



Su Kirliliğinde Uzaktan Algılama

© Doç. Dr. Özgür ZEYDAN
<https://ozgurzeydan.com.tr/>



Su Kirliliğinde Uzaktan Algılama

- Sucul ekosistemlerde su kalitesi parametrelerinin izlenmesi (klorofil-a, bulanıklık, toplam katı madde, renkli çözünmüş organik maddeler)
- Endüstriyel deşarjların izlenmesi
- Petrol sızıntılarını izlenmesi
- Termik santral ve yakma tesislerinin soğutma suyu kaynaklı termal kirliliğin tespiti
- İstilacı türlerin izlenmesi

Su Kirliliğinde Uzaktan Algılama

Discover Geoscience

Review

Integration of remote sensing data and GIS technologies in river management system

Chatrabhuj¹ · Kundan Meshram¹ · Umank Mishra¹ · Padam Jee Omar² 




Fig. 3 Application of remote sensing in river management system

<https://doi.org/10.1007/s44288-024-00080-8>

Su Kalitesi İzleme ve Değerlendirmede Kullanılan Sensörler

TABLE 3 Characteristics of sensors commonly applied for water quality assessments and monitoring.

Satellite sensor	Status	Spatial resolution	Temporal resolution	Number of bands	Studies that have utilised the sensors
MODIS (Terra)	1999 - active	250 m–500 m - 1 km	1–2 days	36	McClain et al. (2014), Park and Latrubesse (2014), Shi et al. (2018), Xiong et al. (2019), Liu et al. (2022)
MODIS (Aqua)	2002 - active	250 m–500 m - 1 km	1–2 days	36	McClain et al. (2014), Park and Latrubesse (2014), Shi et al. (2018), Xiong et al. (2019), Liu et al. (2022)
MERIS (Envisat)	2002–2012	300 m	3 days	15	Odermatt et al. (2008), Kratzer et al. (2010), Majozi et al. (2014)
SeaWiFS	1997–2010	1 km	1–2 days	8	Flemming et al. (2002), Reinart and Pierson (2014), Groom et al. (2019)
OLI (Landsat-8)	2013 - active	15 m–30 m	8 days	9	Pizani et al. (2020), Kramer et al. (2023), Omondi et al. (2023)
MSI (Sentinel-2A/B)	2015 - active	10 m–20 m - 60 m	5 days for 2A and 2B	13	Arias-Rodriguez et al. (2023), Kowe et al. (2023), Ndou (2023), Obaid et al. (2021), Sent et al. (2021)
OLCI (Sentinel-3A/3B)	2016/2018 - active	300 m	3 days	21	Soomets et al. (2020), Rodrigues et al. (2022)
OLI-2 (Landsat-9)	2021 - active	15 m–30 m	8 days	9	Ghasempour et al. (2023), Trevisiol et al. (2024)
TIRS (Landsat-9)	2021 - active	100 m	8 days	2	Wang et al. (2023), Eon et al. (2024)

Trends in remote sensing of water quality parameters in inland water bodies: a systematic review

<https://doi.org/10.3389/fenvs.2025.1549301>

Ötrofikasyonun Uzaktan Algılanması

➤ Azot + fosfor artışı



Fitoplankton/alg artışı



Klorofil-a artışı



Suyun optik özellikleri değişir




 uzaktan algılama ile tespit edilir.

➤ Klorofil-a belirleyen indeksler: NDCI, MCI.

➤ Ayrıca NDVI ve EVI gibi bitki indeksleri de klorofil-a tespit etmek için kullanılabilir.


➤ Bulanıklık ve askıda madde belirleyen indeksler: NDTI.

Yansıma Grafikleri



<https://www.usgs.gov/media/images/aquatic-remote-sensing-example-spectra-water-water-algae-and-water-sediment>

Klorofil-a Yansıma Grafiği



<https://www.researchgate.net/publication/315797574> Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks

Normalized Difference Chlorophyll Index (NDCI)

- NDCI (Normalize Fark Klorofil İndeksi), klorofil-a tespit etmek için kullanılır.
- NDCI, klorofil değişimlerine son derece duyarlı olan kırmızı kenar bölgesini kullanır. Kırmızı kenar bandı, diğer indekslerin gözden kaçırabileceği klorofil içeriğindeki ince değişiklikleri yakalar.
- $$NDCI = \frac{(NIR - Red)}{(NIR + Red)}$$
- Negatif değerler berrak suyu, pozitif değerler alg patlamasını gösterir.

Ötrofik Durum Sınıflandırma – NDCI

Table 5. Literature-based interpretive classification of NDCI values.

NDCI Range	Indicative Parameter	Indicative Ecological Condition
<−0.10	<7.5 µg/L	Oligotrophic
−0.10 to 0.00	7.5–16 µg/L	Low productivity
0.00 to 0.10	16–25 µg/L	Mesotrophic
0.10 to 0.20	25–33 µg/L	Eutrophic



Article

Multi-Indicator Remote Sensing of Water Quality Dynamics Across Contrasting Freshwater Systems in Türkiye: A Sentinel-2 and Landsat-Based Change Detection Framework

Venkataraman Lakshmi ¹, Alperen Kir ^{2,*} and Bin Fang ¹

<https://doi.org/10.3390/rs18122048>

NDCI – Uygulama




Figure 6. Spatial distribution of Δ NDCI across the four study sites (2015–2018 vs. 2023–2025).

<https://doi.org/10.3390/rs18122048>

Maximum Chlorophyll Index (MCI)

- MCI (Maksimum Klorofil İndeksi)
- MCI, yüksek klorofil içeriğini tahmin etmek için kırmızı kenar (red-edge) bölgesine odaklanır. Kırmızı kenar bantları, klorofilin güçlü soğurma özelliğini yakalar.
- Yüksek klorofil-a seviyelerinin saptanması için kullanılır.
- $$MCI = \frac{(RedEdge2 - RedEdge1)}{(RedEdge2 + RedEdge1)}$$
- Yüksek MCI değerleri, yüksek klorofil-a konsantrasyonunu gösterir.

Normalized Difference Vegetation Index (NDVI)

- NDVI (Normalize Fark Bitki İndeksi), klorofilin kırmızı ışığı etkili bir şekilde emmesinden ve sağlıklı bitki örtüsünün yakın kızılötesi (NIR) ışığı yüksek oranda yansıtmasından yararlanır.
- $NDVI = \frac{(NIR - Red)}{(NIR + Red)}$
- Değeri +1 ile -1 arasında değişir. Pozitif değerler yüksek klorofil-a konsantrasyonunu gösterir.

Enhanced Vegetation Index (EVI)

- EVI (Geliştirilmiş Bitki Örtüsü Endeksi), atmosferik saçılma ve toprak arka plan gürültüsünü düzeltmek amacıyla mavi bandı dahil ederek NDVI'yi geliştirir; bu da onu yoğun bitki örtüsü koşullarında daha güvenilir kılar.
- Bu indeks, özellikle yoğun alg patlamalarının izlenmesinde ve su kütlelerinin kapsamının değerlendirilmesinde etkilidir.
- $EVI = 2.5 \times (NIR - Red) / (NIR + 6 \times Red - 7.5 \times Blue + 1)$

Bulanıklık

- Su veya başka bir sıvının içindeki askıda katı maddeler (kil, kum, organik partiküller) sebebiyle ışığın geçişinin engellenmesi ve sıvının şeffaflığını yitirerek bulanık görünmesidir.
- Bulanıklık, NTU (Nephelometric Turbidity Unit / Nefelometrik Bulanıklık Birimi) ile ifade edilir.
- Bulanıklık; özellikle kırmızı ve yeşil dalga boylarında ışığın saçılmasına ve soğurulmasına yol açar.

Normalized Difference Turbidity Index (NDTI)

- NDTI (Normalize Fark Bulanıklık İndeksi), askıdaki parçacıkların etkilediği bir su berraklığı ölçütü olan bulanıklığı tahmin etmek için kırmızı ve yeşil ışık arasındaki yansıma farkına odaklanır.
- $NDTI = \frac{(Red - Green)}{(Red + Green)}$
- Değeri +1 ile -1 arasında değişir. Pozitif değerler yüksek bulanıklığı, negatif değerler düşük bulanıklığı (berrak su) gösterir.
- NDTI, doğrudan NTU ölçmez; daha doğru ifadeyle bulanıklılığın optik bir göstergesidir. NTU kestirimi için yerel regresyon veya makine öğrenmesi gibi yöntemlerle kalibrasyon yapılmalıdır.
- Uygulamalar: Aşırı yağışlar veya sel sonrası bulanıklık belirlenmesi.

Bulanıklık Sınıflandırması – NDTI

Table 6. Literature-based interpretive classification of NDTI values.

NDTI Range	Indicative Class	Hydrological Meaning
< -0.10	Very clear	Deep/stable water, very low turbidity
-0.10 to 0.00	Clear	Natural lake conditions, low turbidity
0.00 to 0.05	Slightly turbid	Wind-induced mixing
0.05 to 0.10	Moderately turbid	Surface mixing



Article

Multi-Indicator Remote Sensing of Water Quality Dynamics Across Contrasting Freshwater Systems in Türkiye: A Sentinel-2 and Landsat-Based Change Detection Framework

Venkataraman Lakshmi ¹, Alperen Kir ^{2,*} and Bin Fang ¹

<https://doi.org/10.3390/rs18122048>

NDTI – Uygulama





Figure 7. Spatial distribution of Δ NDTI across the four study sites (2015–2018 vs. 2023–2025).

<https://doi.org/10.3390/rs18122048>

Normalized Difference Turbidity Index (NDTI)

Fig. 10 PlanetScope natural color composite (RGB) images and NDTI maps at the Goksu intake and Main Source when turbidity exceeded 200 NTU on March 21, 2023 (a), and turbidity was measured as 21.9 NTU on May 27, 2023 (b) at the Goksu intake. The white marker pinpoints the location of the turbidity instrument



Natural Hazards (2026) 122:99
<https://doi.org/10.1007/s11069-025-07885-x>

ORIGINAL PAPER



Post-seismic turbidity response in the Goksu Stream after the 2023 Kahramanmaras earthquakes

Selcuk Toprak¹ · Seyhmus Can Tunc¹ · Erdal Emirhan Ovunc¹ · Ali Levent Yagci² · Oguz Dal¹

<https://doi.org/10.1007/s11069-025-07885-x>

Görüntü Yorumlama

- Sahada ölçülen su kalitesi parametrelerinin uzaktan algılama verileri (belirli bantlardaki değerler veya bunları kombinasyonları) yardımıyla tahmin edilmesidir.
- En basit yöntem basit doğrusal regresyon denklemi geliştirilmesidir.
- Çoklu regresyon; polinom, logaritmik veya üstel modeller kullanılabilir.
- Sahada ölçülen parametreler ile bant değerleri arasındaki ilişki R^2 , RMSE, MAE gibi hata metrikleri ile yorumlanır.
- Makine öğrenmesi yöntemleri (rastgele orman, yapay sinir ağları vb.) ile daha iyi sonuç veren modeller bulmak mümkündür.

Regresyon Analizi

- $Y = \beta_0 + \beta_1 * X_1 + \varepsilon$ (Basit doğrusal regresyon)
- $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon$ (Çoklu doğrusal regresyon)
- Y: Bağımlı değişken (sahada ölçülen parametre)
- $X_{1...n}$: Bağımsız değişken(ler) (belirli banttaki piksel değeri)
- $B_{1...n}$: Katsayı(lar)
- ε : Hata terimi

Model Performansı Analiz Metrikleri

TABLE 4: Water quality estimation performance analysis metrics.

Error estimator	Error equation
Pearson correlation coefficient and coefficient of determination	$R = \sum_{i=1}^n (y_i - \bar{y}) \cdot (x_i - \bar{x}) / \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \cdot \sum_{i=1}^n (x_i - \bar{x})^2}, R^2$
Mean absolute error	$MAE = 1/n \sum_{i=1}^n x_i - y_i $
Root mean square error	$RMSE = \sqrt{1/n \sum_{i=1}^n (x_i - y_i)^2}$
Normalized mean absolute error percent	$NMAE\% = \left[1/n \sum_{i=1}^n (x_i - y_i /x_i) \right] * 100$

Belirleme Katsayısı (Coefficient of Determination – R^2)

$$R^2 = \left(\frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sigma_O \times \sigma_P} \right)^2$$

- $\bar{O}$: Ölçülen değerlerin ortalaması
- $\bar{P}$: Tahmin edilen değerlerin ortalaması
- n : Veri sayısı
- σ_O : Ölçülen değerlerin standart sapması
- σ_P : Tahmin edilen değerlerin standart sapması

- Belirleme katsayısı (R^2 veya r^2), bir istatistiksel modelin bağımlı değişkendeki toplam varyasyonu açıklama yüzdesini gösterir.
- Değeri 0 ile 1 arasında değişir.
- R^2 açıklanan varyansın bir ölçüsüdür; tek başına modelin hatasız veya güvenilir olduğunu göstermez.

Ortalama Mutlak Hata (Mean Absolute Error - MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i|$$

- $\bar{O}$: Ölçülen değerlerin ortalaması
- $\bar{P}$: Tahmin edilen değerlerin ortalaması
- n : Veri sayısı
- Ortalama mutlak hata (MAE) da ise ölçülen ve tahmin edilen konsantrasyonlar arasındaki farkın mutlak değeri alındığından hatanın büyüklüğünü miktar olarak vermekte fakat yanlışlığın yönü yani modelin az veya fazla tahmin etmesi hakkında herhangi bir bilgi vermemektedir.

Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error - RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2}$$

- $\bar{O}$: Ölçülen değerlerin ortalaması
- $\bar{P}$: Tahmin edilen değerlerin ortalaması
- n : Veri sayısı
- Hata kareleri ortalamasının karekökü (RMSE), hatanın boyutları verilerin boyutları ile aynı büyüklükte ifade edilebilmektedir. Aynı zamanda, veri setindeki uç değerlerin atılması durumunda RMSE değeri diğer parametrelere göre daha fazla etkilenmektedir.

Regresyon Analizi - Su Kalitesi - Örnek Çalışmalar

TABLE 7: Regression model for the estimation of TSS from Sentinel-2A MSI.

Sentinel-2A regression model equation for estimation of TSS	Band combination for deriving R_{rs} (= x)	R^2	MAE	NMAE%	RMSE
$y = 93011x^2 - 82773x + 18442$	$(B4 + (B8/B4))/2$	0.6133	5.4969	4.3039	8.3845
$y = 89013x^2 - 78936x + 17526$	$(B8A + (B8/B4))/2$	0.5940	9.5691	6.8105	13.4793
$y = 83708x^2 - 73811x + 16299$	$(B8 + (B8/B4))/2$	0.5998	6.6792	7.5058	12.9244
$y = 19420x^2 - 26272x + 8945.4$	B4/B3	0.4846	23.7299	15.7569	24.8370
$y = 46042x^2 - 32585x + 5822.6$	$(B3 + (B4/B3))/2$	0.4722	13.9118	12.9250	21.7248

TABLE 8: Regression model for the estimation of TSS from Landsat-8 OLI.

Landsat OLI regression model equation for estimation of TSS	Band combination for deriving R_{rs} (= x)	R^2	MAE	NMAE%	RMSE
$y = 2781.9x - 1393.5$	B2	0.9240	4.7391	12.3842	3.3185
$y = 27176x - 1184.6$	B3	0.9245	6.8510	29.896	12.8425
$y = 2454.1x - 1584.4$	B3/B2	0.9249	0.5473	0.7000	0.0349
$y = 1714.7 \ln(x) + 1171$	B3/B4	0.9161	2.3885	9.3736	2.1329
$y = 1905.3 \ln(x) + 821.01$	B3/B2	0.9159	3.7496	12.1181	4.5714

Hindawi
Journal of Sensors
Volume 2020, Article ID 8858408, 21 pages
<https://doi.org/10.1155/2020/8858408>



Research Article

Modelling Reservoir Chlorophyll-*a*, TSS, and Turbidity Using Sentinel-2A MSI and Landsat-8 OLI Satellite Sensors with Empirical Multivariate Regression

<https://doi.org/10.1155/2020/8858408>

Regresyon Analizi - Su Kalitesi - Örnek Çalışmalar

Table 3. Predicting WQ parameters using satellite imagery: R^2 and coefficient analysis.

Sl. no.	Parameter	R^2	Model
1.	Temp.	0.82	$24.8 - 1.165\left(\frac{B1}{B10}\right) + 0.3\left(\frac{B2}{B3}\right)$
2.	DO	0.79	$10.8 - 1.114\left(\frac{B2}{B10}\right) + 0.37(B10)$
3.	pH	0.76	$8.47 - 0.856\left(\frac{B10}{B4}\right) + 0.89\left(\frac{B3}{B2}\right)$
4.	EC	0.69	$295.89 - 0.28\left(\frac{B1}{B10}\right) + 1.68\left(\frac{B3}{B1}\right)$
5.	BOD	0.73	$2.81 - 0.05\left(\frac{B2}{B10}\right) + 0.3(B1)$
6.	TC	0.70	$3029.8 - 1.89\left(\frac{B2}{B1}\right) + 0.3\left(\frac{B10}{B3}\right)$

J. Earth Syst. Sci. (2025)134 69
<https://doi.org/10.1007/s12040-025-02535-z>

© Indian Academy

Geospatial assessment of water quality in the Ganga River: Leveraging Landsat-8 and GIS

ABHISHEK KUMAR TRIPATHI*, SUDHIR KUMAR and MAHESH KUMAR JAT




Figure 2. (a, b) Physio-chemical WQ data derived from satellite imagery – 2019.

<https://doi.org/10.1007/s12040-025-02535-z>


Regresyon Analizi - Su Kalitesi - Örnek Çalışmalar

EXHIBIT 4 | Parameters and equations of the regression analysis.

Parameters and equations	R^2
$\text{Ln (pH)} = 0.665 + 0.00066 \text{ B2} + 0.00129 \text{ B4}$	0.09
$\text{Ln (Turbidity)} = -11.64 + 0.01739 \text{ B4} + 0.000571 \text{ B5}$	0.76
$\text{Ln (TDS)} = 2.990 + 0.001494 \text{ B5}$	0.67

EXHIBIT 5 | Comparison of output from MRN and ANN models.

Water quality parameter	MRM		ANN	
	MAPE	RMSE	MAPE	RMSE
Turbidity	26.43	3.10	15.04	1.68
TDS	6.70	14.73	5.60	12.34



Environmental Quality Management

WILEY

RESEARCH ARTICLE

GIS-Based Integrated Remote Sensing and Machine Learning Framework for Spatiotemporal Water Quality Assessment of Deepor Beel Wetland

Rajib Kumar Talukdar¹ | Arnob Bormudoi¹ | Ananya Kalita¹  | Ankur Pan Saikia² 

<https://doi.org/10.1002/tqem.70325>

Su Kalitesi Uygulamaları

Uygulama	Uydu gözlemi	Çevresel çıkarım
Endüstriyel deşarj	Suyun spektral özelliklerindeki değişim	Deşarjın etkilediği alanın araştırılması
Petrol sızıntısı	SAR geri saçılımındaki anomali	Olası petrol filminin belirlenmesi
Termal deşarj	Yüzey sıcaklığındaki değişim	Isınan suyun yayılımının izlenmesi
İstilacı türler	Yüzey örtüsü ve spektral özellikler	Türün olası dağılımının haritalanması

Endüstriyel Deşarjların İzlenmesi



Figure 2. Supervised dataset. The first row represents samples with drainage and the second row represents samples without drainage. A red box has been added to visually highlight the location of the outfall.

Petrol Sızıntılarını İzlenmesi

- Synthetic Aperture Radar (SAR) görüntülerinde petrol filmi, deniz yüzeyindeki küçük dalgalanmaları sönümlediği için **düşük geri saçılım (backscatter)** üretir; bu nedenle petrol sızıntısı çevresindeki denizden daha koyu alan olarak görünür. Ancak düşük rüzgâr bölgeleri, biyojenik filmler ve iç dalgalar da benzer “koyu leke” oluşturabildiği için bunlar **look-alike** olarak adlandırılır ve dikkatle ayrıştırılmalıdır.
- SAR Buluttan etkilenmez, gece de çalışır.
- Optik verileri ise doğrulama ve look-alike ayrıştırma amaçlı kullanılır.

Petrol Sızıntılarını İzlenmesi




Fig. 4 The results of two implemented methods compared to field data. Red and green patches were extracted from Sentinel-1 data and Sentinel-2 data, respectively. Orange patches represent the same results of methods

<https://doi.org/10.1007/s12524-021-01399-2>

Petrol Sızıntılarını İzlenmesi

scientific reports

OPEN **Ten years of oil pollution detection in the Eastern Mediterranean shipping lanes opposite the Egyptian coast using remote sensing techniques**

Salma M. Baghdady^{1✉} & Ali A. Abdelsalam²

 Check for updates




Figure 16. Detected ships illegally discharging oil and creating large oil spills, captured by SAR imagery.

<https://doi.org/10.1038/s41598-024-67983-x>

Termal Deşarjların İzlenmesi

Deşarj noktası çevresinde **deniz yüzey sıcaklığı (SST)** haritası üreterek sıcaklık artışı, termal plume alanı ve yayılım yönü belirlenir.



Article

Long-Term Changes and Factors That Influence Changes in Thermal Discharge from Nuclear Power Plants in Daya Bay, China

Zhihua Zhang ^{1,2}, Difeng Wang ^{2,3,*}, Yinhe Cheng ¹ and Fang Gong ^{2,3}





Figure 5. Seasonal changes (spring, summer, autumn, winter) in sea surface temperature (°C) contours for the period 1993–2020.

<https://doi.org/10.3390/rs14030763>

İstilacı Türlerin İzlenmesi



Article Genus-Level Mapping of Invasive Floating Aquatic Vegetation Using Sentinel-2 Satellite Remote Sensing

Christiana Ade ^{1,*}, Shruti Khanna ², Mui Lay ³, Susan L. Ustin ³  and Erin L. Hestir ¹ 

Figure 1. (A) Field photos of vegetation classes and list of species in each vegetation community type. (B) Mean spectral signatures for 2019 Sentinel-2 training data; shading represents 95% confidence interval. (C) Mean spectral signatures for 2019 AIS training data; shading represents 95% confidence interval. Data come from the HyMap sensor described in Section 2.3. See [32] for more in-depth descriptions of targeted invasive aquatic vegetation.

İstilacı Türlerin İzlenmesi



Article

Genus-Level Mapping of Invasive Floating Aquatic Vegetation Using Sentinel-2 Satellite Remote Sensing

Christiana Ade ^{1,*}, Shruti Khanna ², Mui Lay ³, Susan L. Ustin ³ and Erin L. Hestir ¹

<https://doi.org/10.3390/rs14133013>




Figure 4. (a) Ward Cut and (b) Rhode Island comparison between 2019 Sentinel-2 and imaging spectrometer maps. The comparison shows good agreement at the FAV genus level between locations of larger water primrose (yellow) and water hyacinth patches (purple).