

Landsat 8 Görüntüleri ile Cheney Rezervuarında Bulanıklık Tahmini: Regresyon, MARS ve TreeNet Yöntemlerinin Karşılaştırılması

Estimation of Turbidity in the Cheney Reservoir Using Landsat 8 Images: A Comparison of Regression, MARS, and TreeNet Methods

Ömer Dilmen^{1*}, Sinan Nacar², Esra Tunç Görmüş³, Adem Bayram⁴

¹Abdullah Gül Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 38080, Kayseri/Türkiye.

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

³Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 61080, Trabzon/Türkiye.

⁴Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 61080, Trabzon/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Ömer Dilmen
omer.dilmen@agu.edu.tr

doi: 10.48123/rsgis.1451338

Yayın süreci

Geliş tarihi: 12.03.2024

Kabul tarihi: 13.06.2024

Basım tarihi: 26.09.2024

Özet

Rezervuarlardaki su kalitesi takibi, suyun kullanım amacına uygunluğu ve su canlılarının korunması için önemlidir ve su kalitesinin belirlenmesinde en yaygın kullanılan değişkenlerden biri de bulanıklıktır. Bu değişkenin takibinde kullanılan geleneksel yöntemlerin maliyetli ve zaman alıcı olması, su kalitesi takibi için daha ekonomik ve hızlı bir alternatif olan uzaktan algılama çalışmalarını ön plana çıkarmıştır. Bu çalışmada, Landsat 8 Operational Land Imager (OLI) görüntüleri kullanılarak Cheney Rezervuarında (Kansas, ABD) bulanıklık değişkenini tahmin edebilecek bir model kurulması amaçlanmıştır. Bu amaçla 99 Landsat 8 OLI görüntüsü, 2014-2022 yılları arasında rezervuarda takibi yapılan bulanıklık verileriyle aralarındaki zaman farkı 20 dakikadan az olacak şekilde eşleştirilmiştir. Tahmin modellerinin kurulmasında regresyon analizi, çok değişkenli uyarlanabilir regresyon eğrileri (MARS) ve TreeNet gradyan arttırma makinesi (TreeNet) yöntemleri kullanılmıştır. Kurulan modellerin performansları, ortalama karesel hata, ortalama karesel hatanın karekökü, ortalama mutlak hata ve Nash-Sutcliffe (NS) verimlilik katsayısı performans istatistikleri ile kıyaslanmıştır. MARS ve TreeNet yöntemlerinin tahmin gücünün test veri seti için birbirine eşit olduğu görülmüştür (NS = 0.61). En önemli parametrenin MARS yöntemi kullanılarak oluşturulan modelde B_4/B_1 (kırmızı/kıyı aerosol), TreeNet yöntemiyle oluşturulan modelde ise B_4/B_2 (kırmızı/mavi) olduğu belirlenmiştir.

Anahtar kelimeler: Bulanıklık, Cheney rezervuarı, Landsat 8 OLI, Regresyon analizi

Abstract

Monitoring water quality in reservoirs is crucial for determining the suitability of water for its intended use and protecting aquatic life. One of the most commonly used indicators of reservoir water quality is turbidity. As a cost-effective and quick alternative to traditional monitoring methods, studies with remote sensing have gained traction. This study aims to develop a model to estimate turbidity in the Cheney Reservoir (Kansas, USA) using Landsat 8 Operational Land Imager (OLI) images. In total 99 Landsat 8 images were matched with turbidity data monitored in the reservoir between 2014 and 2022 with a time difference of at most 20 minutes. Estimation models were developed using regression analysis, multivariate adaptive regression splines (MARS), and TreeNet gradient boosting machine (TreeNet) methods. The success of the models was compared with the performance statistics of mean squared error, root mean squared error, mean absolute error, and Nash-Sutcliffe (NS) efficiency coefficient. The MARS and TreeNet methods were found to have equal predictive ability for the test dataset (NS = 0.61). The most significant parameter was determined as B_4/B_1 (red/coastal aerosol) with the MARS method, while B_4/B_2 (red/blue) was determined with the TreeNet model.

Keywords: Turbidity, Cheney reservoir, Landsat 8 OLI, Regression analysis

1. Giriş

Su, canlılığın devamı için vazgeçilmez bir unsurdur ve tarih boyunca medeniyetler su kaynaklarına yakın bölgelerde kurulmuştur. Günümüzde de bir bölgede tatlı su kaynaklarının bulunması, o bölgenin nüfusunun artmasında ve kalkınmasındaki en önemli etkenlerden bir tanesidir. Gerek doğal yollarla gerekse de artan nüfus ve buna paralel olarak gelişen şehirleşme ve sanayileşme ile temiz su kaynakları her geçen gün kirlenmektedir. Kirliliğin de bir göstergesi olan ve suda askıda bulunan parçacıkların neden olduğu bulanıklık, içme suyu kaynakları için hem suyun kullanılabilirliği açısından hem de estetik açıdan sorunlara yol açmaktadır. Bulanıklık halk sağlığı için doğrudan bir risk teşkil etmemesine karşın, hastalık sebebi mikroorganizmaların suda barınmasına ve su kaynağından kullanım noktasına kadar olan şebeke sistemi boyunca istenmeyen durumların meydana gelmesine sebep olabilmektedir. Ayrıca içme sularının bulanıklığı ile mide-bağırsak hastalıkları arasındaki ilişkileri gösteren çalışmalar mevcuttur (De Roos vd., 2017; Mann vd., 2007). Bulanık bir suyun içme suyu olarak kullanılmadan önce klorlanması durumunda, bulanıklığa neden olan bazı maddelerin serbest klor ile reaksiyona girerek kansere neden olduğu düşünülen yan ürünlerin oluşmasına yol açmakta olduğu literatürde ifade edilmektedir (Boyd, 2015). Bu sebeple, özellikle içme suyu kaynaklarında bulanıklık değişkeninin takibi önem arz etmektedir. Ancak yerinde yapılan su kalitesi ölçümleri hem zaman alıcı hem de maliyetli olmaktadır. Bu nedenle su kalitesi ölçümleri için alternatif bir yöntem arayışı başlamıştır. Su kalitesi değişkenlerinin uzaktan algılama teknikleri ile tahmin edilmesi araştırmacıların dikkatini çeken alternatif bir yol olarak literatürde yerini almıştır.

Uzaktan algılama, radyasyon yansıma ve yayılımını temas olmaksızın ölçerek bir bölgenin fiziksel özelliklerini belirleme ve takip etme olarak ifade edilmektedir (Çölkesen, 2015). Uzaktan algılama ile su kalitesi tahmini çalışmalarının çoğu yersel olarak ölçülmüş su kalitesi değişkeni ile değişkenin ölçüm tarihine ait ve çalışma alanını kapsayan uydu görüntülerinin bant yansıma değerleri arasındaki korelasyonları araştırarak tahmin modeli oluşturmayı hedeflemiştir (Dilmen, 2023; Gholizadeh vd. 2016). Bulanıklık, optik özellikleri nedeniyle yaygın olarak değerlendirilen bir su kalitesi değişkenidir ve uydu görüntüleri ile yüksek korelasyon potansiyeline sahip olduğu henüz kullanıma hazır uydu görüntüleri mevcut değilken öngörülmüştür (Moore, 1980).

Uzaktan algılama ile bulanıklık tahmininde Landsat 5, Landsat 8 ve Sentinel 2 uyduları önceki çalışmalarda (Al-Fahdawi vd., 2015; Gholizadeh vd., 2016; Gonzalez-Marquez vd., 2018; Pizani vd., 2020) sıklıkla kullanılmıştır. Bu nedenle, bu çalışmada da yüksek performanslı bir bulanıklık tahmin modeli geliştirmek için Landsat 8 Operational Land Imager (OLI) görüntüleri kullanılmıştır. Uydu görüntülerinin içerdiği veriler, rezervuardaki fiziki özelliklerin belirli bir andaki ürünü olduğundan, o ana ait yersel ölçümlerin kullanılması, tahmin gücü yüksek model kurulmasında en etkili parametre olarak ifade edilebilir. Yerinde ölçümler, rezervuar içinde tek bir noktadan gerçekleştirilebileceği gibi, su üstünde hareket eden vasıtalar kullanılarak farklı noktalardan da gerçekleştirilebilmektedir. Farklı noktalardan ölçüm alınmak istendiği takdirde, çoğu zaman ölçüm olanaklarının yetersizliğinden dolayı, ölçümler belirli bir zaman farkı ile gerçekleştirilebilmektedir. Uydu görüntüleri rezervuarın tamamını kapsayacak nitelikte olsa bile çoğu durumda zamansal çözünürlükleri yeterince yüksek olmamaktadır. Bu nedenle, farklı noktalardan alınan yersel ölçümlerin yeterli zamansal yakınlıkta uydu karşılıklarını elde etmek çoğu zaman mümkün olmamaktadır. Literatürde bulunan çalışmaların birçoğunda yersel ve uydu ölçümleri arasındaki zaman farkı saatlerle ifade edilmektedir (Hossain vd., 2021; Mortula vd., 2020; Pizani vd., 2020; Bonansea vd., 2018). Bu çalışmada, uzaktan algılama ve takibi yapılan bulanıklık verileri birlikte kullanılarak rezervuarda bulanıklık değişkenini tahmin edecek bir model oluşturulması hedeflenmiştir. Ayrıca yersel ölçümler ile uydu görüntüleri arasındaki zaman farkının 20 dakikadan daha az olması, çalışmayı bu yönüyle literatürdeki diğer çalışmalardan ayırmaktadır.

Bantlar ve yersel olarak ölçülmüş bulanıklık arasındaki ilişkileri araştırmada sıklıkla kullanılan yöntemlerden biri regresyon analizidir (Meng vd., 2022; Chu vd., 2021; Theologou vd., 2015). Bu çalışma kapsamında da regresyon tabanlı klasik regresyon analizi, çok değişkenli uyarlanabilir regresyon eğrileri (MARS) ve TreeNet gradyan arttırma makinesi (TreeNet) yöntemleri kullanılarak bulanıklık tahmini amaçlanmıştır. Tahmin modellerinin geliştirilmesinde kullanılacak olan bağımsız değişkenler hem işlem yükü hem de modelleme performansı bakımından oldukça önemlidir. Birçok araştırmacı, spektral bantlar ve farklı indeksleri bağımsız değişken olarak kullanarak su kalitesi parametrelerini tahmin etmeye çalışmışlardır (Hossen vd., 2022; Meng vd., 2022; Sun vd., 2022). Yapılmış olan çalışmalarda çeşitli bantlar denendikten sonra, bulanıklık ile kırmızı ve yakın kızıl ötesi bantlar arasında yüksek korelasyon olduğu görülmüştür. Bu nedenle modeller genel olarak bu bantların tek başına veya diğer bantlarla birlikte kullanılmasıyla geliştirilmiştir (Liu & Wang, 2019; Surisetty vd., 2018). Bu çalışmada da 2014 – 2022 yılları arasına ait Landsat 8 OLI bantları hem tek başına hem de farklı kombinasyonları ile kullanılarak modeller geliştirilmiştir. Çalışma kapsamında Amerika Birleşik Devletleri'nin (ABD) Kansas eyaletinde yer alan, içme ve sulama suyu kaynağı olan ve rekreasyon merkezi olarak bölge için büyük bir öneme sahip olan Cheney Rezervuarı (Stone vd., 2015) çalışma alanı olarak seçilmiştir.

Tablo 1. Landsat 8'in sahip olduğu bantlar ve özellikleri

Bantlar	Dalga boyu (μm)	Konumsal çözünürlük (m)
1 - Kıyı aerosol	0.435-0.451	30
2 - Mavi	0.452-0.512	30
3 - Yeşil	0.533-0.590	30
4 - Kırmızı	0.636-0.673	30
5 - Yakın kızılötesi (NIR)	0.851-0.879	30
6 - Kısa dalga kızılötesi (SWIR) 1	1.566-1.651	30
7 - Kısa dalga kızılötesi (SWIR) 2	2.107-2.294	30
8 - Pankromatik	0.503-0.676	15
9 - Sirkül	1.363-1.384	30
10 - Termal kızılötesi sensör (TIRS) 1	1.060-1.119	100
11 - Termal kızılötesi sensör (TIRS) 2	1.150-1.251	100

Landsat Seviye 1 görüntüleri her spektral bant için radyometrik ve geometrik olarak düzeltilmiş veriler içerir ancak atmosferik düzeltmeleri yapılmamıştır (Pinto vd., 2020). Buna karşın Landsat Seviye 2 görüntüleri atmosferik olarak düzeltilmiş haldedir ve yansıma değerleri çalışmalarda doğrudan kullanılmaktadır (Khalid vd., 2021; Agapiou, 2020). Bu yüzden bu çalışmada Landsat Seviye 2 görüntüleri kullanılmıştır. Çalışma alanını kapsayan ilk Landsat 8 OLI Seviye 2 uydu görüntüsü 30 Mart 2013 tarihinde çekilmiştir. Bu tarihten sonraki Landsat 8 OLI Seviye 2 görüntüleri mevcut olup, bulutluluk oranı %15'ten az olanlarına USGS Earth Explorer (<https://earthexplorer.usgs.gov>) üzerinden erişilmiştir. Uydu görüntüleri ile yersel ölçüm verileri kullanılarak yapılan modelleme çalışmalarında ideal olarak bu iki veri setinin eş zamanlı olması gereklidir. Bu yüzden elde edilen Landsat 8 OLI uydu görüntüleri ile bulanıklık verileri, aralarındaki zaman farkı en az olacak şekilde (20 dakikadan daha az) eşleştirilmiştir. Böylece görüntü tarihi 2014 – 2022 yılları arasında olan 99 Landsat 8 OLI görüntüsü ile bulanıklık verisi eşleştirmesi yapılabilmektedir. Bulanıklık verisi ile eşleştirilmiş her bir uydu görüntüsünde Cheney Rezervuarı gözlem istasyonuna karşılık gelen piksellerin yansıma değerleri elde edilmiş ve veriler modelleme için hazır hale getirilmiştir.

2.3 Regresyon Analizi

Regresyon analizleri, bir değişkendeki değişimin başka bir değişkeni nasıl etkilediğini incelemek için kullanılan bir yöntemdir. Regresyon analizinde gözlem değerlerinin ve bu değerlerden etkilenen olayların matematiksel bir yolla, yani bir fonksiyon ile ifade edilmesi gerekir. Ortaya çıkan matematiksel ifadeye regresyon modeli denir. Regresyon modeli diğer birçok uygulamada kullanıldığı gibi uzaktan algılama verilerinin istatistiksel analizinde de sıklıkla kullanılmaktadır (Abdul Wahid & Arunbabu, 2022; Alparslan vd., 2007; Batur, 2019; Hossen vd., 2022; Meng vd., 2022). Bu çalışmada klasik regresyon analizi için kullanılan doğrusal (DF), üs (ÜF), eksponansiyel (EF) ve kuadratik (KF) fonksiyonlar aşağıda verilmektedir.

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

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

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

$$P_K = w_0 + w_1x_1 + \dots + w_nx_n + w_{n+1}x_1x_2 + w_{n+2}x_1x_3 + \dots + w_{C(n,2)+n+1}x_1^2 + \dots + w_{C(n,2)+2n}x_n^2 \quad (4)$$

Verilen bu eşitliklerde n bağımsız değişken sayısı ve $C(n, 2)$ n 'nin ikili kombinasyonlarının sayısı olmak üzere P_i , w_i ve x_i sırasıyla bağımlı değişkenleri, regresyon katsayılarını ve bağımsız değişkenleri temsil etmektedir (Nacar vd. 2020a).

2.4 Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (MARS)

Friedman (1991) tarafından tanımlanan MARS, bağımlı ve bağımsız değişkenler arasında parametrik olmayan bir model kurmak için kullanılan bir yöntemdir. Doğrusal olmayan veri setleri ile yapılan modelleme çalışmaları ile dikkat çeken

MARS yöntemi farklı alanlardaki birçok araştırmacı tarafından kullanılmıştır (Sharda vd., 2008; Nacar vd., 2020a; Wang vd., 2020; Şan vd., 2023; Şan vd., 2024; Nacar vd., 2024). MARS yöntemi, veri setindeki her doğrusal ilişkinin sonunda ayrı bir regresyon denklemi oluşturmaktadır. Bu yöntemde öncelikle veri setleri küçük gruplara ayrılmakta ve her bir grup için farklı bir denklem veya temel fonksiyon oluşturulmaktadır. Oluşturulan temel fonksiyonların (5) genel formu aşağıdaki gibidir;

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

Burada, x tahmin edici değişken ve k bir eşik değeridir (Nacar vd., 2020a). Temel denklemlerin doğrusal kombinasyonlarından oluşan MARS yönteminin genel denklemi Eşitlik (6)'da verilmektedir.

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

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

Bu eşitliklerde y bilinmeyen olup, $f(x)$ Eşitlik 6 ile tahmin edilen bağımlı değişken iken ε ise hata miktarıdır. Eşitlik (7)'deki m değeri araştırılan veriye uygun olarak seçilmiş temel fonksiyon sayısı, TF_m m 'inci temel fonksiyon ve β_m bu temel fonksiyonun katsayısıdır (Nacar vd., 2020a).

2.5 TreeNet Gradyan Arttırma Makinesi (TreeNet)

Friedman (2001) tarafından geliştirilen TreeNet gradyan arttırma, makine öğrenimi alanında önemli bir ilerleme olarak kabul edilmektedir. TreeNet yöntemi, gradyan arttırma algoritmasını kullanarak sınıflandırma ve regresyon problemlerini çözmek için etkili bir strateji sunmaktadır. Bu yöntem, yüksek doğruluk, hızlı sonuç üretimi ve eksik veri kümelerinde yüksek hata toleransı sağlaması ile öne çıkmaktadır. TreeNet modeli, birçok küçük ağaçtan oluşmakta ve bu ağaçların her biri için alt uç düğüm içermektedir. Her ağaç, nihai modele küçük bir katkıda bulunmakta ve nihai model, tüm bu katkıların birleşiminden meydana gelmektedir. TreeNet modeli, karmaşık olmasına rağmen, Fourier ya da Taylor serileri gibi seri açılımlarına benzemektedir (Friedman, 2001; Nacar vd., 2020a). TreeNet model açılımı Eşitlik (8)'de verilmektedir.

$$F(x) = F_0 + B_1T_1(x) + B_2T_2(x) + B_3T_3(x) + \dots + B_nT_n(x) \quad (8)$$

Eşitlik (8)'de her bir T_i küçük bir ağacı temsil etmekte ve her biri bu ağacın uygun uç düğümünden elde edilen terimlerin ağırlıklı bir toplamı olarak değerlendirilmektedir.

3. Modelleme Çalışmaları

Modelleme çalışmalarında bulanıklık değerleri bağımlı değişken ve bant yansıma değerleri bağımsız değişken olarak ele alınmıştır. Tüm veriler kronolojik olarak sıralandıktan sonra eğitim, doğrulama ve test verilerine karar verilmiştir. Modellerin günümüzden daha sonra elde edilmiş verileri kullanarak tahmin yapacakları göz önünde bulundurularak, tarih sıralı verilerin ilk %60'lık kısmı eğitim, bu verileri takip eden %20'lik kısım doğrulama ve geri kalan günümüze en yakın veriler ise test verisi olarak kullanılmıştır. Bağımsız değişken olarak ele alınan bant yansıma değerleri tek bir bant veya birden fazla bant yansıma değerlerinden oluşabilmektedir. Çeşitli bant oranlarına sahip regresyon modellerinin, sadece tek bant yansıma değerleri kullanılarak oluşturulan regresyon modellerine kıyasla daha güvenilir olduğu ilgili literatürde belirtilmiştir. (Abdelmalik, 2018; Hossen vd., 2022). Bu nedenle, analizler için tek bir bant yerine, literatürde önerilen bant oranları da dahil olmak üzere 60 farklı bant kombinasyonu kullanılmıştır (Gholizadeh vd., 2016; Rodriguez-Lopez vd., 2021). Modelleme çalışmalarında fazla sayıda bağımsız değişken kullanılması işlem yükü oluşturması açısından tercih edilmemektedir. Bu nedenle üretilen kombinasyonlar arasından ilk aşamada bulanıklık verisiyle en yüksek korelasyona sahip 12 bağımsız değişken seçilmiştir. Daha sonra tüm olası regresyon analizleri gerçekleştirilerek bağımsız değişken sayısının azaltılması yoluna gidilmiştir. B_n Landsat bant numaralarını temsil etmek üzere; B_1/B_4 , B_3/B_4 , B_4/B_1 , B_4/B_3 , B_4/B_2 , B_2+B_4 ve B_3+B_4 kombinasyonlarının bulanıklık parametresiyle daha yüksek bir ilişkiye sahip olduğu görülmüş ve modeller bu değişkenler kullanılarak oluşturulmuştur. Modellemeyi kolaylaştırmak, hesap yükünü azaltmak ve daha etkin sonuçlara ulaşmak adına, bağımlı ve bağımsız değişkenlere ait tüm veriler Eşitlik (9) kullanılarak normalize edilmiştir (Nacar vd., 2020b).

$$X_n = \frac{X_i - X_{min}}{X_{mak} - X_{min}} \times 0.8 + 0.1 \quad (9)$$

Burada X_n normalize değeri, X_{min} ve X_{mak} sırasıyla her bir bağımsız değişken için en küçük ve en büyük değerleri ifade etmektedir.

Çalışmada kullanılan yöntemlerin ve oluşturulan modellerin tahmin performanslarını karşılaştırmak için ortalama karesel hata (MSE), ortalama karesel hatanın karekökü (RMSE), ortalama mutlak hata (MAE) ve Nash-Sutcliffe (NS) verimlilik katsayısı performans istatistikleri kullanılmıştır. Bu performans istatistikleri aşağıda verilen eşitlikler kullanılarak hesaplanmaktadır.

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2} \quad (11)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |t_i - td_i| \quad (12)$$

$$NS = 1 - \frac{\sum_{i=1}^N (t_i - td_i)^2}{\sum_{i=1}^N (t_i - \bar{t})^2} \quad (13)$$

Yukarıda verilen eşitliklerde, t_i ölçüm değerlerini, td_i tahmin değerlerini, \bar{t} ölçüm değerlerinin ortalamasını ve N veri sayısını temsil etmektedir. NS verimlilik katsayısı $-\infty$ ile 1 arasında değerler almakta ve değeri 1'e yaklaştıkça modelin doğruluğu artmaktadır. NS değerinin 0'dan küçük olduğu durumlar ortalama gözlem değerinin modelleme sonucundan daha başarılı bir tahmin değeri olduğu ve dolayısıyla modelin başarısız olduğu anlamına gelmektedir. Ayrıca, daha küçük MSE, RMSE ve MAE değerlerine sahip modellerin daha güvenilir olduğu kabul edilmektedir (Moriassi vd., 2007; Nacar vd., 2020a).

4. Bulgular ve İrdeleme

Landsat 8 OLI bantlarından, B₁, B₂, B₃ ve B₄'ün yansıma değerleri ile Cheney rezervuarında ölçülen bulanıklık değerlerinin orta ila güçlü derecede (R = 0.496 ila 0.864) ilişkili olduğu Tablo 2'de verilmektedir. Öte yandan, B₅, B₆ ve B₇ ile elde edilen yansıma değerleri ile bulanıklık değerleri arasında zayıf bir korelasyon (R < 0.253) olduğu görülmektedir. Tablo 2'de de görüldüğü üzere Landsat 8 OLI bantları ve oluşturulan 60 bant kombinasyonu arasından B₄, B₁/B₄, B₃/B₄, B₄/B₁, B₄/B₃, B₂/B₄, B₄/B₂, B₄/B₅, B₅/B₄, B₂+B₄, B₃+B₄ ve (B₂/B₅)+B₄ kombinasyonları bulanıklık değişkeni ile daha iyi bir korelasyona sahiptir (R = ±0.782 ila 0.910). Bu nedenle bu kombinasyonlar modelleme çalışmalarında kullanılan kombinasyonlar olmuştur. Tek bir Landsat 8 OLI bandı ile bulanıklık değişkeni arasındaki en yüksek R değeri 0.864 iken, bant kombinasyonları ile bulanıklık değişkeni arasındaki en büyük ve en küçük R değerleri sırasıyla 0.910 ve 0.782 olarak hesaplanmıştır.

Modelleme çalışmalarında olabildiğince az sayıda bağımsız değişken kullanılması model güvenilirliğini arttırmakla birlikte işlem yükünü azaltması bakımından tercih edilir. Tüm olası regresyon analizleri modele en iyi katkı vermesi beklenen bağımsız değişkenleri belirlemede kullanılan bir yöntemdir. Tablo 3'te görüldüğü üzere bulanıklık değişkeni ile en yüksek korelasyona sahip 12 bağımsız değişken kullanılarak yapılan tüm olası regresyon analizleri sonucu modelde kullanılacak bağımsız değişken sayısı 7'ye düşürülmüştür. Başka bir deyişle 7'den daha fazla bağımsız değişken kullanılması model doğruluğunu neredeyse etkilememiştir. Bu 7 bağımsız değişken kullanılarak oluşturulan bulanıklık tahmin modellerine ait performans istatistikleri Şekil 2'de gösterilmektedir.

Tablo 2. Bulanıklık değişkeni ile en iyi korelasyona sahip Landsat 8 OLI bantları ve kombinasyonları

Bantlar ve Kombinasyonlar	R
B ₁	0.496
B ₂	0.566
B ₃	0.737
B ₄	0.864
B ₅	0.253
B ₆	0.045
B ₇	0.034
B ₁ /B ₄	-0.845
B ₂ /B ₄	-0.907
B ₃ /B ₄	-0.900
B ₄ /B ₁	0.849
B ₄ /B ₃	0.902
B ₄ /B ₂	0.910
B ₄ /B ₅	0.798
B ₅ /B ₄	-0.782
B ₂ +B ₄	0.782
B ₃ +B ₄	0.822
(B ₂ /B ₅)+B ₄	0.864


Tablo 3. Tüm olası regresyon analizleri sonucu bulanıklık modellemede kullanılacak bağımsız değişkenler

Bağımsız değişken sayısı	B ₄	B ₁ /B ₄	B ₂ /B ₄	B ₃ /B ₄	B ₄ /B ₁	B ₄ /B ₃	B ₄ /B ₂	B ₄ /B ₅	B ₅ /B ₄	B ₂ +B ₄	B ₃ +B ₄	(B ₂ /B ₅)+B ₄	NS
1							✓						0.828
2					✓		✓						0.876
3					✓		✓				✓		0.888
4	✓		✓		✓		✓						0.890
5			✓	✓	✓	✓				✓			0.896
6		✓		✓	✓		✓			✓	✓		0.900
7		✓		✓	✓	✓	✓			✓	✓		0.900
8		✓		✓	✓	✓	✓	✓		✓	✓		0.900
9	✓	✓		✓	✓		✓		✓	✓	✓	✓	0.901
10	✓	✓		✓	✓		✓	✓	✓	✓	✓	✓	0.902
11	✓	✓	✓	✓	✓		✓	✓	✓	✓	✓	✓	0.902
12	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	0.902


Tahmin modellerinin performansları, MSE, RMSE, MAE ve NS verimlilik katsayısı istatistikleri ile kıyaslanmıştır. Eğitim veri seti için Tablo 4 ve Şekil 2a'da görüldüğü üzere DF, ÜF ve EF için NS değerleri birbirine eşit ve diğer yöntemlere kıyasla başarısız sonuçlar (NS= 0.92) vermişlerdir. Ancak bu değerler 1'e çok yakın olduğu için model performanslarının yüksek olduğunu söylemek mümkündür. KF, MARS ve TreeNet yöntemleri eğitim veri seti için birbirine yakın sonuçlar vermiş olup en başarılı sonucu (Sırasıyla NS= 0.97, 0.96 ve 0.94) KF vermiştir. Doğrulama veri seti için Tablo 4 ve Şekil 2b'de görüldüğü üzere TreeNet en başarısız sonuçları (NS = 0.56) vermiştir. DF, ÜF, EF ve MARS için modeller benzer sonuçlar vermiş olup en iyi sonucu (Sırasıyla NS= 0.73, 0.72, 0.72 ve 0.75) MARS vermiştir. Her ne kadar eğitim veri seti için yüksek NS değerleri vermiş olsa da KF modeli genel anlamda başarısız olmuş ve O'dan küçük olan NS değeri grafiğe dahil edilmemiştir. Ayrıca KF modelinin MSE değeri diğer modellerin sonuçlarına kıyasla oldukça büyüktür (242.86 FNU).

Test verileri için Tablo 4 ve Şekil 2c’de görüldüğü üzere MARS ve TreeNet birbirine eşit ve en başarısız sonuçları vermişlerdir (NS= 0.61). DF, ÜF ve EF için modeller benzer sonuçlar vermiş olup en iyi sonucu ÜF vermiştir (Sırasıyla NS= 0.64, 0.66 ve 0.65). KF modeli test verilerinde de genel anlamda başarısız olmuş ve 0’dan küçük olan NS değeri grafiğe dahil edilmemiştir. Ayrıca KF modelinin MSE değerinin diğer modellerin sonuçlarına kıyasla oldukça büyük olduğu görülmüştür (96.58 FNU).

DF, ÜF, EF ve KF modellerinin eğitim, doğrulama ve test verileri saçılım grafikleri sırasıyla Şekil 3a, b, c ve d’de gösterilmektedir. Saçılım grafiklerinde, köşegene yakın bir veri dağılımı modelin iyi performans gösterdiği anlamına gelmektedir (Nacar vd., 2020b). Şekil 3d’den de görüldüğü üzere, KF için eğitim verileri, diğer fonksiyonların eğitim verilerine kıyasla köşegene en yakın verilerdir, ancak test verileri için durum bunun tam tersidir. MARS ve TreeNet yöntemleri ile oluşturulan modellerin saçılım grafikleri sırasıyla Şekil 3e ve 3f’de görülmektedir. MARS ve TreeNet yöntemlerinin tahmin performanslarının birbirine yakın olduğu Şekil 3e ve 3f’de görülmektedir.



Şekil 2. Bulanıklık tahmin modellerinin eğitim, doğrulama ve test verileri için performans istatistikleri



Şekil 3. Bulanıklık tahmin değerlerinin ölçüm verileri ile olan ilişkilerini gösteren saçılım grafikleri (a) DF, (b) ÜF, (c) EF, (d) KF, (e) MARS ve (f) TreeNet

Tablo 4. Regresyon fonksiyonları, MARS ve TreeNet yöntemlerine ait performans istatistikleri


Veri seti/Model	DF	ÜF	EF	KF	MARS	TreeNet
Eğitim						
MSE (FNU)	4.77	4.29	4.30	1.84	1.87	2.94
RMSE (FNU)	2.18	2.07	2.07	1.36	1.36	1.71
MAE (FNU)	1.70	1.56	1.53	0.96	1.05	0.77
NS	0.92	0.92	0.92	0.97	0.96	0.94
Doğrulama						
MSE (FNU)	3.32	3.50	3.41	242.86	3.04	5.38
RMSE (FNU)	1.82	1.87	1.85	15.58	1.74	2.32
MAE (FNU)	1.47	1.54	1.49	6.52	1.33	1.86
NS	0.73	0.72	0.72	-18.67	0.75	0.56
Test						
MSE (FNU)	8.87	8.55	8.69	96.58	9.65	9.58
RMSE (FNU)	2.98	2.92	2.95	9.83	3.10	3.09
MAE (FNU)	2.55	2.54	2.50	6.63	2.54	2.60
NS	0.64	0.66	0.65	-2.88	0.61	0.61

MARS yönteminin uygulanması sonucu elde edilen TF'ler Tablo 5'te verilmektedir. Tüm TF'lerin B_4 değişkenini içermesi, bulanıklık değişkeninin B_4 ile yüksek bir korelasyon içerisinde olmasının bir sonucudur. MARS yöntemi kullanılarak elde edilen, Cheney Rezervuarında bulanıklığı tahmin etmesi beklenen denklem Eşitlik (14)'te verilmektedir. Şekil 4a ve 4b'de görüldüğü üzere MARS yönteminde göreceli önemi en yüksek olan parametre B_4/B_1 iken TreeNet yönetimiyle oluşturulan modelde B_4/B_2 'dir.

Tablo 5. MARS yöntemiyle elde edilen denkleme ait temel fonksiyonlar

Temel Fonksiyon No	Temel Fonksiyon
TF01	$\text{maks}(0, B_4/B_2 - 0.129930)$
TF02	$\text{maks}(0, B_4/B_1 - 0.189615)$
TF04	$\text{maks}(0, B_1/B_4 - 0.382259) \times \text{TF01}$
TF06	$\text{maks}(0, B_3/B_4 - 0.301666)$
TF07	$\text{maks}(0, 0.301666 - B_3/B_4)$
TF10	$\text{maks}(0, B_4/B_1 - 0.575208) \times \text{TF04}$
TF12	$\text{maks}(0, B_4/B_3 - 0.409036) \times \text{TF04}$
TF13	$\text{maks}(0, 0.409036 - B_4/B_3) \times \text{TF04}$
TF14	$\text{maks}(0, B_3/B_4 - 0.380915) \times \text{TF01}$
TF15	$\text{maks}(0, 0.380915 - B_3/B_4) \times \text{TF01}$
TF17	$\text{maks}(0, 0.428972 - B_4/B_3) \times \text{TF14}$
TF18	$\text{maks}(0, B_1/B_4 - 0.341339) \times \text{TF02}$
TF20	$\text{maks}(0, B_3+B_4 - 0.724787) \times \text{TF18}$

$$\begin{aligned} \text{Bulanıklık} = & -0.0881 + 3.2455 \times \text{TF01} - 2.1008 \times \text{TF02} + 0.3992 \times \text{TF06} + 3.5339 \times \text{TF07} - 3.6110 \times 10^6 \\ & \times \text{TF10} - 24.2435 \times \text{TF12} - 25.7938 \times \text{TF13} - 2.1854 \times \text{TF14} - 4.2622 \times \text{TF15} + 16.4792 \\ & \times \text{TF17} + 50.7029 \times \text{TF20} \end{aligned} \quad (14)$$



Şekil 4. (a) MARS ve (b) TreeNet yöntemleriyle oluşturulmuş bulanıklık modellerindeki bağımsız değişkenlerin göreceli önem dereceleri

Literatürde Landsat 8 görüntüleri kullanılarak yapılan bulanıklık (NTU) tahmin çalışmalarına ait uydu görüntüleri ile yersel olarak ölçülmüş bulanıklık değerleri arasındaki zaman farkı, modelleri kurmak için kullanılan yöntem, modellerde kullanılan uydu görüntüsü verisi – bulanıklık ölçümü sayısı ve modellerin RMSE değerleri Tablo 6’da verilmektedir. Modelleme çalışmalarında kullanılan ölçüm sayısının modellerin güvenilirliğini arttırdığı bilinmektedir. Bu çalışmada 99 uydu görüntüsü – bulanıklık verisi kullanılarak modeller kurulmuştur. Hossain vd. (2021) yaptıkları çalışmada 71 uydu görüntüsü – bulanıklık verisi eşleştirmesi yaparak oluşturdukları modelde RMSE değerini 1.41 NTU olarak elde etmişlerdir. Ancak bu modeli başka bir tarihte elde edilmiş 25 uydu görüntüsü – bulanıklık verisi ile test ettiklerinde RMSE değerinin 18.08 NTU’ya çıktığını tespit etmişlerdir. Bu durum literatürde daha az sayıda uydu görüntüsü – bulanıklık verisi kullanılarak oluşturulmuş modellerin düşük RMSE değerlerini tartışmaya açık hale getirmektedir.

Tablo 6. Landsat 8 görüntülerinin kullanıldığı bazı bulanıklık tahmin çalışmaları ve özellikleri

Yazarlar	Çalışma Alanı	Ölçüm Sayısı	Yöntem	Zaman Farkı	RMSE (NTU)
Sharaf El Din vd. (2017)	Saint John Nehri (Kanada)	38	Geri yayımlı yapay sinir ağları	< 1 gün	0.31
Liu ve Wang (2019)	Tseng-Wen ve Nan-Hwa Rezervuarları(Tayvan)	73	Gen ifade programlama yöntemleri	< 1 gün	0.93
Pizani vd. (2020)	Tres Marias Rezervuarı (Brezilya)	13	Regresyon analizleri	< 1 gün	0.16
Hossain vd. (2021)	Tennessee Nehri (ABD)	71	Regresyon analizleri	< 1 gün	1.41
Rodriguez-Lopez vd. (2021)	Araucanian Gölleri (Şili)	25	Regresyon analizleri	< 10 gün	0.31
Meng vd. (2022)	Shanmei Rezervuarı (Çin)	14	Regresyon analizleri	< 2 saat	1.95

4. Sonuçlar ve Öneriler

Su kalitesinin önemli göstergelerinden biri olan bulanıklık değişkeninin yersel olarak ölçülmesi zaman alıcı ve maliyetli olabilmektedir. Bu çalışmada Landsat 8 OLI uydu görüntüleri kullanılarak Cheney Rezervuarında bulanıklık tahmini yapabilecek bir model oluşturulması hedeflenmiştir. Cheney Rezervuarında yersel olarak takibi yapılmış bulanıklık verileri ve bu verilerle arasındaki zaman farkı 20 dakikayı geçmeyen Landsat 8 OLI uydu görüntüleri arasındaki ilişkiler incelenerek regresyon tabanlı tahmin modelleri kurulmuştur. Eşleştirilmesi yapılan bulanıklık verileri ile uydu görüntüleri arasındaki zaman farkının bu derecede az olması, çalışmayı bu yönüyle literatürdeki diğer çalışmalardan ayırmaktadır. Bu çalışma kapsamında regresyon analizi, çok değişkenli uyarlanabilir regresyon eğrileri (MARS) ve TreeNet gradyan arttırma makinesi (TreeNet) yöntemleri kullanılmıştır. Kurulan modellerin performansları çeşitli performans istatistikleri kullanılarak değerlendirilmiştir.

Landsat 8 OLI yansıma değerleri ve bulanıklık verileri arasında yapılan regresyon analizleri ile elde edilen üs fonksiyon modeli, test veri seti için doğrusal, eksponansiyel ve kuadratik fonksiyon modellerine kıyasla daha doğru tahminler (NS = 0.66) ortaya koymuştur. MARS ve TreeNet yöntemlerinin tahmin değerlerinin test veri seti için birbirine eşit olduğu

görülmüştür (NS = 0.61). B_4 yansıma değerleri ile bulanıklık verileri arasında güçlü bir ilişki ($R > 0.85$) olduğu belirlenmiştir. MARS yöntemi kullanılarak oluşturulan modelde en önemli parametre B_4/B_1 (kırmızı/kıyı aerosol) olarak, TreeNet yöntemi ile oluşturulan modelde ise en önemli parametre B_4/B_2 (kırmızı/mavi) olarak belirlenmiştir. Elde edilen bulgularla, Cheney Rezervuarında bulanıklık değişkenini tahmin etmede uzaktan algılama verilerinin kullanılabilmesi sonucuna ulaşılmıştır.

Uzaktan algılama ile bulanıklık tahmini çalışmalarında sıklıkla Landsat 8 OLI uydu görüntüleri kullanılmıştır. Yapılan çalışmaların büyük çoğunluğunda bulanıklık verileri ile Landsat 8 OLI görüntülerinin ilk dört bandı arasında yüksek bir ilişki olduğu saptanmış olup, bulanıklık değişkenini tahmin etmede en kullanışlı dalga boyu aralığının 0.700 – 0.800 μm olduğu belirtilmiştir. Bu çalışmada elde edilen sonuçlar bu durumu destekler niteliktedir.

Gelecekte, uzaktan algılama ile su kalitesi tahmin çalışmalarında sıklıkla kullanılan başka çok bantlı uydu görüntüleri ile Cheney Rezervuarında bulanıklık değişkenini tahmin edebilecek modeller kurulabilir. Ancak hiperspektral uydu görüntüleri, çok bantlı uydu görüntülerine kıyasla daha yüksek spektral çözünürlüğe sahip olduklarından, su kalitesi parametreleri hakkında daha ayrıntılı bilgi sağlayabilir ve bu nedenle su kalitesi tahminlerinde kullanılabilirlikleri araştırılabilir. Bu çalışma kapsamında sadece regresyon tabanlı modellerin performansları karşılaştırılmıştır. Farklı algoritmalar ve hibrit modelleme teknikleri kullanılarak benzer analizler gerçekleştirilebilir ve performansları bu çalışma kapsamında elde edilen regresyon tabanlı modellerin performansları ile karşılaştırılabilir.

Teşekkür

Yazarlar, veri izleme, işleme ve yönetimi için USGS personeline ve ücretsiz olarak sağladıkları veriler için NASA/USGS'ye teşekkür ederler. Yazarlar, değerli zamanlarını ayırarak çalışmayı inceleyip değerlendiren ve kıymetli önerileri ile katkıda bulunan hakemlere de teşekkür ederler.

Kaynaklar

- Abdelmalik, K. W. (2018). Role of statistical remote sensing for inland water quality parameters prediction. *The Egyptian Journal of Remote Sensing and Space Science*, 21(2), 193-200.
- Abdul Wahid, A., & Arunbabu, E. (2022). Forecasting water quality using seasonal ARIMA model by integrating in-situ measurements and remote sensing techniques in Krishnagiri reservoir, India. *Water Practice & Technology*, 17(5), 1230-1252.
- Agapiou, A. (2020). Evaluation of Landsat 8 OLI/TIRS level-2 and Sentinel 2 level-1C fusion techniques intended for image segmentation of archaeological landscapes and proxies. *Remote Sensing*, 12(3), Article 579. <https://doi.org/10.3390/rs12030579>
- Al-Fahdawi, A. A., Rabee, A. M., & Al-Hirmizy, S. M. (2015). Water quality monitoring of Al-Habbaniyah Lake using remote sensing and in situ measurements. *Environmental Monitoring and Assessment*, 187, 1-11.
- Alparslan, E., Aydın, C., Tufekci, V., & Tufekci, H. (2007). Water quality assessment at Ömerli Dam using remote sensing techniques. *Environmental Monitoring and Assessment*, 135, 391-398.
- Batur, E. (2019). *Uzaktan algılama verilerinden su kalitesi parametrelerinin tespit edilmesi* [Doktora tezi, İstanbul Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Bonanse, M., Ledesma, M., Rodriguez, C., & Pinotti, L. (2018). Using new remote sensing satellites for assessing water quality in a reservoir. *Hydrological Sciences Journal*, 64(1), 34-44.
- Boyd, C. E. (2019). *Water quality: an introduction*. Springer Nature.
- Christensen, V. G., Graham, J. L., Milligan, C. R., Pope, L. M., & Ziegler, A. C. (2006). *Water quality and relation to taste-and-odor compounds in the North Fork Ninescah River and Cheney Reservoir, South-central Kansas, 1997-2003*. U. S. Geological Survey.
- Chu, H. J., He, Y. C., Chusnah, W. N. U., Jaelani, L. M., & Chang, C. H. (2021). Multi-reservoir water quality mapping from remote sensing using spatial regression. *Sustainability*, 13(11), Article 6416. <https://doi.org/10.3390/su13116416>
- Çölkesen, İ. (2015). *Yüksek çözünürlüklü uydu görüntüleri kullanarak benzer spektral özelliklere sahip doğal nesnelerin ayırt edilmesine yönelik bir metodoloji geliştirme* [Doktora tezi, İstanbul Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- De Roos, A. J., Gurian, P. L., Robinson, L. F., Rai, A., Zakeri, I., & Kondo, M. C. (2017). Review of epidemiological studies of drinking-water turbidity in relation to acute gastrointestinal illness. *Environmental Health Perspectives*, 125(8), Article 086003. <https://doi.org/10.1289/ehp1090>
- Dilmen, Ö. (2023). *Landsat 8 ve Sentinel 2 uydu görüntüleri ile içme suyu baraj göllerinde bulanıklık tahmini* [Yüksek lisans tezi, Karadeniz Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>

- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232.
- Friedman, J. H. (1991). Multivariate adaptive regression splines. *Annals of Statistics*, 19(1), 1-67.
- Gholizadeh, M. H., Melesse, A. M., & Reddi, L. (2016). A comprehensive review on water quality parameters estimation using remote sensing techniques. *Sensors*, 16(8), Article 1298. <https://doi.org/10.3390/s16081298>
- Gonzalez-Marquez, L. C., Torres-Bejarano, F. M., Rodriguez-Cuevas, C., Torregroza-Espinosa, A. C., & Sandoval-Romero, J. A. (2018). Estimation of water quality parameters using Landsat 8 images: application to Playa Colorada Bay, Sinaloa, Mexico. *Applied Geomatics*, 10, 147-158.
- Hossain, A. A., Mathias, C., & Blanton, R. (2021). Remote sensing of turbidity in the Tennessee River using Landsat 8 satellite. *Remote Sensing*, 13(18), Article 3785. <https://doi.org/10.3390/rs13183785>
- Hossen, H., Mahmud, W. E., Negm, A., & Nakamura, T. (2022). Assessing water quality parameters in Burullus Lake using Sentinel-2 satellite images. *Water Resources*, 49(2), 321-331.
- Khalid, H. W., Khalil, R. M. Z., & Qureshi, M. A. (2021). Evaluating spectral indices for water bodies extraction in western Tibetan Plateau. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3), 619-634.
- Liu, L. W., & Wang, Y. M. (2019). Modelling reservoir turbidity using Landsat 8 satellite imagery by gene expression programming. *Water*, 11(7), Article 1479. <https://doi.org/10.3390/w11071479>
- Mann, A. G., Tam, C. C., Higgins, C. D., & Rodrigues, L. C. (2007). The association between drinking water turbidity and gastrointestinal illness: a systematic review. *BMC Public Health*, 7(1), Article 256. <https://doi.org/10.1186/1471-2458-7-256>
- Meng, H., Zhang, J., & Zheng, Z. (2022). Retrieving inland reservoir water quality parameters using Landsat 8-9 OLI and Sentinel-2 MSI sensors with empirical multivariate regression. *International Journal of Environmental Research and Public Health*, 19(13), Article 7725. <https://doi.org/10.3390/ijerph19137725>
- Moore, G. K. (1980). Satellite remote sensing of water turbidity. *Hydrological Sciences Journal*, 25(4), 407-421.
- 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.
- Mortula, M., Ali, T., Bachir, A., Elaksher, A., & Abouleish, M. (2020). Towards monitoring of nutrient pollution in coastal lake using remote sensing and regression analysis. *Water*, 12(7), Article 1954. <https://doi.org/10.3390/w12071954>
- Nacar, S., Mete, B., & Bayram, A. (2020a). Estimation of daily dissolved oxygen concentration for river water quality using conventional regression analysis, multivariate adaptive regression splines, and TreeNet techniques. *Environmental Monitoring and Assessment*, 192(12), Article 752. <https://doi.org/10.1007/s10661-020-08649-9>
- Nacar, S., Mete, B., & Bayram, A. (2020b). Günlük çözünmüş oksijen konsantrasyonunun çok değişkenli uyarlanabilir regresyon eğrileri ile tahmin edilmesi. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 25(3), 1479-1498.
- Nacar, S., Şan, M., Kankal, M., & Okkan, U. (2024). Innovative polygonal trend analysis (IPTA) in detecting the seasonal trend behavior of statistically downscaled precipitation for the Eastern Black Sea Basin of Turkey. *Urban Water Journal*, 21(4), 406-418.
- Pinto, C. T., Jing, X., & Leigh, L. (2020). Evaluation analysis of Landsat level-1 and level-2 data products using in situ measurements. *Remote sensing*, 12(16), Article 2597. <https://doi.org/10.3390/rs12162597>
- Pizani, F. M., Maillard, P., Ferreira, A. F., & de Amorim, C. C. (2020). Estimation of water quality in a reservoir from Sentinel-2 MSI and Landsat-8 OLI sensors. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3, 401-408.
- Rodriguez-Lopez, L., Duran-Llacer, I., Gonzalez-Rodriguez, L., Cardenas, R., & Urrutia, R. (2021). Retrieving water turbidity in Araucanian lakes (South-central Chile) based on multispectral Landsat imagery. *Remote Sensing*, 13(16), Article 3133. <https://doi.org/10.3390/rs13163133>
- Sharaf El Din, E., Zhang, Y., & Suliman, A. (2017). Mapping concentrations of surface water quality parameters using a novel remote sensing and artificial intelligence framework. *International Journal of Remote Sensing*, 38(4), 1023-1042.
- Sharda, V. N., Prasher, S. O., Patel, R. M., Ojasvi, P. R., & Prakash, C. (2008). Performance of multivariate adaptive regression splines (MARS) in predicting runoff in mid-Himalayan micro-watersheds with limited data. *Hydrological Sciences Journal*, 53(6), 1165-1175.
- Sun, X., Zhang, Y., Shi, K., Zhang, Y., Li, N., Wang, W., Huang, X., & Qin, B. (2022). Monitoring water quality using proximal remote sensing technology. *Science of the Total Environment*, 803, Article 149805. <https://doi.org/10.1016/j.scitotenv.2021.149805>
- Surisetty, V. V. A. K., Sahay, A., Ramakrishnan, R., Samal, R. N., & Rajawat, A. S. (2018). Improved turbidity estimates in complex inland waters using combined NIR-SWIR atmospheric correction approach for Landsat 8 OLI data. *International Journal of Remote Sensing*, 39(21), 7463-7482.

- State of Kansas (2023, 6 Aralık). *2022 Certified Kansas Population by County*. 6 Aralık 2023'te https://budget.kansas.gov/wp-content/uploads/2022_Kansas_Certified_Population_7-1-23.pdf adresinden alındı.
- Stone, M. L., Juracek, K. E., Graham, J. L., & Foster, G. M. (2015). Quantifying suspended sediment loads delivered to Cheney Reservoir, Kansas: Temporal patterns and management implications. *Journal of Soil and Water Conservation*, *70*(2), 91-100.
- Şan, M., Nacar, S., Kankal, M., & Bayram, A. (2023). Daily precipitation performances of regression-based statistical downscaling models in a basin with mountain and semi-arid climates. *Stochastic Environmental Research and Risk Assessment*, *37*(4), 1431-1455.
- Şan, M., Nacar, S., Kankal, M., & Bayram, A. (2024). Spatiotemporal analysis of transition probabilities of wet and dry days under SSPs scenarios in the semi-arid Susurluk Basin, Türkiye. *Science of the Total Environment*, *912*, Article 168641. <https://doi.org/10.1016/j.scitotenv.2023.168641>
- Theologou, I., Patelaki, M., & Karantzalos, K. (2015). Can single empirical algorithms accurately predict inland shallow water quality status from high resolution, multi-sensor, multi-temporal satellite data? *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, *40*, 1511-1516.
- U.S. Geological Survey (2023, 6 Aralık). *Turbidity data in Cheney reservoir*. U.S. Geological Survey. 6 Aralık 2023'te https://waterdata.usgs.gov/nwis/uv?site_no=07144790&legacy=1 adresinden alındı.
- Wang, F., Qin, Z., Song, C., Tu, L., Karnieli, A., & Zhao, S. (2015). An improved mono-window algorithm for land surface temperature retrieval from Landsat 8 thermal infrared sensor data. *Remote Sensing*, *7*(4), 4268-4289.
- Wang, L., Wu, C., Gu, X., Liu, H., Mei, G., & Zhang, W. (2020). Probabilistic stability analysis of earth dam slope under transient seepage using multivariate adaptive regression splines. *Bulletin of Engineering Geology and the Environment*, *79*, 2763-2775.