Artvin Çoruh Üniversitesi
Doğal Afetler Uygulama ve Araştırma Merkezi
Doğal Afetler ve Çevre Dergisi

Artvin Çoruh University
Natural Hazards Application and Research Center
Journal of Natural Hazards and Environment

Araştırma Makalesi / Research Article, Doğ Afet Çev Derg, 2026; 12(1): 146–158, DOI: 10.21324/dacd.1740145

Regresyon Tabanlı Yöntemler Kullanılarak Baraj Etkisindeki Akarsularda Askıda Katı Madde Tahmini

Mahir Kumantaş[1], Betül Mete[1,*], Sinan Nacar[2], Adem Bayram[1]

[1]*Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 61080, Trabzon, Türkiye.*
[2]*Tokat Gaziosmanpaşa Üniversitesi, Mühendislik ve Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, 61050, Tokat, Türkiye.*

Özet

Askıda katı madde (AKM) tahmini, baraj gölleri, nehir ekosistemleri, su kaynaklarının yapısal değişiklikleri, çeşitli operasyonel faaliyetler, çevre güvenliği ve su yönetimi bakımından oldukça önemlidir. Bu çalışmada Amerika Birleşik Devletleri'ndeki Patapsco Nehri'nin günlük ortalama AKM (mg/L) değerlerini tahmin etmek için klasik regresyon analizi (KRA) ve çok değişkenli uyarlanabilir regresyon eğrileri (ÇDURE) yöntemleri kullanılmıştır. Modelleri oluşturmak için Catonsville ve Elkridge gözlem istasyonlarından alınan günlük ortalama debi (Q), bulanıklık (T) ve AKM verileri kullanılmıştır. Ekim 2016 ile Eylül 2021 dönemini kapsayan 1824 veriden 1199'u eğitim (%65.74), 300'ü doğrulama (%16.45) ve 325'i test (%17.81) seti için kullanılmıştır. Geliştirilen modellerin performansları ortalama karesel hatanın karekökü, ortalama mutlak hata ve Nash-Sutcliffe verimlilik katsayısı istatistikleri kullanılarak değerlendirilmiştir. AKM tahmini için Q ve T parametreleri ile üç farklı model kurulmuştur. Q ve T parametrelerinin birlikte kullanıldığı model diğer modellere kıyasla her iki istasyonda da daha yüksek tahmin performansı göstermiştir. Ayrıca eğitim veri setinde KRA yöntemi, doğrulama ve test veri setlerinde ise ÇDURE yöntemi yüksek performans göstermiştir. ÇDURE yönteminin KRA yöntemine kıyasla daha yüksek tahmin performansı sergilediği sonucuna ulaşılmıştır.

Anahtar Sözcükler

Askıda Katı Madde, ÇDURE, Klasik Regresyon Analizi, Modelleme, Patapsco Nehri Havzası

Estimation of Suspended Sediment in Dam-impacted Streams Using Regression-based Methods

Abstract

The estimation of suspended sediment (SS) is a crucial factor for dam reservoirs, river ecosystems, structural changes in water resources, various operational activities, environmental safety, and water management. In this study, classical regression analysis (CRA) and multivariate adaptive regression splines (MARS) methods were used to estimate the mean daily SS (mg/L) of the Patapsco River in the United States. Mean daily discharge (Q), turbidity (T) and SS data from the Catonsville and Elkridge observation stations were used to build the models. For each station, 1199 (65.74%) of the 1824 data recorded between October 2016 and September 2021 were used for training, 300 (16.45%) for validation and 325 (17.81%) for testing datasets. The performance of the developed models was evaluated using the root mean square error, the mean absolute error, and the Nash-Sutcliffe efficiency coefficient statistics. Three different models were developed for estimating SS using Q and T parameters. The model including both Q and T parameters together showed higher estimation performance than the other models at both stations. In addition, the CRA method showed high performance in the training dataset, while the MARS method showed high performance in the validation and testing datasets. It was concluded that the MARS method demonstrated superior estimation performance compared to the CRA method.

Keywords

Suspended Sediment, MARS, Classical Regression Analysis, Modeling, Patapsco River Basin

1. Giriş

Bir nehir sistemindeki sediment taşıma mekanizması, zamana ve mekana göre değişen jeolojik ve hidrolojik parametrelerin etkileşimini içeren karmaşık ve doğrusal olmayan bir süreçtir. Sediment konsantrasyonunun tahmini ile sediment taşınımı bilgisi arazi kullanımı, su kaynaklarının yönetimi, bölgesel tehlikeler ve hidrolik yapılar üzerinde çeşitli etkilere sahiptir (Khan vd., 2019). Bu nedenle, sediment dinamiklerinin doğru bir şekilde anlaşılması ve modellenmesi, özellikle askıda katı madde (AKM) gibi parametrelerin tahmini açısından büyük önem taşımaktadır. Doğrusal olmayan ve oldukça karmaşık bir çevresel süreç olan AKM konsantrasyonunun tahmini, ciddi düzeyde bilimsel ve teknik zorluklar içermektedir. Literatürde AKM konsantrasyonlarını tahmin etmek amacıyla birçok model önerilmektedir (Bayram vd., 2012; Kisi & Zounemat-Kermani, 2016; Samantaray & Sahoo, 2021). Bu modeller arasında, denklem elde etme imkanı sunmaları nedeniyle regresyon tabanlı yöntemler öne çıkmaktadır (Katatchambo vd., 2025).

* Sorumlu Yazar: Tel: +90 (462) 3772606 Faks: +90 (462) 3774413
E-posta: mkumantas@ktu.edu.tr (Kumantaş M.), betulmete@ktu.edu.tr (Mete B.)
sinan.nacar@gop.edu.tr (Nacar S.), abayram@ktu.edu.tr (Bayram A.)

Gönderim Tarihi / Received : 11/07/2025
Kabul Tarihi / Accepted : 05/10/2025

Özellikle, farklı regresyon yöntemlerinin AKM tahmininde etkin biçimde kullanıldığı ve başarılı sonuçların elde edildiği çalışmalar mevcuttur (Essam vd., 2022; Meshram vd., 2021; Mete vd., 2023; Nguyen vd., 2024). Yilmaz vd. (2018), AKM yükünün regresyon tabanlı yöntemler ile tahmin edilebilirliğini araştırmışlardır. Çoruh Nehri üzerindeki İnanlı (2005–2011) ve Altınsu (1984–2001) gözlem istasyonlarından elde ettikleri aylık AKM yükü ve debi (Q) verilerini kullandıkları çalışmada çok değişkenli uyarlanabilir regresyon eğrileri (ÇDURE) yönteminin diğer yöntemlere kıyasla daha başarılı sonuçlar verdiğini belirlemişlerdir. Adnan vd. (2019) Çin'deki Guangyuan ve Beibei bölgelerinde seçilen gözlem istasyonlarına ait AKM yükü ve Q verilerini kullanarak AKM yükünün veriye dayalı modeller ile tahmin edilebilirliğini araştırmışlardır. ÇDURE yönteminin klasik regresyon analizinden (KRA) daha başarılı olduğunu belirlemiştir. Achite vd. (2022), Cezayir'deki Wadi Abd Havzası'ndaki bir izleme istasyonundan elde edilen debi ve AKM konsantrasyonu verilerini kullanarak AKM tahmininde dört farklı makine öğrenmesi yönteminin performansını karşılaştırmıştır. Çalışmada, girdi parametrelerinin model performansı üzerinde doğrudan etkili olduğu ve ÇDURE yönteminin AKM tahmininde güvenilir bir yöntem olduğu vurgulanmıştır. Van vd. (2023), Vietnam'daki Ca Nehri Havzası'ndaki günlük AKM konsantrasyonlarını tahmin etmek amacıyla sediment anahtar eğrisi, çoklu regresyon ve uzun kısa süreli bellek modellerini karşılaştırmıştır. Çalışmada, 2009-2019 dönemi için Yen Thuong istasyonundaki günlük AKM konsantrasyonu verileri ile havzada yer alan beş farklı istasyonun günlük Q verileri kullanılmışlardır. Çalışma sonucunda çoklu regresyon yönteminin AKM konsantrasyonlarını kabul edilebilir doğrulukta tahmin edebildiğini belirtmişlerdir. Adnan vd. (2025), Çin'in Bailong Nehri Havzası'nda günlük AKM yükünü hibrit yöntemler kullanarak tahmin etmişlerdir. Girdi parametrelerini optimize etmek için ÇDURE yönteminin kullanıldığı çalışmada geçmiş AKM yükü ve Q verileri model girdileri olarak değerlendirilmiştir. Girdi parametrelerinin yöntemlerin tahmin performansını artırmada kritik bir rol oynadığı ve uygun veri seçiminin AKM yükü tahmin doğruluğunu önemli ölçüde iyileştirebileceğini belirtmişlerdir. Ayrıca literatürde ÇDURE yönteminin AKM tahmininde sediment anahtar eğrisi yöntemine kıyasla daha yüksek performans gösterdiği belirtilmiştir (Demirci & Baltaci, 2013; Malik vd., 2019; Shiri vd., 2020; Keshtegar vd., 2023). Bu bağlamda, regresyon tabanlı yöntemlerden biri olan ÇDURE ile KRA arasında performans karşılaştırması, bu çalışmanın temel amacını oluşturmaktadır.

Çalışma alanı olarak belirlenen Patapsco Nehri Havzası'nda sediment hareketini etkileyen başlıca faktörler olarak yağış rejimi, arazi kullanımı, jeolojik yapı, topoğrafya ve hidrolik yapılar öne çıkmaktadır. Kısa süreli ve şiddetli yağışlar yüzeysel akışı artırarak erozyonu tetiklemekte, bu durum AKM konsantrasyonlarında ani artışlara yol açmaktadır. Arazi kullanımındaki değişimler yüzeysel akışın ve dolayısıyla sediment taşınımının önemli belirleyicilerindendir. Barajların varlığı ise sediment taşınım sürecini doğrudan etkilemekte; sedimentlerin tutulmasına, taşkın sonrası ani salınımlarına veya mansap bölgelerinde morfolojik değişimlere neden olmaktadır (Collins vd., 2017). Ayrıca havza geçmişte baraj inşaları ve kaldırmaları gibi yapısal müdahalelere maruz kalmış olup, bu durum havzanın doğal akarsu ekosisteminin önemli ölçüde bozulmasına yol açmıştır. Bu faktörler arasındaki etkileşim, havzada sediment üretim dinamiklerinin mekana ve zamana bağlı değişimlerini şekillendirmekte olup, AKM tahmin çalışmalarının zorluğunu artırmaktadır.

Bu çalışmada son 15 yıllık süreçte birçok taşkına ve baraj kaldırma çalışmalarına maruz kalan, Chesapeake Körfezi'ne dökülen Patapsco Nehri'nde günlük AKM konsantrasyon değerleri KRA ve ÇDURE yöntemleri ile tahmin edilmiştir. Modelleme çalışmalarında bağımsız değişken olarak birçok çalışmada (Bayram vd., 2012; Mohammadi vd., 2021 Teixeira vd., 2020) Q ve bulanıklık (T) parametreleri kullanılmıştır. Veriler Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu (United States Geological Survey, USGS) tarafından Catonsville ve Elkridge istasyonlarında günlük olarak ölçülmüştür. Verilerin temin edildiği iki gözlem istasyonu için girdi parametreleri ile bir ve iki girdili olmak üzere üç model kurulmuştur. Çalışma kapsamında, hem KRA ve ÇDURE yöntemlerinin AKM tahmininde kullanılabilirliği hem de kullanılan girdi parametrelerinin model performansına etkileri ayrıntılı olarak değerlendirilmiştir. Literatür incelendiğinde Patapsco Nehri Havzası için henüz yönteme bağlı karşılaştırma içeren bir çalışmanın yapılmamış olması bu çalışmanın özgünlüğünü oluşturmaktadır. Ayrıca, kullanılan yöntemlerin tahmin denklemlerini açıkça sunması, modellerin gelecekte farklı veri setleri için uygulanabilmesini mümkün kılmaktadır. Böylece çalışmanın hem istasyon tabanlı modelleme yaklaşımı hem de yöntemlerin kolay yorumlanabilir ve sürdürülebilir çıktılar sağlaması bakımından literatüre katkı sağlayacağı düşünülmektedir.

2. Materyal ve Metot

2.1. Çalışma Alanı

Patapsco Nehri Amerika Birleşik Devletleri'nin (ABD) 21 hidrolojik bölgeden biri olan Orta Atlantik bölgesinin Yukarı Chesapeake alt bölgesinde yer almaktadır. Nehir güney ve kuzey olmak üzere iki yan kola sahiptir. Güney kolu Parr's Spring'ten doğup 31.2 km boyunca akarak Carrol şehrindeki kaynağından doğan ve 33.6 km boyunca akan kuzey kolu ile Baltimore şehir merkezinin yaklaşık 24.0 km batısında birleşerek Patapsco Nehri'nin ana kolunu oluşturmaktadırlar. Chesapeake Körfezi'ne dökülen Patapsco Nehri, 63 km uzunluğa ve 1760 km² drenaj alanına sahiptir. Nehir, uzunluğunun büyük bir kısmında dar bir vadi içerisinde akan küçük bir nehir niteliğindeyken, son 16 km'si Chesapeake Körfezi'nin büyük gelgit halici girişini oluşturmaktadır (Terrain360, 2025; Kumantaş vd. 2025).

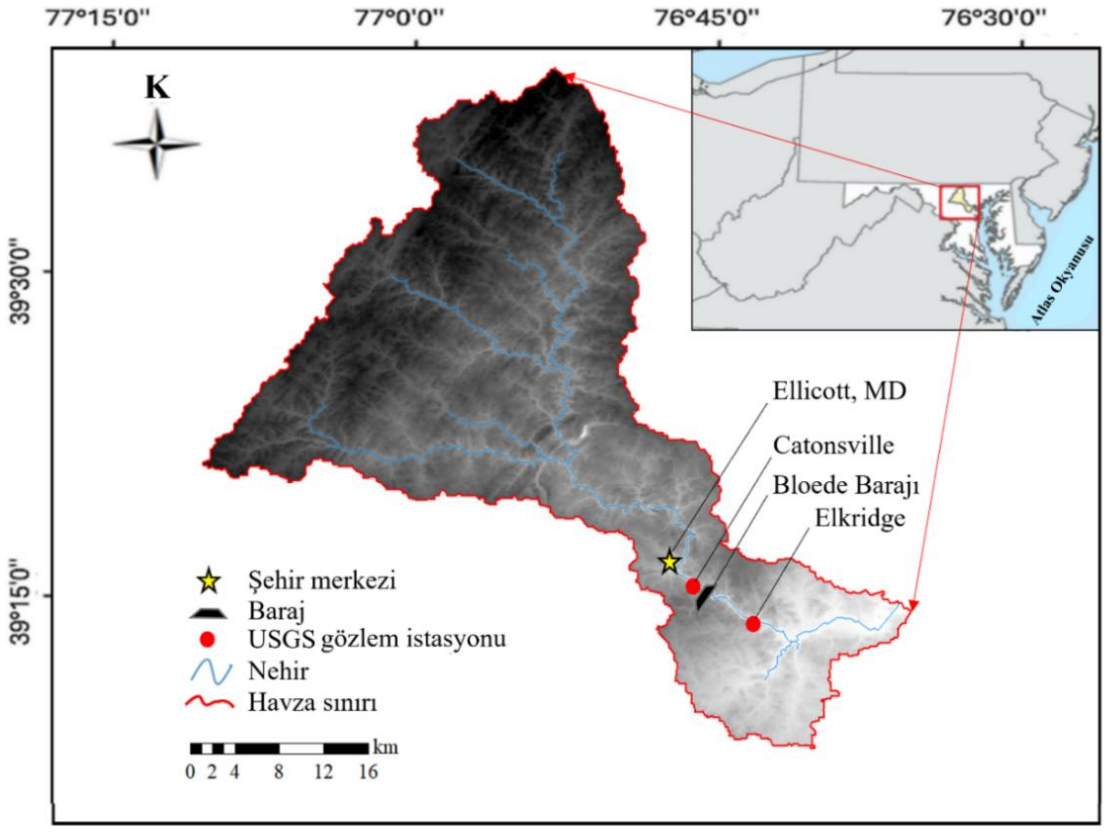
Patapsco Nehri Havzası'nda kışları ılıman, yazları sıcak ve nemli geçen nemli bir karasal iklim hakimdir. Doğuda Chesapeake Körfezi ve Atlas Okyanusu, batıda ise Appalachain Dağları bölge ikliminin ılımanlaşmasını sağlamaktadır.

Yıl boyunca dengeli bir dağılıma sahip olan yağış değeri USGS verilerine göre yılda ortalama 1016 mm'dir. Yağış yoğunluğunun en fazla olduğu dönemler şiddetli fırtına ve kasırgaların meydana geldiği Temmuz ve Ağustos aylarıdır. Bölge genelinde şiddetli kuraklıklar nadir görülmektedir. Temmuz en sıcak (22.0 °C), Ocak ise en soğuk (–2.0 °C) aydır (Travers, 2016). Tarihsel veriler, nehrin önemli bir taşkın geçmişine sahip olduğunu göstermektedir. Havzada meydana gelen taşkınlar Halverson (2019) tarafından ayrıntılı olarak ele alınmıştır. USGS verilerine göre Patapsco Nehri yıllık ortalama Q değeri 9.20 m^3/s'dir. En yüksek değer 762.01 m^3/s ile Mayıs 2018'de en düşük değer ise 0.89 m^3/s ile Eylül 2017'de ölçülmüştür. Bu değerler havzada meydana gelen taşkınların sebepleri arasında değerlendirilmektedir.

1760'ta başlayan sanayi devrimi ile Patapsco Nehri Havzası'nda da birçok sanayi faaliyeti yürütülmüştür. Bilinçsizce sürdürülen sanayi faaliyetleri, insan ve sanayi atıklarının doğrudan nehre deşarj edilmesi, Liberty Barajı'nın inşası ile yaşanan Q değerindeki düşüşler gibi birçok sebepten ötürü 1960'lara gelindiğinde Patapsco Nehri'nin su kalitesi ekosistem için sürdürülemez bir düzeye inmiş; nehir ve haliç ekolojik açıdan neredeyse işlevsiz bir hale gelmiştir. Su kalitesini iyileştirmek amacıyla kar amacı gütmeyen kuruluşların öncülük ettiği 1980'lerde başlayan ve günümüzde de devam eden nehri koruma ve temizleme çalışmaları yapılmıştır (Kemper, 2021). Yapılan bu çalışmaların başında da nehrin ana kolu üzerinde bulunan atıl barajların kaldırılması gelmektedir. Patapsco Nehri Havzası'nda farklı amaçlar için inşa edilmiş biri yan kol üzerinde olmak üzere toplam beş adet baraj bulunmaktadır. Bu barajlar kuzey kolundaki Liberty Barajı ve ana kol üzerinde membadan mansaba doğru sırasıyla Daniels, Union, Simkins ve Bloede barajlarıdır (Şekil 1). Nehri korumak amacıyla bu barajlardan Union 2010 yılında, Simkins 2011 yılında ve Bloede Barajı 2018 yılında kaldırılmıştır (Cui vd., 2019; Huang vd., 2023; Collins vd., 2024).

2.2. Kullanılan Veriler

Bu çalışmada Patapsco Nehri üzerinde bulunan 01589025 numaralı Catonsville ile 01589035 numaralı Elkridge gözlem istasyonlarının 2016-2021 yılları arasındaki beş su yılına ait günlük ortalama AKM (mg/L), T (FNU) ve Q (m^3/s) verileri kullanılmıştır. 2016-2021 döneminin dikkate alınmasında, AKM ve T verilerinde 2016 öncesi %10'u aşan eksiklerin olması 2021 sonrasında ise ilgili parametrelerin ölçümlerinin bulunmaması etkili olmuştur. Gözlem istasyonlarının konumları Şekil 1'de gösterilmektedir. İstasyonlara ait veriler USGS'nin web sitesinden temin edilmiştir. Eksik veriler regresyon analizi yöntemi kullanılarak tamamlanmıştır. İstasyonlara ait AKM, T ve Q verilerinin temel istatistikleri Tablo 1'de, parametrelerin birbiri ile olan korelasyonları ise Tablo 2'de verilmektedir. Tablo 1'de tüm değişkenlerin yüksek bir C_{sx} değerine sahip olduğu görülmektedir. Bu değerler değişkenlerin normal dağılıma uymadığını göstermektedir.



Şekil 1: Patapsco Nehri üzerindeki baraj ve gözlem istasyonlarının konumu (Cashman vd., 2021)

Tablo 1: Patapsco Nehri'nde takibi yapılan değişkenlere ait temel istatistikleri

İstasyon	Catonsville			Elkridge		
	AKM (mg/L)	T (FNU)	Q (m^3/s)	AKM (mg/L)	T (FNU)	Q (m^3/s)
Min	0.20	0.20	0.89	0.40	0.20	1.02
Ort	33.10	15.84	9.20	45.95	20.46	10.07
Maks	2360.00	1210.64	153.76	2540.00	1118.41	169.90
SS	143.77	67.08	13.55	151.18	68.42	14.98
C_{sx}	9.49	10.39	0.13	8.13	8.51	0.14

Min: minimum, Ort: ortalama, Maks: maksimum, SS: standart sapma ve C_{sx}: çarpıklık katsayısı

Tablo 2: Patapsco Nehri'nde takibi yapılan değişkenler arasındaki korelasyon katsayıları

	Catonsville			Elkridge	
	Q	T		Q	T
AKM	0.729	0.867	AKM	0.723	0.974
Q		0.571	Q		0.655

2.3. Klasik Regresyon Analizi (KRA)

Bir bağımlı değişken ile bir ya da daha fazla bağımsız değişken arasındaki ilişkiyi nicel olarak inceleyen ve bu ilişkiyi matematiksel bir model aracılığıyla ifade eden KRA istatistiksel bir yöntemdir (Bayazıt, 1981; Nacar vd., 2018). Temel amacı, bağımlı değişkenin değerini, bağımsız değişken veya değişkenlerin bilinen değerlerine dayanarak tahmin etmek ve açıklamaktır.

Bu çalışma kapsamında yapılan analizler IBM SPSS Statistics 26 yazılımı kullanılarak gerçekleştirilmiştir. Modelleme çalışmalarında AKM'yi tahmin etmek için dört regresyon fonksiyonu kullanılmıştır. Doğrusal (DF), üs (ÜSF), üstel (ÜTF) ve kuadratik (KF) fonksiyonlarına ait denklemler Eşitlik (1)-(4)'te verilmektedir.

$$AKM_{DF} = w_0 + w_1x_1 + w_2x_2 + w_3x_3 + \cdots + w_nx_n \quad (1)$$

$$AKM_{ÜSF} = w_0x_1^{w_1}x_2^{w_2}x_3^{w_3}x_4^{w_4} \ldots x_n^{w_n} \quad (2)$$

$$AKM_{ÜTF} = w_0 + exp\,(w_1 + w_2x_1 + w_3x_2 + \cdots + w_{n+1}x_n) \quad (3)$$

$$AKM_{KF} = w_0 + w_1x_1 + w_2x_2 + w_3x_1x_2 + w_4x_1^2 + w_5x_2^2 \quad (4)$$

burada n, x_n ve w_n sırasıyla bağımsız değişken sayısını, bağımsız değişkenleri ve bağımsız değişkenlere ait katsayıları temsil etmektedir.

2.4. Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (ÇDURE)

Friedman (1991) tarafından tanıtılan ÇDURE, bağımsız değişkenler ve bağımlı değişken arasında parametrik olmayan bir model oluşturmak için kullanılan bir yöntemdir. ÇDURE parametrik olmayan regresyon teknikleri kullanarak değişkenler arasındaki doğrusal olmayan ilişkileri göstermektedir. ÇDURE yönteminde, tutarlı ve doğru parametre tahmini için hem ileri hem de geri besleme algoritmalarını kullanılmaktadır. Yöntem doğrusal olmayan veri seti ile yapılan modelleme çalışmalarında başarısını kanıtlamış ve farklı alanlarda çalışan birçok araştırmacı tarafından tercih edilmiştir (Parsaie vd., 2016; Yilmaz vd., 2018; Raja vd., 2021; Sahraei vd., 2021; Abed vd., 2023; Dukalang & Otok, 2025).

ÇDURE yöntemi, veri setindeki her doğrusal ilişkinin sonunda bir regresyon denklemi oluşturmaktadır. Bu yöntem önce veri kümesini küçük gruplara bölmekte ve her veri grubu için bir temel fonksiyon (TF) oluşturmaktadır. TF'lere ait genel denklem Eşitlik (5)'te verilmektedir.

$$maks(0, x - k)\ veya\ maks(0, k - x) \quad (5)$$

burada x tahmin değişkeni ve k eşik değeridir (Zabihi vd., 2016). TF'lerin doğrusal bir kombinasyonundan oluşan ÇDURE'nin genel denklemi Eşitlik (6)'da verilmektedir.

$$y = f(x) + \varepsilon \quad (6)$$

burada y ve *f(x)* bilinmeyen fonksiyonu tarafından tahmin edilen bağımlı değişke ve ε hata değeridir. *f(x)* Eşitlik (7)'de verilmektedir.

$$f(x) = \beta_0 + \beta_m \times TF_m(x) \quad (7)$$

burada TF_m, m'nci, β_m ona ait katsayı ve m değeri verilere uygun olan maksimum *TF* sayısıdır (Yılmaz vd., 2018).

ÇDURE'nin temel etki unsuru, aşırı uyumdan kaçınırken son derece genel bir regresyon modeline uymanın etkili bir yöntemini geliştirmesidir. ÇDURE hem sürekli hem de kategorik değişkenler dahil olmak üzere çok çeşitli öngörücü türlerini doğal bir şekilde içerir. İç içe geçmiş değişkenleri işleme kabiliyetine sahiptir ve verileri atmadan olmayan değerleri tamamlayabilir. Bununla birlikte, ikili yanıt durumu gibi daha karmaşık yanıtlarla kullanım için iyi bir yapı taşıdır (Friedman & Roosen, 1995). Bu da ÇDURE yönteminin, çok değişkenli regresyon problemleri için uygun bir yöntem haline getirmektedir (Conoscenti vd., 2016). ÇDURE ile ilgili daha fazla bilgiye Friedman (1991) ve Samui & Kothari (2012) çalışmalarından ulaşılabilir.

Bu çalışmada ÇDURE yönteminin uygulamaları Salford Predictive Modeler 8.0 yazılımı kullanılarak gerçekleştirilmiştir. ÇDURE yönteminde her model için en yüksek performans değerlerini veren denklem ve TF'ler belirlenmiştir. ÇDURE yöntemiyle yapılan modellemede, modelin maksimum TF'leri, maksimum etkileşimi, hız faktörü, düğümler arası minimum gözlem sayısı, eklenen değişken ceza katsayısı ve düğüm optimizasyonu için serbestlik dereceleri gibi çeşitli parametreler model sonucunu etkileyebilmektedir. ÇDURE modelleri için optimum parametreler deneme yanılma yöntemiyle belirlenmiştir. Maksimum TF, ÇDURE'nin en güçlü modelini oluşturmak için aldığı ileri adım sayısını belirtmektedir (Yilmaz vd., 2018). Maksimum TF tanımlamak için deneme yanılma yolu ile 5 ile 40 arasındaki çeşitli değerler kullanılmıştır. ÇDURE'nin dikkate alabileceği maksimum etkileşim miktarını tanımlamak için 1 ile 10 arasında bir maksimum etkileşim sınırı belirlenmiştir. Hız faktörü (hız ve doğruluk arasındaki dengeyi kontrol eder) ve düğümler arasındaki minimum gözlem sayısı 1 ile 5 arasındaki değerlerle test edilmiştir. Modelleme çalışmalarında, eklenen değişken ceza değeri "yok" olarak tanımlanmış ve analizler bu şekilde gerçekleştirilmiştir.

2.5. Modelleme Çalışmaları

Modelleme çalışmalarında Catonsville ve Elkridge gözlem istasyonlarından elde edilen toplam 1824 adet günlük ortalama veriden 1199'u (%65.74) eğitim, 300'ü (%16.45) doğrulama, geri kalan 325'i (%17.81) ise test için ayrılmıştır. Verilerin gruplara ayrılmasından sonra, her bir girdi parametresinin AKM konsantrasyonu üzerindeki etkisini belirlemek için farklı girdi kombinasyonları denenmiştir. Bu çalışmada her bir istasyon için sadece T (CM1 ve EM1), sadece Q (CM2 ve EM2) ve hem T hem de Q (CM3 ve EM3) girdi parametresi olacak şekilde üçer model kurulmuştur. CM ve EM sırasıyla Catonsville ve Elkridge istasyonları için kurulan modelleri temsil etmektedir. Veri setinde bulunabilecek uç değerlerin optimizasyonu zor olabilmektedir. Optimizasyonu kolaylaştırmak ve daha etkili sonuçlar elde etmek için normal dağılım göstermeyen parametrelere logaritmik dönüşüm uygulanmış ve Eşitlik (8) kullanılarak veriler 0.1 ile 0.9 arasında normalize edilmiştir (Hameed vd., 2017).

$$Normalize\ Değer = \left[\frac{Ham\ Değer - Minimum\ Değer}{Maksimum\ Değer - Minimum\ Değer}\right] \times (0.8) + 0.1 \quad (8)$$

2.6. Modellerin Değerlendirilmesi

KRA ve ÇDURE yöntemleri ile farklı girdi parametreleri içeren modellerin tahmin yeteneklerini karşılaştırmak için, ortalama karesel hatanın karekökü (OKHK), ortalama mutlak hata (OMH) ve Nash-Sutcliffe (NS) verimlilik katsayısı performans istatistikleri kullanılmıştır. NS, 0 ile 1 arasında değişen değerlere sahiptir. Bu değer 1'e ne kadar yakın ise model doğruluğu o kadar yüksektir. Moriasi vd., (2007), yapmış oldukları modelleme çalışmalarında NS verimlilik katsayısı kullanımının model değerlendirmesi bakımından önemini vurgulamışlardır. Ayrıca OKHK ve OMH değerlerinin düşük olması da model doğruluğunun bir göstergesidir. OKHK, OMH ve NS istatistikleri Eşitlik (9)-(11) kullanılarak hesaplanmıştır.

$$OKHK = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(AKM_{ö} - AKM_t)^2} \quad (9)$$

$$OMH = \frac{1}{N}\sum_{i=1}^{N}|AKM_{ö} - AKM_t| \quad (10)$$

$$NS = 1 - \frac{\sum_{i=1}^{N}(AKM_{ö} - AKM_t)^2}{\sum_{i=1}^{N}(AKM_{ö} - \overline{AKM_{ö}})^2} \quad (11)$$

burada $AKM_{ö}$ ölçüm değeri, AKM_t tahmin değeri, $\overline{AKM_{ö}}$ ölçüm değerlerinin ortalaması ve N ise toplam veri sayısıdır.

3. Bulgular ve Tartışma

Çalışmanın bu bölümünde, AKM tahmini için kurulan modellere ait bulgular sunulmaktadır. Modelleme çalışmalarında, KRA'nın dört formu ve ÇDURE yöntemi eğitim veri setleri kullanılarak en uygun katsayıları ve en uygun girdi kombinasyonunu belirlemek için eğitilmiştir. Daha sonra eğitim veri seti için elde edilen katsayılar doğrulama ve test veri setlerine uygulanmış ve modellerin tahmin performansları karşılaştırılmıştır.

KRA analizinde her bir istasyon (Catonsville ve Elkridge) ve model için kullanılan regresyon fonksiyonlarına ait katsayılar Tablo 3'te, ÇDURE yönteminde ise aynı modeller için belirlenen TF'ler ve bu TF'ler kullanılarak oluşturulan denklemler ise Tablo 4'te verilmektedir. KRA ve ÇDURE yöntemlerinin Catonsville ve Elkridge istasyonları için günlük ortalama AKM konsantrasyonunu tahmin etme kabiliyetini belirlemek amacıyla, modeller için hesaplanan performans istatistikleri birbirleri ile karşılaştırılmıştır (Tablo 5 ve 6). Her bir model için en iyi performans değerleri koyu olarak belirtilmiştir. Tablo 5 ve 6, iki istasyon için üç modelden ikisinin yüksek bir doğruluk seviyesine sahip olduğunu göstermektedir. Her iki yöntem ve iki istasyon için en yüksek performans değerleri üçüncü modelden, en düşük performans değerleri ise ikinci modelden elde edilmiştir. En düşük hata değerleri T ve Q değişkenlerinin birlikte kullanıldığı modelden elde edilmiştir. Bu sonuçlar, T ve Q değişkenlerinin girdi parametresi olarak dahil edilmesinin tek parametre ile kurulan modellere kıyasla model doğruluğunu artırdığını göstermektedir. İki istasyon için de kurulan modellerde en iyi sonuçlar eğitim setinde genellikle KRA yönteminden doğrulama ve test veri setlerinde ise ÇDURE yönteminden elde edilmiştir. Ayrıca KRA yöntemi için en düşük hata değerleri doğrusal ve üstel fonksiyonlardan elde edilmiştir. KRA ve ÇDURE yöntemleri sadece performans bakımından değil, yorumlanabilirlik düzeyleri bakımından da değerlendirilmiştir. KRA yöntemi, her bir bağımsız değişkenin AKM üzerindeki etkisini katsayılar aracılığıyla doğrudan ortaya koymakta ve bu yönüyle kolay anlaşılır bir yapı sunmaktadır. ÇDURE yöntemi ise eşik tabanlı temel fonksiyonlara dayanan daha karmaşık bir yapıya sahiptir. Bu çalışmada tek girdili modeller 3 (CM) ve 2 (EM), iki girdili modeller ise 6 (CM3) ve 7 (EM3) temel fonksiyona sahiptir. Çoklu temel fonksiyonlar modelin yorumlanmasını zorlaştırsa da tahmin değerleri gözlem verilerine daha iyi uyum sağlamaktadır. Bu durum özellikle doğrulama ve test veri setlerinde tahmin performansını artırmaktadır. Dolayısıyla KRA yöntemi şeffaflık ve yorumlanabilirlik avantajına sahipken, ÇDURE yöntemi esnek yapısı sayesinde daha yüksek uyum kabiliyeti göstermektedir.

Tablo 3: Klasik regresyon analizinden elde edilen katsayılar

Fonksiyon	Model	Katsayı					
		w_0	w_1	w_2	w_3	w_4	w_5
DF	CM1	0.069	0.898				
	CM2	0.184	0.550				
	CM3	0.057	0.821	0.103			
ÜSF	CM1	0.936	0.845				
	CM2	0.660	0.521				
	CM3	0.963	0.762	0.113			
ÜTF	CM1	–2.482	0.945	0.305			
	CM2	0.197	–2.705	2.604			
	CM3	–1.400	0.401	0.438	0.061		
KF	CM1	0.094	0.768	0.150			
	CM2	0.258	0.130	0.508			
	CM3	0.089	0.623	0.157	1.240	–0.405	–0.637
DF	EM1	0.003	0.990				
	EM2	0.117	0.733				
	EM3	–0.005	0.867	0.152			
ÜSF	EM1	0.994	0.995				
	EM2	0.794	0.705				
	EM3	1.022	0.866	0.147			
ÜTF	EM1	–7.102	1.962	0.131			
	EM2	–0.066	–1.385	1.534			
	EM3	–3.096	1.137	0.243	0.044		
KF	EM1	0.015	0.932	0.065			
	EM2	0.200	0.257	0.584			
	EM3	0.015	0.775	0.164	0.997	–0.362	–0.537

Catonsville istasyonu için, KRA yönteminde OKHK, OMH ve NS değerleri sırasıyla 51.21-164.61 mg/L, 8.87- 37.11 mg/L ve 0.060-0.909 arasında değişmektedir. En düşük OKHK ve OMH değerleri sırasıyla CM3'ün test ve eğitim veri setlerinden, en yüksek NS değeri ise CM3'ün test veri setinden elde edilmiştir. ÇDURE yönteminde ise OKHK, OMH ve NS değerleri sırasıyla 42.15-136.64 mg/L, 8.57-27.05 mg/L ve 0.195-0.932 arasında değişmektedir. En düşük OKHK ve OMH değerleri sırasıyla CM3'ün doğrulama ve eğitim veri setlerinden, en yüksek NS değeri ise CM3'ün doğrulama veri setinden elde edilmiştir. Her iki yöntem için de CM2 tüm veri setlerinde en düşük performansa sahiptir. Eğitim, doğrulama ve test aşamalarında CM1 ve CM3 için hesaplanan NS değerleri, Moriasi vd. (2007) tarafından sağlanan performans derecelendirmelerine göre "çok iyi" sınıfına girmektedir. Her iki yöntem için en iyi modele ait sonuçların saçılım grafikleri sırasıyla, eğitim, doğrulama ve test veri setleri için Şekil 2'de verilmiştir.

Tablo 4: Çok değişkenli uyarlanabilir regresyon eğrileri yönteminden elde edilen temel fonksiyonlar ve denklemler

Model	Temek fonksiyon	Denklem
CM1	TF1 = maks (0, T – 0.215086) TF3 = maks (0, T – 0.163677) TF5 = maks (0, T – 0.311529)	AKM = 0.262651 + 1.423970 × TF1 – 0.343284 × TF3 – 0.176734 × TF5
CM2	TF1 = maks (0, Q – 0.567343) TF2 = maks (0, 0.567343 – Q) TF3 = maks (0, Q – 0.247677)	AKM = 0.756355 + 2.438540 × TF1 – 1.259950 × TF2 – 0.966105 × TF3
CM3	TF3 = maks (0, Q – 0.163808) TF5 = maks (0, T – 0.311529) × TF3 TF6 = maks (0, 0.311529 – T) × TF3 TF7 = maks (0, Q – 0.24323) TF9 = maks (0, T – 0.513219) × TF7 TF10 = maks (0, 0.513219 – T) × TF7	AKM = 0.248732 + 1.419610 × TF3 + 7.731270 × TF5 – 9.305970 × TF6 –2.76414 × TF7 –7.447570 × TF9 + 6.519570 × TF10
EM1	TF1 = maks (0, T – 0.184949) TF2 = maks (0, 0.184949 – T)	AKM = 0.185269 + 0.994543 × TF1 – 0.359114 × TF2
EM2	TF1 = maks (0, Q – 0.44335) TF2 = maks (0, 0.44335 – Q)	AKM = 0.410205 + 1.044450 × TF1 – 0.543647 × TF2
EM3	TF1 = maks (0, T – 0.184949) TF2 = maks (0, 0.184949 – T) TF3 = maks (0, Q – 0.411826) TF4 = maks (0, 0.411826 – Q) TF5 = maks (0, Q – 0.298687) TF7 = maks (0, Q – 0.598385) TF9 = maks (0, T – 0.370505)	AKM = 0.244563 + 0.790314 × TF1 – 0.485496 × TF2 + 0.49195 × TF3 – 0.242674 × TF4 – 0.236466 × TF5 – 0.189823 × TF7 + 0.097721 × TF9

Tablo 5: Catonsville gözlem istasyonu için regresyon tabanlı yöntemlerden elde edilen bulguların karşılaştırılması

	İstatistik	Model	KRA_DF	KRA_ÜSF	KRA_ÜTF	KRA_KF	ÇDURE
Eğitim	OKHK	CM1	**61.61**	64.16	71.74	73.07	61.64
	OMH		**10.57**	11.08	11.98	12.09	10.60
	NS		**0.777**	0.758	0.698	0.687	**0.777**
	OKHK	CM2	122.88	126.16	**98.47**	110.09	117.16
	OMH		25.65	26.24	**21.99**	23.80	23.50
	NS		0.114	0.066	**0.431**	0.289	0.195
	OKHK	CM3	**52.22**	52.58	79.85	72.73	60.88
	OMH		9.09	8.87	11.28	10.87	**8.57**
	NS		**0.840**	0.838	0.626	0.689	0.783
Doğrulama	OKHK	CM1	92.19	99.55	83.08	**81.12**	89.71
	OMH		18.97	20.14	17.53	**17.15**	18.50
	NS		0.675	0.621	0.736	**0.748**	0.692
	OKHK	CM2	148.69	154.87	86.67	125.18	**84.25**
	OMH		35.75	37.11	**23.31**	31.17	24.65
	NS		0.154	0.082	0.712	0.400	**0.728**
	OKHK	CM3	80.59	82.53	55.76	61.264	**42.15**
	OMH		16.55	16.66	12.64	13.55	**9.74**
	NS		0.751	0.739	0.881	0.856	**0.932**
Test	OKHK	CM1	96.29	106.89	81.69	**79.08**	93.33
	OMH		15.32	16.51	13.87	**13.55**	14.92
	NS		0.678	0.604	0.769	**0.783**	0.698
	OKHK	CM2	160.39	164.61	**125.14**	144.52	136.64
	OMH		28.56	29.27	**23.89**	25.82	27.05
	NS		0.108	0.060	**0.457**	0.276	0.353
	OKHK	CM3	87.97	92.80	51.29	59.12	**50.41**
	OMH		14.13	14.53	9.98	10.89	**9.69**
	NS		0.732	0.701	0.909	0.879	**0.912**

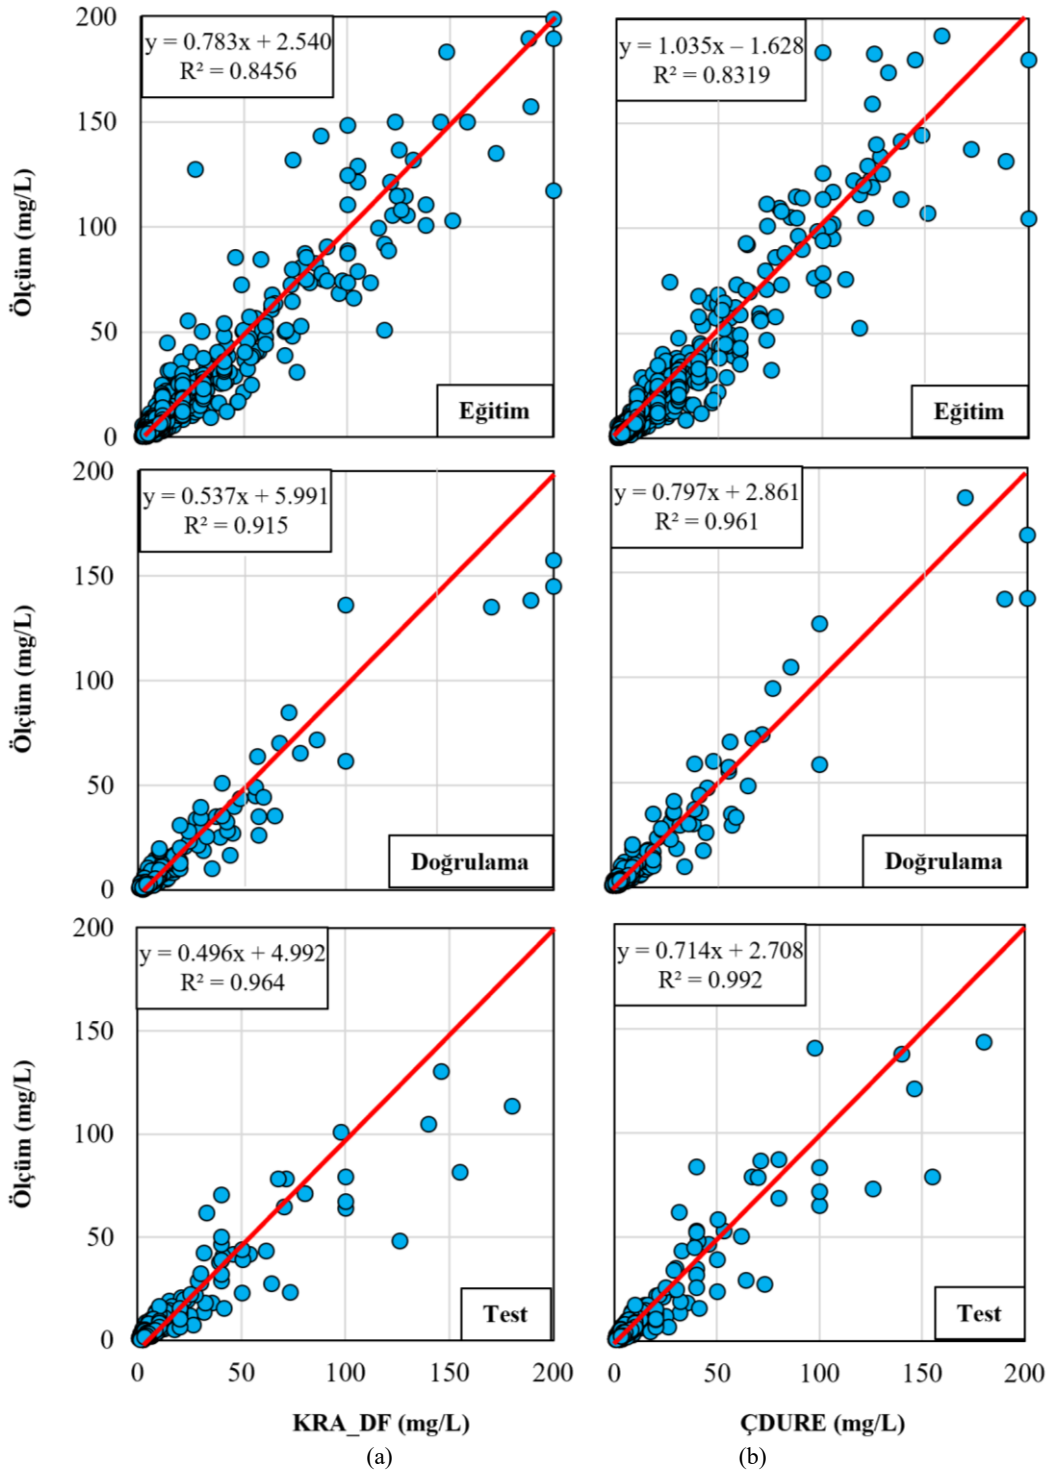
Ekridge istasyonu için, KRA yönteminde OKHK, OMH ve NS değerleri sırasıyla 27.70-192.99 mg/L, 8.04-38.66 mg/L ve 0.171-0.981 arasında değişmektedir. En düşük OKHK ve OMH değerleri sırasıyla CM3'ün doğrulama ve test veri setlerinden, en yüksek NS değeri ise CM3'ün test veri setinden elde edilmiştir. ÇDURE yönteminde ise OKHK, OMH ve NS değerleri sırasıyla 24.56-155.98 mg/L, 86.71-34.69 mg/L ve 0.324-0.988 arasında değişmektedir. En düşük OKHK ve OMH değerleri ile en yüksek NS değeri CM3'ün test veri setinden elde ediliştir. Tüm veri setlerinde en düşük performansa sahip model CM2'dir. Eğitim, doğrulama ve test aşamalarında CM1 ve CM3 için hesaplanan NS değerleri, Moriasi vd. (2007) tarafından sağlanan performans derecelendirmelerine göre "çok iyi" sınıfına girmektedir. Her iki yöntem için en iyi modele ait sonuçların saçılım grafikleri sırasıyla, eğitim, doğrulama ve test veri setleri için Şekil 3'te verilmektedir.

Tablo 6. Elkridge gözlem istasyonu için regresyon tabanlı yöntemlerden elde edilen bulguların karşılaştırılması

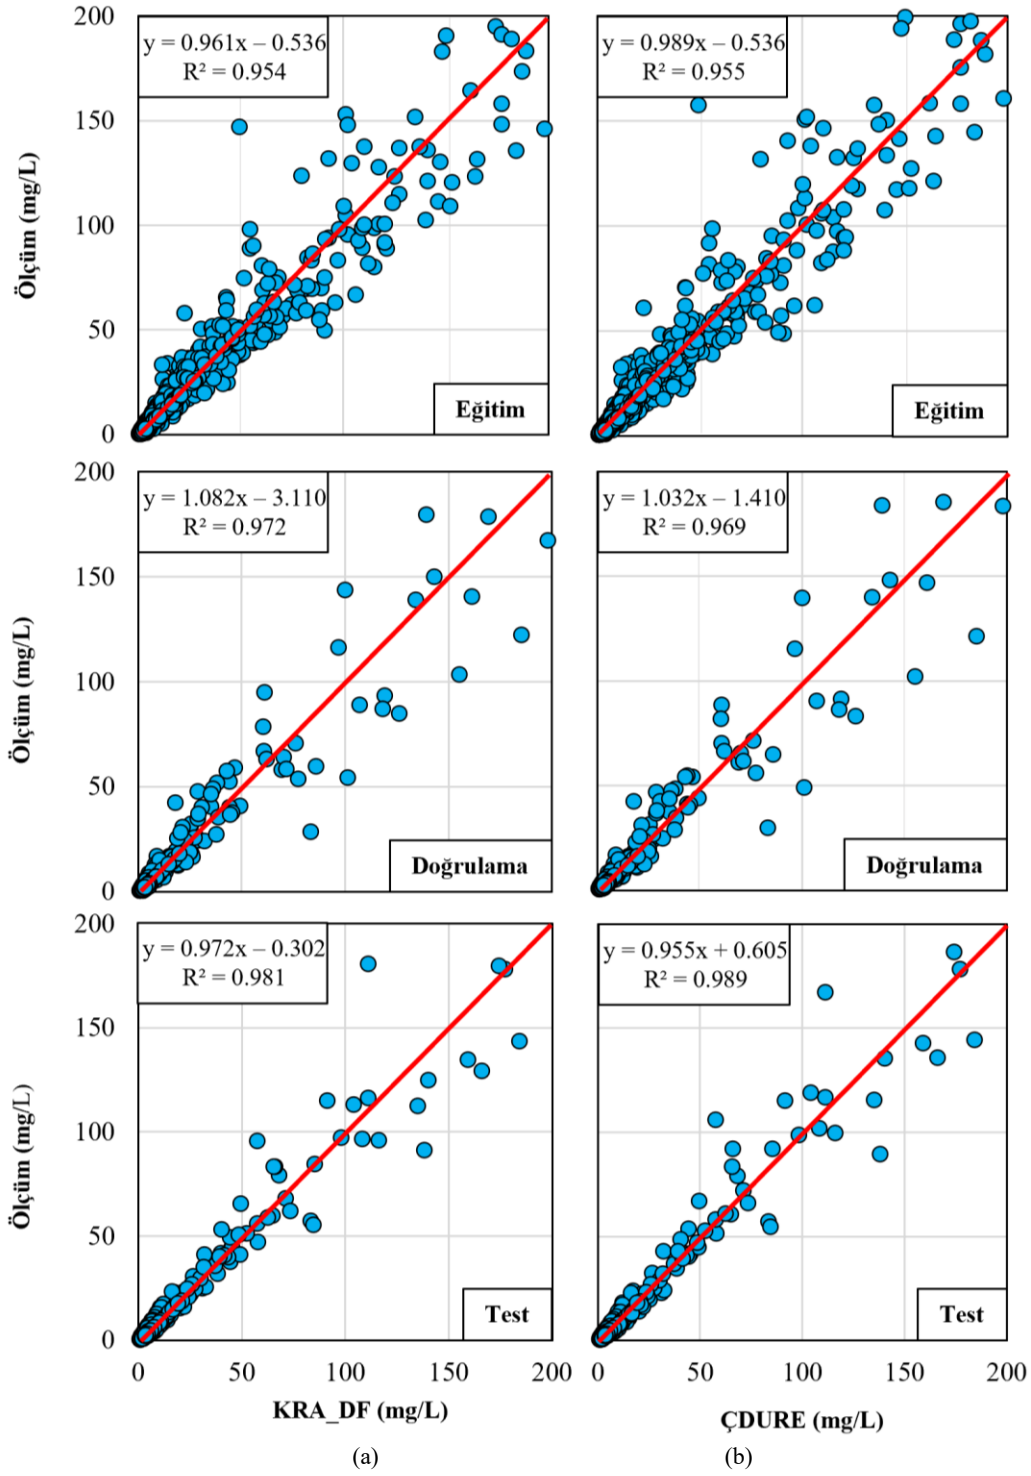
	İstatistik	Model	KRA_DF	KRA_ÜSF	KRA_ÜTF	KRA_KF	ÇDURE
Eğitim	OKHK		**36.36**	36.44	41.65	41.51	36.93
	OMH	EM1	10.09	10.05	10.16	10.15	**10.02**
	NS		**0.923**	0.922	0.899	0.899	0.920
	OKHK		108.24	112.63	133.93	116.05	**107.49**
	OMH	EM2	**30.06**	31.28	32.06	30.95	30.18
	NS		0.315	0.258	–0.049	0.212	**0.324**
	OKHK		**28.14**	29.77	41.34	37.63	28.22
	OMH	EM3	8.31	8.27	9.61	9.25	**7.98**
	NS		**0.954**	0.948	0.900	0.917	0.953
Doğrulama	OKHK		30.53	30.07	30.19	**29.21**	29.80
	OMH	EM1	11.14	10.96	11.13	**10.22**	10.84
	NS		0.951	0.952	0.952	**0.955**	0.953
	OKHK		85.24	99.06	125.26	95.12	**85.16**
	OMH	EM2	30.01	32.99	35.23	31.21	**29.70**
	NS		0.616	0.481	0.171	0.522	**0.617**
	OKHK		27.70	32.68	49.85	48.05	**25.75**
	OMH	EM3	9.31	10.19	13.48	13.06	**8.56**
	NS		0.959	0.944	0.869	0.878	**0.965**
Test	OKHK		32.96	31.88	**30.82**	32.56	30.95
	OMH	EM1	9.74	9.42	9.14	9.27	**9.12**
	NS		0.977	0.979	**0.980**	0.978	**0.980**
	OKHK		183.87	192.99	172.23	160.89	**155.98**
	OMH	EM2	36.55	38.66	35.45	34.79	**34.69**
	NS		0.290	0.218	0.377	0.456	**0.489**
	OKHK		30.11	32.90	70.49	71.24	**24.56**
	OMH	EM3	8.13	8.04	10.82	10.67	**6.71**
	NS		0.981	0.977	0.896	0.893	**0.988**

Tüm sonuçlar değerlendirildiğinde, en iyi performans değerleri iki istasyon için her üç modelde eğitim aşamasında KRA, doğrulama ve test aşamalarında ise ÇDURE yönteminden elde edilmiştir. Ayrıca Tablo 5 ve 6'dan tüm tekniklere en uygun hata değerlerinin iki girdili modellerden elde edildiği anlaşılmaktadır. Ayrıca, her bir model için ÇDURE ve KRA yöntemlerinden elde edilen AKM tahmin değerleri paired t-test yardımıyla karşılaştırılmıştır. ÇDURE yönteminin KRA yöntemine kıyasla daha yüksek performans değerlerine sahip olması rağmen analizler iki yöntem arasında istatistiksel olarak anlamlı bir farklılık olmadığını göstermektedir. Bu durum AKM tahmininde girdi parametrelerinin kullanılan yöntemlere kıyasla daha belirleyici olduğunu ortaya koymaktadır.

AKM tahmin çalışmalarında kullanılan parametrelerin tahmin başarısına etkileri çalışma alanına bağlı olarak değişiklik gösterebilmektedir. Steffy ve Shank (2018) Susquehanna Nehri Havzası'nda (ABD) gerçekleştirdikleri çalışmada AKM'nin benzer hidrolojik koşullar altında büyük ölçüde değişiklik göstermesi sebebiyle Q'nun AKM tahmininde güvenilir bir parametre olmadığını ifade etmişlerdir. Ayrıca Teixeira vd. (2020) Potiribu Nehri Havzası'nda (Brezilya) yürüttükleri çalışmada AKM tahmininde etkili olan parametrelerin farklı yöntemler için değişiklik gösterdiğini ve T'nin model performansını artırdığını fakat alternatif parametreler olması durumunda AKM tahmini için özellikle T'ye ihtiyaç duyulmadığını belirtmişlerdir. Bu çalışmada T değişkeni, Q'ya kıyasla AKM tahmininde daha etkin olsa da her iki parametrenin birlikte kullanılması model doğruluğunu anlamlı şekilde artırmıştır. Benzer şekilde Wang vd. (2009) tropikal fırtına olaylarında AKM tahmini üzerine gerçekleştirdikleri çalışmada T'nin AKM tahmini için Q'ya göre daha baskın bir girdi parametresi olduğunu belirtmişlerdir. Campos ve Pedrollo (2021) Yukarı Paraguay Nehri Havzası'nda (Brezilya) yürüttükleri çalışmada AKM konsantrasyonlarını toprak tipi, arazi kullanımı, drenaj alanı, ortalama havza eğimi, yağış, T ve Q parametrelerinin farklı kombinasyonları ile kurdukları modeller yardımıyla tahmin etmişlerdir. En iyi tahmin performansının tüm parametreleri içeren modelden elde edildiğini fakat sadece bulanıklığın dahil edilmediği modelde tahmin performansının önemli ölçüde düştüğünü belirtmişlerdir. Sadece Q'nun dahil edilmediği modelde ise daha az bir performans düşüşü olduğunu ifade etmişlerdir. Bu farklılıkların kurulan modellerin ilgili çalışma alanlarına özgü olmasından kaynaklandığı düşünülmektedir. Jung vd. (2020) tarafından Patos Lagünü'ne akan Guaiba ve Camaqua nehirleri ile Sao Gonçalo Kanalı'nda yürütülen çalışmada, Q verileri kullanılarak farklı sediment anahtar eğrileri değerlendirilmiştir. Aylık ortalamaların dikkate alındığı en iyi modelin NS değerlerinin 0.71 ile 0.90 arasında değiştiği belirtilmiştir. Benzer şekilde, Asadi vd. (2025) tarafından İran'daki Kal-e Shur Sabzevar Nehri'nde gerçekleştirilen çalışmada, Q, AKM ve yağış verileri kullanılarak farklı makine öğrenme algoritmalarının performansı karşılaştırılmış ve en iyi model için NS değerinin 0.78 olduğu bildirilmiştir. İlgili çalışmalarda farklı parametreler ve yöntemler kullanılmış olmakla birlikte, elde edilen NS değerlerinin AKM tahmini için kabul edilebilir aralıkta olduğu ifade edilmiştir. Bu çalışmada her iki istasyon için de en yüksek performans gösteren iki girdili modelin NS değerlerinin 0.783 ile 0.988 arasında değişmesi, modellerin AKM tahmininde güvenilir şekilde kullanılabileceğini ortaya koymaktadır.



Şekil 2: Patapsco Nehri'nde (Catonsville) regresyon tabanlı yöntemlerle CM3 tarafından tahmin edilen AKM değerleri ile ölçüm verilerinin saçılım grafikleri



Şekil 3: Patapsco Nehri'nde (Elkridge) regresyon tabanlı yöntemlerle EM3 tarafından tahmin edilen AKM değerleri ile ölçüm verilerinin saçılım grafikleri

4. Sonuçlar

Bu çalışmada Amerika Birleşik Devletleri'ndeki Patapsco Nehri Havzasında askıda katı madde (AKM) konsantrasyonlarının regresyon tabanlı yöntemler kullanılarak tahmin edilebilirliği araştırılmıştır. Çalışma için Amerika Birleşik Devletleri Jeolojik Araştırmalar Kurumu (USGS) işletmesinde olan ve 2011-2021 yılları arasında bulanıklık (T), debi (Q) ve AKM parametrelerinin en az eksikle ölçüldüğü Catonsville ve Elkridge gözlem istasyonları tercih edilmiştir. Modelleme çalışmalarında Ekim 2016 ve Eylül 2021 yılları arasındaki günlük otalama veriler dikkate alınmıştır. Modellemelerde bu istasyonlarda ölçülen T, Q ve AKM konsantrasyonu parametreleri kullanılmıştır. Modellemeler klasik regresyon analizi (KRA) ve çok değişkenli uyarlanabilir regresyon eğrileri (ÇDURE) yöntemleri ile yapılmıştır.

Değişkenlerin tahmin performansları üzerindeki etkilerini değerlendirebilmek ve gelecekteki çalışmalarda bağımsız değişkenleri belirlemede rehber olması amacıyla çalışma kapsamında verilerin temin edildiği iki istasyon için farklı girdi kombinasyonlarına dayalı olarak üçer adet model geliştirilmiştir: yalnızca T parametresi kullanılan modeller (CM1 ve EM1), yalnızca Q parametresi kullanılan modeller (CM2 ve EM2) ve hem T hem de Q parametresi kullanılan modeller (CM3 ve EM3). Bu doğrultuda, toplamda altı farklı model ile AKM konsantrasyonu tahmin edilmiştir. Çalışmada yöntemlerin performanslarını karşılaştırmak için ortalama karesel hatanın karekökü (OKHK), ortalama mutlak hata (OMH) ve Nash-Sutcliffe (NS) verimlilik katsayısı performans istatistikleri kullanılmıştır.

Modelleme çalışmaları kapsamında eğitim veri seti için en iyi performans değerleri KRA yöntemi ile elde edilmiştir. Bununla birlikte, doğrulama ve test veri setleri için en iyi performans değerleri ÇDURE yöntemi tarafından sağlanmıştır. KRA yönteminde doğrusal fonksiyon diğer fonksiyonlara kıyasla daha iyi performans göstermiştir.

Tek girdili modeller kıyaslandığında T parametresi ile kurulan modelin Q parametresi ile kurulan modele kıyasla daha başarılı sonuçlar verdiği tespit edilmiştir. Fakat en yüksek tahmin performansları T ve Q parametrelerinin birlikte kullanıldığı modellerden elde edilmiştir. Catonsville ve Elkridge istasyonlarında en iyi sonuçlar sırasıyla M3, M1 ve M2 modellerinde elde edilmiştir. Analizler sonucunda tüm modeller dikkate alındığında en düşük OKHK ve OMH değerleri ile en yüksek NS değerleri için eğitim setinde elde edilen en iyi 18 sonucun 10'u (%55.55) doğrusal fonksiyon, üçü (%16.67) üstel fonksiyon (ÜTF) ve beşi (%27.78) ÇDURE ile elde edilmiştir. Buna karşılık doğrulama setinde biri (%5.56) ÜTF, altısı (%33.33) kuadratik fonksiyon (KF) ve 11'i (%61.11) ÇDURE ile elde edilmiştir. Test setinde ise dördü (%22.22) ÜTF, üçü (%16.67) KF ve 11'i (%61.11) ÇDURE ile elde edilmiştir. Özellikle ÇDURE yönteminde her iki parametrenin de kullanıldığı modeller için 0.783-0.988 arasında değişen NS değerleri, Patapsco Nehri özelinde yürütülen bu çalışmada, ÇDURE yönteminin AKM konsantrasyonunun modellenmesinde uygulanabilir ve güvenilir sonuçlar sunma potansiyeline sahip olduğunu ortaya koymuştur.

Bu çalışma, Patapsco Nehri örneğinde olduğu gibi, bir akarsuda belirli bir izleme alanı için geliştirilen modellerin hem aynı akarsuyun farklı bölgelerinde hem de benzer yapısal akarsu düzenlemeleri uygulanan başka akarsularda uygulanabileceğini ortaya koymuştur. Elde edilen bulgular, özellikle su kaynakları yönetimi ve hidrolojik modelleme alanlarında çalışan araştırmacılar için değerli bilgiler sunmaktadır. Patapsco Nehri Havzası için kurulan modellerin benzer hidrolojik koşullara sahip nehir sistemlerinde AKM konsantrasyonunun tahmini için bir altyapı oluşturabileceği düşünülmektedir.

Kullanılan modelleme yöntemleri, iki parametre (T ve Q) ile sınırlı olup, diğer potansiyel etkili parametrelerin (örneğin yağış, arazi kullanımı) dikkate alınmaması, model performansını sınırlayabilir. Gelecekteki çalışmalar için yağış, arazi kullanımı ve diğer hidro-meteorolojik parametrelerin modellere dahil edilmesi önerilmektedir. Ayrıca, çalışma yalnızca Patapsco Nehri özelinde yürütüldüğü için, farklı coğrafi ve iklimsel özelliklere sahip akarsu sistemlerinde yöntemlerin başarısı değişkenlik gösterebilir. Bu nedenle, geliştirilen modellerin başka akarsu sistemlerinde de test edilmesi ve daha geniş veri seti ile kullanılmasının faydalı olacağı düşünülmektedir. Gelecekteki araştırmalarda, çoklu değişkenlerin dahil edildiği modelleme çalışmalarının yapılması, yapay zeka tabanlı yöntemlerin sürece entegre edilmesi ve farklı nehirlerde model performansının test edilmesi önerilmektedir. Bu tür çalışmalar, AKM tahmininin doğruluğunu artırarak, sürdürülebilir su yönetimi planlarının geliştirilmesine katkı sağlayacaktır.

Kaynaklar

Abed, M. S., Kadhim, F. J., Almusawi, J. K., Imran, H., Bernardo, L. F. A., & Henedy, S. N. (2023). Utilizing multivariate adaptive regression splines (MARS) for precise estimation of soil compaction parameters. *Applied Sciences*, *13*(21), Article 11634. https://doi.org/10.3390/app132111634

Achite, M., Yaseen, Z. M., Heddam, S., Malik, A., & Kisi, O. (2022). Advanced machine learning models development for suspended sediment prediction: comparative analysis study. *Geocarto International*, *37*(21), 6116–6140. https://doi.org/10.1080/10106049.2021.1933210

Adnan, R. M., Liang, Z., El-Shafie, A., Zounemat-Kermani, M., & Kisi, O. (2019). Prediction of suspended sediment load using data-driven models. *Water*, *11*(10), Article 2060. https://doi.org/10.3390/w11102060

Adnan, R., Wang, M., Masood, A., Kisi, O., Shahid, S., & Zounemat-Kermani, M. (2025). Applications of advanced optimized neuro fuzzy models for enhancing daily suspended sediment load prediction. *Computer Modeling in Engineering & Sciences*, *143*(1), Article 1249. https://doi.org/10.32604/cmes.2025.062339

Asadi, M. A., Mokhtari, L. G., Zandi, R., & Naemitabar, M. (2025). Modeling, evaluation and forecasting of suspended sediment load in Kal-e Shur River, Sabzevar Basin, in northeast of Iran. *Applied Water Science*, *15*(3), Article 44. https://doi.org/10.1007/s13201-025-02361-0

Bayazıt, M. (1981). *Hidrolojide istatistik yöntemler.* İstanbul Teknik Üniversitesi Matbaası.

Bayram, A., Kankal, M., & Onsoy, H. (2012). Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks. *Environmental Monitoring and Assessment*, *184*(7), 4355–4365. https://doi.org/10.1007/s10661-011-2269-2

Cashman, M. J., Gellis, A. C., Boyd, E., Collins, M. J., Anderson, S. W., McFarland, B. D., & Ryan, A. M. (2021). Channel response to a dam-removal sediment pulse captured at high-temporal resolution using routine gage data. *Earth Surface Processes and Landforms*, *46*(6), 1145–1159. https://doi.org/10.1002/esp.5083

Collins, M. J., Snyder, N. P., Boardman, G., Banks, W. S., Andrews, M., Baker, M. E., & Wilcock, P. (2017). Channel response to sediment release: Insights from a paired analysis of dam removal. *Earth Surface Processes and Landforms*, *42*(11), 1636–1651. https://doi.org/10.1002/esp.4122

Collins, M. J., Baker, M. E., Cashman, M. J., Miller, A., & Van Ryswick, S. (2024). Impounded sediment and dam removal: Erosion rates and proximal downstream fate. *Earth Surface Processes and Landforms*, *49*(9), 2690–2703. https://doi.org/10.1002/esp.5850

Campos, J. A., & Pedrollo, O. C. (2021). A regional ANN-based model to estimate suspended sediment concentrations in ungauged heterogeneous basins. *Hydrological Sciences Journal*, *66*(7), 1222–1232. https://doi.org/10.1080/02626667.2021.1918695

Conoscenti, C., Rotigliano, E., Cama, M., Caraballo-Arias, N. A., Lombardo, L., & Agnesi, V. (2016). Exploring the effect of absence selection on landslide susceptibility models: A case study in Sicily, Italy. *Geomorphology*, *261*, 222–235. https://doi.org/10.1016/j.geomorph.2016.03.006

Cui, Y., Collins, M. J., Andrews, M., Boardman, G. C., Wooster, J. K., Melchior, M., & McClain, S. (2019). Comparing 1-D sediment transport modeling with field observations: Simkins Dam removal case study. *International Journal of River Basin Management*, *17*(2), 185–197. https://doi.org/10.1080/15715124.2018.1508024

Demirci, M., & Baltaci, A. (2013). Prediction of suspended sediment in river using fuzzy logic and multilinear regression approaches. *Neural Computing and Applications*, *23*(1), 145–151. https://doi.org/10.1007/s00521-012-1280-z

Dukalang, H. H., & Otok, B. W. (2025). Modified partial least square structural equation model with multivariate adaptive regression spline: Parameter estimation technique and applications. *MethodsX*, *14*, Article 103381. https://doi.org/10.1016/j.mex.2025.103381

Essam, Y., Huang, Y. F., Birima, A. H., Al-Hashimi, A., & Zain, M. (2022). Predicting suspended sediment load in Peninsular Malaysia using support vector machine and deep learning algorithms. *Scientific Reports*, *12*, Article 302. https://doi.org/10.1038/s41598-021-04419-w

Friedman, J. H. (1991). Multivariate adaptive regression splines. *The Annals of Statistics*, *19*(1), 1–67. https://doi.org/10.1214/aos/1176347963

Friedman, J. H., & Roosen, C. B. (1995). An introduction to multivariate adaptive regression splines. *Statistical Methods in Medical Research*, 4, 197–217. https://doi.org/10.1177/0962280295004003

Halverson, J. B. (2019). Flood City, USA: Ellicott City faces latest historical flooding. *Weatherwise*, *72*(2), 12–18. https://doi.org/10.1080/00431672.2019.1559267

Hameed, M., Sharqi, S. S., Yaseen, Z. M., & Al-Ansari, N. (2017). Application of artificial intelligence (AI) techniques in water quality index prediction: A case study in tropical region, Malaysia. *Neural Computing and Applications*, *28*, 893–905. https://doi.org/10.1007/s00521-016-2404-7

Huang, C. S., Legett, H. D., Plough, L. V., Aguilar, R., Fitzgerald, C., Gregory, B., Heggie, K., Lee, B., Richie, K. D., Harbold, W., & Ogburn, M. B. (2023). Early detection and recovery of river herring spawning habitat use in response to a mainstem dam removal. *PLOS One, 18*(5), Article e0284561. https://doi.org/10.1371/journal.pone.0284561

Jung, B. M., Fernandes, E. H., Moller Jr, O. O., & Garcia-Rodriguez, F. (2020). Estimating suspended sediment concentrations from river discharge data for reconstructing gaps of information of long-term variability studies. *Water*, *12*(9), Article 2382. https://doi.org/10.3390/w12092382

Katatchambo, A. Y., & Bingöl, Ş. (2025). Comparison of regression based functions and ANN models for predicting the compressive strength of geopolymer mortars. *Scientific Reports*, *15*(1), Article 11652. https://doi.org/10.1038/s41598-025-96772-3

Kemper, J. T. (2021). *Patapsco River, Maryland*. https://storymaps.arcgis.com/stories/99fe45668d5843ebb5e784a2da2e7dbd

Keshtegar, B., Piri, J., Hussan, W. U., Ikram, K., Yaseen, M., Kisi, O., Adnan, R. M., Adnan, M., & Waseem, M. (2023). Prediction of sediment yields using a data-driven radial M5 tree model. *Water, 15*(7), Article 1437. https://doi.org/10.3390/w15071437

Khan, M. Y. A., Tian, F., Hasan, F., & Chakrapani, G. J. (2019). Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India. *International Journal of Sediment Research*, *34*(2), 95–107. https://doi.org/10.1016/j.ijsrc.2018.09.001

Kisi, O., & Zounemat-Kermani, M. (2016). Suspended sediment modeling using neuro-fuzzy embedded fuzzy c-means clustering technique. *Water Resources Management*, *30*, 3979–3994. https://doi.org/10.1007/s11269-016-1405-8

Kumantaş, M., Mete, B., Nacar, S., & Bayram, A. (2025). *Estimation of suspended sediment concentration using regression analysis: A case study from the Patapsco River Basin, USA.* In Y. Kaya, E. K. Oztekin, I. H. Hasan, N. Hasim, S. Oztekin, S. Kosunalp & U. Yildirim (Eds.), *Proceedings of the 2nd international conference on engineering, natural sciences, and technological developments* (pp. 405–411). Bayburt, Türkiye.

Malik, A., Kumar, A., Kisi, O., & Shiri, J. (2019). Evaluating the performance of four different heuristic approaches with Gamma test for daily suspended sediment concentration modeling. *Environmental Science and Pollution Research*, *26*(22), 22670–22687. https://doi.org/10.1007/s11356-019-05553-9

Meshram, S. G., Safari, M. J. S., Khosravi, K., & Meshram, C. (2021). Iterative classifier optimizer-based pace regression and random forest hybrid models for suspended sediment load prediction. *Environmental Science and Pollution Research*, *28*, 11637–11649. https://doi.org/10.1007/s11356-020-11335-5

Mete, B., Nacar, S., Bayram, A., & Baki, O. T. (2023). Estimation of total suspended solids concentration in streams using regression and artificial neural networks methods. *Journal of Natural Hazards and Environment*, *9*(1), 125–135. https://doi.org/10.21324/dacd.1133981

Mohammadi, B., Guan, Y., Moazenzadeh, R., & Safari, M. J. S. (2021). Implementation of hybrid particle swarm optimization-differential evolution algorithms coupled with multi-layer perceptron for suspended sediment load estimation. *Catena*, *198*, Article 105024. https://doi.org/10.1016/j.catena.2020.105024

Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, *50*(3), 885–900. https://doi.org/10.13031/2013.23153

Nacar, S., Kankal, M., & Hınıs, M. A. (2018). Çok değişkenli uyarlanabilir regresyon eğrileri (ÇDURE) ile günlük akarsu akımlarının tahmini-Haldizen Deresi örneği. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, *8*(1), 38–47.

Nguyen, S. Q., Nguyen, L. C., Ngo-Duc, T., & Ouillon, S. (2024). Applying a machine learning-based method for the prediction of suspended sediment concentration in the Red River Basin. *Modeling Earth Systems and Environment*, *10*(2), 2675–2692. https://doi.org/10.1007/s40808-023-01915-y

Parsaie, A., Haghiabi, A. H., Saneie, M., & Torabi, H. (2016). Prediction of energy dissipation on the stepped spillway using the multivariate adaptive regression splines. *ISH Journal of Hydraulic Engineering*, *22*(3), 281–292. https://doi.org/10.1080/09715010.2016.1201782

Raja, M. N. A., & Shukla, S. K. (2021). Multivariate adaptive regression splines model for reinforced soil foundations. *Geosynthetics International*, *28*(4), 368–390. https://doi.org/10.1680/jgein.20.00049

Sahraei, M. A., Duman, H., Çodur, M. Y., & Eyduran, E. (2021). Prediction of transportation energy demand: Multivariate adaptive regression splines. *Energy*, *224*, Article 120090. https://doi.org/10.1016/j.energy.2021.120090

Samantaray, S., & Sahoo, A. (2021). Prediction of suspended sediment concentration using hybrid SVM-WOA approaches. *Geocarto International*, *37*(19), 5609–5635. https://doi.org/10.1080/10106049.2021.1920638

Samui, P., & Kothari, D. P. (2012). A multivariate adaptive regression spline approach for prediction of maximum shear modulus and minimum damping ratio. *Engineering Journal*, *16*(5), 69–78. https://doi.org/10.4186/ej.2012.16.5.69

Shiri, N., Shiri, J., Nourani, V., & Karimi, S. (2020). Coupling wavelet transform with multivariate adaptive regression spline for simulating suspended sediment load: Independent testing approach. *ISH Journal of Hydraulic Engineering*, *28*(sup1), 356–365. https://doi.org/10.1080/09715010.2020.1801528

Steffy, L. Y., & Shank, M. K. (2018). Considerations for using turbidity as a surrogate for suspended sediment in small, ungaged streams: Time-series selection, streamflow estimation, and regional transferability. *River Research and Applications*, *34*(10), 1304–1314. https://doi.org/10.1002/rra.3373

Teixeira, L. C., Mariani, P. P., Pedrollo, O. C., dos Reis Castro, N. M., & Sari, V. (2020). Artificial neural network and fuzzy inference system models for forecasting suspended sediment and turbidity in basins at different scales. *Water Resources Management*, *34*(11), 3709–3723. https://doi.org/10.1007/s11269-020-02647-9

Terrain360. (2025). *Patapsco River Terrain360 Map Collection, Baltimore's crown jewel*. 19 Ocak 2026'da https://www.terrain360.com/map/patapsco-river/visual#10.7/39.1856/-76.5401 adresinden alındı.

Travers, P. (2016). *The Patapsco: Baltimore's river of history*. Shiffer Publishing.

Van, C. P., Le, H., & Chin, L. V. (2023). Estimation of daily suspended sediment concentration in the Ca River Basin using a sediment rating curve, multiple regression, and long short-term memory model. *Journal of Water and Climate Change*, *14*(12), 4356–4375. https://doi.org/10.2166/wcc.2023.229

Wang, Y. M., T. Kerh, & S. (2009). Traore. Neural networks approaches for modelling river suspended sediment concentration due to tropical storms. *Global Nest Journal*, *11*(4), 457–466.

Yilmaz, B., Aras, E., Nacar, S., & 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. https://doi.org/10.1016/j.scitotenv.2018.05.153

Zabihi, M., Pourghasemi, H. R., Pourtaghi, Z. S., & Behzadfar, M. (2016). GIS-based multivariate adaptive regression spline and random forest models for groundwater potential mapping in Iran. *Environmental Earth Sciences*, *75*(8), Article 665. https://doi.org/10.1007/s12665-016-5424-9