

Regresyon ve Yapay Sinir Ağları Yöntemleri ile Akarsularda Askıda Katı Madde Konsantrasyonu Tahmini

Betül Mete^{1,*}, Sinan Nacar², Adem Bayram¹, Osman Tuğrul Baki³

¹Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 61080, Trabzon.

²Tokat Gaziosmanpaşa Üniversitesi, Mühendislik ve Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, 60150, Tokat.

³Karadeniz Teknik Üniversitesi, Of Teknoloji Fakültesi, İnşaat Mühendisliği Bölümü, 61830, Trabzon.

Özet

Bu çalışmada bir akarsu havzasında takibi yapılan askıda katı madde (AKM) konsantrasyonu kapsamında, mansap verilerinden memba değerlerinin tahmin edilebilirliği hem regresyon analizinin doğrusal, üs, üstel ve kuadratik fonksiyonlara uygulanması hem de yapay sinir ağları (YSA) yöntemi ile araştırılmıştır. Kullanılan veriler Sera Deresi Havzası'nda (Trabzon) seçilen sekiz gözlem istasyonunda Haziran 2019-Mart 2020 döneminde 40 kez gerçekleştirilen örnekleme çalışmaları kapsamında elde edilmiş AKM verileridir. İstasyonlar memba (ilk dördü) ve mansap (son dördü) olarak iki gruba ayrılmıştır. Mansap verilerinin %50'si (iki istasyon) eğitim, %25'i (bir istasyon) doğrulama ve kalan %25'i (bir istasyon) test aşamasında kullanılmıştır. Farklı bağımsız değişken kombinasyonlarına sahip iki model oluşturulmuş olup ilk modelde (M1) sadece AKM verileri, diğer modelde (M2) ise AKM verilerinin yanı sıra örnekleme tarihlerine ait ay ve hafta bilgileri sayısallaştırılmış ve kullanılmıştır. Modellerin ve yöntemlerin tahmin performanslarının değerlendirilmesinde ortalama karesel hatanın karekökü, ortalama mutlak hata ve Nash-Sutcliffe (NS) verimlilik katsayısı olmak üzere üç farklı istatistik kullanılmıştır. Regresyon analizinde en iyi tahmin sonuçları üs fonksiyondan elde edilmiş olup YSA yönteminin regresyon analizine kıyasla daha iyi sonuçlar verdiği belirlenmiştir. Her iki yöntemde de M2 genel olarak daha iyi bir performans göstermiştir. YSA yönteminde M1 ve M2'den hesap edilen NS verimlilik katsayıları eğitim veri seti için sırasıyla 0.980 ve 0.997 ve test veri seti için ise 0.978 ve 0.978 olarak hesaplanmıştır. Bu değerler ile AKM modelleme çalışmalarında, gerçek verilerin ait olduğu tarih bilgilerinin bağımsız değişken olarak kullanımının model performansını olumlu etkileyeceği anlaşılmıştır. Bu çalışma kapsamında, akarsu havzalarının mansap tarafı AKM verilerinden memba tarafı AKM değerlerinin başarılı bir şekilde tahmin edilebileceği sonucuna ulaşılmıştır.

Anahtar Sözcükler

Askıda Katı Madde, Regresyon Analizi, Sera Deresi Havzası, Yapay Sinir Ağları

Estimation of Total Suspended Solids Concentration in Streams Using Regression and Artificial Neural Networks Methods

Abstract

In this study considering total suspended solids (TSS) parameter monitored in a stream watershed, the predictability of upstream values from downstream data was investigated using regression analysis, which were applied to linear, power, exponential, and quadratic functions, and artificial neural networks (ANNs) method. The data were obtained within the scope of sampling studies carried out 40 times between June 2019 and March 2020 at eight monitoring stations selected in the Sera Stream Watershed (Trabzon). The monitoring stations were divided into two groups as upstream, the first four, and downstream, the last four, stations. Half of downstream data (two stations) was used for training, a quarter (one station) for validation, and the rest (one station) for testing. Two models with different combinations of independent variables were established. In the first model (M1), only the TSS values, and in the other model (M2), the month and week information of the sampling dates were digitized and used as independent variables, in addition to the TSS values. Root mean square error, mean absolute error, and Nash-Sutcliffe (NS) efficiency coefficient statistics were used to evaluate the model and method performances. Compared to other functions, the power one had the best estimation results in the regression analysis. On the other hand, the ANNs method gave better results than the regression analysis. In both methods, M2 performed better overall. In the ANNs method, the NS efficiency coefficients obtained from M1 and M2 were calculated as 0.980 and 0.997, respectively, for the training, and 0.978 and 0.978, respectively, for the testing data sets. Considering the efficiency values, it has been understood that the use of date information as an independent variable will positively affect the model performance in the stream TSS modeling studies. Within the scope of this study, it has been concluded that upstream TSS values can be successfully estimated from downstream TSS data in stream watersheds.

Keywords

Total Suspended Solids, Regression Analysis, Sera Stream Watershed, Artificial Neural Networks

1. Giriş

Askıda katı madde (AKM) birçok akarsuda toplam katı maddenin %75-95'lik kısmını oluşturmaktadır (Yang 1996; Ülke vd. 2011). Taşınan AKM danelerinin akarsuyun taşıma kapasitesinin azaldığı yerlerde çökeliş birikmesi; akarsuların taşıma kapasitelerinin azalması, sulama ve drenaj kanal kesitlerinin daralması, liman ve rezervuarların dolması, taşkın ve yüksek kamu maliyeti gibi ciddi sorunlar oluşturabilmektedir. Akarsularda taşkın ve erozyon kontrolü, kirliliğin azaltılması, canlı yaşamının iyileştirilmesi, hidroelektrik tesislerde su alma yapılarının boyutlandırılması, toprak ve su kaynaklarının geliştirilmesi amacıyla yapılan projelerin etkinliğini artırmak için yapılacak olan çalışmalarda ilgili akarsu tarafından taşınan AKM miktarının bilinmesi önem arz etmektedir (Mete vd. 2022).

AKM'nin belirlenmesinde en güvenilir yöntem doğrudan ölçüm olsa da akarsularda istenen kesitlerde ölçüm istasyonları kurmak ve yeterince uzun bir süre veri toplamak zahmetli ve masraflıdır. Ülkemizde yüzey sularının sediment taşıma özellikleri ile ilgili uluslararası standartlarla uyumlu sistematik veri toplamasına 1961 yılında Devlet Su İşleri (DSİ) ve Elektrik İşleri Etüt İdaresi (EİE) Genel Müdürlükleri tarafından bir istasyon ile başlanmıştır. Sediment gözlemleri 2017 yılı itibarıyla 155 istasyonda sürdürülmüştür (DSİ 2017). Ülkemiz akarsu ağı göz önüne alındığında bu sayının yeterli olmadığı ve her bir akarsu havzasında da ölçüm verisine sahip olunmadığı bilinmektedir. AKM'nin belirlenmesi için literatürde yer alan formüllerin ise elde edildikleri koşullara benzer durumlar için geçerli olmaları araştırmacıları AKM'yi tahmin etmeye yönelik çalışmalara yönlendirmiştir.

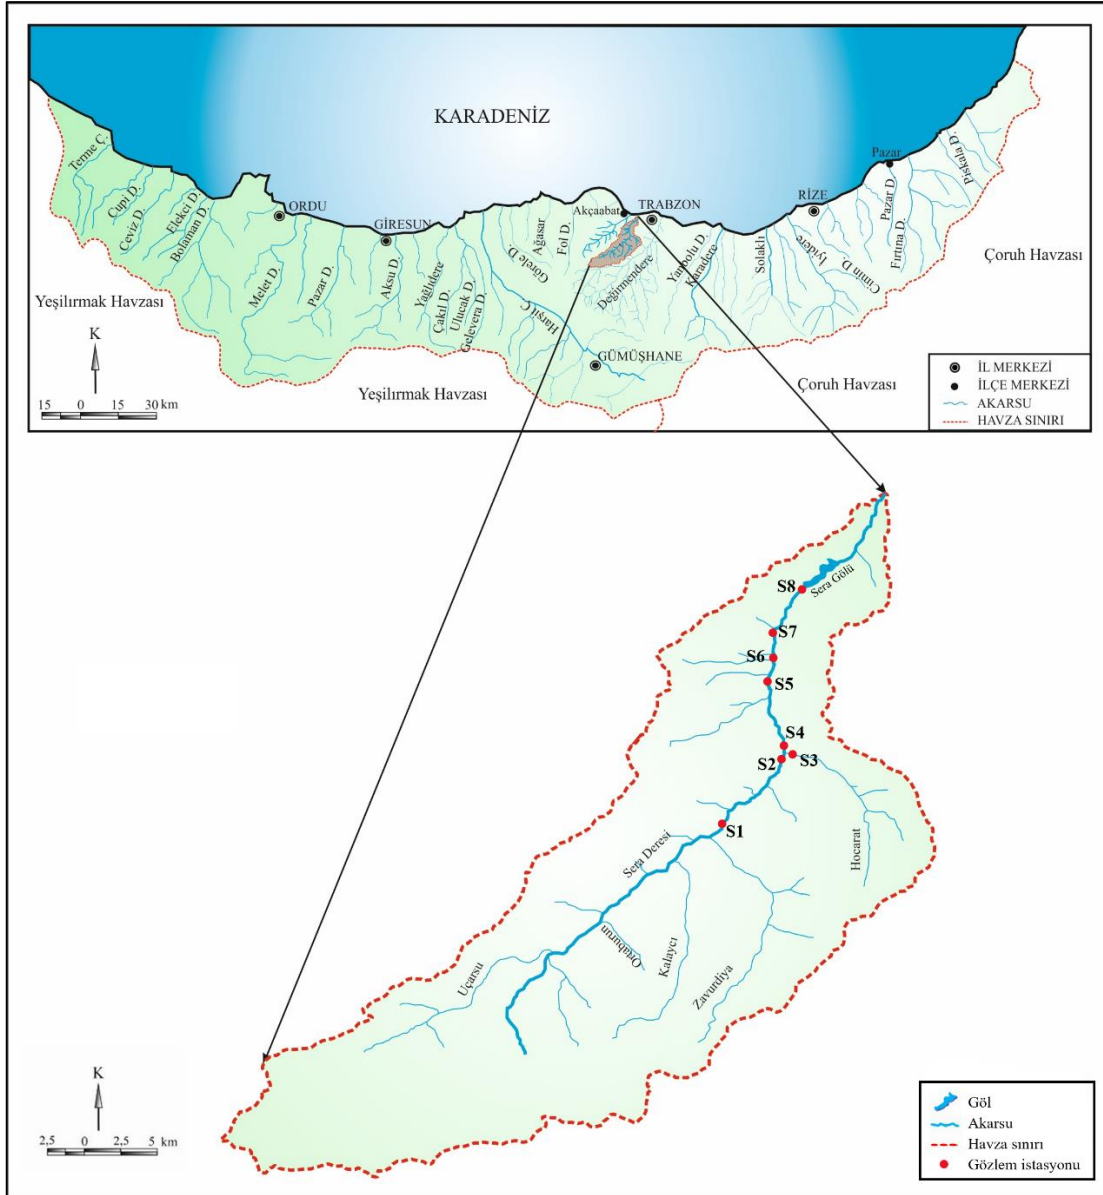
Bayram vd. (2012), Harşit Çayı Havzası'nda (Gümüşhane) AKM konsantrasyonunu yapay sinir ağları (YSA) ve regresyon analizi yöntemlerini kullanarak tahmin etmişlerdir. Çalışmada ana kol üzerinde seçilen altı gözlem istasyonundan elde ettikleri AKM konsantrasyonu ve bulanıklık verilerini kullanmışlardır. AKM konsantrasyonu tahmininde bulanıklık verilerin kullanılabilir olduğunu ve YSA yönteminin kabul edilebilir sonuçlar verdiğini tespit etmişlerdir. Kisi vd. (2012), yapay arı kolonisi (YAK) algoritması ile YSA yönteminin günlük debi ve AKM konsantrasyonu ilişkisini modelleme performansını araştırmışlardır. YSA-YAK model doğruluğunu, Kisi (2005) ve Kisi (2010) tarafından aynı istasyonlarda ve aynı zaman diliminde gerçekleştirilen çalışmalardan elde edilen sinirsel diferansiyel evrim, uyarlanabilir sinirsel bulanık yaklaşım, YSA ve sediment anahtar eğrisi yöntemleri ile karşılaştırmışlardır. YSA-YAK modelinin genel olarak diğer yöntemlerden daha iyi performans gösterdiğini tespit etmiştir. Zounemat-Kermani vd. (2016), YSA, destek vektör regresyon, çoklu doğrusal regresyon ve sediment anahtar eğrisi yöntemleri ile AKM konsantrasyonlarını tahmin etmişlerdir. Çalışmada Büyük Francis, Cristina ve Kootenai nehirleri (Amerika) üzerinde yer alan üç istasyona ait sekiz yıllık AKM ve debi verilerini kullanmışlardır. YSA ve destek vektör regresyon yöntemlerinin geleneksel yöntemlere kıyasla %15-23 daha yüksek performans gösterdiğini tespit etmişlerdir. Sari vd. (2017), AKM konsantrasyonu tahmininde YSA yönteminin kullanılabilirliğini araştırmışlardır. Çalışmada Taboa Nehri'nde (Brezilya) belirledikleri bir istasyonda Haziran 2013-Ekim 2015 tarihleri arasında gerçekleştirdikleri toplam 59 çalışma sonucunda elde ettikleri su seviyesi, bulanıklık ve AKM verilerini kullanmışlardır. YSA yönteminin AKM konsantrasyonu tahmininde veri sayısının çok fazla olmadığı durumlarda da başarılı sonuçlar verdiğini belirlemişlerdir. Yadav vd. (2018), sediment anahtar eğrisi, çoklu doğrusal regresyon ve YSA yöntemlerini kullanarak Mahanadi Havzası'nda (Hindistan) AKM verimini tahmin etmişlerdir. Çalışmada, havzanın mansabında yer alan Tikarapara gözlem istasyonuna ait 1989-2004 yılları arası aylık yağış, hava sıcaklığı ve debi verilerini kullanarak yedi model oluşturmuşlardır. Debi ve yağış verilerinin girdi parametresi olarak kullanıldığı modelin diğer modellere göre daha yüksek performansa sahip olduğunu ve YSA yönteminin sediment anahtar eğrisi ve çoklu doğrusal regresyon yöntemlerine göre daha başarılı sonuçlar verdiğini tespit etmişlerdir. Gaur vd. (2021), YSA yöntemini kullanarak Ganj Nehri'nde (Hindistan) AKM yükünün tahmin edilebilirliğini araştırmışlardır. Havzadaki iki istasyona ait Nisan 2001-Mart 2010 yılları arası günlük AKM yükü, yağış, nehir seviyesi, su derinliği ve nehir yatak seviyesi verilerini kullanarak altı model oluşturmuşlardır. Memba istasyonuna ait veriler kullanılarak mansap istasyonu AKM yükünün tahmininde YSA yönteminin başarılı sonuçlar verdiği sonucuna ulaşmışlardır.

Literatür incelendiğinde AKM konsantrasyonlarının tahmin edilmesinde çeşitli parametreler kullanıldığı görülmektedir. Ülkemizde debi, AKM ve diğer su kalitesi parametrelerinin takibinin eş zamanlı olarak yürütüldüğü akarsular oldukça sınırlıdır. Bu çalışmada, sürüntü hareketinin yanı sıra yoğun bir askı hareketinin olduğu Sera Deresi Havzası'nda (Akçaabat-Trabzon) seçilen sekiz AKM gözlem istasyonunda mansap istasyonlarına ait AKM konsantrasyonları kullanılarak memba istasyonlarındaki AKM değerlerinin tahmin edilebilirliği araştırılmıştır. Gerek memba istasyonlarına ulaşımın güçlüğü gerekse arazi koşulları sebebiyle arazi çalışmaları sırasında karşılaşılan zorluklar, ulaşımın ve örneklemelerin nispeten kolay olduğu mansap istasyonlarından memba istasyonlarına ait AKM konsantrasyonlarının tahmin edilmesi fikrini doğurmuştur. İlgili kesitlerde AKM konsantrasyonlarının mevcut verilerle ekonomik bir şekilde belirlenmesi ve literatürdeki modelleme çalışmalarında sadece AKM ve zaman değişkenleri kullanılarak gerçekleştirilen çalışmalara rastlanılmaması bu çalışmanın motivasyonunu oluşturmaktadır. Çalışmada tahmin yöntemi olarak AKM modelleme çalışmalarında etkinliği ispatlanmış olan YSA yöntemi kullanılmıştır. YSA yönteminden elde edilen sonuçların değerlendirilebilmesi için regresyon analizi dört farklı fonksiyona uygulanmıştır. Çeşitli istatistikler kullanılarak yöntemlerin performansları değerlendirilmiştir.

2. Materyal ve Metot

2.1. Çalışma Alanı ve Askıda Katı Madde Verileri

Doğu Karadeniz Havzası sınırları içerisinde yer alan Trabzon, 4,664 km²'lik alana ve toplamda 816,684 kişilik nüfusa sahip bir sahil kentidir (TÜİK 2022). Doğu Karadeniz ikliminin hakim olduğu Trabzon'da yıllık ortalama yağış miktarı (828.90 mm) Türkiye ortalamasının (573.40 mm) üzerindedir (MGM 2022a, 2022b). Trabzon il sınırları içerisinde kalan Sera Deresi Havzası (Şekil 1) 40°51'-40°54' kuzey enlemleri ile 39°37'-39°28' doğu boylamları arasında bulunmaktadır. Drenaj alanı yaklaşık olarak 127 km²'dir (Mete 2020). Yüksek eğimli arazilere sahip olan havzada, orman, mera ve tarımsal arazi olmak üzere üç farklı arazi kullanımı söz konusudur. Havzanın ana akarsuyu Sera Deresi olup bu akarsu Uçarsu, Kalaycı, Zavrudiya ve Hocarat isimli yan kollar ile beslenmektedir. Havzada 1950 yılında meydana gelen heyelan sonucu oluşan, 1,200 m uzunluğa, 150 m ortalama genişliğe ve 20 m ortalama derinliğe sahip ve sahilden yaklaşık 3 km içeride bulunan Sera Gölü yer almaktadır (Beret 1955). Göl 2005 yılında doğal koruma alanı olarak belirlenmiş ve etrafındaki 94 ha'lık alan 2010 yılında Tabiat Parkı ilan edilmiştir (URL-1 2010). Beşeri faaliyetler, jeolojik yapı ve eğim gibi özellikleri nedeniyle Sera Deresi Havzası'nda yüksek miktarda AKM taşınımı söz konusudur (Hacısalihoğlu 1995). Yoğun askı ve sürüntü hareketinin mevcut olduğu havzada Sera Gölü'nü korumak amacıyla tersip bentleri inşa edilmiştir. Havzada 40° 57' 14.67" K-39° 36' 02.72" D koordinatlarında DSİ 22. Bölge Müdürlüğü tarafından işletilmekte olan bir adet akım gözlem istasyonu bulunmakla beraber AKM takibinin yapıldığı herhangi bir istasyon söz konusu değildir.



Şekil 1: Sera Deresi Havzası ve askıda katı madde gözlem istasyonları (Mete 2020)

Çalışmada Sera Gölü'nün membaında yer alan tersip bentlerinin konumları dikkate alınarak belirlenen sekiz AKM gözlem istasyonunda (Şekil 1) Haziran 2019-Mart 2020 tarihleri arasında haftalık periyotlarla su örnekleme çalışmaları gerçekleştirilmiştir. İstasyonlardan su örneklerinin alınması sırasında numune kapları, içerisinde olası bir kalıntı ihtimaline karşı akarsuyun suyu ile iki kez çalkalanmıştır. Belirlenen kesitlerde, numune kapları su yüzeyinin 30-40 cm aşağısından ve içerisinde hava kalmayacak şekilde doldurularak kapakları sıkıca kapatılmıştır. AKM konsantrasyonları toplanan su örneklerinin laboratuvar ortamında vakumlu filtrasyon seti ve gözenek boyutu 1.2 µm olan cam elyaf filtreler kullanılarak gerçekleştirilen filtrasyon işlemi sonucunda belirlenmiştir. Cam elyaf filtre kağıtları kullanılmadan önce 0.0001 mg hassasiyetle tartım yapabilen analitik hassas terazi ile tartılmış ve filtre edeceği numune ile aynı olacak şekilde adlandırılmıştır. Filtrasyon işleminden sonra cam elyaf filtre kağıtlar etüvde 105 °C'de kurutulup soğutulduktan sonra tekrar tartılmıştır. AKM konsantrasyonları her bir numune için son ağırlıktan ilk ağırlık çıkarılarak elde edilen farkın örnek hacmine bölünmesi ile elde edilmiştir.

Modelleme çalışmalarında toplam 320 adet AKM (mg/L) verisi kullanılmıştır. AKM gözlem istasyonları kendi içerisinde memba (S1, S2, S3 ve S4) ve mansap (S5, S6, S7 ve S8) olacak şekilde iki gruba ayrılmış ve mansap istasyonları AKM verilerinden memba istasyonları AKM değerleri tahmin edilmiştir. Aşırı yağış sebebiyle ulaşılamayan S3 istasyonunda bir adet ve arazi koşulları sebebiyle örnekleme çalışmalarına ancak yedinci çalışma itibariyle başlanabilen S6 istasyonunda altı adet olmak üzere toplamda yedi adet AKM (mg/L) verisi eksiktir. Söz konusu veriler istasyonlar ile en yüksek korelasyon gösteren gözlem istasyonlarına ait veriler kullanılarak gerçekleştirilen regresyon analizleri sonucunda tamamlanmıştır. AKM takibinin yapıldığı istasyonların konum bilgileri Tablo 1'de verilmektedir.

Tablo 1: Sera Deresi Havzası AKM gözlem istasyonları konum ve yükseklik bilgileri (Mete 2020)

İstasyonlar	Kuzey	Doğu	Yükseklik (m)
S1	40°55'15.84"	39°35'21.50"	299
S2	40°56'10.56"	39°36'16.14"	214
S3 (Yan kol)	40°56'11.28"	39°36'23.37"	204
S4	40°56'18.04"	39°36'14.79"	201
S5	40°57'22.65"	39°35'59.22"	134
S6	40°57'57.38"	39°36'04.99"	120
S7	40°58'12.37"	39°36'05.27"	116
S8 (Göl giriş)	40°58'37.13"	39°36'23.82"	109

2.2. Regresyon Analizi

Regresyon, bir bağımlı değişken ile iki ya da daha fazla sayıdaki bağımsız değişken arasındaki ilişkiyi tahmin etmek amacıyla kullanılan istatistiksel bir yöntemdir. Bu değişkenler arasındaki ilişkiyi gösteren matematiksel ifadeler regresyon denklemi olarak adlandırılmaktadır (Bayazıt ve Yeğen Oğuz 2005). Bağımlı değişkenin değerini en iyi şekilde tahmin eden regresyon denkleminin belirlenmesine de regresyon analizi denilmektedir (Bayazıt 1981). Çalışma kapsamında doğrusal, üs, üstel ve kuadratik olmak üzere toplam dört fonksiyon (y_D , y_U , y_E ve y_K) kullanılmış ve Eşitlik 1-4 ile hesaplanmıştır.

$$y_D = w_0 + w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n \quad (1)$$

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

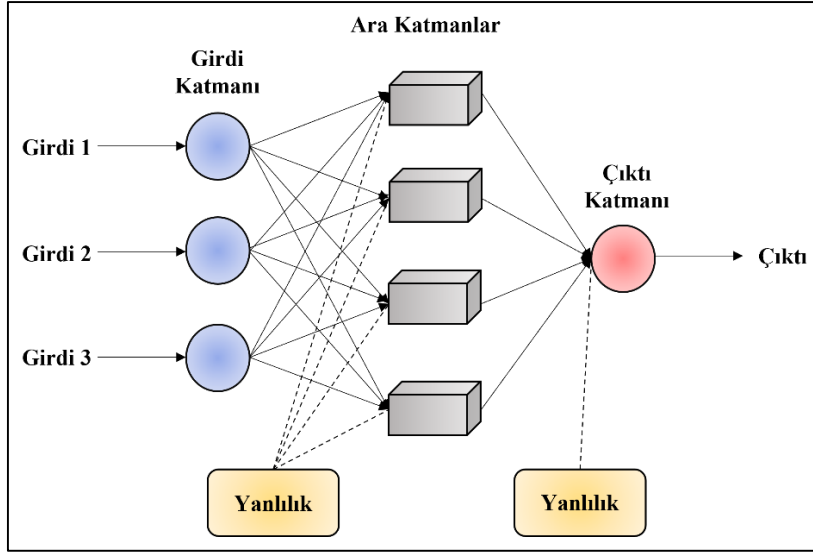
$$y_E = w_0 + \exp(w_1 + w_2x_1 + w_3x_2 + \dots + w_{n+1}x_n) \quad (3)$$

$$y_K = w_0 + w_1x_1 + w_2x_2 + \dots + w_5x_1x_2 + w_6x_1x_3 + \dots + w_{11}x_1^2 + w_{12}x_2^2 + \dots + w_{14}x_4^2 \quad (4)$$

Bu eşitliklerde AKM konsantrasyonlarını y , ağırlıkları w ve bağımsız değişkenleri ise x temsil etmektedir.

2.3. Yapay Sinir Ağları

YSA, insan beyin yapısından esinlenerek yapay sinir hücrelerinin farklı bağlantı geometrileriyle birbirine bağlandığı karmaşık sistemler olarak tanımlanmaktadır (Kohonen 1988). Girdi ve çıktı veri kümeleri arasındaki karmaşık ve doğrusal olmayan ilişkileri tanımlayabilen YSA, eğitim ve öğrenme süreçlerine dayalı çıktı değerlerini tahmin edebilen esnek matematiksel yapılardır (Tachi vd. 2016). Bir YSA nöron adı verilen birçok işlem biriminden oluşur. Nöronlar genelde katman denilen mantıksal gruplar içinde yer alır. YSA mimarisi (Şekil 2) girdi katmanı, ara katmanlar ve çıktı katmanı olmak üzere üç ya da daha çok katmandan oluşan hiyerarşik bir yapıya sahiptir. Çok katmanlı bir ağda ara katman sayısı birden fazla olabilmektedir (Zounemat-Kermani vd. 2016).



Şekil 2: Yapay sinir ağı mimarisi

2.4. Askıda Katı Madde Model Uygulamaları

AKM konsantrasyonunun modellenmesinde araştırmacılar sediment anahtar eğrisi (Sadeghi vd. 2008; Isik 2013), regresyon analizi (Singh vd. 2018; Bayram vd. 2014), YSA (Atieh vd. 2015; Sari vd. 2017) bulanık mantık ve bulanık çıkarım (Wieprecht vd. 2013; Kisi ve Zounemat-Kermani 2016) ve hibrit yaklaşımlar (Guo vd. 2021; Samantaray ve Sahoo 2021) gibi yöntemler ve debi, AKM, Fe, Cr, elektriksel iletkenlik, bulanıklık, akarsu seviyesi, yağış gibi çeşitli parametreler kullanmışlardır. Literatür incelendiğinde en çok kullanılan parametrelerin debi ve AKM konsantrasyonu olduğu görülmüştür. Bu çalışmada sadece bir istasyonda mevcut olması sebebiyle debi bağımsız değişken olarak kullanılamamıştır. Kendi içerisinde memba (S1, S2, S3 ve S4) ve mansap (S5, S6, S7 ve S8) olarak gruplandırılan istasyonların, eğitim veri setinde ikisi girdi (S5 ve S6) ve ikisi çıktı (S1 ve S2), doğrulama veri setinde biri girdi (S7) ve biri çıktı (S3), ve test veri setinde biri girdi (S8) ve biri çıktı (S4) olacak şekilde eşleştirilmiştir. Çalışmada girdi parametresi olarak AKM verilerinin yanı sıra örnekleme tarih bilgileri de kullanılmıştır. Örnekleme yapıldığı aylar (çalışmanın kaçınıcı ayda yapıldığı) ve haftalar (çalışmanın ilgili ay içerisindeki kaçınıcı hafta yapıldığı) sayısallaştırılarak modellere bağımsız değişken olarak dahil edilmiştir. AKM konsantrasyonu tahmininde tarih bilgilerinin tahmin performanslarına olan etkisini belirleyebilmek için iki farklı model oluşturulmuştur. Modellerde kullanılan değişkenler ile girdi istasyonlarına karşılık gelen çıktı istasyonlarına ait bilgiler Tablo 2’de, çalışmada kullanılan modellerin bağımsız değişkenleri ise Tablo 3’te verilmektedir.

Tablo 2: Eğitim, doğrulama ve test veri setleri için askıda katı madde model girdi ve çıktıları

Model	Veri Seti		
	Eğitim	Doğrulama	Test
M1			
M2			

A: çalışmanın gerçekleştirildiği ayın sayısal değeri

H: çalışmanın gerçekleştirildiği haftanın sayısal değeri

Tablo 3: Askıda katı madde tahmin modelleri

Model	Bağımsız Değişken
M1	AKM
M2	AKM A H

Çalışmada her bir istasyon için 40, toplamda 320 AKM verisi kullanılmıştır. Tahminler 160 adet girdi ve 160 adet çıktı verisi üzerinden gerçekleştirilmiştir. Memba ve mansap istasyonlarına ait AKM verilerinin 80'i (%50'si) eğitim, 40'ı (%25'i) doğrulama ve geri kalan 40'ı (%25'i) test aşamasında kullanılmıştır. Veriler eğitim, doğrulama ve test gruplarına ayrılırken tüm uç durumların eğitim veri seti içinde kalmasına dikkat edilmiştir. Veri setlerine ait temel istatistikler Tablo 4'te verilmektedir.

Tablo 4: Askıda katı madde (mg/L) verilerine ait temel istatistikler

Veri seti	Min	Ort	Mak	SS
Eğitim	0.17	90.67	4,144.90	420.01
Doğrulama	1.17	100.11	2,109.83	363.85
Test	0.17	74.26	2,302.50	311.88
Tümü	0.17	88.93	4,144.90	381.71

SS: Standart sapma

Veri setlerindeki uç değerlerin modellemesini kolaylaştırmak, farklı boyutların etkisini en aza indirmek ve daha etkili sonuçlar elde etmek için tüm veriler Eşitlik 5 kullanılarak normalize edilmiştir (Gulbag vd. 2008; Partovian vd. 2016).

$$X_n = \frac{\text{Ölçüm değeri} - \text{En küçük değer}}{\text{En büyük değer} - \text{En küçük değer}} a + b \quad (5)$$

Bu eşitlikte X_n normalize değeri ifade etmektedir. Bu çalışmada a ve b katsayıları sırasıyla 0.8 ve 0.1 olarak seçilmiştir. Böylece modellemede kullanılan tüm veriler 0.1 ile 0.9 arasında normalize edilmiştir.

2.5. Model Tahmin Performanslarının Karşılaştırılması

Kullanılan yöntemlerin ve kurulan modellerin tahmin performanslarının karşılaştırılmasında ortalama karesel hatanın karekökü (OKHK), ortalama mutlak hata (OMH) ve Nash-Sutcliffe (NS) verimlilik katsayısı istatistikleri dikkate alınmış ve Eşitlik 6-8 kullanılarak hesaplanmıştır.

$$\text{OKHK} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - yd_i)^2} \quad (6)$$

$$\text{OMH} = \frac{1}{N} \sum_{i=1}^N |y_i - yd_i| \quad (7)$$

$$\text{NS} = 1 - \frac{\sum_{i=1}^N (y_i - yd_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (8)$$

Bu eşitliklerde veri sayısını N , ölçüm değerlerini y_i , tahmin değerlerini yd_i ve ölçüm değerlerinin ortalamasını \bar{y} temsil etmektedir.

3. Bulgular ve Tartışma

Bu çalışmada Sera Deresi Havzası'nda AKM konsantrasyonlarının tahmin edilebilirliğinin araştırılması için regresyon ve YSA yöntemleri kullanılmıştır. İlk olarak eğitim veri seti üzerinde IBM SPSS Statistics 26 programı ile regresyon analizleri gerçekleştirilmiştir. Analizde kullanılan doğrusal, üs, üstel ve kuadratik fonksiyonlara (DF, ÜF, EF ve KF) ait ağırlıklar (Tablo 5) belirlendikten sonra bu ağırlıklar fonksiyonlarda yerlerine konarak doğrulama ve test veri setleri için model tahmin sonuçları hesaplanmıştır. Daha sonra veri setlerine YSA yöntemi uygulanmış ve her veri seti için hata değerleri belirlenmiştir. YSA yöntemi için Matlab2020a programından faydalanılmıştır. Yöntemlerin eğitim, doğrulama ve test veri setleri için gerçekleştirdiği tahmin sonuçları ile ölçüm değerleri arasında hesaplanan performans istatistikleri Tablo 6'da verilmektedir.

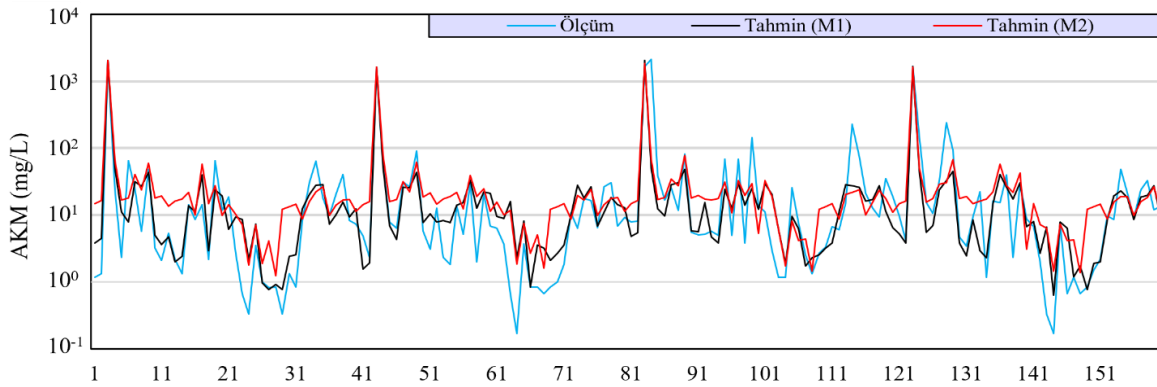
Tablo 5: Doğrusal, üs, üstel ve kuadratik fonksiyonlara ait ağırlıklar

Model	Fonksiyon	Ağırlık										
		W ₀	W ₁	W ₂	W ₃	W ₄	W ₅	W ₆	W ₇	W ₈	W ₉	
M1	DF	0.005	0.948									
	ÜF	0.933	0.963									
	EF	-0.080	1.844	-0.998								
	KF	-45.367	3.815	0.021								
M2	DF	0.015	-0.025	0.008	0.947							
	ÜF	0.902	-0.091	0.065	0.955							
	EF	-50.946	3.931	0.000	0.000	0.018						
	KF	-0.482	0.542	-0.020	6.021	0.010	-5.734	0.411	0.047	-0.036	-2.823	

Tablo 6: Eğitim, doğrulama ve test veri setleri performans istatistikleri

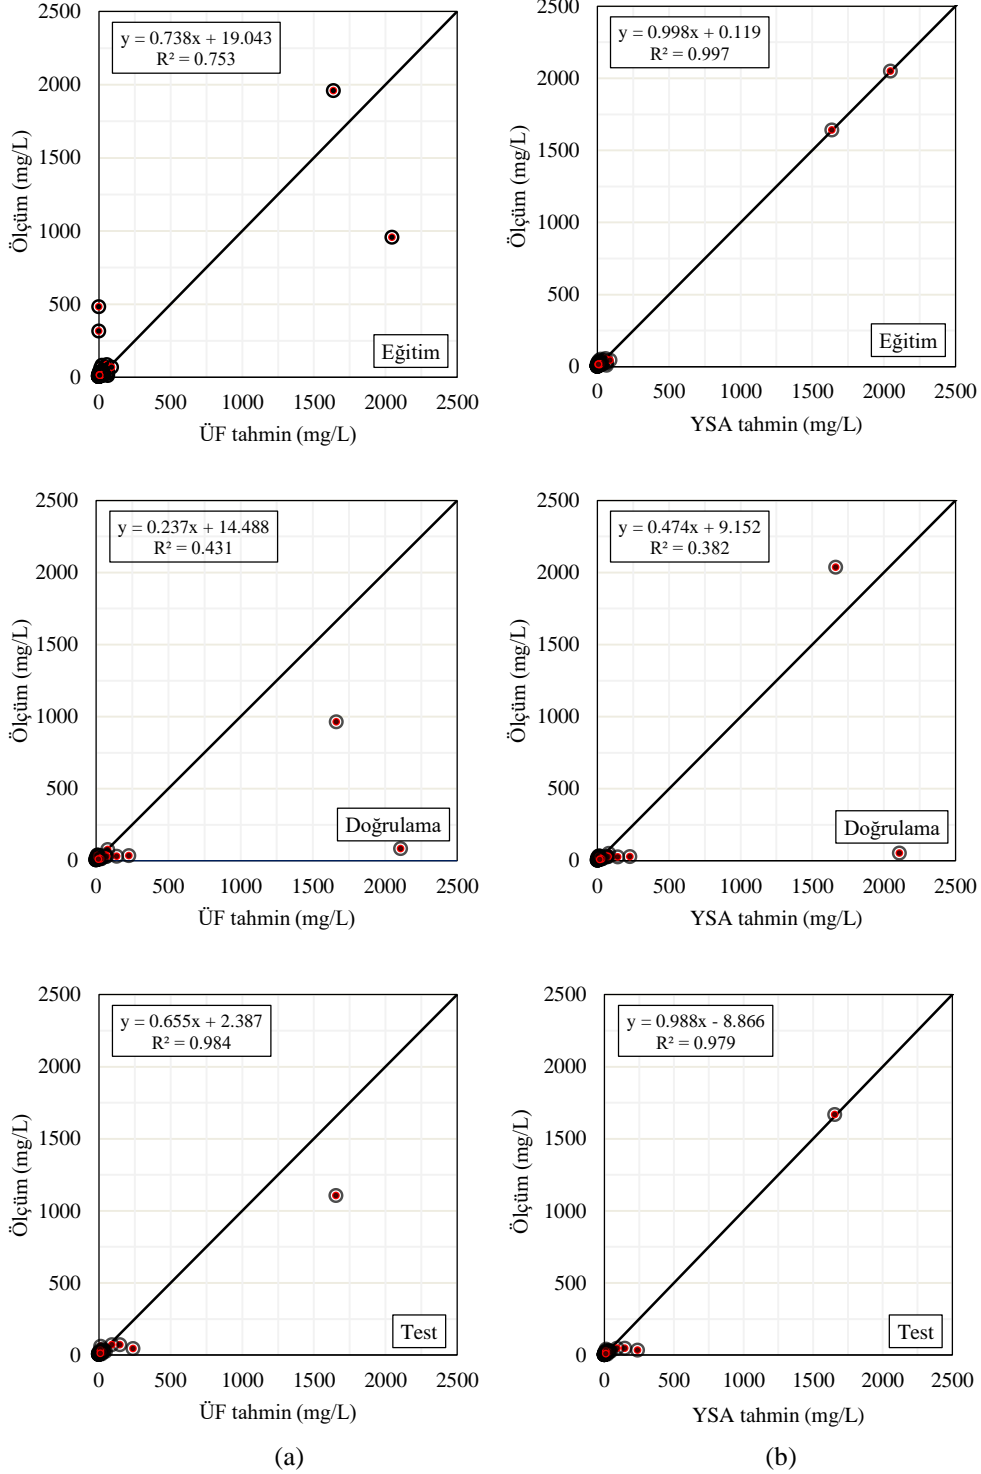
Model	Veri Seti	Yöntem	M1			M2		
			OKHK 10 ³ mg/L	OMH 10 ³ mg/L	NS	OKHK 10 ³ mg/L	OMH 10 ³ mg/L	NS
Eğitim		DF	0.144	0.036	0.751	0.142	0.040	0.756
		ÜF	0.143	0.037	0.753	0.141	0.043	0.762
		EF	0.144	0.036	0.750	0.143	0.040	0.755
		KF	0.132	0.037	0.789	0.036	0.019	0.984
		YSA	0.013	0.007	0.980	0.015	0.011	0.997
Doğrulama		DF	0.343	0.087	0.304	0.341	0.090	0.313
		ÜF	0.342	0.086	0.308	0.339	0.091	0.320
		EF	0.343	0.087	0.303	0.341	0.090	0.312
		KF	0.325	0.081	0.376	0.309	0.079	0.434
		YSA	0.333	0.079	0.342	0.327	0.074	0.368
Test		DF	0.094	0.028	0.869	0.093	0.032	0.871
		ÜF	0.094	0.027	0.868	0.093	0.034	0.871
		EF	0.094	0.028	0.868	0.093	0.032	0.870
		KF	0.054	0.022	0.956	0.076	0.028	0.915
		YSA	0.038	0.014	0.978	0.039	0.017	0.978

Regresyon analizinde her iki model için en düşük OKHK ve OMH ile en yüksek NS değerlerinin KF'den elde edilmesine rağmen tahmin sonuçlarındaki negatif değer sayısının fazlalığı model doğruluğunu etkilemektedir. ÜF'nin negatif tahmin sayısının KF'ye kıyasla daha az olmasının yanı sıra düşük OKHK ve OMH ile yüksek NS değerlerine sahip olması sebebiyle de diğer fonksiyonlara göre daha başarılı olduğu belirlenmiştir. YSA ve ÜF'ye ait performans istatistikleri karşılaştırıldığında her iki model için de daha düşük OKHK ve OMH ile daha yüksek NS değerlerinin YSA yönteminden elde edildiği tespit edilmiştir. YSA yöntemi tahmin sonuçlarında negatif değerlerin olmaması yöntemin daha doğru sonuçlar verdiğini destekler niteliktedir. Ölçüm verileri ile her iki model için YSA yönteminden elde edilen tahmin değerleri logaritmik zaman serisi grafiği ile Şekil 3'te verilmektedir.

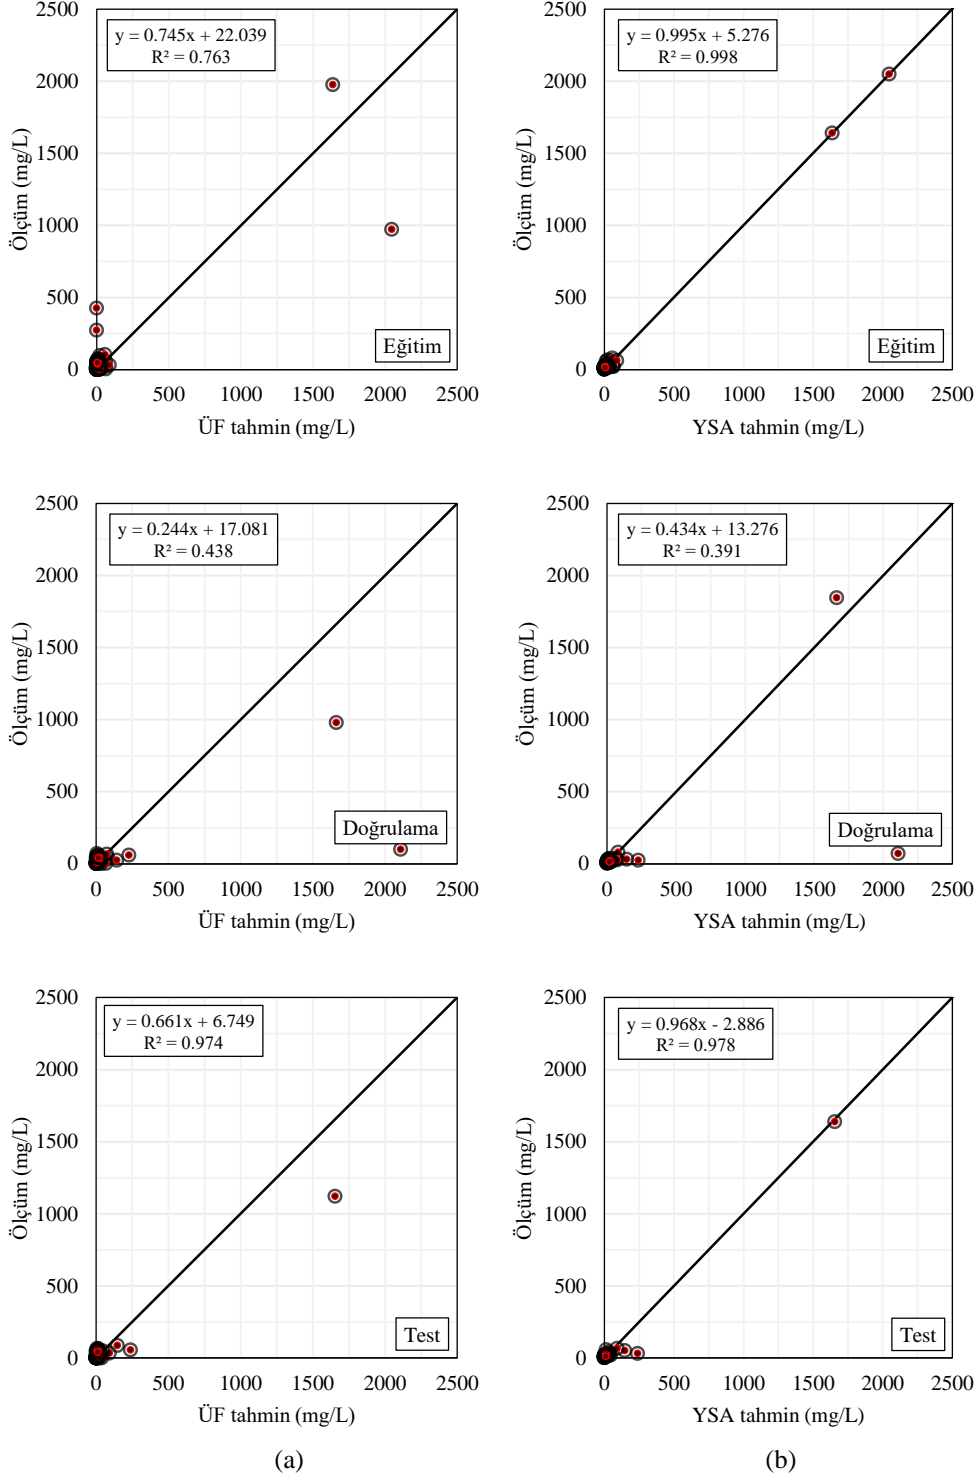


Şekil 3: Askıda katı madde ölçüm verileri ile YSA yönteminden elde edilen tahmin değerlerine ait logaritmik zaman serileri (Haziran 2019-Mart 2020)

YSA yönteminde M1'e ait NS değerleri eğitim, doğrulama ve test veri setleri için sırasıyla 0.980, 0.342 ve 0.978 olarak hesaplanmıştır. M2 için bu değerler sırasıyla 0.997, 0.368 ve 0.978'dir. Modellerin test veri seti için aynı NS değerine sahip olmasına karşın eğitim ve doğrulama veri setleri için M2 daha yüksek performans göstermiştir. Ölçüm verileri ile ÜF ve YSA yöntemlerinden elde edilen tahmin değerleri saçılım grafikleri M1 için Şekil 4 ve M2 için Şekil 5'te verilmektedir.



Şekil 4: Askıda katı madde ölçüm verileri ile Model 1'in (a) regresyon analizi ve (b) YSA tahmin değerlerinin karşılaştırılması



Şekil 5: Askıda katı madde ölçüm verileri ile Model 2'nin (a) regresyon analizi ve (b) YSA tahmin değerlerinin karşılaştırılması

Saçılım grafiklerindeki dağılımının 45°'lik eğim çizgisine yaklaşması tahmin değerleri ile ölçüm verilerinin birbirine yakın olduğunu göstermektedir. Ayrıca, bu çizgi üzerindeki noktalarda OKHK ve OMH değerleri sıfırdır (Bayram ve Kankal 2015; Kushwaha ve Kumar 2017). Modellerin eğitim, doğrulama ve test veri setleri için hazırlanmış olan karşılaştırmalı saçılım grafikleri (Şekil 4 ve 5) incelendiğinde YSA yönteminde özellikle yüksek değerlerdeki saçılımların 45°'lik eğim çizgisine daha yakın olduğu görülmektedir. Verilerin büyük bir çoğunluğu çizgi üzerinde dağılmaktadır.

Heddam (2016) herhangi bir su kalitesi parametresi kullanmaksızın sadece örnekleme tarih (yıl, ay, gün ve saat) verilerini (toplamda 11,730 adet) girdi parametresi olarak kullanarak saatlik çözünmüş oksijen konsantrasyonlarını tahmin etmeye yönelik bir çalışma gerçekleştirmiştir. Test aşamasında gözlem verileri ile tahmin değerleri arasındaki korelasyonu radyal tabanlı fonksiyon sinir ağı ve çoklu doğrusal regresyon yöntemleri için sırasıyla 0.970 ve 0.654 olarak hesaplamıştır. Sonuçlar modelleme çalışmalarında gözlem tarihine ait bilgilerin kullanılabilir olduğunu göstermektedir. Kısıtlı su kalitesi değişkeni verisi içeren akarsu havzalarında gerçekleştirilecek AKM tahmin çalışmalarında kurulacak modellere gözlem tarihi verilerinin dahil edilmesinin tahmin sonuçlarını olumlu yönde etkileyebileceği düşünülmektedir. Bu çalışmada her iki yöntemde de örnekleme tarihine ait ay ve hafta bilgilerinin sayısallaştırılarak dahil edilmesiyle oluşturulan M2'nin M1'e kıyasla genel olarak daha iyi sonuçlar verdiği tespit edilmiştir. M2'nin test aşamasında ölçüm verileri ile tahmin değerleri arasındaki Pearson korelasyon katsayıları ÜF ve YSA yöntemleri için sırasıyla 0.992 ve 0.989 olarak hesaplanmıştır. Bu durum tarih verilerinin AKM tahmin çalışmalarında da kullanılabilirliğini destekler niteliktedir.

4. Sonuçlar

Bu çalışmada, Sera Deresi Havzası'nda (Trabzon) takibi yapılmış askıda katı madde (AKM) konsantrasyonlarının tahmin edilebilirliği araştırılmıştır. Havzada Haziran 2019-Mart 2020 döneminde ayda dört kez olacak şekilde AKM takibinin yapıldığı sekiz gözlem istasyonu konumlarına göre memba ve mansap olmak üzere iki gruba ayrılmıştır. Mansap istasyonlarına ait AKM ve örnekleme tarihlerine ait sayısallaştırılmış ay (A) ve hafta (H) verileri kullanılarak mansap istasyonlarına kıyasla daha uzak ve çeşitli dönemlerde ulaşımın zor olduğu memba istasyonlarında AKM değerlerinin mevcut verilerle ekonomik bir şekilde tahmin edilmesi amaçlanmıştır. Sadece AKM konsantrasyonları (M1) ve AKM konsantrasyonlarının yanı sıra A ve H verileri de (M2) kullanılarak oluşturulan modellere regresyon analizi ve yapay sinir ağları (YSA) yöntemleri uygulanmıştır. Regresyon analizinde doğrusal (DF), üs (ÜF), üstel (EF) ve kuadratik (KF) olmak üzere dört farklı fonksiyon kullanılmıştır. Yöntem ve modellerin AKM konsantrasyonu tahmin başarılarının belirlenmesinde ortalama karesel hatanın karekökü (OKHK), ortalama mutlak hata (OMH) ve Nash-Sutcliffe (NS) verimlilik katsayısı performans istatistikleri kullanılmıştır. Elde edilen sonuçlar maddeler halinde aşağıda verilmektedir.

- Regresyon analizinde en başarılı konsantrasyon tahmini ÜF'den elde edilmiştir. ÜF'ye göre daha düşük OKHK ve OMH ile daha yüksek NS değerlerine sahip olan KF'nin tahmin sonuçlarındaki negatif değerlerin model doğruluğunu olumsuz etkilediği belirlenmiştir. Performans istatistikleri YSA yönteminin ÜF'den de daha iyi tahminler yaptığını ortaya koymuştur.
- Regresyon analizinde en iyi performans istatistikleri eğitim ve doğrulama veri setlerinde M2'den, test veri setinde M1'den elde edilmiş olup YSA yönteminde ise tüm veri setleri için M2'den elde edilmiştir. Girdi parametresi olarak sadece AKM konsantrasyonunun kullanıldığı M1 ile AKM'nin yanı sıra A ve H parametrelerinin de dahil edildiği M2'ye ait tahmin performansları karşılaştırıldığında dahil edilen parametrelerin tahmin performansını artırdığı tespit edilmiştir.
- Çeşitli sebeplerle AKM takibinin yapılamadığı istasyon ya da tarihlerdeki değerlerin mansap istasyonlarına ait veriler kullanılarak güvenilir, hızlı ve ekonomik bir şekilde tahmin edilebileceği belirlenmiştir.
- Yapılan çalışma AKM konsantrasyonlarının tahmininde sınırlı veri ile de doğru sonuçlar elde edilebileceğini göstermektedir. Yine de daha uzun süreli veri setlerinin kullanılmasının sonuçları olumlu yönde etkileyeceği düşünülmektedir. Membadaki AKM konsantrasyonları havzadaki yoğun katı madde hareketine karşı alınacak önlemler ve mevcut akarsu düzenleme yapılarının işlevselliği için önem arz etmektedir. Çalışmanın kısıtlı veri içeren akarsu havzalarında gerçekleştirilecek çalışmalarda uygulanabilir olduğu ve ileride yapılması muhtemel çalışmalar için altlık oluşturacağı düşünülmektedir.
- Çalışmada regresyon analizi ve YSA yöntemleri kullanılmıştır. Gelecek çalışmalar için bu yöntemlere ek olarak literatürde AKM modelleme çalışmalarında yüksek performansa sahip olduğu ifade edilen uyarlamalı ağ tabanlı bulanık çıkarım sistemi, bulanık mantık, sinirsel diferansiyel evrim ve hibrit sinir ağı gibi yöntemler uygulanarak tahmin performansları karşılaştırılması önerilmektedir.

Kaynaklar

- Atieh M., Mehlretter S.L., Gharabaghi B., Rudra R., (2015), *Integrative neural networks model for prediction of sediment rating curve parameters for ungauged basins*, Journal of Hydrology, 531, 1095-1107.
- Bayazıt M., (1981), *Hidrolojide istatistik yöntemler*, İTÜ Matbaası, Gümüşsuyu, İstanbul, 223ss.
- Bayazıt M., Yeğen Oğuz B., (2005), *Mühendisler için istatistik*, Birsan Yayınevi, İstanbul, 197ss.
- Bayram A., Kankal M., (2015), *Artificial neural network modeling of dissolved oxygen concentration in a Turkish Watershed*, Polish Journal of Environmental Studies, 24(4), 1507-1515.
- 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.
- Bayram A., Kankal M., Tayfur G., Onsoy H., (2014), *Prediction of suspended sediment concentration from water quality variables*, Neural Computing and Applications, 24(5), 1079-1087.

- Beret B., (1955), *Sera heyelanı*, Türk Coğrafya Dergisi, 13-14, 155-161.
- DSİ, (2017), *Devlet Su İşleri Genel Müdürlüğü, 2017 Faaliyet Raporu*, <https://cdniys.tarimorman.gov.tr/api/File/GetFile/425/KonuIcerik/759/1107/DosyaGaleri/dsi-2017-faaliyet-raporu.pdf>, [Erişim 08 Kasım 2022].
- Gaur S., Mishra A., Gupta A., Jain A., Dave A., Eslamian S., Dwivedi S.B., Graillot D., (2021), *Application of artificial neural network model for the prediction of suspended sediment load in the Large River*, Water Resources, 48(4), 565-575.
- Gulbag A., Temurtas F., Yusubov I., (2008), *Quantitative discrimination of the binary gas mixtures using a combinational structure of the probabilistic and multilayer neural networks*, Sensors and Actuators B: Chemical, 131(1), 196-204.
- Guo F., Zhang J., Zhu A.X., Zhang Z., Zhang H., (2021), *An assimilation simulation approach for the suspended sediment concentration in Inland Lakes using a hybrid perturbation generation method*. Water Resources Management, 35(6), 2007-2022.
- Hacısalıhoğlu S., (1995), *Trabzon Sera Deresi yağış havzasında farklı arazi kullanımı altındaki toprakların bazı fiziksel kimyasal ve hidrolojik özellikleri üzerine araştırmalar*, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Trabzon.
- Heddam S., (2016), *New modelling strategy based on radial basis function neural network (RBFNN) for predicting dissolved oxygen concentration using the components of the Gregorian calendar as inputs: case study of Clackamas River, Oregon, USA*, Modeling Earth Systems and Environment, 2, 167. doi: 10.1007/s40808-016-0232-5.
- Isik S., (2013), *Regional rating curve models of suspended sediment transport for Turkey*. Earth Science Informatics, 6(2), 87-98.
- Kisi O., (2005), *Suspended sediment estimation using neuro-fuzzy and neural network approaches*, Hydrological Sciences Journal, 50(4), 683-696.
- Kisi O., (2010), *River suspended sediment concentration modeling using a neural differential evolution approach*, Journal of Hydrology, 389(1-2), 227-235.
- Kisi O., Ozkan C., Akay B., (2012), *Modeling discharge-sediment relationship using neural networks with artificial bee colony algorithm*, Journal of Hydrology, 428, 94-103.
- Kisi O., Zounemat-Kermani M., (2016), *Suspended sediment modeling using neuro-fuzzy embedded fuzzy c-means clustering technique*, Water Resources Management. 30(11), 3979-3994.
- Kohonen T., (1988), *An Introduction to Neural Computing*, Neural Networks, 1, 3-16.
- Kushwaha D.P., Kumar D., (2017), *Modeling suspended sediment concentration using multilayer feedforward artificial neural network at the outlet of the watershed*, International Journal of Agricultural Engineering, 10(2), 302-313.
- Mete B., (2020), *Tersip bentlerinin askıda katı madde taşınımına etkilerinin incelenmesi: Sera Deresi Havzası (Trabzon) örneği*, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Trabzon.
- Mete B., Baki O.T., Bayram A., (2022), *Sera Deresi Havzasında (Trabzon) askıda katı madde hareketinin incelenmesi ve değerlendirilmesi*, Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 27(1), 419-436.
- MGM, (2022a), *İllerimize ait genel istatistik verileri*, Meteoroloji Genel Müdürlüğü, <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=A&m=TRABZON>, [Erişim 08 Kasım 2022].
- MGM, (2022b), *Meteorolojik parametrelerin Türkiye analizi*, Meteoroloji Genel Müdürlüğü, <https://www.mgm.gov.tr/veridegerlendirme/yillik-toplam-yagis-verileri.aspx>, [Erişim 08 Kasım 2022].
- Partovian A., Nourani V., Alami M.T., (2016), *Hybrid denoising-jittering data processing approach to enhance sediment load prediction of muddy rivers*, Journal of Mountain Science, 13(12), 2135-2146.
- Sadeghi S.H.R., Mizuyama T., Miyata S., Gomi T., Kosugi K., Fukushima T., Mizugaki S., Onda Y., (2008), *Development, evaluation and interpretation of sediment rating curves for a Japanese small mountainous reforested watershed*. Geoderma, 144(1-2), 198-211.
- Samantaray S., Sahoo A., (2021), *Prediction of suspended sediment concentration using hybrid SVM-WOA approaches*, Geocarto International, 37(19), 5609-5635.
- Sari V., dos Reis Castro N.M., Pedrollo O. C., (2017), *Estimate of suspended sediment concentration from monitored data of turbidity and water level using artificial neural networks*, Water Resources Management, 31(15), 4909-4923.
- Singh V.K., Kumar D., Kashyap P.S., Kisi O., (2018), *Simulation of suspended sediment based on gamma test, heuristic, and regression-based techniques*. Environmental Earth Sciences, 77(19), 1-14.
- Tachi S.E., Ouerdachi L., Remaoun M., Derdous O., Boutaghane H., (2016), *Forecasting suspended sediment load using regularized neural network: Case study of the Isser River (Algeria)*, Journal of Water and Land Development, (29), 75-81.
- TÜİK, (2022), *Türkiye İstatistik Kurumu, Adrese dayalı nüfus kayıt sistemi veri tabanı*, <https://cip.tuik.gov.tr/>, [Erişim 08 Kasım 2022].
- URL-1, (2010), *Bakanlar Kurulu Kararı, Karar Sayısı: 2010/291*, Resmi Gazete Tarih: 24 Nisan 2010, Sayı: 27561, <https://www.resmigazete.gov.tr/eskiler/2010/04/20100424-4.htm>, [Erişim 08 Kasım 2022].
- Ülke A., Özkul S., Tayfur G., (2011), *Ampirik yöntemlerle Gediz Nehri için askıda katı madde yükü tahmini*, Teknik Dergi, 22(107), 5387-5407.
- Wieprecht S., Tolossa H.G., Yang C.T., (2013), *A neuro-fuzzy-based modelling approach for sediment transport computation*, Hydrological Sciences Journal, 58(3), 587-599.
- Yadav A., Chatterjee S., Equeenuddin S.K., (2018), *Prediction of suspended sediment yield by artificial neural network and traditional mathematical model in Mahanadi river basin, India*, Sustainable Water Resources Management, 4(4), 745-759.
- Yang C.T., (1996), *Sediment transport theory and practice*, McGraw-Hill, USA.
- Zounemat-Kermani M., Kisi O., Adamowski J., Ramezani-Charmahineh A., (2016), *Evaluation of data driven models for river suspended sediment concentration modeling*, Journal of Hydrology, 535, 457-472.