankal (2015) tarafından yapılan çalışmada yüzey sularındaki ÇO konsantrasyonunu etkileyen en önemli etkenlerden birinin su sıcaklığı (T) olduğu ifade edilmiştir. Sıcaklığın artması sudaki oksijenin çözünürlüğünü azaltmaktadır. Bu ilişkiye dayanarak soğuk suda çözünen oksijen miktarının sıcak sulara oranla daha yüksek olduğunu söylemek mümkündür. Bu durumda sıcaklıkların düşük olduğu kış aylarında yüzey sularındaki ÇO konsantrasyonu artarken sıcaklıkların yüksek olduğu yaz aylarında ise azalmaktadır. Su sıcaklığı, su ortamında bulunabilecek en yüksek miktardaki ÇO konsantrasyonunu ifade eden doygunluk konsantrasyonunu etkileyen önemli bir değişkendir. Sıcaklığın artması ile oksijenin sudaki çözünürlüğü azalır. Bu sebeple aynı doygunluktaki sulardan daha soğuk olan daha fazla ÇO tutma kapasitesine sahip olacaktır. Su içerisinde gerçekleşen fotosentez veya hızlı bir sıcaklık

değişimi ÇO doygunluğunun %100'ün üzerine çıkmasına sebep olabilmektedir. ÇO konsantrasyonu ayrıca elektriksel iletkenliğe de (Eİ) bağlıdır. Düşük T, Eİ ve yüksek atmosfer basıncı, sudaki ÇO konsantrasyonunu artıran faktörlerdir (Lewis, 2006).

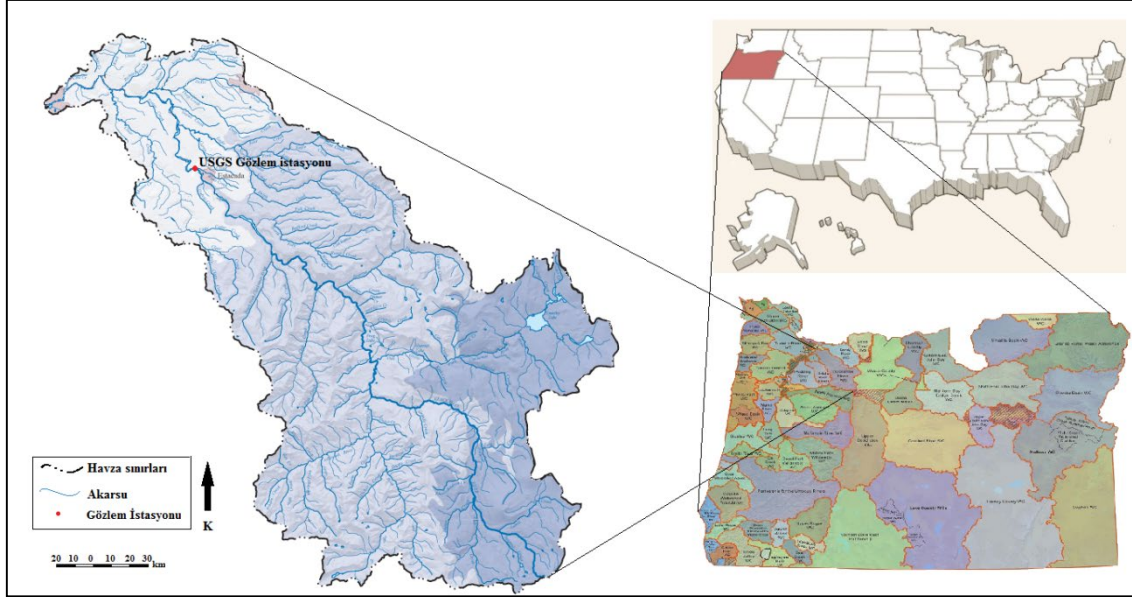
Akarsuların su kalitelerinin belirlenmesinde ve su kaynaklarının yönetiminde ÇO konsantrasyonunun sürekli takibi oldukça önemlidir. Akarsularda ÇO konsantrasyonu değişiminin sürekli belirlenmesinin zamansal ve ekonomik bakımdan zahmetli olması, araştırmacıları diğer su kalitesi değişkenlerine bağlı olarak ÇO konsantrasyonu değişimini belirlemeye yönelik çalışmalara yönlendirmiştir. Bu durum farklı su kalitesi değişkenlerini kullanarak ÇO konsantrasyonu değerlerini tahmin etmeye yönelik yapılan çalışmaların temel nedeni olmuştur (Cox, 2003a; Cox, 2003b; Heddam ve Kisi, 2018). Yerüstü sularında ÇO konsantrasyonunu ve su kalitesini tahmin etmeye yönelik yapılan çalışmalarda birçok yöntem kullanılmıştır. Yapay sinir ağları (Panepinto ve Genon, 2010), Mike 11 (Radwan ve diğ., 2003; Kanda ve diğ., 2016), uyarlanabilir bulanık mantık yöntemleri (Najah ve diğ., 2014; Ay ve Kisi, 2017) ve çok değişkenli istatistiksel yöntemler (Singh ve diğ., 2004; Zhang ve diğ., 2009; Bu ve diğ., 2010; Akbal ve diğ., 2011) bunlardan bazılarıdır. Çok değişkenli uyarlanabilir regresyon eğrileri (MARS) yönteminin en büyük üstünlüğü hem bağımsız değişkenlerin bireysel etkilerini hem de birbirleriyle etkileşimlerini modelde tanımlaması ve grafiklerle sunmasıdır. Bu sayede açıklayıcı değişkenlerin modeldeki önemlerinin belirlenmesini mümkün kılmaktadır (Friedman, 1991). Bu kapsamda farklı mühendislik problemlerinin çözümünde başarıyla uygulanmış olan, bağımlı ve bağımsız değişkenler arasındaki fonksiyonel ilişkiye dair varsayımlarda bulunmayan ve parametrik olmayan bir regresyon yöntemi olan MARS yöntemi kullanılmıştır. Son yıllarda yapılan çalışmalar incelendiğinde, Samui (2013) birleştirilmiş kaya kütlelerinin elastik modülünün tahmininde, Kisi (2015) buharlaşma tahmininde, Kisi vd. (2017) hava kirleticilerin modellenmesinde, Heddam ve Kisi (2018) ÇO konsantrasyonu modellemesinde, Yılmaz vd. (2018) askıda katı madde yükünü tahmin etmede MARS yöntemini kullanmışlar ve elde edilen sonuçların başarılı olduğu sonucuna ulaşmışlardır.

Bu çalışmada ÇO konsantrasyonu değerlerinin T, Eİ, pH ve debi (Q) değişkenlerine ait veriler ile tahmin edilmesi amaçlanmıştır. Çalışmada Clackamas Nehri'nin, Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu (USGS) tarafından kullanıma sunulan, Eylül 2016-Ağustos 2017 dönemine ait günlük ölçülmüş verileri kullanılmıştır. Bu amaçla T, Eİ, pH ve Q değişkenleri ile sekiz farklı girdi modeli oluşturulmuş, MARS ve regresyon analizi (RA) yöntemleri kullanılmıştır.

2. KULLANILAN VERİLER VE YÖNTEMLER

2.1. Çalışma Alanı

Çalışma alanı olarak Oregon (ABD) eyaletinin kuzey batısında yer alan, Willamette Nehri'nin yan kolu olan Clackamas Nehri seçilmiştir. 134 km ana kol uzunluğuna ve 2435 km²'lik havza alanına sahip nehir çoğunlukla ormanlık ve engebeli araziden akmaktadır (Şekil 1). Yüksek dağlık alanlardan düz vadilere kadar su kalitesini etkileyen çeşitli hidrolojik ve kimyasal faktörleri şekillendiren; iklim, jeoloji, toprak ve bitki örtüsünün farklı kombinasyonlarından oluşan beş alt havzaya sahiptir. Willamette Nehri ile birleşmeden önceki son üçte birlik kısmında daha düz tarım arazilerinden ve yerleşim yerlerinden geçen Clackamas Nehri Portland (Oregon, ABD) şehrinin elektrik ve içme suyu ihtiyacının bir bölümünü karşılamaktadır. Havzadaki kereste hasadı, yol yapımı ve kentsel gelişmeler, tarım, çakıl madenciliği ve hidroelektrik enerji üretimi gibi insani faaliyetler nehrin su kalitesini etkileyen nedenler arasında yer almaktadır. Clackamas Nehri'nde ayrıca bazı dönemlerde özellikle kış aylarındaki şiddetli yağışlar sonrası havzanın üst bölümlerinde meydana gelen taşkınlarla yüksek düzeyde bulanıklık gibi su kalitesi sorunlarıyla da karşılaşmaktadır (Carpenter, 2003; Khani ve Rajae, 2017).



Şekil 1:
Clackamas Nehri Havzası, Oregon, ABD

2.2. Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (MARS)

MARS yöntemi Freidman (1991) tarafından geliştirilen ve parametrik olmayan, bağımlı ve bağımsız değişkenler arasındaki fonksiyonel ilişkiye dair varsayımlarda bulunmayan bir regresyon yöntemidir. Bunun yerine regresyon verisinden kendisinin çıkardığı temel fonksiyonlara dayanarak yeni bir ilişki oluşturmaktadır. MARS yöntemi bağımsız değişkenlerin farklı aralıklarına karşılık gelen temel fonksiyonları kullanarak esnek bir regresyon modeli kurmaktadır (Toprak, 2011; Nacar ve diğ., 2018b). Genel bir MARS modeli Eşitlik 1 ile ve her bir temel fonksiyon Eşitlik 2 ile tanımlanabilir (Özbalcı, 2008);

$$Y = \beta_0 + \sum_{k=1}^K a_k \beta_k(X_t) + \varepsilon_i \quad (1)$$

Burada;

- k : düğüm sayısı,
- K : temel fonksiyon sayısı,
- X : bağımsız değişken,
- a_k : k. temel fonksiyonun kat sayısı,
- β_0 : modeldeki sabit terim,
- $\beta_k(X_t)$: t. bağımsız değişken için k. temel fonksiyon,
- ε_i : hata miktarıdır.

$$B_m(x) = \prod_{t=1}^{L_m} [S_{1,m}(x_{v(1,m)} - k_{1,m})] \quad (2)$$

Burada;

- L_m : etkileşim derecesi,
- $S_{1,m}$: $\in[\pm 1]$,
- $k_{1,m}$: düğüm değeri,
- $x_{v(1,m)}$: bağımsız değişken değeridir.

MARS yönteminde en doğru sonuçları veren model elde edilene kadar devam eden iki aşamalı bir süreç vardır. İlk aşamada mümkün olan tüm temel fonksiyonlar oluşturulur. Çok büyük bir model bulununcaya kadar yani modelin karmaşıklığı maksimum seviyeye ulaşıncaya kadar eklenen temel fonksiyonlarla model geliştirilir. İkinci aşamada oluşturulan maksimum model budanarak yani önemli bağımsız değişkenler ve bu değişkenlerin karşılıklı etkileşimleri belirlenerek hata miktarı en küçük olan en uygun model oluşturulur (Ünal, 2009). MARS yöntemi ile ilgili daha detaylı bilgiler Yılmaz ve diğ. (2018) yapmış olduğu çalışmada bulunabilir.

2.3. Regresyon Analizi

İki ya da daha fazla sayıdaki değişkenin aynı gözlem sırasında aldıkları değerler istatistiksel olarak birbirinden bağımsız değildir. Bir başka deyişle bir mühendislik probleminde yer alan bağımsız değişkenlerin birbirleriyle ilişkili olduğu görülür. Bağımlı ve bağımsız değişkenler arasındaki ilişkiler fonksiyonel değildir. Yani bağımsız değişkenlerden biri bir değer aldığında diğer değişkenler bu değere karşılık daima aynı değeri almaz. Değişkenler arasındaki fonksiyonel olmayan bu tür ilişkilerin ortaya çıkarılması mühendislik problemlerinin çözümünde oldukça önemlidir. Değişkenler arasındaki ilişkiyi ifade eden matematiksel ifadelere regresyon denklemi denir (Bayazıt ve Yeğen, 2005). Çalışma kapsamında kullanılan fonksiyonlar Eşitlik 3-6 ile verilmektedir.

$$y_{Dogrusal} = w_0 + w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n \quad (3)$$

$$y_{Üs} = w_0x_1^{w_1}x_2^{w_2}x_3^{w_3}x_4^{w_4} \dots x_n^{w_n} \quad (4)$$

$$y_{Üstel} = w_0 + \exp(w_1 + w_2x_1 + w_3x_2 + \dots + w_{n+1}x_n) \quad (5)$$

$$y_{Kuadratik} = w_0 + w_1x_1 + w_2x_2 + \dots + w_5x_1x_2 + w_6x_1x_3 + \dots + w_{11}x_1^2 + w_{12}x_2^2 + \dots + w_{14}x_4^2 \quad (6)$$

Bu eşitliklerde w 'ler regresyon katsayılarını, x 'ler bağımsız değişkenleri ve y 'ler ise ÇO konsantrasyonunu ifade etmektedir. Bir değişkenin değerini bir veya daha fazla değişken kullanarak en iyi şekilde tahmin etmeye yarayan matematiksel ifadenin belirlenmesine de RA denilmektedir (Bayazıt, 1981). RA bir mühendislik probleminde yer alan değişkenler arasında anlamlı bir ilişki olup olmadığını belirlemek, eğer anlamlı bir ilişki bulunuyorsa bu ilişkiyi matematiksel olarak ifade etmek ve bu eşitlikleri kullanarak yapılacak tahminlerin güven aralıklarını belirlemektedir (Şentürk, 2008).

2.4. Model Uygulamaları

ÇO konsantrasyonu tahmininde kullanılacak su kalitesi değişkenlerinin doğru belirlenmesi model sonuçlarını doğrudan ilgilendiren önemli bir konudur. ÇO konsantrasyonu modellemesi konusunda son yıllarda yapılmış olan çalışmalar Tablo 1'de verilmektedir. En fazla kullanılan su kalitesi değişkenlerinin sırasıyla pH, T, Q ve iletkenlik (elektriksel ya da özgül) olduğu bu tabloda görülmektedir.

Tablo 1. Çözünmüş oksijen konsantrasyonu tahmini yapılan çalışmalar ve kullanılan su kalitesi değişkenleri

Yazarlar	Yıl	Su kalitesi değişkenleri																							
		Q	T	pH	Eİ	Öİ	WD	TS	TA	WH	AT	NO ₂ ⁻	NO ₃ ⁻	NH ₄ ⁺	PO ₄ ³⁻	TP	KOİ	SO ₄ ²⁻	Na ⁺	K ⁺	Ca ²⁺	Cl ⁻	BOİ		
Chen ve Li	2008	*	*	*																					
Singh vd.	2009			*				*	*	*			*	*	*		*		*	*			*		
Ay ve Kisi	2012	*	*	*	*																				
Wen vd.	2013			*	*					*	*			*	*							*	*		
Antanasijevic vd.	2013	*	*	*	*																				
Kisi vd.	2013	*	*	*		*																			
Heddām	2014a		*	*		*	*																		
Heddām	2014b		*	*		*	*																		
Heddām	2014c		*	*		*	*																		
Nemati vd.	2015		*	*	*						*	*	*		*								*		
Bayram ve Kankal	2015		*	*																					
Kanda vd.	2016		*	*	*					*															
Olyae vd.	2017	*	*	*	*																				
Heddām ve Kisi	2018	*	*	*		*																			
Elkiran vd.	2018		*	*																					*
Yaseen vd.	2018	*	*	*		*																			
Csabragi vd.	2019	*	*	*	*																				
Kisi vd.	2020		*	*		*																			
Nacar vd.	2020		*	*	*																				

Bu çalışmada Tablo 1’de yer alan çalışmalar dikkate alınarak T, Eİ, Q ve pH değişkenlerinin bağımsız değişkenler olarak kullanılmasına karar verilmiştir. Çalışma kapsamında kullanılan değişkenlere ait Pearson korelasyon katsayıları Tablo 2’de verilmektedir.

Tablo 2. Su kalitesi değişkenlerine ait korelasyon katsayıları

	ÇO	T	Eİ	Q
T	-0,971			
Eİ	-0,913	0,874		
Q	0,648	-0,492	-0,692	
pH	0,254	-0,351	-0,055	-0,323

Tablo 2 incelendiğinde T’nin ÇO konsantrasyonu ile negatif fakat yüksek korelasyon katsayısına sahip olduğu ve bunun yanında ÇO konsantrasyonu ile en düşük korelasyon katsayısına sahip olan değişkenin pH olduğu görülmektedir. ÇO konsantrasyonu tahmininde kullanılacak değişkenlerin tahmin performanslarına olan katkılarının belirlenebilmesi için sekiz farklı model oluşturulmuştur. Bu modellerde ÇO konsantrasyonu ile en yüksek korelasyona sahip olan T sabit tutulmuş diğer değişkenler ise sırasıyla dahil edilmiştir. Bu şekilde bir, iki, üç ve dört bağımsız değişkene sahip birçok model denenmiştir. Çalışmada kullanılan modeller Tablo 3’te verilmektedir.

Tablo 3’te verilen modellerde yer alan değişkenler yardımıyla ÇO konsantrasyonu değerlerini RA yöntemi ile tahmin etmek için biri doğrusal (LF) ve üçü doğrusal olmayan toplamda dört farklı fonksiyon kullanılmıştır. Doğrusal olmayanlar sırası ile üs (ÜF), üstel (EF) ve kuadratik (KF) fonksiyonlarıdır.

Tablo 3. Çözünmüş oksijen konsantrasyonu tahmini için kurulan modeller

Model	Kısaltma	Bağımsız Değişkenler			
Model 1	M1	T			
Model 2	M2	T	Eİ		
Model 3	M3	T	Q		
Model 4	M4	T	pH		
Model 5	M5	T	Eİ	Q	
Model 6	M6	T	Eİ	pH	
Model 7	M7	T	Q	pH	
Model 8	M8	T	Eİ	Q	pH

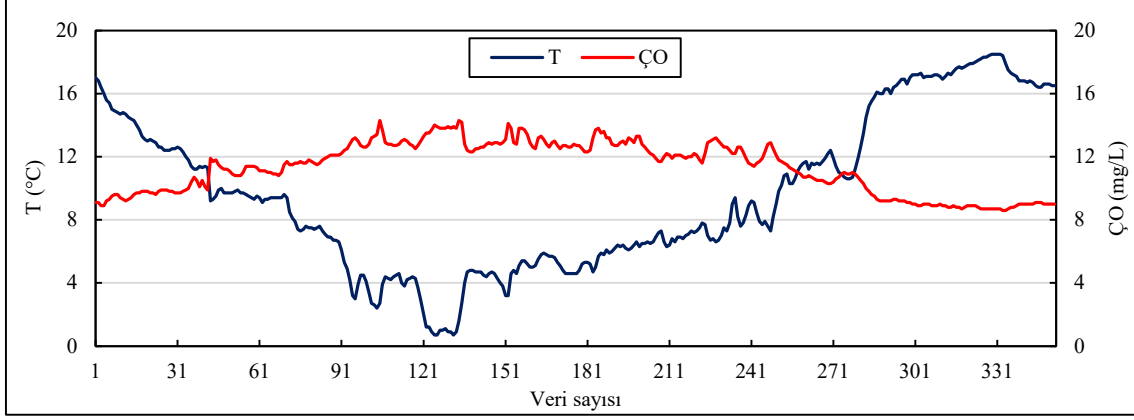
Çalışma kapsamında ABD'nin Oregon Eyaletindeki Clackamas Nehri'nde ölçülen ve kaydedilen günlük ortalama T, Eİ, Q, pH ve ÇO su kalitesi değişkenlerine ait veriler USGS'nin web sayfasından (<https://waterdata.usgs.gov/nwis/>) temin edilmiştir. Çalışmada kullanılan ve Eylül 2016-Ağustos 2017 dönemine ait 352 adet verinin 232'si (yaklaşık 2/3'ü) modellerin eğitim aşamasında, geriye kalan kısım ise modellerin test aşamasında kullanılmıştır. Verileri eğitim ve test gruplarına ayırırken her ayın ilk 20 günü eğitim veri setine, geri kalan 10 günü ise test veri setine dahil edilmiştir. Böylece her iki veri setinde de tüm yılı temsil edebilecek verilerin olması sağlanmıştır. Palani ve diğ., (2008) tarafından ifade edilen yaklaşıma göre modelleme çalışmalarında iyi bir eğitim veri seti elde etmek için tüm ekstrem durumların eğitim veri setinde yer alması gerekmektedir. Bu sebeple veriler eğitim ve test setlerine ayrılırken bu yaklaşım da göz önünde bulundurulmuştur. Eğitim, test ve tüm verilere ait temel istatistikler Tablo 4'de verilmektedir.

Tablo 4. Takibi yapılan su kalitesi değişkenlerine ait temel istatistikler


Veri seti	Değişken	Birim	En küçük	Ortalama	En büyük	Standart sapma
Tümü	T	°C	0,70	9,60	18,50	4,92
	Eİ	µS/cm	18,14	35,37	58,46	11,88
	Q	m ³ /s	19,40	89,47	495,54	72,15
	pH	-	7,20	7,46	7,60	0,08
	ÇO	mg/L	8,60	11,30	14,30	1,62
Eğitim	T	°C	2,40	9,74	18,50	4,60
	Eİ	µS/cm	18,14	35,25	58,46	12,18
	Q	m ³ /s	19,40	95,32	495,54	79,95
	pH	-	7,20	7,45	7,60	0,08
	ÇO	mg/L	8,60	11,30	14,30	1,58
Test	T	°C	0,70	9,33	17,90	5,49
	Eİ	µS/cm	21,40	35,63	55,32	11,26
	Q	m ³ /s	23,05	77,72	238,14	51,15
	pH	-	7,30	7,47	7,60	0,08
	ÇO	mg/L	8,70	11,31	14,30	1,72

Tablo 4 incelendiğinde T dışındaki değişkenlerin en küçük ve en büyük değerlerinin eğitim veri seti içerisinde yer aldığı görülmektedir. Bu durum veri setinin eğitim ve test setlerine uygun bir şekilde ayrıldığını göstermektedir. Tablodan ortalama su sıcaklığının 9,6 °C, ÇO konsantrasyonunun ise 11,3 mg/L olduğu görülmektedir. En yüksek ÇO konsantrasyonu 14,3 mg/L olarak, T'nin 2,4 °C ile en düşük olduğu ölçümden elde edildiği anlaşılmıştır. Tatlı sular %100 ÇO doygunluğu durumunda 2,4 °C'de yaklaşık olarak 13,6 mg/L ÇO ihtiva ederler. Dolayısıyla 14,3 mg/L'lik (%105,1) değer aşırı doygunluğun söz konusu olduğunu ortaya koymaktadır. Bu durum akarsularda ÇO doygunluğunun türbülanslı akımdan kaynaklanan doğal havalandırma ve aşırı fotosentetik faaliyetler nedeniyle %100'e yakın veya bu değerlerin bir miktar üzerinde olma eğiliminde olmasıyla açıklanabilmektedir. Aşırı doygunluk durumu balıklarda gaz kabarcığı hastalığına neden olduğu bilinmektedir. ÇO doygunluğunun bir süre boyunca %115-

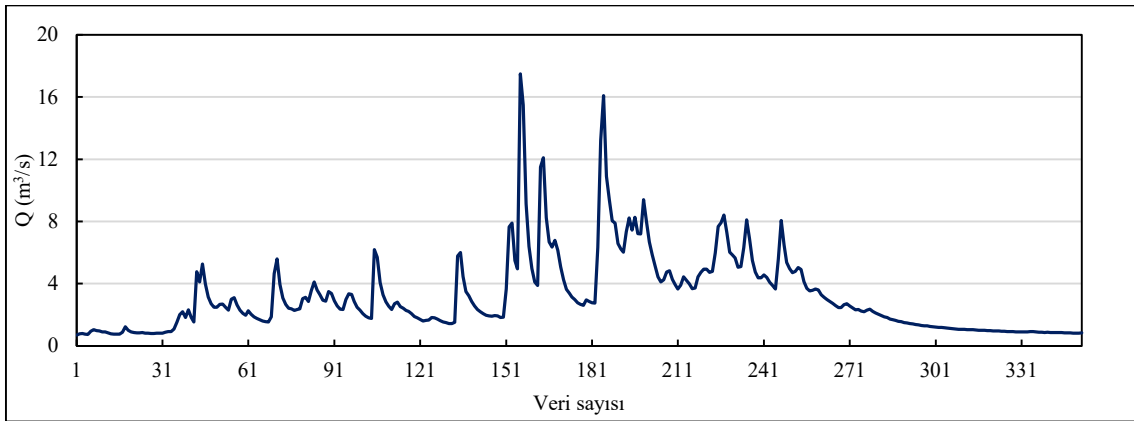
120 seviyelerinde kalması sudaki canlıların ölümlerine neden olabilmektedir (EPA, 1986). Tüm verilere ait zaman serileri Şekil 2’de verilmektedir.



(a)



(b)



(c)

Şekil 2:
Clackamas Nehri Havzası 'nda (ABD) USGS tarafından işletilen gözlem istasyonundan elde edilen günlük (a) ÇO-T, (b) Eİ-pH, (c) Q değişkenlerine ait zaman serileri (01.09.2016-31.08.2017)

Çalışmada kullanılacak veri setinde bulunan uç değerlerin modellenmesi zor olabilmektedir. Modellemeleri kolaylaştırmak, farklı boyutların etkisini en aza indirmek ve daha etkili sonuçlar elde etmek için bağımlı ve bağımsız değişkenlere ait verilerin tamamı Eşitlik 7 kullanılarak normalize edilmiştir (Bayram ve diğ., 2012; Fetene ve diğ., 2018; Nacar ve diğ., 2018a). Su kalitesi modelleme çalışmalarında normalizasyon için farklı bağıntılar kullanılmaktadır. Yapılan çalışmada verilerin normalizasyonu için Eşitlik 7 kullanılmıştır.

$$X_n = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \times a + b \quad (7)$$

Burada, X_n normalize değeri, X_{\min} en küçük değeri ve X_{\max} en büyük değeri ifade etmektedir. Bu çalışmada a ve b katsayıları sırasıyla 0,8 ve 0,1 olarak seçilmiştir. Böylece modellemede kullanılan tüm veriler 0,1-0,9 arasında normalize edilmiştir.

Eşitlik 3-6'da verilen regresyon katsayılarını belirlemek için kullanılan RA, IBM SPSS statistics 25 programı kullanılarak gerçekleştirilmiştir. Regresyon katsayıları belirlendikten sonra eşitliklerde bu katsayılar yerlerine yazılarak test veri seti için model tahmin sonuçları hesaplanmıştır. Daha sonra aynı eğitim veri setine MARS yöntemi uygulanmış ve en düşük hata değerlerini veren temel fonksiyonlar (TF) ve denklemler (Y_M) elde edilmiştir. Elde edilen TF'ler ve Y_M 'ler kullanılarak test veri seti için model tahmin sonuçları hesaplanmıştır.

Kullanılan yöntemlerin ve modellerin tahmin performanslarını karşılaştırmak amacıyla ortalama karesel hatanın karekökü (OKHK), ortalama mutlak hata (OMH), saçılım indeksi (SI) ve Nash Sutcliffe verimlilik katsayısı (NS) istatistikleri Eşitlik 8-11 kullanılarak hesaplanmıştır.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2} \quad (8)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |(t_i - td_i)| \quad (9)$$

$$SI = \frac{RMSE}{\bar{t}} \quad (10)$$

$$NSCE = 1 - \frac{\sum_{i=1}^N (t_i - td_i)^2}{\sum_{i=1}^N (t_i - \bar{t})^2} \quad (11)$$

Bu eşitliklerde, t_i ölçüm değerlerini, td_i tahmin değerlerini, \bar{t} ölçüm değerleri ortalamasını ve N veri adedini temsil etmektedir.

3. BULGULAR VE İRDELEME

Çalışma kapsamında ilk olarak regresyon analizleri gerçekleştirilmiş ve kullanılan LF, ÜF, EF ve KF regresyon formlarına ait katsayılar belirlenmiştir. Her bir su kalitesi değişkeninin ÇO konsantrasyonu tahminindeki önemini belirlemek için kurulan sekiz modele ait elde edilen katsayılar her bir fonksiyon için Tablo 5'te verilmektedir. Daha sonra bu sekiz modele MARS yöntemi uygulanmış ve her bir modele ait TF'ler ve bu fonksiyonlar kullanılarak elde edilen denklemler belirlenmiştir. Modellere ait TF'ler Tablo 6'da, bu TF'ler kullanılarak elde edilen en düşük hata değerlerini veren denklemler Tablo 7'de verilmektedir. Ayrıca her bir model için elde edilen denklemlerde model içinde kullanılan su kalitesi değişkenlerinin denklemlerdeki göreceli önemini gösteren %'lik değerler Tablo 8'de verilmektedir.

Tablo 5. Regresyon analizinden elde edilen doğrusal, üs, üstel ve kuadratik fonksiyonlara ait katsayılar

Model	Fonksiyon	Regresyon analizinden elde edilen katsayılar															
		w ₀	w ₁	w ₂	w ₃	w ₄	w ₅	w ₆	w ₇	w ₈	w ₉	w ₁₀	w ₁₁	w ₁₂	w ₁₃	w ₁₄	
M1	LF	1,0033	-1,0361														
	ÜF	0,2310	-0,8745														
	EF	-7,9240	2,1910	-0,1239													
	KF	1,0216	-1,1148	0,0720													
M2	LF	0,9816	-0,7614	-0,2670													
	ÜF	0,1776	-0,6081	-0,4427													
	EF	-0,1099	0,3565	-1,1925	-0,8363												
	KF	1,1833	-0,9890	-1,0025	0,0764	0,1932	0,6307										
M3	LF	0,8295	-0,8830	0,4234													
	ÜF	0,4197	-0,7451	0,3241													
	EF	-5,9203	1,9120	-0,1400	0,0638												
	KF	0,8990	-1,4559	0,5897	0,7183	0,4869	-0,4946										
M4	LF	1,0897	-1,0515	-0,1294													
	ÜF	0,1836	-0,9617	-0,2797													
	EF	-0,6548	0,7049	-0,9842	-0,1659												
	KF	1,4535	-1,8858	-0,6340	0,6429	0,3819	0,1426										
M5	LF	0,8395	-0,8240	-0,0709	0,3850												
	ÜF	0,2519	-0,6489	-0,2860	0,1407												
	EF	-0,6671	0,4928	-0,6924	-0,1766	0,2282											
	KF	0,8447	-1,5198	0,2417	0,8259	-0,4353	0,6388	-0,5047	0,7526	0,0738	-0,6151						
M6	LF	1,0137	-0,7999	-0,2347	-0,0441												
	ÜF	0,1854	-0,5019	-0,5588	0,1502												
	EF	-0,1445	0,4092	-1,2069	-0,6951	-0,0652											
	KF	1,2645	-1,0576	-0,9355	-0,2568	0,0906	0,0533	0,0607	0,2152	0,5307	0,1570						
M7	LF	0,7784	-0,8618	0,4654	0,0506												
	ÜF	0,4654	-0,7163	0,3554	0,0579												
	EF	-15,0834	2,7645	-0,0558	0,0293	0,0030											
	KF	0,6475	-0,9899	1,2051	0,1494	0,2054	-0,2180	-0,3154	0,2943	-0,8011	0,0551						
M8	LF	0,7695	-0,7667	-0,1025	0,4291	0,0739											
	ÜF	0,2977	-0,5211	-0,3904	0,1851	0,1993											
	EF	-0,7168	0,4688	-0,6184	-0,1913	0,2535	0,0514										
	KF	0,7030	-0,8624	-0,0726	0,9867	0,0507	-0,0548	0,1889	-0,3656	-0,5701	0,2160	0,0686	0,3000	0,0070	-0,6300	0,0617	

Tablo 6. MARS yönteminden elde edilen modellere ait temel fonksiyonlar

Model	Temel Fonksiyon	Model	Temel Fonksiyon	Model	Temel Fonksiyon
M1		M2		M3	
TF01	(T-0,329213)	TF01	(T-0,329213)	TF01	(T-0,329213)
TF02	(0,329213-T)	TF02	(0,329213-T)	TF02	(0,329213-T)
TF04	(0,657303-T)	TF03	(Eİ-0,30248)	TF04	(0,442789-Q)
TF06	(0,266292-T)	TF04	(0,30248-Eİ)	TF05	(T-0,625843) × TF04
TF08	(0,38764-T)	TF08	(0,634831-T)	TF06	(0,625843-T) × TF04
TF09	(T-0,549438)	TF09	(Eİ-0,200218) × TF02	TF07	(Q-0,156378)
TF11	(T-0,306742)			TF08	(0,156378-Q)
TF12	(0,306742-T)			TF10	(0,567416-T) × TF07
TF14	(0,634831-T)			TF11	(Q-0,238686)
TF15	(T-0,176404)				
M4		M5		M5 Devamı	
TF01	(T-0,329213)	TF01	(T-0,324719)	TF14	(0,310051-Q)
TF02	(0,329213-T)	TF02	(0,324719-T)	TF15	(Q-0,168272)
TF04	(0,657303-T)	TF03	(Q-0,443265)	TF16	(0,168272-Q)
TF05	(pH-0,7) × TF04	TF04	(0,443265-Q)	TF18	(0,190158-Q) × TF01
TF06	(0,7-pH) × TF04	TF05	(T-0,630337) × TF04	TF19	(T-0,477528) × TF16
TF07	(T-0,306742)	TF06	(0,630337-T) × TF04	TF20	(0,477528-T) × TF16
TF08	(0,306742-T)	TF07	(T-0,365169) × TF03	TF21	(T-0,275281) × TF14
TF09	(pH-0,7) × TF08	TF08	(0,365169-T) × TF03		
TF10	(0,7-pH) × TF08	TF09	(Q-0,254862)	M6	
TF11	(T-0,567416)	TF10	(0,254862-Q)	TF01	(T-0,324719)
TF12	(0,567416-T)	TF11	(T-0,320225) × TF04	TF02	(0,324719-T)
TF13	(T-0,401124)	TF12	(0,320225-T) × TF04	TF03	(Eİ-0,30248)
TF14	(0,401124-T)	TF13	(Q-0,310051)	TF04	(0,30248-Eİ)
				TF08	(0,634831-T)
				TF09	(Eİ-0,205979) × TF02
M7		M7 Devamı		M8 Devamı	
TF01	(T-0,324719)	TF12	(0,320225-T) × TF04	TF11	(Q-0,24154) × TF02
TF02	(0,324719-T)	TF13	(Q-0,310051)	TF12	(0,24154-Q) × TF02
TF03	(Q-0,443265)	TF14	(0,310051-Q)	TF13	(Q-0,37523) × TF01
TF04	(0,443265-Q)	TF15	(T-0,176404) × TF14	TF15	(Q-0,261047)
TF05	(T-0,630337) × TF04	M8		TF18	(0,396629-T) × TF15
TF06	(0,630337-T) × TF04	TF01	(T-0,324719)	TF20	(0,308147-Q) × TF01
TF07	(T-0,365169) × TF03	TF02	(0,324719-T)	TF22	(0,141629-Q)
TF08	(0,365169-T) × TF03	TF03	(Q-0,442789)	TF25	(Eİ-0,182815) × TF18
TF09	(Q-0,254862)	TF04	(0,442789-Q)	TF26	(0,182815-Eİ) × TF18
TF10	(0,254862-Q)	TF06	(0,630337-T) × TF04	TF27	(Eİ-0,163931) × TF07
TF11	(T-0,320225) × TF04	TF07	(Q-0,157806)	TF28	(0,163931-Eİ) × TF07
		TF08	(0,157806-Q)		

Tablo 7. MARS yönteminden elde edilen modellere ait denklemler

$Y_{M1} = 0.53214 - 0.20733 \times TF01 - 0.53603 \times TF02 + 0.26368 \times TF04 + 0.90882 \times TF06 + 0.27237 \times TF08 - 0.24416 \times TF09 - 0.18769 \times TF11 - 0.41620 \times TF12 + 0.27469 \times TF14 - 0.16121 \times TF15$
$Y_{M2} = 0.51922 - 0.49948 \times TF01 - 0.21687 \times TF03 + 1.03544 \times TF04 + 0.30710 \times TF08 + 7.90582 \times TF09$
$Y_{M3} = 0.73920 - 1.32650 \times TF01 + 1.79160 \times TF02 + 2.09100 \times TF05 - 1.78520 \times TF06 + 0.33640 \times TF07 - 1.41600 \times TF08 - 2.39620 \times TF10 + 0.40162 \times TF11$
$Y_{M4} = 0.48776 - 0.17939 \times TF01 + 0.00511 \times TF02 + 0.24631 \times TF04 + 0.53003 \times TF08 - 0.68283 \times TF09 - 7.00713 \times TF10 - 0.26291 \times TF11 + 0.22620 \times TF12 - 0.20622 \times TF13 - 0.05364 \times TF05 + 1.07624 \times TF06 - 0.16105 \times TF07 + 0.18979 \times TF14$
$Y_{M5} = 0.61857 - 0.35553 \times TF01 + 1.28447 \times TF02 - 0.29474 \times TF03 - 0.30634 \times TF04 - 0.26921 \times TF05 + 0.98089 \times TF06 - 67.42780 \times TF07 - 3.44681 \times TF08 + 0.38556 \times TF09 + 0.30971 \times TF10 - 0.56212 \times TF11 - 0.27940 \times TF12 + 0.11912 \times TF13 - 0.31802 \times TF14 + 0.13870 \times TF15 - 0.79318 \times TF16 + 0.85057 \times TF18 + 0.33894 \times TF19 + 7.70070 \times TF20 - 0.43711 \times TF21 - 5.13701 \times TF22$
$Y_{M6} = 0.52145 - 0.49848 \times TF01 - 0.21778 \times TF03 + 1.02954 \times TF04 + 0.30746 \times TF08 + 8.54272 \times TF09$
$Y_{M7} = 0.64058 - 0.36564 \times TF01 + 1.46152 \times TF02 - 0.22264 \times TF03 - 0.32687 \times TF04 + 0.10931 \times TF05 + 1.08250 \times TF06 - 65.28200 \times TF07 - 3.74640 \times TF08 + 0.46200 \times TF09 + 0.39698 \times TF10 - 0.56950 \times TF11 - 2.71983 \times TF12 + 0.12109 \times TF13 - 0.39068 \times TF14 - 0.65060 \times TF15$
$Y_{M8} = 0.68110 - 0.40395 \times TF01 + 1.00177 \times TF02 - 0.30356 \times TF03 - 0.60545 \times TF04 + 1.10321 \times TF06 - 0.96966 \times TF08 + 2.83791 \times TF11 - 1.78458 \times TF12 - 4.45471 \times TF13 + 0.52021 \times TF15 - 1.44033 \times TF18 - 1.11935 \times TF20 + 1.08434 \times TF22 + 14.84000 \times TF25 + 43.97730 \times TF26 - 1.43060 \times TF27 - 3.69887 \times TF28$

Tablo 6’da MARS yönteminin eğitim verilerine dayalı olarak belirlendiği optimum sayıdaki fonksiyonlar, Tablo 7’de ise bu TF’lerden oluşturulan denklemler verilmektedir. İki değişken ile kurulan tüm modellerde her iki değişken de denklemlere dahil edilmiştir. MARS yöntemi belirlenen tüm modellerde T değişkenini dikkate alırken Model 4 haricinde pH değişkenini içeren modellerde etkisinin çok düşük olması sebebiyle pH’ı denklemlere dahil etmemiştir. Model 8’e ait denklem incelendiğinde pH’ın denkleme dahil edilmediği ve dikkate alınan değişkenlerin Model 5 ile aynı olduğu görülmektedir. Model 5’e ait denklem incelendiğinde ise Eİ değişkeninin denkleme dahil edilmediği, böylece dikkate alınan değişkenlerin Model 3’teki değişkenler ile aynı olduğu fakat oluşturulan denklem bakımından Model 3’e göre daha karışık ve çok daha fazla TF kullanıldığı görülmüştür.

Tablo 8. MARS modellerinde kullanılan değişkenlerin modellerdeki göreceli önemleri

Model	Değişken	Göreceli önem (%)	Model	Değişken	Göreceli önem (%)
M1	T	100,00	M6	T	100,00
M2	T	100,00	M7	Eİ	47,84
	Eİ	47,61		T	100,00
M3	T	100,00		Q	40,74
	Q	47,58	M8	T	100,00
M4	T	100,00		Q	48,24
	pH	12,73		Eİ	6,17
M5	T	100,00			
	Q	45,66			

Tablo 8’de görüldüğü üzere tüm modellerde T’nin MARS yöntemi ile elde edilen denklemlerdeki göreceli öneminin %100 olduğu anlaşılmaktadır. Dahil edildiği modellerin denklemlerinde, Q’nun %40-50 aralığında değişen bir göreceli öneme sahip olduğu göze çarpmaktadır. Ayrıca pH’ın Model 4’e ait denklemde yaklaşık %13’lük bir göreceli öneme sahip olduğu, dahil edildiği Model 6, Model 7 ve Model 8’e ait denklemlerde ise göreceli öneminin olmadığı görülmektedir. Model 8’de Eİ’nin göreceli önemi yaklaşık %6 ve modeldeki diğer değişkenlerin göreceli önemlerinin Model 3’e oldukça yakın olduğu görülmüştür. Kullanılan bu dört değişkenin göreceli önemleri en fazla olandan en az olana doğru sıralaması T, Q, Eİ ve pH olarak belirlenmiştir.

RA ve MARS yöntemlerinin uygulanması sonucunda her bir model için kullanılan fonksiyonlara ait katsayılar ve temel fonksiyonlar eşitliklerdeki yerlerine yazılarak eğitim ve test veri setleri üretilmiştir. Eğitim veri seti için elde edilen tahmin değerleri ile ölçüm değerleri arasında hesaplanan performans istatistikleri Tablo 9’da ve test veri seti için elde edilen tahmin değerleri ile ölçüm değerleri arasında hesaplanan performans istatistikleri Tablo 10’da verilmektedir.

Tablo 9. Eğitim veri seti için hesaplanan performans istatistikleri

Model 1	LF	ÜF	EF	KF	MARS	Model 2	LF	ÜF	EF	KF	MARS
RMSE	0,397	0,710	0,397	0,396	0,355	RMSE	0,331	0,388	0,260	0,249	0,229
MAE	0,319	0,586	0,318	0,318	0,273	MAE	0,269	0,320	0,202	0,187	0,172
SI	0,035	0,063	0,035	0,035	0,031	SI	0,029	0,034	0,023	0,022	0,020
NS	0,937	0,797	0,937	0,937	0,949	NS	0,956	0,939	0,973	0,975	0,979
Model 3	LF	ÜF	EF	KF	MARS	Model 4	LF	ÜF	EF	KF	MARS
RMSE	0,210	0,422	0,209	0,156	0,138	RMSE	0,367	0,608	0,345	0,321	0,294
MAE	0,165	0,347	0,163	0,123	0,109	MAE	0,306	0,500	0,277	0,256	0,224
SI	0,019	0,037	0,019	0,014	0,012	SI	0,032	0,054	0,031	0,028	0,026
NS	0,982	0,928	0,982	0,990	0,992	NS	0,946	0,851	0,952	0,959	0,965
Model 5	LF	ÜF	EF	KF	MARS	Model 6	LF	ÜF	EF	KF	MARS
RMSE	0,204	0,366	0,187	0,154	0,130	RMSE	0,328	0,367	0,257	0,245	0,229
MAE	0,166	0,301	0,150	0,122	0,102	MAE	0,272	0,305	0,198	0,185	0,172
SI	0,018	0,032	0,017	0,014	0,011	SI	0,029	0,032	0,023	0,022	0,020
NS	0,983	0,946	0,986	0,990	0,993	NS	0,957	0,946	0,973	0,976	0,979
Model 7	LF	ÜF	EF	KF	MARS	Model 8	LF	ÜF	EF	KF	MARS
RMSE	0,204	0,419	0,205	0,149	0,133	RMSE	0,193	0,329	0,179	0,146	0,125
MAE	0,157	0,337	0,157	0,118	0,104	MAE	0,151	0,272	0,142	0,117	0,101
SI	0,018	0,037	0,018	0,013	0,012	SI	0,017	0,029	0,016	0,013	0,011
NS	0,983	0,929	0,983	0,991	0,993	NS	0,985	0,956	0,987	0,991	0,994


Tablo 10. Test veri seti için hesaplanan performans istatistikleri

Model 1	LF	ÜF	EF	KF	MARS	Model 2	LF	ÜF	EF	KF	MARS
RMSE	0,390	1,901	0,396	0,397	0,333	RMSE	0,313	0,860	0,293	0,273	0,254
MAE	0,327	1,116	0,329	0,329	0,259	MAE	0,248	0,551	0,231	0,203	0,199
SI	0,035	0,168	0,035	0,035	0,029	SI	0,028	0,076	0,026	0,024	0,023
NS	0,948	-0,222	0,947	0,947	0,963	NS	0,967	0,750	0,971	0,975	0,978
Model 3	LF	ÜF	EF	KF	MARS	Model 4	LF	ÜF	EF	KF	MARS
RMSE	0,253	0,913	0,240	0,207	0,192	RMSE	0,349	1,862	0,381	0,342	0,304
MAE	0,205	0,601	0,192	0,161	0,145	MAE	0,272	1,091	0,297	0,276	0,232
SI	0,022	0,081	0,021	0,018	0,017	SI	0,031	0,165	0,034	0,030	0,027
NS	0,978	0,718	0,981	0,986	0,988	NS	0,959	-0,173	0,951	0,960	0,969
Model 5	LF	ÜF	EF	KF	MARS	Model 6	LF	ÜF	EF	KF	MARS
RMSE	0,263	0,808	0,219	0,201	0,181	RMSE	0,312	0,689	0,292	0,269	0,256
MAE	0,213	0,531	0,173	0,159	0,139	MAE	0,243	0,454	0,229	0,203	0,201
SI	0,023	0,071	0,019	0,018	0,016	SI	0,028	0,061	0,026	0,024	0,023
NS	0,977	0,779	0,984	0,986	0,989	NS	0,967	0,839	0,971	0,976	0,978
Model 7	LF	ÜF	EF	KF	MARS	Model 8	LF	ÜF	EF	KF	MARS
RMSE	0,246	0,849	0,240	0,199	0,183	RMSE	0,257	0,572	0,212	0,190	0,174
MAE	0,200	0,564	0,194	0,156	0,139	MAE	0,210	0,399	0,168	0,147	0,132
SI	0,022	0,075	0,021	0,018	0,016	SI	0,023	0,051	0,019	0,017	0,015
NS	0,980	0,756	0,980	0,987	0,989	NS	0,978	0,889	0,985	0,988	0,990

Tablo 9 genel olarak değerlendirildiğinde tüm modellerde MARS yönteminin RA yöntemine kıyasla daha başarılı sonuçlar verdiği anlaşılmıştır. RA yönteminde en düşük RMSE, MAE ve SI ile en yüksek NS değerleri tüm modellerde KF'den, modeller arasında da en iyi performans değerleri Model 7 ve Model 8'den elde edilmiştir. T ve Q değişkenlerinden oluşan Model 3 ile T, Q ve Eİ değişkenlerinden oluşan Model 5 karşılaştırıldığında, hesaplanan SI ve NS değerlerinin aynı olduğu, T, Q ve pH değişkenlerinden oluşan Model 7 ile T, Q, pH ve Eİ değişkenlerinden oluşan Model 8 karşılaştırıldığında da hesaplanan SI ve NS değerlerinin yine aynı olduğu görülmektedir. Bu sebeple söz konusu modeller kapsamında Eİ değişkeninin ÇO konsantrasyonu tahmin performansına herhangi bir katkısının olmadığı söylenebilir. T değişkenine sırasıyla Eİ, Q ve pH değişkenlerinin eklenmesiyle oluşturulan iki girdili Model 2, Model 3 ve Model 4 için hesaplanan performans istatistikleri incelendiğinde Model 3 için hesaplanan değerlerin diğerlerine kıyasla çok daha iyi olduğu anlaşılmaktadır. Bu sonuçlar ÇO konsantrasyonu tahmininde T'den sonra katkısı en büyük olan değişkenin Q, katkısı en küçük olan değişkenin ise pH olduğunu göstermektedir. MARS yöntemi için hesaplanan performans istatistikleri incelendiğinde ise Model 3, Model 5, Model 7 ve Model 8 için hesaplanan değerlerin birbirine oldukça yakın olduğu ve en iyi performansa sahip modelin tüm değişkenlerin kullanıldığı Model 8 olduğu belirlenmiştir. Fakat daha az değişken kullanarak en iyi modele oldukça yakın sonuçlar vermesi ve daha sade bir model olması sebebiyle günlük ortalama ÇO'nun tahmin edilmesinde

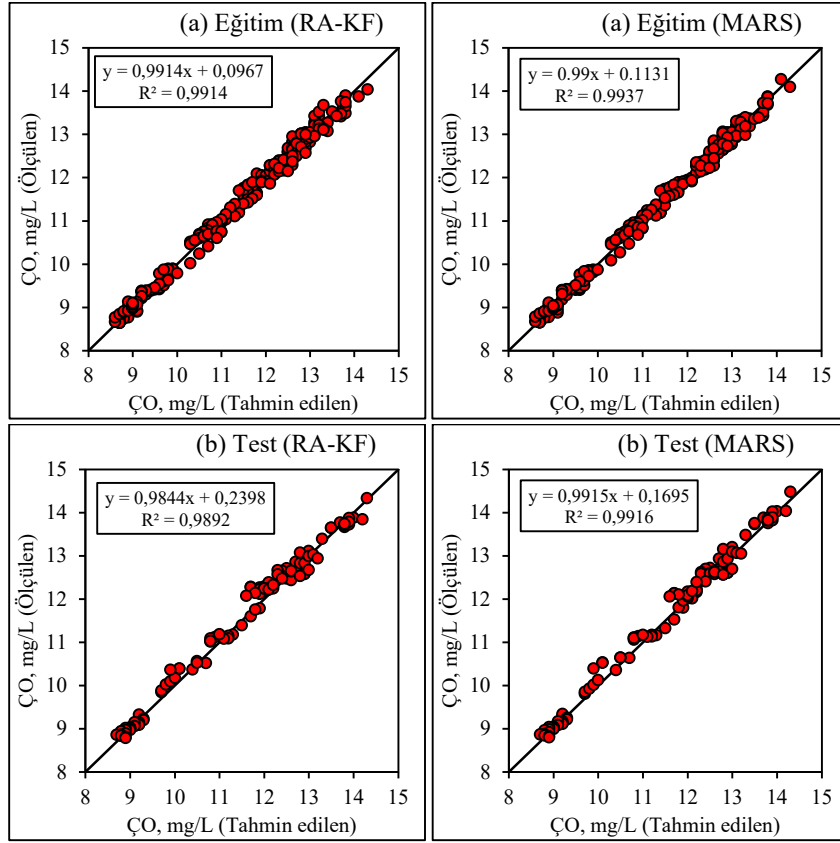
Model 3'ün kullanılması uygun görülmektedir. MARS yöntemi etkisi düşük olan değişkenleri kendiliğinden modelden çıkarmaktadır. Fakat TF'ler ve model ayarlarına bağlı olarak yöntemin farklı sonuçlar verebilmesi sebebiyle tüm değişkenlerin girdi olarak kullanılmasının yanı sıra değişkenlerin çeşitli kombinasyonları ile oluşturulan farklı modeller denenmiştir. T ve Eİ değişkenleri ile oluşturan Model 2 ve bu modele pH'nın eklenmesi ile oluşturulan Model 6 için hesaplanan performans istatistikleri değerlerinin aynı olduğu, T ve Eİ değişkenlerine eklenen pH değişkeninin model performansına etkisinin olmadığı görülmektedir. Bu durum MARS yönteminin Model 7'ye ait TF'leri oluştururken pH'ı denklemlere dahil etmemesi ile açıklanmaktadır.

Tablo 10 incelendiğinde, test veri seti için MARS yönteminin RA yöntemine kıyasla daha başarılı olduğu görülmektedir. RA yöntemi için en iyi tahmin değerleri eğitim veri setinde olduğu gibi KF'den elde edilmiştir. KF'nin Model 3, Model 5, Model 7 ve Model 8 tahmin değerleri ile ölçüm değerleri kullanılarak hesaplanan performans istatistikleri birbirine oldukça yakın çıkmıştır. Bu durum KF'nin T ve Q girdi değişkenleri ile ÇO konsantrasyonu değerlerinin başarılı bir şekilde tahmin edilebileceğini göstermektedir. Bir başka deyişle T ve Q değişkenlerine eklenen Eİ ve pH değişkenlerinin model performanslarını arttırmadığı görülmektedir. Dolayısıyla ÇO tahmininde test veri seti için de Model 3'ün tercih edilmesinin uygun olacağı anlaşılmaktadır. MARS yöntemi için hesaplanan performans istatistikleri irdelendiğinde ise en iyi tahmin sonuçlarının tüm değişkenlerin kullanıldığı Model 8'den elde edildiği görülmektedir. Ancak RA yönteminde olduğu gibi Eİ ve pH'nın MARS yönteminde de model performanslarına katkısının oldukça az olduğu belirlenmiştir. Eğitim ve test veri setleri için RA ve MARS yöntemlerinden hesaplanan performans istatistiklerine göre önerilen Model 3 ve en iyi performans değerlerini veren Model 8 ÇO (mg/L) tahmin değerleri ile ölçüm değerlerine ait saçılım grafikleri Şekil 3 ve Şekil 4'te verilmektedir.



Şekil 3:

Model 3 için RA ve MARS yöntemlerinden elde edilen (a) eğitim ve (b) test veri setleri çözünmüş oksijen tahmin sonuçları ile ölçüm değerlerinin karşılaştırılması



Şekil 4:

Model 8 için RA ve MARS yöntemlerinden elde edilen (a) eğitim ve (b) test veri setleri çözünmüş oksijen tahmin sonuçları ile ölçüm değerlerinin karşılaştırılması

Verilerin saçılım grafiklerinde köşegen üzerine dağılması tahmin değerlerinin ölçüm değerlerine çok yakın olduğunu ve köşegen üzerindeki noktalarda RMSE ve MAE değerlerinin sıfır olduğu anlamına gelmektedir (Bayram ve Kankal, 2015). Eğitim ve test veri setleri için hazırlanmış ve Şekil 3 ile Şekil 4'te verilmiş olan saçılım grafikleri incelendiğinde verilerin büyük bir çoğunluğunun köşegen üzerinde dağıldığı görülmektedir. Bu durum tahmin değerlerinin ölçüm değerlerine oldukça yakın olduğunu göstermektedir. Bunun yanında RA yöntemi KF'den elde edilen tahmin sonuçları için hesaplanmış olan NS değerinin Model 3'e ait eğitim veri seti için 0,990 iken test veri seti için 0,986'dır. MARS yöntemi için hesaplanan NS değerleri ise eğitim ve test veri setleri için sırasıyla 0,992 ve 0,988'dir. Model 8 için RA yöntemi KF'den hesaplanan NS değerleri eğitim ve test veri setleri için sırasıyla 0,991 ve 0,988 iken, MARS yönteminden hesaplanan değerler ise sırasıyla 0,994 ve 0,990'dır. RA ve MARS yöntemleri için hesaplanan NS değerleri karşılaştırıldığında MARS için hesaplanan NS değerlerinin RA'ya kıyasla daha yüksek olduğu ancak her iki yöntemin de ÇO konsantrasyonu tahmininde oldukça başarılı sonuçlar verdiği anlaşılmaktadır. MARS yöntemi ile ÇO konsantrasyonu modelleme çalışmalarında Heddam ve Kişi (2018) Q, T, pH ve Öİ değişkenlerini, Nacar ve diğ. (2020) ise T, pH ve Eİ değişkenlerini kullanarak başarılı sonuçlar elde etmişlerdir. En iyi model sonuçları her iki çalışmada da tüm değişkenlerin girdi olarak kullanıldığı modellerden elde edilmiştir. Bu bakımdan bu çalışmanın önceki çalışmalar ile uyum gösterdiği söylenebilir.

4. SONUÇLAR

Bu çalışmada Clackamas Nehri'nde (Oregon, ABD) Eylül 2016-Ağustos 2017 döneminde ölçülen ve kaydedilen günlük ortalama çözünmüş oksijen (ÇO) konsantrasyonu değerleri regresyon analizi (RA) ve çok değişkenli uyarlanabilir regresyon eğrileri (MARS) yöntemleri ile tahmin edilmiştir. RA yöntemi biri doğrusal üçü doğrusal olmayan dört farklı fonksiyona uygulanmış ve ölçüm değerlerine en yakın tahminleri veren fonksiyon ve bu fonksiyonun oluşturulmasında kullanılan regresyon katsayıları belirlenmiştir. MARS yönteminde ise ölçüm değerlerine en yakın tahmin değerlerini elde etmek için kullanılan temel fonksiyonlar ve denklemler belirlenmiştir. Tahmin modellerinde girdi değişkeni olarak yine aynı dönemde günlük ölçülen su sıcaklığı (T), elektriksel iletkenlik (Eİ), debi (Q) ve pH su kalitesi değişkenleri, sekiz farklı model oluşturularak kullanılmıştır. RA ve MARS yöntemlerinin ÇO konsantrasyonu tahminindeki başarıları ve her bir su kalitesi değişkeninin tahmin başarısına katkısı hesaplanan performans istatistikleri ile belirlenmiştir. Çalışmadan elde edilen sonuçlar maddeler halinde aşağıda verilmektedir;

- Hesaplanan performans istatistiklerine göre günlük ortalama ÇO konsantrasyonu tahmininde en başarılı eşitliğin MARS yönteminden elde edildiği, ayrıca RA yönteminden de başarılı sonuçlar veren eşitliklerin olduğu belirlenmiştir. RA yönteminde ölçüm değerlerine en yakın tahmin değerleri KF'den elde edilmiştir.
- MARS yönteminde eğitim ve test veri setleri için en iyi performans değerleri tüm değişkenlerin kullanıldığı Model 8'den elde edilmiştir. Ancak T ve Q değişkenlerinin kullanıldığı Model 3 ile arasında önemli bir farkın olmadığı dolayısıyla da Eİ ve pH değişkenlerinin model performanslarına etkilerinin çok düşük olduğu belirlenmiştir. ÇO konsantrasyonu tahmininde daha sade bir model olması ve daha az değişken kullanarak en iyi modele çok yakın sonuçlar vermesi sebebiyle Model 3'ün kullanılmasının daha avantajlı olduğu sonucuna ulaşılmıştır.
- Sadece T'nin kullanıldığı Model 1'e ait performans istatistikleri ile T ve diğer değişkenlerin birlikte kullanıldığı iki değişkenli modellere ait performans istatistikleri karşılaştırıldığında Q'nun dahil edildiği Model 3'e ait değerlerin diğerlerine kıyasla daha iyi olduğu anlaşılmıştır. Bu sonuçlar ÇO konsantrasyonu tahmininde Q'nun diğer değişkenlerden daha etkili olduğunu göstermiştir.
- RA yönteminde en iyi performans değerleri eğitim veri setinde Model 7 ve Model 8'den test veri seti için ise Model 8'den elde edilmiştir.
- RA yönteminde tüm fonksiyonlarda Q, Eİ ve pH değişkenleri arasında en etkili değişkenin MARS yönteminde olduğu gibi Q değişkeninin olduğu belirlenmiştir.
- Günlük ortalama ÇO konsantrasyonu tahmininde en az etkiye sahip değişkenin her iki yöntem için de pH olduğu sonucuna varılmıştır.
- Kurulan modellerden elde edilen tahmin değerleri ile ölçüm değerlerinin MARS yönteminde en az %94,9 ve en fazla %99,4 oranında uyumlu olduğu tespit edilmiştir.
- Kullanılan günlük ortalama veriler akarsu üzerinde belirlenen tek bir gözlem istasyonuna ait bir yıllık süreyi kapsamaktadır. Modellemeler daha uzun süreli ölçümlere dayanan veriler ile veya aynı akarsu üzerinde birden fazla istasyona ait veriler kullanılarak gerçekleştirilebilir.
- Çalışmada RA ve MARS yöntemleri kullanılmıştır. Genetik programlama, yapay sinir ağları ve farklı regresyon analizi türleri gibi yöntemlerin de ÇO'nun tahmininde kullanılabilirliğine yönelik çalışmalar yürütülebilir.

KAYNAKLAR

1. Akbal, F., Gurel, L., Bahadir, T., Guler, I., Bakan, G. ve Buyukgungor, H. (2011) Multivariate statistical techniques for the assessment of surface water quality at the mid-black sea coast of Turkey, *Water, Air, and Soil Pollution*, 216(1-4), 21-37.
2. Antanasijevic, D., Pocajt, V., Povrenovic, D., Peric-Grujic, A. ve Ristic, M. (2013) Modelling of dissolved oxygen content using artificial neural networks: Danube River, North Serbia, case study. *Environmental Science and Pollution Research*, 20(12), 9006-9013.
3. Ay, M. ve Kisi, O. (2012) Modeling of dissolved oxygen concentration using different neural network techniques in Foundation Creek, El Paso County, Colorado, *Journal of Environmental Engineering*, 138(6), 654-662.
4. Ay, M. ve Kisi, O. (2017) Estimation of dissolved oxygen by using neural networks and neuro fuzzy computing techniques, *KSCE Journal of Civil Engineering*, 21(5), 1631-1639.
5. Bayazit, M., (1981) *Hidrolojide istatistik yöntemler*, İTÜ Matbaası, Gümüşsuyu, İstanbul.
6. Bayazit, M., Yeğen Oğuz, B. (2005) *Mühendisler için istatistik*, Birsen Yayınevi, İstanbul.
7. Bayram, A. ve Kankal, M. (2015) Artificial neural network modeling of dissolved oxygen concentration in a Turkish Watershed, *Polish Journal of Environmental Studies*, 24(4), 1507-1515.
8. Bayram, A., Kankal, M. ve Onsoy, H. (2012) Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks, *Environmental Monitoring and Assessment*, 184(7), 4355-4365.
9. Bu, H., Tan, X., Li, S. ve Zhang, Q. (2010) Water quality assessment of the Jinshui River (China) using multivariate statistical techniques, *Environmental Earth Sciences*, 60(8), 1631-1639.
10. Carpenter, K.D. (2003) Water-quality and algal conditions in the Clackamas River Basin, Oregon ve their relations to land and water management, US Department of the Interior, *US Geological Survey*, 2, (4189).
11. Chen, L.H. ve Li, L. (2008) Evaluation of dissolved oxygen in water by artificial neural network and sample optimization, *Journal of Central South University of Technology*, 15(2), 416-420.
12. Cox, B.A. (2003a) A review of dissolved oxygen modelling techniques for lowland rivers, *Science of the Total Environment*, 314, 303-334.
13. Cox, B.A. (2003b) A review of currently available in-stream water-quality models and their applicability for simulating dissolved oxygen in lowland rivers, *Science of the Total Environment*, 314, 335-377.
14. Csabragi, A., Molnar, S., Tanos, P., Kovacs, J., Molnar, M., Szabo, I. ve Hatvani, I. G. (2019) Estimation of dissolved oxygen in riverine ecosystems: Comparison of differently optimized neural networks, *Ecological Engineering*, 138, 298-309.
15. Elkiran, G., Nourani, V., Abba, S. I. ve Abdullahi, J. (2018) Artificial intelligence-based approaches for multi-station modelling of dissolve oxygen in river, *Global Journal of Environmental Science and Management*, 4(4), 439-450.
16. EPA. (1986). Quality Criteria for Water. *Washington DC: Office of Water Regulations and Standards*.

17. Fetene, B.N., Shufen, R. ve Dixit, U.S. (2018) FEM-based neural network modeling of laser-assisted bending, *Neural Computing and Applications*, 29(6), 69-82.
18. Friedman, J.H. (1991) Multivariate adaptive regression splines, *The Annals of Statistics*, 19(1), 1-67.
19. Fondriest Environmental, Inc. "Dissolved Oxygen." Fundamentals of Environmental Measurements. 19 Nov. 2013. Web. < <https://www.fondriest.com/environmental-measurements/parameters/water-quality/dissolved-oxygen/> >.
20. Heddham, S. (2014a) Modeling hourly dissolved oxygen concentration (DO) using two different adaptive neuro-fuzzy inference systems (ANFIS): a comparative study, *Environmental Monitoring and Assessment*, 186(1), 597-619.
21. Heddham, S. (2014b) Generalized regression neural network-based approach for modelling hourly dissolved oxygen concentration in the Upper Klamath River, Oregon, USA, *Environmental Technology*, 35(13), 1650-1657.
22. Heddham, S. (2014c) Modeling hourly dissolved oxygen concentration (DO) using two different adaptive neuro-fuzzy inference systems (ANFIS): a comparative study, *Environmental Monitoring and Assessment*, 186(1), 597-619.
23. Heddham, S. (2016) Use of optimally pruned extreme learning machine (OP-ELM) in forecasting dissolved oxygen concentration (DO) several hours in advance: a case study from the Klamath River, Oregon, USA, *Environmental Processes*, 3(4), 909-937.
24. Heddham, S. ve Kisi, O. (2018) Modelling daily dissolved oxygen concentration using least square support vector machine, multivariate adaptive regression splines and M5 model tree, *Journal of Hydrology*, 559, 499-509.
25. Kalff, J. (2002) *Limnology: Inland Water Ecosystems*, Prentice-Hall, New Jersey, USA, 1-92.
26. Kanda, E. K., Kosgei, J. R. ve Kipkorir, E. C. (2015) Simulation of organic carbon loading using MIKE 11 model: a case of River Nzoia, Kenya, *Water Practice and Technology*, 10(2), 298-304.
27. Kanda, E., Kipkorir, E. ve Kosgei, J. (2016) Dissolved oxygen modelling using artificial neural network: a case of River Nzoia, Lake Victoria basin, Kenya, *Journal of Water Security*, 2, jws2016004, 1-7.
28. Khani, S. ve Rajae, T. (2017) Modeling of dissolved oxygen concentration and its hysteresis behavior in rivers using wavelet transform-based hybrid models, *CLEAN–Soil, Air, Water*, 45(2), 1500395, 1-19.
29. Kisi, O., Akbari, N., Sanatipour, M., Hashemi, A., Teimourzadeh, K. ve Shiri, J. (2013) Modeling of dissolved oxygen in river water using artificial intelligence techniques, *Journal of Environmental Informatics*, 22(2), 92-101.
30. Kisi, O. (2015). Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*, 528, 312-320.
31. Kisi, O., Parmar, K. S., Soni, K., ve Demir, V. (2017). Modeling of air pollutants using least square support vector regression, multivariate adaptive regression spline, and M5 model tree models. *Air Quality, Atmosphere & Health*, 10(7), 873-883.
32. Kisi, O., Alizamir, M. ve Gorgij, A. D. (2020) Dissolved oxygen prediction using a new ensemble method, *Environmental Science and Pollution Research*, 27(9), 9589-9603.

33. Lewis M.E. (2006) Dissolved oxygen. Version 2.0, Chapter A6, section 6.2, techniques of water-resources investigations, Book 9, US Geological Survey.
34. Liu, B., Wang, W.L., Han, R.M., Sheng, M., Ye, L.L., Du, X., Wu, X.T., Wang, G.X. ve Wang, G.X. (2016) Dynamics of dissolved oxygen and the affecting factors in sediment of polluted urban rivers under aeration treatment, *Water, Air, and Soil Pollution*, 227(6), 172, 1-13
35. Mulholland, P.J., Houser, J.N. ve Maloney, K.O. (2005) Stream diurnal dissolved oxygen profiles as indicators of in-stream metabolism and disturbance effects: Fort Benning as a case study, *Ecological Indicators*, 5(3), 243-252.
36. Murrell, M.C., Caffrey, J.M., Marcovich, D.T., Beck, M.W., Jarvis, B.M. ve Hagy, J.D. (2018) Seasonal oxygen dynamics in a warm temperate estuary: effects of hydrologic variability on measurements of primary production, respiration, and net metabolism, *Estuaries and Coasts*, 41(3), 690-707.
37. Nacar, S., Bayram, A., Satılmış, U. ve Baki, O.T. (2016) The surface water quality monitoring and assessment of the Eastern Black Sea Basin (Trabzon Province) streams, Turkey, *12. International Congress on Advances in Civil Engineering (Full text in CD)* İstanbul, Turkey 21-23 September İstanbul, 1-6.
38. Nacar, S., Hınıs, M.A. ve Kankal, M. (2018a) Forecasting daily streamflow discharges using various neural network models and training algorithms, *KSCE Journal of Civil Engineering*, 22(9), 3676-3685.
39. Nacar, S., Kankal, M. ve Hınıs, M.A. (2018b) Çok deęişkenli uyarlanabilir regresyon eğrileri (ÇDURE) ile günlük akarsu akımlarının tahmini-haldizen deresi örneęi, *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 8(1), 38-47.
40. Nacar, S., Bayram, A., Baki, O. T., Kankal, M., ve Aras, E. (2020). Spatial forecasting of dissolved oxygen concentration in the Eastern Black Sea Basin, Turkey. *Water*, 12(4), 1041, 1-23.
41. Najah, A., El-Shafie, A., Karim, O.A. ve El-Shafie, A.H. (2014) Performance of ANFIS versus MLP-NN dissolved oxygen prediction models in water quality monitoring, *Environmental Science and Pollution Research*, 21(3), 1658-1670.
42. Nemati, S., Fazelifard, M. H., Terzi, O. ve Ghorbani, M. A. (2015) Estimation of dissolved oxygen using data-driven techniques in the Tai Po River, Hong Kong, *Environmental Earth Sciences*, 74(5), 4065-4073.
43. Olyaie, E., Abyaneh, H. Z. ve Mehr, A. D. (2017) A comparative analysis among computational intelligence techniques for dissolved oxygen prediction in Delaware River, *Geoscience Frontiers*, 8(3), 517-527.
44. Özfalçı, Y., (2008) Çok Deęişkenli Uyarlanabilir Regresyon Kesitleri: Mars, *Yüksek Lisans Tezi*, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
45. Palani, S., Liong, S.Y. ve Tkalich, P. (2008) An ANN application for water quality forecasting, *Marine Pollution Bulletin*, 56(9), 1586-1597.
46. Panepinto, D. ve Genon, G. (2010) Modeling of Po river water quality in Torino (Italy), *Water Resources Management*, 24(12), 2937-2958.
47. Post, C.J., Cope, M.P., Gerard, P.D., Masto, N.M., Vine, J.R., Stiglitz, R.Y., Hallstrom, J.O., Newman, J.C. ve Mikhailova, E.A. (2018) Monitoring spatial and temporal variation of dissolved oxygen and water temperature in the Savannah River using a sensor network, *Environmental Monitoring and Assessment*, 190(5), 272, 1-14.

48. Radwan, M., Willems, P., El-Sadek, A. ve Berlamont, J. (2003) Modelling of dissolved oxygen and biochemical oxygen demand in river water using a detailed and a simplified model, *International Journal of River Basin Management*, 1(2), 97-103.
49. Rankovic, V., Radulovic, J., Radojevic, I., Ostojic, A. ve Comic, L. (2010) Neural network modeling of dissolved oxygen in the Gruža reservoir, Serbia, *Ecological Modelling*, 221(8), 1239-1244.
50. Samui, P. (2013). Multivariate adaptive regression spline (Mars) for prediction of elastic modulus of jointed rock mass. *Geotechnical and Geological Engineering*, 31(1), 249-253.
51. Sanchez, E., Colmenarejo, M.F., Vicente, J., Rubio, A., Garcia, M.G., Travieso, L. ve Borja, R. (2007) Use of the water quality index and dissolved oxygen deficit as simple indicators of watersheds pollution, *Ecological Indicators*, 7(2), 315-328.
52. Sarkar, A. ve Pandey, P. (2015) River water quality modelling using artificial neural network technique, *Aquatic Procedia*, 4, 1070-1077.
53. Singh, K.P., Basant, A., Malik, A. ve Jain, G. (2009) Artificial neural network modeling of the river water quality-a case study, *Ecological Modelling*, 220(6), 888-895.
54. Singh, K.P., Malik, A., Mohan, D. ve Sinha, S. (2004) Multivariate statistical techniques for the evaluation of spatial and temporal variations in water quality of Gomti River (India) a case study, *Water Research*, 38(18), 3980-3992.
55. Spanou, M. ve Chen, D. (2000) An object-oriented tool for the control of point-source pollution in river systems, *Environmental Modelling and Software*, 15(1), 35-54.
56. Şentürk, K. (2008) Akım Gözlem İstasyonu Olmayan Havzalarda su potansiyelinin belirlenmesi, *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
57. Toprak, S. (2011) Çok değişkenli uyarlamalı regresyon eğrileri ve konik programlama ile zaman serilerinin modellenmesi, *Yüksek Lisans Tezi*, Dicle Üniversitesi, Fen Bilimleri Enstitüsü, Diyarbakır.
58. Ünal, B. (2009) Çok değişkenli uyarlamalı regresyon uzanımları, *Yüksek Lisans Tezi*, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
59. Wen, X., Fang, J., Diao, M. ve Zhang, C. (2013) Artificial neural network modeling of dissolved oxygen in the Heihe River, Northwestern China, *Environmental Monitoring and Assessment*, 185(5), 4361-4371.
60. Yaseen, Z. M., Ehteram, M., Sharafati, A., Shahid, S., Al-Ansari, N. ve El-Shafie, A. (2018) The integration of nature-inspired algorithms with least square support vector regression models: application to modeling river dissolved oxygen concentration, *Water*, 10(9), 1124, 1-21.
61. Yilmaz, B., Aras, E., Nacar, S. ve Kankal, M. (2018) Estimating suspended sediment load with multivariate adaptive regression spline, teaching-learning based optimization, and artificial bee colony models, *Science of the Total Environment*, 639, 826-840.
62. Zhang, Q., Li, Z., Zeng, G., Li, J., Fang, Y., Yuan, Q., Wang Y. ve Ye, F. (2009) Assessment of surface water quality using multivariate statistical techniques in red soil hilly region: a case study of Xiangjiang watershed, China, *Environmental Monitoring and Assessment*, 152(1-4), 123-131.

