

Sentinel-2 görüntüleri kullanılarak su yüzey alanlarının belirlenmesinde sınıflandırıcıların performanslarının incelenmesi

Investigation of the performance of classifiers in the extraction of water body areas using Sentinel-2 images

Mehmet Akif GÜNEN^{1*,a}

¹ Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, 29100, Gümüşhane

• Geliş tarihi / Received: 07.09.2021

• Düzeltilerek geliş tarihi / Received in revised form: 30.11.2021

• Kabul tarihi / Accepted: 06.12.2021

Öz

Nehirler, akarsular, göller ve göletler gibi su yapılarının haritalanması, su kaynaklarının gözlenmesi, zaman içerisinde değişiminin belirlenmesi ve yönetilmesi açısından oldukça önemlidir. Su yüzey alanlarının tespit edilmesi birçok faktörden etkilenen karmaşık bir süreçtir. Su ve su olmayan alanların belirlenmesi problemi için çeşitli çok kanallı bantlı uydu görüntüleri ve sınıflandırma tabanlı yaklaşımlar kullanılmaktadır. Bu çalışmada, sınıflandırma algoritmalarının etkinliğinin araştırılmasında indeks tabanlı yöntemlerden daha başarılı sonuç üreten parametrik olmayan (Destek Vektör Makinalar, k-En Yakın Komşuluk ve Karar Ağaçları), olasılıksal (Saklı Markov Model) ve derin öğrenme (Oto-Kodlayıcı) tabanlı danişmalı sınıflandırma yöntemleri kullanılmıştır. Çok bantlı ve yüksek mekansal çözünürlüklü uydu görüntüleri yüksek maliyetli olduğundan sınıflandırma için Sentinel-2 uydu görüntüsüne ait sadece kırmızı, yeşil ve mavi bantlar kullanılarak Arıklar ve Denizli Göletlerine ait su yüzey alanları belirlenmiştir. Deneysel sonuçlar doğruluk, özgüllük, kesinlik, duyarlılık, f-skor gibi karışıklık matrisinden elde edilen metrikler ve görüntü kalite belirlemede kullanılan ortalama karesel hata, yapısal benzerlik indeksi, pik sinyal-gürültü oranı ve Kohen'in Kappa metriği gibi istatistiksel araçları kullanılarak karşılaştırılmıştır. Elde edilen nicel ve nitel deneysel sonuçlarda derin öğrenme tabanlı oto-kodlayıcı istatistiksel olarak en başarılı yöntem olurken, zamansal karşılaştırma açısından karar ağaçları yönteminin daha hızlı çalıştığı belirlenmiştir.

Anahtar kelimeler: Görüntü sınıflandırma, Sentinel-2, Sınıflandırma, Su yüzey alanı belirleme

Abstract

The mapping of water body areas such as rivers, streams, lakes and ponds is very important in terms of monitoring water resources, determining, and managing their change over time. Extracting water body areas is a complicated process that is influenced by a variety of factors. For the problem of identifying water and non-water areas, various multi spectral band satellite imagery and classification-based approaches are used. In this study, non-parametric (Support Vector Machines, k-Nearest Neighborhood and Decision Trees), probabilistic (Hidden Markov Model) and deep learning (Auto-Encoder) based supervised classification, which produce more successful results than index-based methods, were used to investigate the effectiveness of classification algorithms. Since multispectral high spatial resolution satellite images are costly, the water surface areas of Arıklar and Denizli ponds were determined by using only the red, green and blue bands of the Sentinel-2 satellite image for classification. Experimental results were compared using metrics obtained from the confusion matrix such as accuracy, specificity, precision, sensitivity, f-Score, and statistical tools such as mean square error, structural similarity index, peak signal-to-noise ratio, and Kohen's Kappa metric used in image quality determination. In the quantitative and qualitative experimental results obtained, while the deep learning-based auto-encoder was the most successful method statistically, it was determined that the decision trees method worked faster in terms of time comparison.

Keywords: Image classification, Sentinel-2, Classification, Water body extraction

*a Mehmet Akif GÜNEN; akif@gumushane.edu.tr, Tel: 0(456) 233 1000, orcid.org/ 0000-0001-5164-375X

1. Giriş

1. Introduction

Tüm yaşamın temelini hiç kuşkusuz su oluşturmaktadır. Bio-çeşitliliğin korunması, ekonomik gelişmelerin ilerlemesine ve ekolojik dengenin korunmasına katkı sağladığından dolayı su kaynakları hassas ve doğru bir şekilde yönetilmelidir. Bölgesel ve küresel iklimi, halk sağlığını ve ortak yaşam alanlarını önemli ölçüde etkileyen su yapısı, kentsel ve kırsal yaşamın önemli bileşenidir. Sürdürülebilir su kaynaklarının yönetimi için su kaynaklarının sürekli gözlenmesi ve analiz edilmesi gereklidir. (Özçalık vd., 2020; Pan vd., 2020; Tercan & Atasever, 2021). Dünya yüzey alanının yaklaşık %1,1'ini akarsular, göller, göletler ve bataklıklar gibi su yapıları oluşturmaktadır. Hızlı kentleşmeye bağlı olarak artan su ihtiyacı ve buna bağlı olarak oluşan kentsel atıklar, kentsel yüzey su kütlelerinin giderek daha fazla hasar görmesine ve azalmasına neden olmaktadır (Allen & Pavelsky, 2018).

Su yüzey alanlarının belirlenmesi ile ilgili literatürde yoğun çalışmalar gerçekleştirilmektedir. Hem optik (Herndon vd., 2020; W. Jiang vd., 2021; Liu vd., 2016; Xiaohong Yang vd., 2020; Xiucheng Yang vd., 2018) hem de mikrodalga uzaktan algılama yöntemleri (Aswatha vd., 2020; Liao & Wen, 2020; Zhang vd., 2020) yüzey su yüzey alanlarını araştırmak için yaygın olarak kullanılmaktadır. Ancak her iki yöntemin de bazı avantajları ve sınırlamaları vardır. Mikrodalga uzaktan algılama bulutlarda, atmosferik etkilerden ve güneş ışığından büyük oranda etkilenmediğinden veri toplama süreci daha etkindir, ancak genellikle kaba uzamsal çözünürlüklere sahiptir ve zamansal çözünürlüğü de düşüktür. Optik uzaktan algılaması, yalnızca açık gökyüzü ve gün ışığı koşullarında veri toplama yeteneğine sahiptir, özellikle ticari uydulara monte edilen yüksek teknoloji sensörler sayesinde yüksek mekânsal ve zamansal çözünürlüğe sahip görüntüler yakalayabilmektedir (Orhan, 2021; Orhan vd., 2021). Ancak ticari uydu görüntülerinin yüksek fiyatları nedeniyle su yüzey alanlarının belirlenmesi için genellikle orta-düşük çözünürlüklü uydu görüntüleri kullanılmaktadır. Yüzey su yüzey alanlarının haritalanmasında göller (Torun & Gündüz, 2020), nehirler (H. Jiang vd., 2014), kıyı şeritleri (Li vd., 2016) ve kırsal alanlardaki su yüzey alanlarının (Song vd., 2020) yüksek uzamsal çözünürlüğe sahip uzaktan algılama görüntüleri kullanılarak çıkartılmaktadır.

Uzaktan algılama görüntüleri kullanılarak su yüzey alanlarının haritalanmasıyla su ve su olmayan

pikselleri belirlemek için ilgili araştırmalarda çeşitli su yüzey alanları çıkartma indeksleri, denetimsiz veya denetimli görüntü sınıflandırma algoritmaları kullanılmaktadır. İlgili yöntemlerin başarılarının belirlenmesi için yer gerçeklik verisi kullanılmaktadır. Su kütlesi çıkartma indeksleri genellikle çok kanallı ve yüksek mekânsal çözünürlüklü uydu görüntülerine ihtiyaç duyar ve su alanlarındaki özel bölgelerin çıkartılmasında kullanılır. İndeks tabanlı yöntemlerde ihtiyaç duyulan bantların spektral aralığındaki küçük bir değişiklik, indeks tabanlı su yüzey alanlarının çıkartma başarımlarında ciddi değişikliklere yol açmaktadır (Wang vd., 2018; Zhou vd., 2017). Sınıflandırıcı tabanlı yöntemler, eşik değeri gerektiren indeks tabanlı yöntemlerden daha iyi su yüzey alanı belirleme performansı sağlar çünkü bu yöntemlerde uygulama alanına göre değişiklik gösterebilen eşik değeri ayarlaması gerekmez (Ko vd., 2015). Bu çalışmada olduğu gibi, sınıflandırma yöntemleri, indeks tabanlı yöntemlere göre daha az sayıda görüntü bandı kullanarak su yüzey alanlarının belirlenmesinde kullanılarak daha tutarlı sonuçlar elde edilmesinde kullanılmaktadır. Denetimli sınıflandırma yöntemleri, denetimsiz yöntemlere göre daha doğru ve güvenilir çıktılar sunar, ancak yüksek çözünürlüklü veriler için kullanıldığında sonuçlar değişebilir. Denetimli sınıflandırma için sınıflandırma için görüntünün spektral özelliklerine göre pikselleri sınıflandıran piksel tabanlı yaklaşım veya homojen objeler oluşturmak için spektral, dokusal, geometrik ve istatistiksel özelliklerin kullanıldığı obje tabanlı sınıflandırma yöntemleri kullanılmaktadır. Objeye tabanlı yöntemler uzmanlık ve tecrübe isteyen yaklaşımlar sunmaktadır ve özellikleri oluşturmak için kullanılan parametrelerin ayarlanması oldukça zordur (Huang vd., 2015; Weih ve Riggan, 2010).

Bu çalışmada, su yüzey alanlarının belirlenmesinde Saklı Markov Model (SMM), Destek Vektör Makinaları (DVM), k-En Yakın Komşuluk (k-NN), Karar Ağaçları (KA) ve Oto-Kodlayıcı (OK) sınıflandırma yöntemleri kullanılmıştır. SMM ve OK yöntemlerinin su yüzey alanı araştırmalarında kullanıldığı çalışma sayısı kısıtlıdır. Ayrıca, literatür araştırmasında, Sentinel-2 uydusunun sadece kırmızı, yeşil ve mavi (KYM) bantları kullanılarak su yüzey alanlarının denetimli sınıflandırma yöntemleri ile belirlenerek ayrıntılı performans karşılaştırılmasının gerçekleştirildiği çalışma bildiğimiz kadarıyla yoktur. Yalnızca KYM bantlarının kullanılmasının en büyük nedeni, yüksek çözünürlüklü ve çok bantlı uydu görüntüleri yüksek maliyetlidir. Veri boyutunun artmasına bağlı olarak sınıflandırıcıların hesaplama yükleri de artmaktadır. Ayrıca, KYM

bantlarının mekânsal çözünürlüğü genellikle diğer bantlara göre yüksektir. Farklı stratejilere ve yapısal özelliklere (parametrik olmayan, olasılıksal, derin öğrenme vb.) sahip sınıflandırıcıların su yüzey alanı belirlemede performanslarının karşılaştırılması için Marmara bölgesinde bulunan Arıklar ve Denizli Göletleri kullanılmıştır. Performans karşılaştırması için Doğruluk, Özgüllük, Kesinlik, Duyarlılık, F-Skor, ortalama karesel hata (OKH), yapısal benzerlik indeksi (SSIM), pik sinyal-gürültü oranı (PSNR), KAPPA gibi başarı metriklerinin yanı sıra yöntemler eğitim süreleri açısından da karşılaştırılmışlardır.

2. Çalışma alanı

2. Study area

Avrupa Uzay Ajansı tarafından fırlatılan Sentinel-2'nin KYM bantları Landsat-8'e göre daha yüksek mekânsal çözünürlüğe sahiptir. Sentinel-2 güneş eşzamanlı yörüngede çalışan iki takımyıldızı uydudan oluşur. Yörünge yüksekliği 786 km, eğimi 98.5°, tekrar ziyaret süresi 5 gün ve tasarım ömrü 7 yıldır. Spektral aralığı 0.4 µm ile 2.4 µm arasında değişmekte ve mekânsal çözünürlükleri 10 m, 20 m ve 60 m olan 13 banttan oluşmaktadır (Drusch vd., 2012; W. Jiang vd., 2021). Bu çalışmada kullanılan Sentinel-2 görüntü bantlarına teknik özellikleri Tablo 1'de verilmiştir.


Tablo 1. Sentinel-2 uydu görüntüsüne ait bant bilgileri.

Table 1. Band information of Sentinel-2 satellite image.

Bantlar	Dalga boyu aralığı/µm	Mekânsal Çözünürlük (m)
Mavi	0.4575–0.5225	10
Yeşil	0.5425–0.5775	10
Kırmızı	0.65–0.68	10

Ramsar sözleşmesine göre sulak alanlar deniz/kıyı, iç ve insan yapımı olmak üzere üç sınıfa ayrılmaktadır. Sulak alanlar yapay ve doğal göletler, göller, sulanan tarım arazileri ve çakıl ocaklarını içerir (Ramsar, 2016). Şekil 1'de bu çalışmada kullanılan Arıklar ve Denizli Göletlerine ait Sentinel-2 uydu görüntüsü, görüntü yakalama sensörleri maruz kaldığı ışığa bağlı olarak, bir görüntünün kontrastı zayıf veya parlak olabildiğinden ilgili görüntülerin görsel açıdan iyileştirilmiş halleri ve karşılık gelen yer gerçeklik

görüntüleri verilmiştir. Test alanları içme suyu, balıkçılık ve sulama amacıyla kullanılmaktadır. Arıklar Göleti Kandıra/Kocaeli'nde yer almaktadır ve özellikle tarımsal sulama için oldukça önemlidir. Gebze'de bulunan Denizli Göleti ise tarımsal faaliyetlerin yanı sıra sanayi alanındaki işletmelerin su ihtiyacının karşılanmasında kullanılmaktadır. Bu göletlerin bölge halkına ekonomik ve turistik katkıları olduğu için korunması gerekmektedir.



Şekil 1. Arıklar ve Denizli Göletlerinin sırasıyla Sentinel-2, görüntü iyileştirilmiş ve yer gerçeklik verileri.


Figure 1. Sentinel-2, image enhanced and ground truth data of Arıklar and Denizli Ponds, respectively.

3. Materyal ve yöntem

3. Material and method

Bu çalışmada kullanılan test alanlarına ait Sentinel-2 görüntüleri Avrupa Uzay Ajansı ait <https://scihub.copernicus.eu/dhus/#/home> internet sitesinden sağlanmıştır. Gerçekleştirilen deneysel uygulamaya ait iş akış şeması Şekil 2'de verilmiştir. Uydu görüntüleri elde edildikten sonra ön-işlem aşamasında ENVI yazılımı kullanılarak

1024x1024 boyutlarında ilgili su alanlarını kapsayacak şekilde kesilmiş, daha sonra yer gerçeklik verilerinin elde edilmesi için el ile su yüzey alan sınırları belirlenmiştir. Sınıflandırma işlemi için veriler %30 test ve %70 eğitim verisi olacak şekilde rastsal olarak bölünmüştür. İlgili deneysel çalışmalar i5, 8 GB RAM, 2,5 Ghz işlemci ve Windows 7 işletim sistemine sahip dizüstü bilgisayarda Matlab 2021a yazılımı kullanılarak gerçekleştirilmiştir.



Şekil 2. Önerilen yöntemle ait iş akış şeması

Figure 2. Flow chart of the proposed method

3.1. Sınıflandırma yöntemleri

3.1. Classification methods

Bu çalışmada su yüzey alanlarının belirlenmesi için denetimli sınıflandırma yöntemlerinden SMM, DVM, k-NN, KA ve OK sınıflandırma yöntemleri kullanılmıştır. Her yöntemin farklı avantajları ve dezavantajları vardır. Sınıflandırma algoritmalarının sahip oldukları parametreleri belirlemek için eğitim veri seti kullanılarak çapraz doğrulama stratejisi uygulanmıştır. Bir durumdan diğer duruma geçişin tanımlandığı Markov zincirler karmaşık problemlerin çözümünde kullanılan olasılık tabanlı bir yaklaşımdır. SMM'de doğrudan durum gözlemleri yerine gözlemler her durumda meydana gelen çıktılardan oluşturularak gözlem dizileri oluşturulur. SMM'de bu diziler bilinmemekte ve saklı kalmaktadır. İlgili gözlemler zamandan bağımsızdır. SMM'de viterbi algoritması genellikle her bir gözlemin durumunu ayrı ayrı bulan global kod çözme işlemini gerçekleştirmek için kullanılır. Viterbi algoritmasının kullanılması, gözlemlenen veri dizisine karşılık gelen en olası gizli durum dizisini bulmayı amaçlar. Ayrıca Viterbi algoritması, bir gözlem dizisinin en iyi tek durum dizisini bulmak için kullanılabilir (Aurdal vd., 2005; Osman & Selçuk, 2018).

DVM, çoğunlukla regresyon ve sınıflandırma analizi için kullanılan denetimli bir makine öğrenme algoritmasıdır. DVM ilk olarak ikili sınıflandırma için geliştirilmiştir. Bir DVM, destek

vektörleri olarak adlandırılan karşı sınıftaki en yakın eğitim verileri arasındaki en büyük mesafeye sahip bir optimal hiper düzlem oluşturur. Fonksiyonel marjin olarak isimlendirilen bu mesafe sınıflandırmanın genelleme hatasıyla ters orantılıdır. DVM'de çekirdek fonksiyonu ile doğrusal olmayan sınıflandırıcılar oluşturularak da maksimum marjin hiper düzlemi elde edilmektedir. Bu çalışmada radyal tabanlı çekirdek kullanılmıştır (Kesikoglu vd., 2019; Tercan & Atasever, 2021; Vapnik, 2013).

Kontrollü sınıflandırma için sıklıkla kullanılan yöntemlerin başında gelen k-NN yöntemi Cover ve Hart tarafından 1967 yılında geliştirilmiştir (Cover & Hart, 1967). Komşuluk sorgusu gerçekleştirdiği için büyük veri setlerinde oldukça hantal çalışmaktadır. Yöntemde sınıflandırılacak piksele en yakın eğitim verisi noktası aranması esastır. Yöntemin isminde geçen k aranacak en yakın komşuluk sayısını ifade etmektedir. Oldukça kolay ve gürbüz olan yöntemde sorgu çeşitli mesafe ölçülerine göre gerçekleştirilmektedir. Eğitim veri setini öğrenmek yerine daha çok ezberleme ile sınıflandırma gerçekleştirilir. Bu sebeple sınıflandırma gerçekleştirirken bütün veri setinde komşuluk araması gerçekleştirilir. Bu çalışmada komşuluk sayısı 10 ve mesafe ölçütü olarak Öklid uzaklığı kullanılmıştır.

Son yıllarda popülerliğini artıran diğer denetimli sınıflandırıcı KA'dır. KA sınıflandırma için katmanlı bir yapı kullanılmaktadır. Bir KA temel olarak dal, yaprak ve düğüm ismi verilen üç

bileşenden oluşmaktadır. Uydu görüntüsü için her bant düğüm ile temsil edilmektedir. Eğitim verisindeki bant özelliklerine ait birtakım sorular sorularak kökten düğüm ve yapraklar oluşturulur. Böylece karar kuralları oluşturulur. Kökten yaprağa doğru yalnızca bir karar kuralı vardır. KA'da ağaç dallanmalarının hangi kıyasa göre gerçekleştirildiğinin belirlenmesi önemlidir (Kavzoğlu & Çölkesen, 2010; Pal & Mather, 2003). Bu çalışmada Gini indeksi kullanılmıştır ve maksimum bölünme sayısı 20 olarak belirlenmiştir.

Arazi kullanım/örtüsü uygulamalarında son yıllarda oldukça yoğun olarak kullanılan derin öğrenme yapılarından birisi OK'lardır. OK'lar temel olarak öz öğrenme prensibine dayanır, kodlayıcı ve kod çözücü olmak üzere iki yapıdan oluşmaktadır. Kodlayıcı yapı veriyi transfer fonksiyonu yardımıyla farklı bir boyuta dönüştürür. Kod çözücü yapı ise transfer sonucunda oluşan yapıyı orijinal veri boyutuna tekrar transfer eder. Her iki yapı ardışık olarak çalışmaktadır ve çok sayıda gizli katmanlardan oluşmaktadır. Kod çözücünden sonra çıktılar bir sınıfa ait olma olasılığının hesaplandığı, sigmoid fonksiyona benzer özellik gösteren ve birden fazla sınıflandırma işleminin gerçekleştirilebildiği çıktı katmanı olan Softmax katmanına bağlanarak sınıflandırma işlemi gerçekleştirilir (Günen vd., 2020; Tercan & Atasever, 2021). Bu çalışmada kullanılan OK'un kodlayıcı ve kod çözücü yapılarında sırasıyla lineer ve logaritmik sigmoid transfer fonksiyonları, 20 saklı katman ve 1000 epok kullanılmıştır.

3.2. İstatistiksel değerlendirme

3.2. Statistical evaluation

Eğitim verileri kullanılarak elde edilen sınıflandırıcılar ile sınıflandırılan test verilerinin sınıflandırılma başarısı performans analizlerinin temelini oluşturur. Sınıflandırma analizi için Sentinel-2'nin atmosferik olarak düzeltilmiş spektral bantlarının yüzey yansımaları kullanılmıştır. Yer gerçeklik verisinin mevcut olduğu uygulamalarda ilgili performans metriklerinin oluşturulması için karışıklık matrisi oluşturulur. Karışıklık matrisinin incelenmesi, her sınıf için ihmal ve görev hatalarını ortaya çıkarır. Temel doğruluk verileri mevcutsa, sınıflandırma yöntemlerini istatistiksel olarak analiz etmek için karışıklık matrisi elemanları olarak kullanılabilir. Karışıklık matrisi Doğru Pozitif (DF), Yanlış Negatif (YN), Yanlış Pozitif (YP) ve Doğru Negatif (DN) parametrelerinden oluşmaktadır. Karışıklık matrisi parametrelerinden üretilen doğruluk metriği dengesiz veri setlerinde anlamlı sonuç sağlamamaktadır. Bundan dolayı doğruluk metriğinin yanından özgüllük, kesinlik, duyarlılık ve f-skor gibi karışıklık matrisinden elde edilebilen metriklerde kullanılmaktadır. Bu çalışmada, görüntü yer gerçeklik görüntüsü ile sınıflandırıcı tarafından tahmin edilen görüntü arasındaki ortalama hatayı hesaplamada ortalama karesel hata (OKH), iki görüntü arasındaki benzerliği değerlendirmek için yapısal benzerlik indeksi (SSIM) ve pik sinyal-gürültü oranı (PSNR), iki görüntünün uyumluluğunun belirlenmesi için ise Cohen'in Kappa istatistikleri hesaplanmıştır. İlgili metriklerine ait analitik formüller Tablo 2'de verilmiştir.

Tablo 2. İstatistiksel değerlendirme için kullanılan metrikler (Atasever vd., 2018; Günen, 2021; Tercan & Atasever, 2021)

Table 2. Metrics used for statistical evaluation (Atasever et al., 2018; Günen, 2021; Tercan and Atasever, 2021)

Metrik	Analitik formülü	Metrik	Analitik formülü
Doğruluk	$\frac{DF + DN}{DF + YN + YP + DN}$	F-skor	$2 \times \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}}$
Özgüllük	$\frac{DN}{DN + YP}$	OKH	$\frac{1}{m \times n} \sum_{i=1}^N (A_i - B_i)^2$
Kesinlik=	$\frac{DF}{DF + YP}$	SSIM	$\left(\frac{2\mu_A\mu_B + C_1}{2\mu_A^2 + \mu_B^2 + C_1} \right) \left(\frac{2\sigma_A\sigma_B + C_2}{\sigma_A^2 + \sigma_B^2 + C_2} \right) \left(\frac{\sigma_{AB} + C_3}{\sigma_A\sigma_B + C_3} \right)$
Duyarlılık	$\frac{DF}{DF + YN}$	PSNR	$10 \log_{10} \left(\frac{P_{\max}^2}{\text{OKH}} \right)$

*A sınıflandırma sonucunda tahmin edilen görüntüyü, B yer gerçeklik görüntüsünü, $m \times n$ görüntü boyutlarını, N toplam bant sayısını ve P_{\max} maksimum dinamik aralığı ifade etmektedir.

4. Bulgular ve tartışma

4. Findings and discussion

Su yüzeyi alanı belirlemek için indeks tabanlı ve sınıflandırma tabanlı çok sayıda yöntem önerilmiştir. Literatürde sınıflandırma tabanlı yaklaşımların daha başarılı sonuç ürettiği ve daha az kullanıcı uzmanlığı gerektirdiği gösterilmiştir (Herndon vd., 2020; Pan vd., 2020; Tercan & Atasever, 2021; Xiaohong Yang vd., 2020). Modern denetimli sınıflandırma yöntemlerinin karşılaştırmalı olarak su yüzey alanı belirlenmesi gerçekleştirilen çalışma sayısı oldukça kısıtlıdır. Sentinel-2, yüksek uzaysal çözünürlüğe ve kısa bir geri dönüş periyoduna sahiptir ve büyük ölçekli yüzey suyu haritalamasında uygulama potansiyeline sahiptir. Gerçekleştirilen deneysel çalışma her ne kadar Sentinel-2 uydusu görüntüsünde test edilmiş olsa da yalnızca KYM bantları

kullanıldığı için görece daha az maliyetle elde edilen görüntülere (örn. ortofoto) de uygulanabilir. Çalışma alanı için kullanılan test alanlarına ait görüntüler farklı spektral imza desenine sahip farklı türlerde arazi örtüsü özelliği içerirler. Sınıflandırma sonucunda görüntüler su ve su olmayan olmak üzere iki sınıfa ayrılmıştır. Test alanlarındaki su yüzeylerinin belirlenmesinde Sentinel-2 uydusuna ait KYM bantları kullanılmıştır. Ön işlemden sonra sınıflandırma için kullanılan eğitim verisi ve sınıflandırıcı performansının belirlendiği test verisi, homojen alanlardan rastgele toplanmıştır. Sınıflandırma işleminden sonra elde edilen istatistiksel sonuçlar Arıklar göleti için Tablo 3’de, Denizli göleti için Tablo 4’de sunulmuştur. İlgili tablolarda koyu renk ile işaretlenenler en başarılı sonucu sağlayanlar yöntemlerdir.

Tablo 3. Arıklar Gölet’ine ait istatistiksel değerlendirme sonuçları

Table 3. Statistical evaluation results of Arıklar Pond

Metrik	SMM	DVM	k-NN	KA	OK
Doğruluk	0.9958	0.9981	0.9979	0.9973	0.9985
Özgüllük	1.0000	0.9998	0.9988	0.9994	0.9998
Kesinlik	0.9998	0.9998	0.9127	0.9490	0.9820
Duyarlılık	0.6840	0.8755	0.9348	0.8453	0.9079
F-Skor	0.8123	0.9249	0.9236	0.8942	0.9435
OKH	0.0042	0.0019	0.0021	0.0027	0.0014
SSIM	0.9883	0.9924	0.9860	0.9885	0.9936
PSNR	23.7341	27.2022	26.8414	25.7205	28.3705
KAPPA	0.8102	0.9239	0.9226	0.8928	0.9428

Tabloların yorumlanmasını ve anlaşılabilirliğini arttırmak için Arıklar Göleti için ilgili istatistiksel metrikler azalan başarıya göre sıralandığında;

Doğruluk: OK, DVM, k-NN, KA, SMM;

Özgüllük: SMM, OK, DVM, k-NN, KA; **Kesinlik:**

SMM, DVM, OK, KA, k-NN; **Duyarlılık:** k-NN,

OK, DVM, KA, SMM; **F-Skor:** OK, DVM, k-NN, KA, SMM; **OKH:** OK, DVM, k-NN, KA, SMM; **SSIM:** OK, DVM, KA, SMM, k-NN; **PSNR:** OK, DVM, k-NN, KA, **PSNR;** KAPPA: OK, DVM, k-NN, KA, SMM.

Tablo 4. Denizli Gölet’ine ait istatistiksel değerlendirme sonuçları

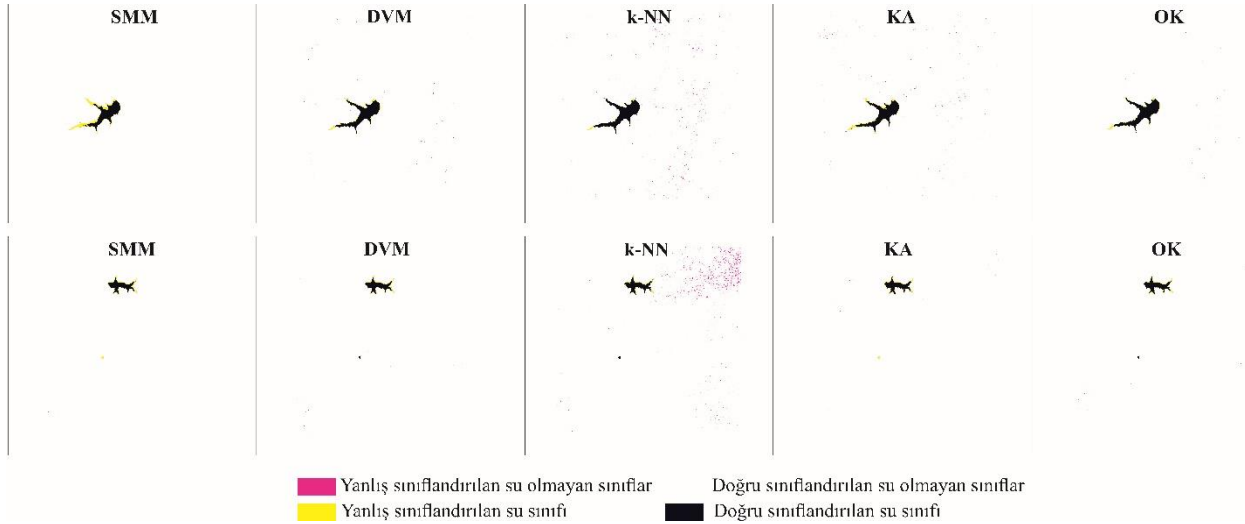
Table 4. Statistical evaluation results of Denizli Pond

Metrik	SMM	DVM	k-NN	KA	OK
Doğruluk	0.9987	0.9988	0.9955	0.9988	0.9990
Özgüllük	1.0000	0.9999	0.9963	0.9999	0.9999
Kesinlik	0.9979	0.9880	0.5800	0.9791	0.9849
Duyarlılık	0.7797	0.8106	0.8651	0.8124	0.8347
F-Skor	0.8754	0.8906	0.6944	0.8880	0.9037
OKH	0.0013	0.0012	0.0045	0.0012	0.0010
SSIM	0.9942	0.9958	0.9696	0.9956	0.9960
PSNR	28.8104	29.2788	23.4565	29.1543	29.7684
KAPPA	0.8748	0.8900	0.6923	0.8873	0.90313

Denizli Göleti için ilgili istatistiksel metriklere göre azalan başarıya göre sıralandığında;
Doğruluk: OK, DVM, KA, SMM, k-NN;
Özgüllük: SMM, OK, DVM, KA, k-NN; **Kesinlik:** SMM, DVM, OK, KA, k-NN; **Duyarlılık:** k-NN, OK, KA, DVM, SMM; **F-Skor:** OK, DVM, KA, SMM, k-NN; **OKH:** OK, DVM, KA, SMM, k-NN; **SSIM:** OK, DVM, KA, SMM, k-NN; **PSNR:** OK, DVM, KA, SMM, k-NN; **KAPPA:** OK, DVM, KA, SMM, k-NN.

Uzaktan algılama görüntüsünden su yüzey alanlarının tespit edilmesinde tüm yöntemlerin genel performansının yüksek olduğu görülmektedir. Test verilerinin doğruluk metriğinin oldukça yüksek olduğu ve sınıflandırma yöntemlerinin birbirlerine yakın değerler elde edilmesine karşın diğer metrikler açısından karşılaştırma yapıldığında yöntemler arasında farklılıklar olduğu gözlenmektedir. Test


doğruluğunun ilgili sınıflandırma yöntemlerinin performans karşılaştırmasında tek başına kullanılamayacağı da aşikârdır. Doğruluk metriği özellikle dengesiz veri setlerinde yanıltıcı sonuçlar sağlamaktadır. Genel olarak bakıldığında F-Skor ve görüntü kalite belirleme metriklerinin (SSIM, PSNR, KAPPA) daha yansız sonuç ürettiği söylenebilir. Test görüntülerindeki başarı değişimi en fazla OKH metriğinde meydana gelmiştir. Bunun en büyük nedeni de OKH'nın yer gerçeklik ve tahmin edilen görüntü pikselleri arasındaki mesafeyi doğrudan hesaplamasından kaynaklanmaktadır. Nicel karşılaştırmanın yanı sıra nitel karşılaştırmanın önemi de oldukça büyüktür. Sınıflandırma sonucunda yer gerçeklik verisine göre su ve su olmayan alanların farklı renklerle gösterildiği analiz sonuçları görsel olarak Şekil 3'te sunulmuştur. Görsel inceleme ile denetimli sınıflandırıcıların çıktılarının çoğunda su piksellerinin doğru atandığı görülmektedir.



Şekil 3. Arıklar ve Denizli Göletlerinin sınıflandırılmış haritaları
Figure 3. Classified maps of Arıklar and Denizli Ponds

Her iki test görüntüsüne ait Tablo 3 ve Tablo 4'ten elde edilen sıralanmış başarı ölçüleri ve Şekil 3 birlikte değerlendirildiğinde istatistiksel ve görsel olarak OK yönteminin en başarılı, k-NN'nin ise en başarısız yöntem olduğu görülmektedir. k-NN yöntemi her iki görüntü içinde en yüksek duyarlılık metriği üretmiş olsa da Şekil 3 incelendiğinde çok sayıda su olmayan piksel su sınıfına atandığı görülmektedir. Benzer şekilde SMM yöntemi her iki görüntüde de en yüksek özgüllük ve kesinlik metriği sağlamış olsa da çok sayıda pikseli su sınıfına atanması gerekirken su olmayan sınıfa


atanmıştır. DVM yöntemin görsel olarak da OK ile yakın sonuç üretmiştir. İlgili sınıflandırma yöntemlerinin karşılaştırılması için algoritma çalışma zamanlarının karşılaştırmasında başarı ölçütü olarak kabul edilmektedir. Bu kapsamda her yöntem merkezi limit teoremi en az 30 deneyin normal dağılım momentlerinin gürbüz hesaplanabilmesi açısından yeterli olduğu gösterdiği için her algoritma 30 kez koşturulmuştur. Yapılan deney sonucunda elde edilen zamansal karşılaştırma sonuçları Şekil 4'te kutu grafiklerle sunulmuştur.



Şekil 4. Zamansal karşılaştırmaya ait kutu grafikler
Figure 4. Box plots of time comparison

Zamansal karşılaştırma algoritmalarının koşuturulduğu yazılıma ve kullanılan bilgisayara bağlıdır. Algoritmaları grafik işlemci ünitesi kullanarak koşuturmak süreyi oldukça kısaltmaktadır. Şekil 4 incelendiği zaman OK ve DVM yöntemlerinin diğer yöntemlere göre oldukça yavaş, KA yönteminin ise oldukça hızlı olduğu görülmektedir. Ancak yine de bütün yöntemlerin hesaplama yükü maliyeti açısından uygulanabilir olduğu sonucuna varılabilir. Yapısal olarak derin öğrenme yöntemleri başlangıç değerlerini ayarlamak rastsal sayı üreticinin

başlangıç değerini ayarlamaya indirgenebilir. Böylece üretilecek ilk parametre değerleri farklı değerler halinde oluşturulmaya zorlanmış olur. Bu çalışmada en başarılı olan OK'nin tutarlı sonuçlar üretip üretmediğinin belirlenmesi için Mersenne Twister yakıştırma sayı üretici kullanılarak 30 kez koşuturulmuştur (Şekil 5). Doğruluk metriği test verisine ait olduğundan grafiğe eklenmemiştir. İlgili grafikte PSNR değeri görselleştirme için normalize edilmiştir. Şekil 5 incelendiğinde ilgili metriklerin aykırı değer üretmediği gözlenmiştir.



Şekil 5. İstatistiksel metrikler göre OK yöntemi için oluşturulan kutu grafikler
Figure 5. Box charts created for the OE method according to statistical metrics

Bu çalışmada sunulan yöntemin sınırlaması, nispeten düşük mekânsal çözünürlüktür. Bu nedenle, kentsel alanlardaki bazı dar nehirler ve küçük göller doğru şekilde çıkartılabilmektedir. Uzamsal çözünürlüğü arttırmak için çeşitli pan keskinleştirme yöntemleri olsa da pan keskinleştirme yöntemlerinin karmaşıklığı, büyük ölçekli yüzey suyu çıkarımında verimliliğini kısıtladığı ve pan keskinleştirme sonucunda meydana gelen spektral değişiklikler, su yüzey alanı çıkartımı performansını etkilemektedir (W. Jiang vd., 2021). Bu nedenle, Sentinel-2 için verimli ve güvenilir

görüntü pan keskinleştirme yöntemleri, büyük ölçeklerde su yüzey alanları çıkarmanın doğruluğunu iyileştirmek için araştırılmalıdır. Diğer bir kısıtlama ise sınıflandırma yöntemlerinin hiper parametrelerinin uygulama alanına özgü seçilme gerçeğinin göz ardı edilerek doğru ayarlanamamasıdır.

5.Sonuçlar

5. Conclusion

Küresel su döngüsünün önemli bir parçası olan yüzey su kütleleri, iklim sistemlerinde ve küresel

ekolojide yeri doldurulamaz bir öneme sahiptir. Kırsal alanlarda gerçekleştirilen düzensiz ve bilinçsiz sulama ve kentlerdeki nüfusun hızla artması ile birlikte, kentlerin su ihtiyacının karşılanmasında kullanılan su kütlelerinin giderek azalmasına neden olmaktadır. Bu çalışmada Marmara bölgesinde yer alan ve Ramsar sözleşmesine göre sulak olan sayılan Arıklar ve Denizli Göletlerinin Sentinel-2 uydu görüntülerinin sadece KYM bantları kullanılarak beş farklı danişmalı sınıflandırma yöntemi kullanılarak belirlenmiştir. KYM bantlarının kullanılması en büyük avantajı çok bantlı bantlara göre daha fazla ulaşılabilir ve nispeten daha yüksek mekansal çözünürlüğe sahiptir. Görsel incelemesi ile su ve su olmayan sınırları belirlemenin göreceli basitliği göz önüne alındığında, denetimli sınıflandırma, eğitim veri seti kullanılarak su pikseli sınıflandırma görevini yerine getirmek için iyi bir seçimdir. Bu amaçla farklı stratejilere sahip SMM, DVM, k-NN, KA ve OK sınıflandırma yöntemleri kullanılmıştır. Performans karşılaştırmasının gerçekleştirilmesi için karışıklık matrisinden ve görüntü kalite belirleme metriklerinden faydalanılarak üretilen sonuçlara göre OK yöntemi istatistiksel olarak en başarılı iken k-NN en başarısız yöntem olarak belirlenmiştir. Daha sonra ilgili sınıflandırma yöntemlerinin Arıklar ve Denizli Göletlerinin su yüzey alanlarının belirlenmesindeki çalışma sürelerine ait kutu grafikler çizdirilmiştir. KA en hızlı yöntem olurken OK en yavaş yöntem olduğu belirlenmiştir. Ancak yine de yöntemlerin etkili hesaplama sürelerine sahip oldukları söylenebilir. Su ve su olmayan alanların belirlenmesi için kullanılan veriler genel olarak dengesiz veri setleri oldukları için sınıflandırıcı performansları karşılaştırmasında karışıklık matrisinden üretilen metriklerin yanı sıra görüntü kalite belirleme metriklerinin de kullanılması gereklidir. Çünkü bu çalışmada görüntü kalite belirleme metriklerinin daha yansız sonuç ürettiği nicel ve nitel karşılaştırmalar sonucunda ulaşılmıştır. Derin öğrenme tabanlı bir yöntem olan OK'un problem çözümünde kullanılan başlangıç değerlerine hassasiyetlerinin belirlenmesi için gerçekleştirilen deneyde OK'un Arıklar Göletinde kesinlik ve duyarlılık metrikleri hariç gürbüz ve tutarlı sonuç ürettiği görülmüştür.

Su yüzey alanı belirleme uygulama kapsamı ile ilgili halen tartışılması gereken bazı hususlar bulunmaktadır. Su yüzeyini haritalamak için tek bir göl üzerinde farklı edinim tarihlerine sahip birden fazla Sentinel-2 görüntüsü kullanılırsa, çeşitli su endekslerinin ve görüntü sınıflandırma algoritmalarının performansları bu çalışmada

sunulan sonuçlardan farklı olabilir. Çünkü su seviyesi değişmesine bağlı olarak tortu su ve bitki örtüsü karışması, bitki örtüsünün daha belirgin hale gelmesi ve bulanıklığın artması gibi birtakım sorunlar ortaya çıkacaktır. Gelecek çalışmalarda önerilen yöntemin insansız hava araçları yardımıyla elde edilen görüntülerle üretilen ortofotolar kullanılarak su yüzey alanı belirlenmesinde etkinliğinin incelenmesi amaçlanmaktadır.

Yazar katkısı

Author contribution

Bu makaledeki metodoloji, kavramsallaştırma, veri toplama, görselleştirme, yazma ve inceleme işlemleri Mehmet Akif Günen tarafından yapılmıştır.

Etik beyanı

Declaration of ethical code

Bu çalışmada, Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi kapsamında uyulması gerekli tüm kurallara uyulduğunu, bahsi geçen yönergenin Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler başlığı altında belirtilen eylemlerden hiçbirinin gerçekleştirilmediğini taahhüt ederiz.

Çıkar çatışması beyanı

Conflicts of interest

Yazar herhangi bir çıkar çatışması olmadığını beyan eder.

Kaynaklar

References

- Allen, G. H., & Pavelsky, T. M. (2018). Global extent of rivers and streams. *Science*, 361(6402), 585-588. <https://doi.org/10.1126/science.aat0636>.
- Aswatha, S. M., Mukherjee, J., Biswas, P. K., & Aikat, S. (2020). Unsupervised classification of land cover using multi-modal data from multi-spectral and hybrid-polarimetric SAR imageries. *International Journal of Remote Sensing*, 41(14), 5277-5304. <https://doi.org/10.1080/01431161.2020.1731771>.
- Atasever, U. H., Günen, M. A., & Beşdok, E. (2018). A new unsupervised change detection approach based on PCA based blocking and GMM clustering for detecting flood damage. *Fresenius Environmental Bulletin*, 27, 1688-1694.
- Aurdal, L., Huseby, R. B., Eikvil, L., Solberg, R., Vikhamar, D., & Solberg, A. (2005). Use of

- hidden Markov models and phenology for multitemporal satellite image classification: Applications to mountain vegetation classification. *International workshop on the analysis of multi-temporal remote sensing images*, Biloxi, USA. <https://doi.org/10.1109/AMTRSI.2005.1469877>.
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27. <https://doi.org/10.1109/TIT.1967.1053964>.
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., & Martimort, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25-36. <https://doi.org/10.1016/j.rse.2011.11.026>.
- Günen, M. A. (2021). Performance comparison of deep learning and machine learning methods in determining wetland water areas using EuroSAT dataset. *Environmental Science Pollution Research*, 1-15. <https://doi.org/10.1007/s11356-021-17177-z>.
- Günen, M. A., Atasever, U. H., & Beşdok, E. (2020). Analyzing the contribution of training algorithms on deep neural networks for hyperspectral image classification. *Photogrammetric Engineering Remote Sensing*, 86(9), 581-588. <https://doi.org/10.14358/PERS.86.9.581>.
- Herndon, K., Muench, R., Cherrington, E., & Griffin, R. (2020). An assessment of surface water detection methods for water resource management in the Nigerien Sahel. *Sensors*, 20(2), 431. <https://doi.org/10.3390/s20020431>.
- Huang, X., Xie, C., Fang, X., & Zhang, L. (2015). Combining pixel-and object-based machine learning for identification of water-body types from urban high-resolution remote-sensing imagery. *IEEE Journal of Selected Topics in Applied Earth Observations Remote Sensing*, 8(5), 2097-2110. <https://doi.org/10.1109/JSTARS.2015.2420713>
- Jiang, H., Feng, M., Zhu, Y., Lu, N., Huang, J., & Xiao, T. (2014). An automated method for extracting rivers and lakes from Landsat imagery. *Remote Sensing*, 6(6), 5067-5089. <https://doi.org/10.3390/rs6065067>.
- Jiang, W., Ni, Y., Pang, Z., Li, X., Ju, H., He, G., & Qin, X. (2021). An effective water body extraction method with new water index for sentinel-2 imagery. *Water*, 13(12), 1647. <https://doi.org/10.3390/w13121647>.
- Kavzoğlu, T., & Çölkesen, İ. (2010). Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.
- Kesikoglu, M. H., Atasever, U. H., Dadaser Celik, F., & Ozkan, C. (2019). Performance of ANN, SVM and MLH techniques for land use/cover change detection at Sultan Marshes wetland, Turkey. *Water Science Technology*, 80(3), 466-477. <https://doi.org/10.2166/wst.2019.290>.
- Ko, B. C., Kim, H. H., & Nam, J. Y. (2015). Classification of potential water bodies using Landsat 8 OLI and a combination of two boosted random forest classifiers. *Sensors*, 15(6), 13763-13777. <https://doi.org/10.3390/s150613763>.
- Li, Y., Gong, X., Guo, Z., Xu, K., Hu, D., & Zhou, H. (2016). An index and approach for water extraction using Landsat-OLI data. *International Journal of Remote Sensing*, 37(16), 3611-3635. <https://doi.org/10.1080/01431161.2016.1201228>.
- Liao, H.-Y., & Wen, T.-H. (2020). Extracting urban water bodies from high-resolution radar images: Measuring the urban surface morphology to control for radar's double-bounce effect. *International Journal of Applied Earth Observation Geoinformation*, 85, 102003. <https://doi.org/10.1016/j.jag.2019.102003>.
- Liu, Z., Yao, Z., & Wang, R. (2016). Assessing methods of identifying open water bodies using Landsat 8 OLI imagery. *Environmental Earth Sciences*, 75(10), 873. <https://doi.org/10.1007/s12665-016-5686-2>.
- Orhan, O. (2021). Monitoring of land subsidence due to excessive groundwater extraction using small baseline subset technique in Konya, Turkey. *Environmental Monitoring Assessment*, 193(4), 1-17. <https://doi.org/10.1007/s10661-021-08962-x>.
- Orhan, O., Oliver-Cabrera, T., Wdowinski, S., Yalvac, S., & Yakar, M. (2021). Land subsidence and its relations with sinkhole activity in Karapınar region, Turkey: a multi-sensor InSAR time series study. *Sensors*, 21(3), 774. <https://doi.org/10.3390/s21030774>.
- Osman, A., & Selçuk, A. (2018). Saklı markov modeli kullanılarak istanbul'daki üniversite öğrencilerinin gsm operatör tercihlerini etkileyen faktörlerin analizi. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 33(4), 203-212. <https://doi.org/10.21605/cukurovaummfd.525235>.
- Özçalık, H. I., Torun, A. T., & Bilgilioğlu, S. S. (2020). Landsat uydu görüntüleri kullanılarak Mogan Gölü'nün su yüzeyi ve arazi örtü değişiminin

- belirlenmesi. *Türkiye Uzaktan Algılama Dergisi*, 2(2), 77-84.
- Pal, M., & Mather, P. M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*, 86(4), 554-565. [https://doi.org/10.1016/S0034-4257\(03\)00132-9](https://doi.org/10.1016/S0034-4257(03)00132-9).
- Pan, F., Xi, X., & Wang, C. (2020). A comparative study of water indices and image classification algorithms for mapping inland surface water bodies using landsat imagery. *Remote Sensing*, 12(10), 1611. <https://doi.org/10.3390/rs12101611>.
- Ramsar. (2016). *An introduction to the convention on wetlands*. Ramsar Convention Secretariat, Gland, Switzerland.
- Song, S., Liu, J., Liu, Y., Feng, G., Han, H., Yao, Y., & Du, M. (2020). Intelligent object recognition of urban water bodies based on deep learning for multi-source and multi-temporal high spatial resolution remote sensing imagery. *Sensors*, 20(2), 397. <https://doi.org/10.3390/s20020397>.
- Tercan, E., & Atasever, U. H. (2021). Effectiveness of autoencoder for lake area extraction from high-resolution RGB imagery: an experimental study. *Environmental Science Pollution Research*, 1-13. <https://doi.org/10.1007/s11356-021-12893-y>.
- Torun, A. T., & Gündüz, H. İ. (2020). Comparison of different classification algorithms for the detection of changes on water bodies; Karakaya Dam Lake. *Turkish Journal of Geosciences*, 1(1), 27-34.
- Vapnik, V. (2013). *The nature of statistical learning theory*: Springer Science & Business Media.
- Wang, Z., Liu, J., Li, J., & Zhang, D. D. (2018). Multi-spectral water index (MuWI): a native 10-m multi-spectral water index for accurate water mapping on Sentinel-2. *Remote Sensing*, 10(10), 1643. <https://doi.org/10.3390/rs10101643>.
- Weih, R. C., & Riggan, N. D. (2010). Object-based classification vs. pixel-based classification: Comparative importance of multi-resolution imagery. *International Archives of the Photogrammetry, Remote Sensing Spatial Information Sciences*.
- Yang, X., Li, Y., Wei, Y., Chen, Z., & Xie, P. (2020). Water body extraction from sentinel-3 image with multiscale spatiotemporal super-resolution mapping. *Water*, 12(9), 2605. <https://doi.org/10.3390/w12092605>.
- Yang, X., Qin, Q., Grussenmeyer, P., & Koehl, M. (2018). Urban surface water body detection with suppressed built-up noise based on water indices from Sentinel-2 MSI imagery. *Remote Sensing of Environment*, 219, 259-270. <https://doi.org/10.1016/j.rse.2018.09.016>.
- Zhang, J., Xing, M., Sun, G.-C., Chen, J., Li, M., Hu, Y., & Bao, Z. (2020). Water body detection in high-resolution SAR images with cascaded fully-convolutional network and variable focal loss. *IEEE Transactions on Geoscience Remote Sensing*, 59(1), 316-332. <https://doi.org/10.1109/TGRS.2020.2999405>
- Zhou, Y., Dong, J., Xiao, X., Xiao, T., Yang, Z., Zhao, G., & Qin, Y. (2017). Open surface water mapping algorithms: A comparison of water-related spectral indices and sensors. *Water*, 9(4), 256. <https://doi.org/10.3390/w9040256>.