



# Sedimandaki Ağır Metal Konsantrasyonunun Çoklu Değişken Regresyon Modelleri ve Çok Katmanlı Algılayıcı Ağ Modeli ile Tahmini

İsmail İşeri<sup>1\*</sup>, Sema Arıman<sup>2</sup>

<sup>1</sup> Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0002-0442-1406)

<sup>2</sup> Samsun Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Meteoroloji Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0001-7201-9243)

(İlk Geliş Tarihi 1 Ağustos 2019 ve Kabul Tarihi 25 Ekim 2019)

(DOI: 10.31590/ejosat.638354)

**ATIF/REFERENCE:** İşeri, İ. & Arıman, S. (2019). Sedimandaki Ağır Metal Konsantrasyonunun Çoklu Değişken Regresyon Modelleri ve Çok Katmanlı Algılayıcı Ağ Modeli ile Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (Özel Sayı), 389-397.

## Öz

Son yıllarda, su ortamındaki metal kirliliğinin fazla bulunması, kalıcılığı ve çevresel toksisitesi nedeniyle küresel olarak dikkat çekmektedir. Metallerin doğal sudaki davranışı, substrat sediment bileşiminin, askıda sediment bileşiminin ve su kimyasının bir işlevidir. Sediman, çeşitli habitatlar ve ortamlar içeren nehir havzasının ayrılmaz ve dinamik bir parçasıdır. Sedimanların kalitesinin değerlendirilmesinde, uzun yarılanma süreleri nedeniyle sucul ekosistemlerdeki ağır metallerin, antropojenik girdilerinin belirlenmesi önemli olarak kabul edilir ve sucul ekosistemlerdeki kirlilik geçmişini yansıtabilir. Bu nedenle, sediman kalitesini etkileyen ağır metallerin konsantrasyonunun belirlenmesi ve tahmin edilmesi oldukça önem taşımaktadır. Bu çalışma kapsamında Orta Karadeniz Kıyı şeridi deniz ve ırmak sedimanlarında ağır metal konsantrasyonunun çoklu değişkenli lineer regresyon (MLR), çoklu değişkenli polinomal regresyon (MPR) ve Çok Katmanlı Algılayıcı Ağ (MLP) modelleri kullanılarak tahminlenebilmesi gerçekleştirilmiştir. Modellerin test ve eğitimleri için 2007-2008 yılları arasında 5 farklı noktadan alınan sediman örneklerine ait fiziko-kimyasal parametreler pH, su içeriği (WC), katyon değişim kapasitesi (CEC), oksidasyon redüksiyon potansiyeli (ORP), elektriksel iletkenlik (EC), zeta potansiyeli (ÇP), toplam karbon (TC), toplam inorganik karbon (TIK), toplam organik karbon (TOK) ve ağır metallerin (Cu, Cr, Cd, Pb, Ni, Fe, Al, Sr, Mn ve Cr) konsantrasyonları kullanılmıştır. Çalışmada her bir ağır metal konsantrasyonu tahmin edilmesi için MLR, MPR ve MLP modellerinin performans karşılaştırmaları yapılmıştır. Sonuç olarak sedimanlardaki ağır metallerin konsantrasyonunun tahminlenmesinde fiziko-kimyasal parametreler bağımsız değişkenler olarak kabul edilerek, regresyon analizleri yapılmış ve gerçekleştirilen modeller arasında en iyi sonucun MPR modeli ile elde edildiği ortaya konulmuştur.

**Anahtar Kelimeler:** Tahminleme, Çoklu Regresyon, Yapay Sinir Ağları, Ağır Metal, Sediman

## Development of Multiple Regression Models and Multiple Linear Perceptron Model For Prediction of Heavy Metal Concentration in Sediment

### Abstract

In recent years, metal pollution in the aquatic environment has attracted global attention due to its high availability, persistence and environmental toxicity. The behavior of metals in natural water is a function of substrate sediment composition, suspended sediment composition and water chemistry. The sediment is an inseparable and dynamic part of the river basin which includes various habitats

\* Sorumlu Yazar: Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0002-0442-1406)

and environments. In assessing the quality of sediments, the determination of anthropogenic inputs of heavy metals in aquatic ecosystems due to their long half-life is considered important and may reflect the history of pollution in aquatic ecosystems. Therefore, it is very important to determine and estimate the concentration of heavy metals that affect sediment quality. In this study, it has been realized that heavy metal concentration in mid-Black Sea coastal sea and river sediments can be estimated by using multivariate linear regression (MLR), multivariate polynomial regression (MPR) and multiple layer perceptron (MLP) models. Physico-chemical parameters of sediment samples taken from 5 different points between 2007-2008 for testing and training of models pH, water content (WC), cation exchange capacity (CEC), oxidation reduction potential (ORP), electrical conductivity (Ec), zeta potential ( $\zeta$ P), total carbon (TC), total inorganic carbon (TIC) and total organic carbon (TOC) and heavy metals (Cu, Cr, Cd, Pb, Ni, Fe, Al, Sr, Mn and Cr). In this study, the performance comparisons of MLR, MPR and MLP models were performed to estimate each heavy metal concentration. As a result, physico-chemical parameters were considered as independent variables in the prediction of concentration of heavy metals in sediments, and regression analyzes were performed and it was found that the best results were obtained with MPR model.

**Keywords:** Prediction, Multivariate Regression, Artificial Neural Network, Heavy Metal, Sediment

## 1. Giriş

Arazi kullanımı/arazi örtüsü değişikliği (Singh ve ark. 2014; Kumar ve ark. 2017), atık su arıtma çamuru, maden atığı, endüstriyel atık, atık su (Gautam ve ark. 2013), atmosferik kirleticiler, pestisitler ve gübre uygulamaları gibi birçok faaliyetle nehirlerle, göllere, nehirlerle, denizler ve haliçlere ağır metaller boşalmakta ve bu nehir akışını kontrol eden başlıca etkenler arasında yer almaktadır (Singh ve ark., 2017).

Sucul sedimanlarda ağır metal kirliliği, endüstriyel alanlarda ve yerleşimin olduğu yerlerde çok önemli bir çevresel problemdir. Metallerin kaynakları, evsel ve endüstriyel atıklar, atmosfer, yağışlar, erozyon, tarımsal kaynaklar, katı atıklar ve litosferdir. Ağır metaller farklı yollarla çevreye girebilir, biyolojik olarak parçalanmaz ve dayanıklılık gösterirler. Metaller, sucul çevreye doğal ve antropojenik kaynaklarla girmektedir. Metaller, yeraltı sularına sızarak, veya göl ve ırmaklarla yağışlarla gelerek katı maddeye adsorbe olabilmektedir. Haliçler, denizler, ırmaklar ve sığ kıyı bölgeleri, çoğunlukla endüstriyel ya da tarımsal su akışları ve su-atmosferi gaz değişimlerinden dolayı, besin zenginleşmesine ve metal kirliliğine maruz kalmaktadır. Sucul ortama taşınan ağır metaller aşırı derecede seyrelirler ve kısmen karbonat, sülfat, sülfür olarak katı bileşik oluşturarak su tabanına çökerek sedimanda birikmektedirler. Sediman tabakasının adsorpsiyon kapasitesi sınırlı olduğundan dolayı da suların ağır metal konsantrasyonu sürekli olarak artmaktadır. Sediman kimyasına bağlı olarak ağır metal reaksiyonları, kirleticilerin toksisitesi ve kimyasal formu, hareketliliği, çözünürlülüğünden etkilenmektedir (Marengo ve ark., 2006). Ağır metaller, sedimanlarda sürekli olarak sabit değildir, fakat onlar sedimandan su kolonuna fiziksel ve biyolojik proseslerle geri dönebilmektedir (Tessier ve Campbell, 1988). Ağır metaller sedimanda kısa süre kalabilir ve suyun fiziko-kimyasal özelliklerine bağlı olarak mevsimsel olarak değişiklik göstermektedir. Uygun ışık kullanılabilirliği ile besin maddelerinin aşırı yüklenmesi sonucunda, birincil üreticilerin hızlı bir şekilde büyümesine ve bozulmasından neden olur ve sedimanda birikerek organik maddeye dönüşerek fazladan biyokütlenin birikmesine yol açabilir (Diaz ve Rosenberg, 1995; Subida ve ark., 2013). Bu ağır metallerin küçük bir kısmı, üstündeki su kütleline tekrar girerek sudaki biota tarafından alınabilmektedir. Nehirler, nehrin dibinde biriken ve sudaki besin zincirinde biyomagnifikasyon işlemi ile çeşitli noktalardan ve dağınık kaynaklardan hem taşıyıcı hem de potansiyel metal birikimi kaynağı olarak hareket ederek sedimanda depolanmaktadır. (Theofanis ve ark. 2001). Sonuç olarak, ağır metaller, çevresel açıdan büyük bir öneme sahip ve toksik etki yaratmaları nedeniyle dikkatli bir şekilde izlenmeleri, kirlenmiş sedimanlarda kirlilik seviyelerinin belirlenmesi ve tahminin yapılması oldukça önemlidir. (Li ve ark., 2000).

Son 30 yılda, hidroloji ve su kaynakları alanında artan yapay sinir ağları (YSA) uygulaması birçok çalışmada bulunmaktadır (ASCE Task Komitesi, 2000; Flood & Kartam, 1994; Rogers ve ark., 1995; Dixon 2005). Yapay sinir ağları, geniş bir alana yayılmış bilimsel ve mühendislik problemlerinin çözümü için uygulanan bir teknolojidir. YSA, insan beynindeki nöronlara karşılık gelen yapay basit işlemcilerin birbirlerine değişik etki seviyeleri ile bağlanmasından oluşan karmaşık bir sistemdir (Gündoğdu, 2006). Yapay Sinir Ağları (YSA), nöronlarla ya da düğümlerle kitlesel bağlantı kuramları ve paralel işleme teorilerine dayanan alternatif hesaplama yaklaşımlarıdır. Örüntü tanıma ve sınıflandırma, kaotik zaman serisi analizi ve zaman serisi tahmini gibi bilimsel ve mühendislik problemlerini çözmek için önerilmişlerdir. Jeofizik veriler için YSA'ların gelişimi ve uygulamaları hızla artmış ve nehir akışını tahmini, aktif çamur tahminleri, günlük su talep tahminleri, akifer parametrelerinin belirlenmesi, yeraltı suyu ıslahı, yağış-akış süreci ve mekansal problemler, toprak özelliklerinin analizi, sediman taşınımlarının belirlenmesi gibi çalışmalar son birkaç yılda yapılmış çalışmalardır (Salas ve ark., 2000).

Son 20 yılda, sedimanın kirlilik derecelerinin tahmini ve kirliliğe maruz kalan bentik toplulukların yapısındaki değişikliklerin değerlendirilmesinde çok değişkenli analizlerin kullanıldığı çalışmaların sayısı da oldukça artmıştır (Carvalho ve ark., 2011; Nunes ve ark. 2008). Çok değişkenli yöntemlerin orta dereceli kirlenmiş sedimanlarda kirleticilerin konsantrasyonunu belirlemede başarılı olmakta ancak bu tür tekniklerin kirlenmiş sedimandaki kirleticilerin kirlilik seviyesi çok düşük olduğunda ise bu yöntemin uygun olmadığı görülmüştür (Pereira ve ark., 2011). Yapay sinir ağları (YSA), bazı durumlarda, çevre koşullarında kirliliğin uzamsal ve zamansal değişikliklerin farklı etkilerini ortaya koyarak, ekoloji ile geleneksel çok değişkenli yaklaşımlardan daha uygun bir yöntem olarak kullanılabilir. (Park ve ark. 2004). Aslında, bu veri analizi aracı, fiziksel, kimyasal ve ekotoksikolojik değişkenleri bütünleştiren sediman kalitesinin sınıflandırılmasında başarıyla uygulanmıştır (Alvarez-Guerra ve ark., 2008). YSA'lar, oşinografide ve limnolojide güçlü bir örüntü tanıma ve özellik çıkarma yöntemi olarak giderek daha fazla uygulanmaktadır (Subida ve ark. 2013).

Bu çalışma, çok değişkenli regresyon yönteminin ve yapay sinir ağlarının, kirlenmiş sedimanlarda ağır metal kirleticilerinin tahminin modellenmesi ve tahmin performanslarının karşılaştırılmasını amaçlamaktadır.


## 2. Materyal ve Metot

### 2.1. Çalışma Alanı ve Verilerin Toplanması

Bu çalışması kapsamında, Orta Karadeniz kıyı şeridinde bulunan; Kızılırmak, Yeşilirmak, Mert ırmağı, Abdal ırmağı ve Kurupelit mevkinden mevsimsel olarak 2007-2008 yılları arasında alınan sediman örneklerinin fizikokimyasal ve ağır metal verileri kullanılmıştır (Arıman ve Bakan, 2010). Tablo 1’de arazi çalışmasında belirlenen örnekleme istasyonları ve özellikleri verilmektedir. Sediman için seçilen örnekleme noktalarının çalışma alanındaki konumları ise Şekil 1’de belirtilmiştir. Bu verilerin elde edilmesi için yüzey sediman örnekleri (0-5 cm) Birge-Ekman grab sediman örnekleycisi kullanılarak gerçekleştirilmiştir. Yaş sediman örneklerinde pH, elektriksel iletkenlik (EC), oksidasyon redüksiyon potansiyeli (ORP), zeta potansiyeli, katyon değişim kapasitesi (CEC) ve % su içeriği (WC), kuru sediman örneklerinde ise Toplam Organik karbon (TOK), Toplam İnorganik karbon (TİK) ve Toplam Karbon (TK) analizleri gerçekleştirilmiştir. Rutin yaş analizler için, yaklaşık 15-20 g yaş sediman örneğinin her biri 105 °C’de 12 saat (veya sabit ağırlık) etüvde kurularak % su içeriği belirlenmiştir. Ayrıca yaş sediman örneklerinde, çoklu parametre ölçüm cihazı ile pH, elektriksel iletkenlik ve redoks potansiyeli analizleri gerçekleştirilmiştir (Golterman ve ark., 1983; Cottenie ve ark.1982; Khwaja ve ark., 2000). Sedimanda ağır metal analizleri (Cu, Pb, Cd, Fe, Al, Cr, Cu, Zn, Mn, Sr) ise standart metotlara (USEPA 1999; Metot 3050 I) göre ICP-OES cihazı ile yapılmıştır.

Tablo 1. Arazi Çalışmasında Belirlenen Örnekleme İstasyonları ve Özelliği

İstasyon No	Örnekleme İstasyonları	Özelliği	Enlem	Boylam
S1	Yeşilirmak	Arıtılmamış evsel atıklar, yüksek akışlı endüstriyel ve tarımsal atıklar	41° 12’ 16’’ N	36° 43’ 34’’ E
S2	Abdal ırmağı	Düşük akışlı arıtılmamış evsel ve tarımsal atıklar	41° 13’ 39’’ N	36° 35’ 09’’ E
S3	Mert ırmağı	Düşük akışlı arıtılmamış evsel ve endüstriyel deşarjlar	41° 16’ 44’’ N	36° 21’ 09’’ E
S4	Kızılırmak	Düşük akışlı arıtılmamış evsel ve tarımsal atıklar	41° 34’ 02’’ N	35° 52’ 52’’ E
S5	Kurupelit (Üniversite)	Arıtılmamış evsel deşarjlar, tarımsal atıklar, OMU arıtılmış atıkları	41° 23’ 02’’ N	36° 13’ 01’’ E



## 2.2. Kullanılan Tahminleme Modelleri

Regresyon analizi, bağımlı ve bağımsız değişken arasındaki ilişkiyi araştıran bir tahminleme tekniğidir. Çalışma kapsamında üç farklı model kullanılarak veriler üzerinde modellerin tahminleme başarımları incelenmiştir. Kullanılan modeller MLR, MPR ve MLP modelleridir. Bu modeller arasında MLP modelini diğer iki modelden ayıran özellik öğrenme yeteneğine sahip yapay sinir ağı modeli olmasıdır. Bu nedenle her bir ağır metal tahminleme modeli için MLP modelinin eğitiminde veri kümesinin %70 lik bölümü eğitim %30' luk bölümü test için ayrılmıştır. Modellerin karşılaştırmalarının homojen olması açısından tüm modeller aynı test verisi ile test edilmiştir.

### 2.2.1 Çoklu Lineer Regresyon (MLR)

Regresyon analizi bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi incelemek amacıyla kullanılan bir analiz yöntemidir. Çoklu regresyon olarak da bilinen çoklu değişkenli doğrusal regresyon birden fazla bağımsız değişken kullanılarak bir bağımlı değişkenin değerinin tahmin edilmesi işlemi gerçekleştirilir (Kahane, 2014). Bir MLR'nin genel olarak matematiksel modeli Denklem-1'de verilmiştir.

$$y = A_0 + A_1x_1 + A_2x_2 + \dots + A_ix_i + \varepsilon \quad (1)$$

Denklem-1'de  $x_i$  ler bağımsız değişkenleri  $y$  bağımlı değişkeni,  $A_0$  tüm bağımsız değişkenlerin değeri sıfır olduğu durumda regresyon eğrisinin  $y$  eksenini kestiği kesişim noktasını,  $A_i$  her bir bağımsız değişkenin  $y$  bağımlı değişkenine çıkış ile olan birim bazlı değişiminin etkisini,  $\varepsilon$  hata değerini temsil etmektedir. Denklem-2'de ise en küçük kareler yöntemi kullanılarak elde edilen tahminleme denklemi verilmektedir.

$$\hat{y}_i = \hat{a}_0 + \hat{a}_1\hat{x}_1 + \hat{a}_2\hat{x}_2 + \dots + \hat{a}_i\hat{x}_i \quad i = 1, 2, \dots, n \quad (2)$$

Çoklu regresyon verilerin modelden sapmalarının karelerinin toplamını minimize ederek Denklem-2'de yer alan  $a_0, a_1, a_2 \dots a_n$  katsayılarının hesaplanmasını sağlamaktadır.

### 2.2.2 Çoklu Polinomal Regresyon (MPR)

Çoklu polinomal regresyonda bağımsız değişkenler ile bağımlı değişken arasındaki ilişki  $n$  inci dereceden polinom denklemi ile ifade edilmektedir (Sinha, 2013). MPR genel modeli Denklem-3'de verilmektedir.


$$y = A_0 + A_1x + A_2x^2 + \dots + A_ix^i + \varepsilon \quad (3)$$

Çoklu polinomal modellerde  $i = 2$  olması durumunda kuadratik,  $i = 3$  olması durumunda kübik ve  $i = 4$  olması durumunda kuartik olarak isimlendirilmektedir. Denklem-4'de ise en küçük kareler yöntemi kullanılarak elde edilen tahminleme denklemi verilmektedir.

$$\hat{y}_i = \hat{a}_0 + \hat{a}_1\hat{x}_1 + \hat{a}_2\hat{x}_2^2 + \dots + \hat{a}_i\hat{x}_i^i \quad i = 1, 2, \dots, n \quad (4)$$

### 2.2.3 Çok Katmanlı Algılayıcı Ağ (MLP)

Çok katmanlı algılayıcı olarak ifade edilen MLP modeli Şekil-1'de görüldüğü gibi bir girdi katmanı, bir veya birden fazla gizli katman ve bir çıkış katmanından oluşmaktadır. Katmanlarda yer alan yapay sinir hücreleri birbirlerini tam bağlıdır. Giriş katmanında yer alan nöron sayısı girdi vektörünün boyutu ile aynı, çıktı katmanındaki yapay sinir hücre sayısı da çıkış vektörünün yapısına göre tasarlanır. Gizli katmanda yer alan nöron sayısı en az bir olmak üzere farklı denemeler ile en uygun eğitim gerçekleştirilene kadar artırılabilir.



Şekil 1. Çok Katmanlı Algılayıcı Modeli

Çok katmanlı algılayıcı ağ modeli Denklem-5'de yer alan eşitlikle ifade edilmektedir.

$$Y_n = f_0\{b_0 + \sum_{k=1}^h [w_k * f_h(b_{hk} + \sum_{i=1}^m w_{ik}X_{ni})]\} \quad (5)$$

Denklem-5’de yer alan değişkenler aşağıda açıklamalı olarak verilmiştir.

$Y_n$ : Normalize edilmiş çıktılar

$f_0$ : Çıkış katman transfer fonksiyonu (bu çalışmada tansig kullanılmıştır)

$b_0$ : Çıkış katmanı bias

$w_k$ : k ıncı gizli katmandan çıkış katmanına olan bağlantı ağırlığı

$f_h$ : Gizli katman transfer fonksiyonu

$b_{hk}$ : k ıncı gizli katmanın bias terimleri

$w_{ik}$ : Girdi katmanındaki i inci nöronun gizli katmandaki k ıncı nörona bağlantı

$X_{ni}$ : Normalize edilmiş girdi vektörü

MLP modelinin eğitiminde 5 farklı istasyondan alınan 20 farklı örneklem verisi kullanılmıştır. MLP modelinin girdilerine fiziko-kimyasal parametreler, çıkış katmanına ise her bir ağır metalin konsantrasyon değeri yerleştirilmiştir. Her bir ağır metal tahminlemesi için 9-10-1 şeklinde MLP modeli eğitilmiştir. MLP modelinin gizli katman sinir hücrelerinin çıktıları hesaplanırken tanjant sigmoid, ve çıkış katmanında ise purelin aktivasyon fonksiyonu kullanılmıştır.

Tüm modellerin sonuçları ortalama mutlak hata (MAE), ortalama karesel hata (MSE) ve korelasyon katsayısı ( $R^2$ ) metriklerine göre karşılaştırılmıştır. Bu metrikler sırasıyla Denklem-6, Denklem-7 ve Denklem-8’de verilmiştir. Denklemlerde yer alan  $Y_m$ : Ölçülen Değer ,  $Y_p$ : Tahminlenen Değer olarak ifade edilmektedir.

$$MAE = \frac{\sum |Y_m - Y_p|}{N} \quad (6)$$

$$MSE = \left( \frac{\sum (Y_m - Y_p)}{N} \right)^2 \quad (7)$$

$$R = \sqrt{\frac{\sum Y_m^2 - \frac{(\sum (Y_m - Y_p))^2}{N}}{\sum Y_m^2}} \quad (8)$$

### 3. Araştırma Sonuçları ve Tartışma

Yapılan deneysel çalışmalarda öncelikle MLR modelinin, MPR modelinin ve MLP modelinin sedimandaki her bir ağır metal (Cu, Cr, Cd, Pb, Ni, Fe, Al, Sr, Mn ve Cr) konsantrasyonunun tahminlemesi amacıyla modeller gerçekleştirilmiştir. Girdi parametresi olarak fiziko-kimyasal parametreler bağlı olarak sedimandaki ağır metal (Cu, Cr, Cd, Pb, Ni, Fe, Al, Sr, Mn ve Cr) konsantrasyonlarını tahminlemesi yapılmıştır.

#### 3.1. Konsantrasyonu Tahminleme

AI konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 2’de görülmektedir. AI tahminlemesi MLR ve MPR modellerinin kestiriminde R değeri 0,97 olarak aynı değere bulunmuştur.

Tablo 2. AI Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	125574	5,58E+11	0,97
MPR	6.2787e+03	2.8562E-18	0,97
MLP	9.9826e+03	2.3286E+07	0,92

Cd konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 3’de görülmektedir. MLP model, Cd konsantrasyonunu tahminlemesinde en düşük R=0,84, MPR modeli ise en yüksek R=1,00 değerine sahiptir.

Tablo 3. Cd Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	125574	5,58E+11	0,97
MPR	7.8652e-12	2.6623E-23	1,00
MLP	15.4181	189.0352	0,84

Cr konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 4’de görülmektedir. Cr konsantrasyonunu tahminlemesinde en yüksek (R=1,00) tahminleme MPR modelinde elde edilmiştir.

Tablo 4. Cr Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	689.8609	1.6213E-24	0,92
MPR	7.3646e-10	2.9643E-19	1,00
MLP	1.1817e+03	2.9414E+05	0,75

Cu konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 5’de görülmektedir. Cu tahminlemesinde en düşük R=0,76 MLR modelinde, en yüksek R=1,00 ise MPR elde edilmiştir.

Tablo 5. Cu Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	57.4584	3.9865e-26	0.7648
MPR	6.0811e-11	1.6525E-21	1,00
MLP	36.6548	23.4064	0,93

Fe konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 6’de görülmektedir. Fe konsantrasyonunun tahminlemesinde en yüksek tahminleme başarısı MPR modelinde (R=1,00) elde edilmiştir.

Tablo 6. Fe Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	3.1973e+04	1.1202E-21	0,94
MPR	1.2044e-08	2.7502E-18	1,00
MLP	1.9291e+04	4.2192E+07	0.9716

Ni konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 7’de görülmektedir. MPR modeli Ni konsantrasyonunu tahminlemesinde MLR ve MLP modeline göre en yüksek kestirime sahiptir.

Tablo 7. Ni Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	34.6101	1.0910E-26	0.9430
MPR	2.8954e-11	2.8082E-23	1,00
MLP	20.3415	2.1171	0.9614

Pb konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 8’de görülmektedir. Pb konsantrasyonunun tahminlemesinde MP modeli en düşük R=0,8041, MPR modeli ise en yüksek R=1,00 değeri elde edilmiştir.

Tablo 8. Pb Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	19.6934	2.9323E-26	0.9103
MPR	3.4470e-11	7.8259E-22	1,00
MLP	27.8255	0.7270	0.8041

Zn konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 9’de görülmektedir. MPR modeli Zn konsantrasyonunun tahminlemesinde diğer modellere göre en iyi performansa sahiptir.

Tablo 9. Zn Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	223.3616	6.6074E-25	0.7326
MPR	1.5641e-11	3.4906E-23	1,00
MLP	157.2361	378.6056	0.6416

Mn konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 10’de görülmektedir. Mn konsantrasyonunun tahminlemesinde en yüksek R=1,00 değer MPR modelinde elde edilmiştir.

Tablo 10. Mn Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	404.8333	2.9861E-24	0.9571
MPR	5.7065e-11	2.0525E-23	1,00
MLP	566.4199	8.3445E+03	0.9320

Sr konsantrasyonunun tahminlemesi için kullanılan MLR, MPR ve MLP modellerinin tahminleme başarımları Tablo 11’de görülmektedir. MLP modeli Sr’un tahminlemesinde en iyi (R=1,00) tahminleme başarımına sahiptir.

Tablo 11. Sr Konsantrasyonu Tahminleme Sonuçları

	MAE	MSE	R
MLR	43.3595	2.3690E-25	0.9801
MPR	1.8654e-10	9.5618E-21	1,00
MLP	26.1497	107.8861	0.9742

## 4. Sonuç

Sucul sedimanlarda ağır metal kirliliği, endüstriyel alanlarda ve yerleşimin olduğu yerlerde çok önemli bir çevresel problemdir. Ağır metaller, sedimandan kimyasal ve biyolojik prosesler ile su kolonuna geri salınabilmektedir. Sedimandaki metal kirleticilerinin birikimi, etrafındaki alanlar ciddi çevresel problem oluşturmaktadır. Sedimanda metal kirliliği, su kalitesini ve sucul organizmalarda metallerin biyobirikimini ve biyoasimilasyonunu etkileyerek, insan sağlığı ve ekosistem üzerinde uzun süreli etkileri olmaktadır. Kıyı alanlarında su kalite yönetim için yaklaşımlar ve kirlilik kontrolü stratejilerini geliştirmek için, sedimandaki ağır metallerin konsantrasyonunu ve onların jeokimyasal dağılımları belirlemek oldukça önemlidir.

Bu çalışma kapsamında ağır metalle kirlenmiş sediman örneklerinde yapılan laboratuvar analizleri sonucunda elde edilen fiziko-kimyasal parametreler kullanılarak, ağır metal konsantrasyonlarının tahminlemesi üzerine bir çalışma gerçekleştirilmiştir. Her bir ağır metal konsantrasyonu tahminlemesi için MLR, MPR ve MLP modelleri geliştirilmiştir. Modellerin tahminleme doğrulukları MAE, MSE ve R metrikleri üzerinden tablolar halinde verilmiştir. Tablolar incelendiğinde MPR modelinin Al, haricinde diğer ağır metal konsantrasyonlarının tahminlemesinde R=1,00 değeri ile oldukça başarılı bir model olduğu görülmektedir. Bu polinomal modelin geliştirilmesinde quadratik polinom fonksiyonu kullanılmıştır. Buna karşın MLP modelinin, Ni, Fe ve Cu konsantrasyonu tahminlemesinde MLR modelinden daha yüksek R değerlerine sahip olduğu buna karşın MPR modelinden ise düşük R değerine sahip olduğu görülmektedir. Sonuç olarak sedimanlarda ağır metal kirliliğinin belirlenmesinde fizikokimyasal parametreler kullanılarak her bir ağır metal konsantrasyonunun tahminlemesinde MPR'nin en iyi model olduğu belirlenmiştir. Bu çalışmanın sonuçları, sediman kalitesinin belirlenmesi ve kirlenmiş sedimanların iyileştirme çalışmalarına yön verebilir.

## Kaynakça

- [1] Arıman S, Bakan G. Assessment Of Heavy Metal Levels In Sediments Of The Mid-Black Sea Coast Of Turkey". 15th International Conference on Heavy Metals in the Environment, 2010; 19-23 September, pg. 472-474, Gdansk, Poland.
- [2] Carvalho S, Pereira P, Pereira F, De Pablo H, Vale C, Gaspar MB. Factors structuring temporal and spatial dynamics of macrobenthic communities in a eutrophic coastal lagoon (Óbidos lagoon, Portugal). *Mar Environ Res* 2011;71:97-110.
- [3] Clarke KR. Non-parametric multivariate analyses of changes in community structure. *Aust J Ecol* 1993;18:117-43.
- [4] Subida, M.D., Berihuete A, Drake P., Blasco, J. Multivariate methods and artificial neural networks in the assessment of the response of infaunal assemblages to sediment metal contamination and organic enrichment. *Science of the Total Environment* 2013; 450-451; 289-300.
- [5] Nunes, M., Coelho J, Cardoso P, Pereira M, Duarte A, PardalM. Themacroenthic community along a mercury contamination in a temperate estuarine system (Ria de Aveiro, Portugal). *Sci Total Environ* 2008;405:186-94.
- [6] Pereira P, Carvalho S, Pereira F, de Pablo H, Gaspar MB, Pacheco M, et al. Environmental quality assessment combining sediment metal levels, biomarkers and macrobenthic communities: application to the Óbidos coastal lagoon (Portugal). *Environ Monit Assess* 2011;184:1-11.
- [7] Carvalho S, Pereira P, Pereira F, de Pablo H, Vale C, Gaspar MB. Factors structuring temporal and spatial dynamics of macrobenthic communities in a eutrophic coastal lagoon (Óbidos lagoon, Portugal). *Mar Environ Res* 2011;71:97-110.
- [8] Nunes M, Coelho J, Cardoso P, Pereira M, Duarte A, PardalM. Themacroenthic community along a mercury contamination in a temperate estuarine system (Ria de Aveiro, Portugal). *Sci Total Environ* 2008;405:186-94.
- [9] Park YS, Chon TS, Kwak IS, Lek S. Hierarchical community classification and assessment of aquatic ecosystems using artificial neural networks. *Sci Total Environ* 2004;327: 105-22.
- [10] Alvarez-Guerra M, González-Piñuela C, Andrés A, Galán B, Viguri JR. Assessment of Self-Organizing Map artificial neural networks for the classification of sediment quality. *Environ Int* 2008;34:782-90
- [11] Cottenie, A., M. Verloo, L. Kieskens, G. Velgehe and R. Camerlynck., 1982. Chemical analysis of Plants and Soils. IWONL, Brussels, Belgium.
- [12] Diaz RJ, Rosenberg R. Marine benthic hypoxia: a review of its ecological effects and the behavioural responses of benthic macrofauna. *Oceanogr Mar Biol Annu Rev* 1995;33: 245-303.
- [13] Li, X, Wai, O.W.H., Li, Y.S., Coles,B.J., Ramsey, H., Thornton, I., 2000. Heavy Metal Distribution in Sediment Profiles of The Pearl River Estuary, South China. *Applied Geochemistry*, 15, 567-581.
- [14] Marengo, E., Gennaro, M.C., Robotti, E., Rossanigo, P., Rinaudo, C., G., M.R., 2006. Investigation of Anthropic Effects Connected with Metal Ions Concentration, Organic Matter and Grain Size in Bormida River Sediments. *Analytica Chimica Acta*, 560(1-2), 172-183.
- [15] Kumar N, Singh SK, Srivastava PK, Narsimlu B (2017) SWAT model calibration and uncertainty analysis for streamflow prediction of the tons river basin, India, using sequential uncertainty fitting (SUFI-2) algorithm. *Model Earth Syst Environ* 3:1-13.
- [16] Singh H, Singh D, Singh SK, Shukla DN (2017) Assessment of river water quality and ecological diversity through multivariate statistical techniques, and earth observation dataset of rivers Ghaghara and Gandak, India. *Int J River Basin Manag*, pp 1-14. doi:10.1080/15715124.2017.1300159.
- [17] Singh SK, Srivastava K, Gupta M, Thakur K, Mukherjee S (2014) Appraisal of land use/land cover of mangrove forest ecosystem using support vector machine. *Environ Earth Sci* 71:2245-2255.
- [18] Gautam SK, Sharma D, Tripathi JK, Singh SK, Ahirwar S (2013) A study of the effectiveness of sewage treatment plants in Delhi region. *Appl Water Sci* 3:57-65.
- [19] Dixon, B. (2005). Applicability of neuro-fuzzy technique in predicting ground-water vulnerability: A GIS-based sensitivity analysis. *Journal of Hydrology*, 309, 17-38.



- [20] Theofanis ZU, Astrid S, Lidia G, Calmano WG (2001) Contaminants in sediments: remobilisation and demobilization. *Sci Total Environ* 266:195–202.
- [21] Salas, J. D., Markus, M., & Tokar, A. S. (2000). Streamflow forecasting based on artificial neural networks. In G. Rao & A. R. Rao (Eds.), *Artificial neural networks in hydrology*. London: Kluwer Academic Publishers.
- [22] ASCE Task Committee (2000). Artificial neural networks in hydrology, 2. Hydrologic applications. *ASCE Journal of Hydrologic Engineering*, 5(2), 124–137.
- [23] Rogers, L. L., Dowla, F. U., & Johnson, V. M. (1995). Optimal field-scale groundwater remediation using neural networks and the genetic algorithm. *Environmental Science and Technology*, 29(5), 1145–1155.
- [24] Flood, I., & Kartam, N. (1994). Neural networks in civil engineering I. Principles and understanding. *Journal of Computing in Civil Engineering*, 8(2), 131–148.
- [25] Tessier A & Campbell PGC (1988) Comments on the testing of the accuracy of an extraction procedure for determining the partitioning of trace metals in sediments. *Anal. Chem.* 60: 1475–1476.
- [26] USEPA (U.S. Environmental Protection Agency), 1999. “SW-846. reference methodology: Method 3050B. Standard Operating Procedure for the Digestion of Soil/Sediment Samples Using a Hot Plate/Beaker Digestion Technique, Chicago, IL.
- [27] Golterman, H.L., Sly, P.G., Thomas R.L., 1983. Study of The Relationship Between Water Quality and Sediment Transport . UNESCO, Technical Papers in Hydrology 26, France.
- [28] Khwaja, A.R., Singh, R., Tandon, S.N., 2000. Monitoring of Ganga Water and Sediments Vis-A-Vis Tannery Pollution at Kanpur (India): A Case Study. *Environ. Monit. Assess.*, 68, 19–35.
- [29] Gündoğdu, M. E., 2006. Meteorolojik Parametrelerin Hava Kirliliğine Etkilerinin Yapay Sinir Ağları Modeli İle İncelenmesi, FBE Çevre Mühendisliği, Yüksek Lisans Tezi, İstanbul
- [30] Kahane, L. (2014). Multiple Regression Analysis. In *Regression Basics* (pp. 59–78). <https://doi.org/10.4135/9781483385662.n4>
- [31] Sinha, P. (2013). Multivariate Polynomial Regression in Data Mining: Methodology, Problems and Solutions. *International Journal of Scientific & Engineering Research*, 4(12), 962–965