

Yusufeli Barajı Su Tutma Sonrası Arazi Örtüsü Değişimlerinin Google Earth Engine ile Analizi

Analysis of Land Cover Changes after the Water Retention of Yusufeli Dam by Google Earth Engine

Ekrem Saralioğlu^{1*}, Baker Alahmed¹

¹Artvin Çoruh Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 08100, Artvin/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Ekrem Saralioğlu
ekremsaralioglu@artvin.edu.tr

doi: 10.48123/rsgis.1660237

Yayın süreci

Geliş tarihi: 18.03.2025
Kabul tarihi: 18.05.2025
Basım tarihi: 27.09.2025

Özet

Bu çalışma, Türkiye'nin en yüksek barajı olan Yusufeli Barajı'nın tamamlanması ve su tutulmaya başlanması sonrasında meydana gelen arazi örtüsü değişimlerini incelemeyi amaçlamaktadır. Araştırma, uzaktan algılama teknikleri ve Google Earth Engine (GEE) platformu kullanılarak gerçekleştirilmiştir. GEE, büyük ölçekli uydu görüntülerinin işlenmesi ve analiz edilmesi için güçlü bir araç olup, bu çalışmada arazi örtüsü değişimlerini hızlı ve etkili bir şekilde tespit etmek için kullanılmıştır. Çalışma kapsamında, en fazla %1 bulutluluğa sahip 2020 ve 2024 yılına ait Sentinel-2 görüntüleri kullanılmıştır. Çalışmada Normalize Edilmiş Fark Su İndeksi (Normalized Difference Water Index (NDWI)) ile değişim analizi, her iki görüntünün Destek Vektör Makineleri (DVM) ile sınıflandırılması, arazi kullanım sınıfları üzerinden analiz çalışmaları gerçekleştirilmiştir. 2020 ve 2024 yıllarına ait Sentinel-2 görüntülerinin DVM ile sınıflandırılması sırasıyla %93.74 ve %92.36 genel doğruluk ile gerçekleştirilmiştir. Yapılan değişim analizleri sonucunda 2020-2024 yılları arasında Çoruh Nehri'nin yüzey alanında 2632.11 ha'lık artış ve su altında kalan en büyük alanları orman toprağı, kayalık ve taşlık alanlar ile iskân alanlarının oluşturduğu tespit edilmiştir.

Anahtar kelimeler: Uzaktan algılama, Değişim analizi, Google Earth Engine, Yusufeli

Abstract

This study aims to investigate the land cover changes in Yusufeli district of Artvin province, which is one of the richest regions in terms of biodiversity in Turkey and also contains Turkey's only biosphere reserve area, after the completion of the Yusufeli Dam and the start of water retention. The research was carried out using remote sensing techniques and Google Earth Engine (GEE) platform. GEE is a powerful tool for processing and analyzing large-scale satellite imagery and was used in this study to quickly and effectively detect land cover changes. Within the scope of the study, Sentinel-2 images of 2020 and 2024 with maximum 1% cloudiness were used. In the study, change analysis with Normalized Difference Water Index (NDWI), classification of both images with Support Vector Machines (SVM), and analysis studies on land use classes were carried out. Classification of Sentinel-2 images of 2020 and 2024 with SVM was performed with an overall accuracy of 93.74% and 92.36%, respectively. As a result of the change analyses, it was determined that the surface area of the Çoruh River increased by 2632.11 ha between 2020 and 2024, and the largest inundated areas were forest land, rocky and stony areas and settlement areas.

Keywords: Remote sensing, Change detection, Google Earth Engine, Yusufeli

1. Giriş

Artvin, biyolojik çeşitlilik açısından zengin bir bölgedir. Türkiye'nin en yüksek, çift eğrilikli beton kemer baraj tipinde ise dünyanın üçüncü yüksek barajı olma özelliğini sağlayan Yusufeli Barajı, baraj inşaatının tamamlanması ve su tutmaya başlaması sonucunda Çoruh Vadisi'nde belirli alanlar su altında kalmıştır (Turan & Bayrakdar, 2020). Bu durum arazi örtüsü değişimine sebep olmuştur. Arazi örtüsü değişimlerinin tespiti, bölge ile ilgili iklim, orman, çevre, sosyal donatılar gibi çok çeşitli alanlarda meydana gelebilecek değişikliklerin takibinde önemli bir veri kaynağı olmaktadır.

Arazi kullanımı ve arazi örtüsü (AK/AÖ), yeryüzündeki doğal kaynakların ve insan faaliyetlerinin mekânsal dağılımını ifade eder ve çevresel değişimlerin anlaşılması, sürdürülebilir kaynak yönetimi ve bölgesel planlama için temel bir altlık oluşturur. Zaman içindeki AK/AÖ değişimlerinin izlenmesi, özellikle büyük ölçekli mühendislik projeleri gibi insan kaynaklı etkilerin çevresel sonuçlarını değerlendirmek açısından kritik bir öneme sahiptir. Bu değişimlerin tespiti ve analizi için uzaktan algılama (UA) teknolojileri, sunduğu geniş alan kapsama, tekrarlı veri toplama yeteneği ve maliyet etkinliği sayesinde vazgeçilmez bir araç haline gelmiştir. Özellikle uydu platformları aracılığıyla elde edilen UA verileri, AK/AÖ haritalarının üretilmesi ve zamansal değişimlerin belirlenmesinde yaygın olarak kullanılmaktadır.

Uydu tabanlı UA'da, Landsat, Sentinel ve MODIS gibi çeşitli platformlardan elde edilen multispektral görüntüler, AK/AÖ çalışmalarında sıklıkla başvurulan veri kaynaklarıdır (Phiri vd., 2020). Bu görüntülerden anlamlı bilgiler çıkarmak için çeşitli analiz yöntemleri geliştirilmiştir. Görüntü sınıflandırma, bu yöntemlerin başında gelmektedir. Sınıflandırma yaklaşımları temel olarak kontrollü (supervised) ve kontrolsüz (unsupervised) olmak üzere ikiye ayrılır. Kontrollü sınıflandırmada, eğitim verileri kullanılarak algoritmalar eğitilirken, kontrolsüz sınıflandırma eğitim işlemi olmadan gerçekleştirilir. Sınıflandırma sürecinde literatürde; Maksimum Olabilirlik sınıflandırıcısı, k-ortalamlar, spektral açı eşleştirici ve Mahalanobis Mesafe sınıflandırması gibi geleneksel yöntemler mevcuttur. Bunun yanında DVM, Rastgele Orman ve K-en yakın komşu gibi daha yeni olan makine öğrenme yöntemlerinin genel olarak diğer sınıflandırıcılardan daha iyi performans gösterdiği ortaya konmuştur (Khatami vd., 2016). Son yıllarda bu yöntemlerin yanında, makine öğrenimi tekniklerinin bir alt kümesi olan derin öğrenme algoritmaları sağladıkları yüksek doğruluk ve genelleştirme yetenekleri ile pek çok alanda olduğu gibi AÖ sınıflandırmada da önemli bir popülerlik kazanmıştır (Akar vd., 2024; Saralioğlu & Gungor, 2020; Zhao vd., 2023; Vali vd., 2020; Seftin vd., 2020).

DL yöntemleri, uzaktan algılanmış verilerin sınıflandırmasında önemli potansiyel sunmakla birlikte genellikle çok fazla miktarda etiketli eğitim verisi ihtiyacı ve yüksek hesaplama kaynakları gerektirir. Bu nedenle bu çalışmada AÖ sınıflandırma aşamasında veri seti boyutu ve hesaplama verimliliği göz önünde bulundurularak, sınırlı eğitim verisiyle dahi etkin genelleme yapabilen ve göreceli olarak daha az hesaplama yükü getiren DVM algoritması tercih edilmiştir. DVM, uzaktan algılamada en çok tercih edilen sınıflandırma yöntemlerinden biridir (Maulik & Chakraborty, 2017). DVM, özellikle yüksek boyutlu veri setlerinde ve sınıflar arasında karmaşık ilişkilerin olduğu durumlarda başarılı sonuçlar veren güçlü bir kontrollü sınıflandırma algoritmasıdır (Kavzoglu & Colkesen, 2009; Mountrakis vd., 2011; Melgani & Bruzzone, 2004). Literatürde DVM'nin AK/AÖ sınıflandırmasındaki etkinliğini gösteren çok sayıda çalışma bulunmaktadır (Saralioğlu & Vatandaslar, 2022; Yousefi vd., 2022; Srivastava vd., 2012; Loukika vd., 2021; Kadavi & Lee, 2018).

Arazi örtüsü sınıflarının belirlenmesinde sınıflandırma algoritmalarının yanı sıra, belirli yüzey tiplerini vurgulamak veya ayırt etmek amacıyla spektral indekslerden de yaygın olarak faydalanılmaktadır. Bu indeksler, uydu görüntülerinin farklı spektral bantları arasındaki matematiksel oranlara dayanır ve belirli bir özelliğin (örneğin su, bitki örtüsü, toprak) varlığını ve yoğunluğunu ortaya çıkarmada etkilidir. Bu bağlamda, özellikle su alanlarının tespiti için geliştirilen NDWI indeksi önemli bir araçtır (McFeeters, 1996). NDWI, genellikle yeşil (Green) ve yakın kızılötesi (Near-Infrared- NIR) bantlardaki yansıma değerlerini kullanarak hesaplanır. Su kütlelerinin NIR bandında güçlü soğurma, yeşil bantta ise nispeten daha yüksek yansıma göstermesi prensibine dayanır. Bu özellik, NDWI değerlerinin su alanlarında yüksek pozitif değerler almasını sağlarken, bitki örtüsü ve toprak gibi diğer yüzeylerde daha düşük veya negatif değerler almasına neden olur. Bu sayede NDWI, su yüzeylerinin diğer arazi örtüsü tiplerinden, özellikle de bitki örtüsünden net bir şekilde ayırt edilmesini kolaylaştırır. Hesaplama basitliği ve etkinliği nedeniyle, nehirler, göller gibi su kütlelerinin alansal değişimlerinin izlenmesi, kıyı çizgisi tespiti ve su kalitesi ile ilgili çalışmalarda sıklıkla başvurulan bir yöntemdir (Özelkan, 2020; Guha vd., 2020; Eid vd., 2020). Bu çalışmada da özellikle Yusufeli Barajı'nın su tutması sonrası Çoruh Nehri'nin yüzey alanındaki değişimi kantitatif olarak belirlemek amacıyla NDWI analizinden yararlanılmıştır.

Çevresel sorunların küresel ölçekte analiz edilmesi amacıyla GEE kullanımı günümüzde giderek yaygınlaşmaktadır. Google tarafından 2010 yılında kullanıma sunulan GEE bir bulut bilişim platformudur (Amani vd., 2020). GEE, bulut tabanlı hesaplamaya olanak tanır ve küresel ölçekteki büyük coğrafi verilerin analiz edilmesi amacıyla kullanılan etkili bir araçtır. Coğrafi büyük verilerin işlenmesi için kullanılabilecek diğer bulut platformları arasında Amazon Web Services (AWS), ve Microsoft Azure bulunmaktadır (Tamiminia vd., 2020). Diğer bulut platformlarıyla karşılaştırıldığında GEE, daha fazla türde coğrafi veriyi desteklemekte ve tüm kullanıcılara yönelik ücretsiz plan desteği sunması gibi çeşitli avantajlara sahiptir. GEE; Landsat, Sentinel ve MODIS uydularından elde edilen verilerin yanı sıra iklim modelleri, sıcaklık ve jeofiziksel özelliklere ilişkin verileri de içermektedir (Liang vd., 2018). Uzun zaman serilerine sahip Dünya gözlem kayıtlarını barındırması sayesinde çevresel izleme faaliyetlerinde önemli bir rol oynamaktadır (Zhao vd., 2021).


Uzaktan algılama alanında GEE, tarımsal üretkenlik (He vd., 2018), bitki örtüsü izleme (Tsai vd., 2018), otlak alanların izlenmesi (Parente vd., 2018), arazi kullanımı ve arazi örtüsü (Aghlmand vd., 2021; Danacioğlu & Öngül, 2023; Zhao vd., 2024; Pande vd., 2024), risk ve afet yönetimi (Halder & Bose, 2024), ısı adaları (Khalil & Kumar, 2025), orman yangınları (Yilgan vd., 2024), batimetri (Guan vd., 2025), madencilik (Zhang vd., 2025) gibi birçok alanda uzaktan algılama için güçlü bir araç haline gelmiştir. Bu çok yönlü uygulamalar, GEE platformunun büyük veri kümelerini yönetme ve bilimsel araştırmaların gelişimine katkıda bulunma potansiyelini göstermektedir (Mutanga vd., 2019).

Son yıllarda birçok araştırmacı, GEE'nin potansiyel uygulamaları üzerinde çalışmalar yapmıştır. Velastegui-Montoya vd., (2023), platformun başlangıcından itibaren yayınlanan literatürü inceleyerek platformun kullanım alanlarını, eğilimlerini ve potansiyelini ortaya koymuştur. Tamiminia vd. (2020), coğrafi büyük veri uygulamalarında GEE kullanımına ilişkin sistematik bir inceleme gerçekleştirmiştir. Benzer şekilde Zhao vd. (2021), Web of Science (WoS) Science Citation Index Expanded (SCIE) ve Social Citation Index (SSCI) veri tabanlarından elde edilen makaleleri kullanarak Google Earth ve GEE platformlarının bilimsel üretim gelişimini incelemiştir.

Artvin ili, zengin biyolojik çeşitliliği ve Türkiye'nin tek biyosfer rezerv alanını barındırmasıyla ekolojik açıdan önemli bir bölgedir. Bölgede inşa edilen Yusufeli Barajı, Türkiye'nin en yüksek, dünyanın ise kendi sınıfında üçüncü yüksek barajı olmasıyla dikkat çekerken, su tutmaya başlamasıyla birlikte Çoruh Vadisi'nde geniş alanların sular altında kalmasına ve dolayısıyla önemli AK/AÖ değişimlerine neden olmuştur (Turan & Bayrakdar, 2020). Bu değişimler, bölgenin ekolojisi, iklimi, tarımsal faaliyetleri ve sosyo-ekonomik yapısı üzerinde derin etkiler oluşturma potansiyeline sahiptir. Yusufeli ve çevresinde daha önce farklı disiplinlerde çalışmalar yapılmış olsa da (Koday & Erhan, 2010; Özalp vd., 2012; Tüfekçioğlu & Yavuz, 2016; Torun, 2021; Polat, 2023), güncel durumda barajın su tutması sonrasında meydana gelen güncel AK/AÖ değişimlerini UA teknikleri ve bulut bilişim platformları kullanarak detaylı bir şekilde analiz eden bir çalışma mevcut değildir. Bu çalışma bu boşluğu doldurmayı amaçlamaktadır. Çalışmanın temel amacı, Yusufeli Barajı'nın su tutması sonrası Yusufeli ilçesinde meydana gelen AK/AÖ değişimlerini, Sentinel-2 uydu görüntülerini ve GEE platformunu kullanarak DVM sınıflandırma algoritması ve NDWI indeksi ile analiz etmektir. Bu çalışmanın önemi, Türkiye'nin en büyük baraj projelerinden birinin neden olduğu çevresel değişimi güncel veriler ve ileri analiz teknikleriyle belgeleyerek bölgesel planlama ve çevresel yönetim için kritik bilgiler sunmasında yatmaktadır. Çalışmanın yenilikçi yönü ise, bu büyük ölçekli değişimin analizinde GEE platformu üzerinden oluşturulan metodoloji ile hızlı ve etkin bir şekilde gerçekleştirilmesidir.

2. Materyal ve Metot

Bu çalışmada, Sentinel-2 uydu görüntülerinin GEE platformunda işlenmesi ve analiz edilmesi yoluyla Yusufeli barajı inşaatı ile su tutma sonrası sular altında kalan alanların tespiti ve arazi örtüsü değişimlerinin araştırılması gerçekleştirilmiştir. İlk olarak, çalışma alanını kapsayan ve bulut oranı %1 i geçmeyecek şekilde 2020 ve 2024 yıllarında 2 adet Sentinel-2 görüntüleri seçilmiştir. Ardından, su değişiminin tespiti için NDWI analizi yapılmıştır. Arazi örtüsü değişimlerini incelemek amacıyla ilk olarak sınıflandırma işlemi için etiketli veri setleri hazırlanmış ve DVM algoritması kullanılarak görüntüler sınıflandırılmıştır. Sınıflandırma sonuçlarının doğruluğu, hata matrisleri ve diğer performans metrikleri (doğruluk, kesinlik, hatırlama ve F1 skoru) ile değerlendirilmiştir. Son olarak değişim analizi yapılmış ve NDWI sonuçları ile sınıflandırma verileri kullanılarak su alanlarındaki ve arazi örtüsündeki değişimler tespit edilmiştir. Toprak verisindeki Arazi Kullanım Kabiliyet (AKK) katmanı su altında kalan alanlar ile karşılaştırılarak su altında kalan alanların özellikleri tespit edilmiştir. Son olarak, yapılan analizler haritalar ve tablolar ile görselleştirilmiş, mekânsal ve zamansal değişimlerin etkileri detaylı bir şekilde ortaya konulmuştur. Bu metodoloji, Sentinel-2 görüntülerinin GEE platformu ile etkin bir şekilde işlenmesi ve analiz edilmesi yoluyla arazi örtüsü değişimlerinin tespiti ve sınıflandırılması için sistematik bir yaklaşım sunmaktadır (Şekil 1).



Şekil 1. Metodoloji

2.1 Çalışma Bölgesi ve Veri Ön İşlemleri

Yusufeli, coğrafi konumu itibarıyla Doğu Karadeniz Bölümü ile Doğu Anadolu Bölgesi arasında bir geçiş sahası niteliği taşımakta olup, bu özelliği nedeniyle her iki bölgenin fiziki coğrafya, iklim, bitki örtüsü ve kültürel yapı gibi çeşitli karakteristik unsurlarını bünyesinde barındırmaktadır. Bu bağlamda Yusufeli, farklı coğrafi bölgelerin kesişim noktasında yer almasının sağladığı avantajla, doğal çevre özellikleri açısından özgün ve karmaşık bir yapı sergilemekte; söz konusu durum, bölgenin ekolojik çeşitliliği, peyzaj özellikleri ve sosyo-kültürel dokusu üzerinde belirgin etkiler oluşturmaktadır. Çalışma alanı Şekil 2’de gösterilmektedir.

Bu çalışma Sentinel-2 görüntüleri işlenerek gerçekleştirilmiştir. Avrupa Uzay Ajansı’na (ESA) bağlı olarak yürütülen Copernicus Programı kapsamında, ilk Sentinel uydusu olan Sentinel-1A, 2014 yılında yörüngeye yerleştirilmiştir. Günümüze kadar Copernicus Programı çerçevesinde Sentinel-1, Sentinel-2, Sentinel-3 ve Sentinel-5 gibi çeşitli uydu görevleri gerçekleştirilmiştir. Bu görevler arasında özellikle Sentinel-2 uydularının fırlatılması, programın önemli mihenk taşlarından biri olarak kabul edilmektedir. Sentinel-2 misyonu, Sentinel-2A ve Sentinel-2B isimli iki eş uydudan oluşan bir takımyıldız şeklinde yapılandırılmıştır. Sentinel-2A uydusu 23 Haziran 2015 tarihinde fırlatılmış olup, ilk görüntü verileri fırlatmadan birkaç gün sonra elde edilmiştir (Immitzer vd., 2016). Sentinel-2B ise 7 Mart 2017 tarihinde yörüngeye yerleştirilmiştir. Sentinel-2 uyduları, 13 farklı spektral bantta veri toplama kapasitesine sahip Çok Bantlı Görüntüleme Cihazları (Multispectral Instrument - MSI) taşımaktadır (Phiri vd., 2020). Verilerine ücretsiz olarak erişilebilen Sentinel-2 uyduları, yeryüzü gözlemleri ve çevresel izleme çalışmalarında önemli katkılar sağlamaktadır.

Sentinel-2 uydularının sunduğu çok bantlı spektral veriler ve yüksek zamansal çözünürlük, arazi örtüsü değişimlerinin tespiti ve analizi için ideal bir altyapı sağlamaktadır. Bu kapsamda bu çalışmada Sentinel-2 verileri kullanılmıştır.



Şekil 2. Çalışma alanı: Yusufeli İlçesi

Çalışma alanı olarak belirlenen Artvin ili Yusufeli ilçesine ait idari sınırların poligon verisi GEE platformuna aktarılmıştır. GEE platformu üzerinden 2020-06-01 ile 2020-10-01 ve 2024-06-01 ile 2024-10-01 tarih aralıklarında bulutluluk oranı en fazla %1 olacak şekilde iki adet Sentinel-2 görüntüsü filtrelenmiş ve çalışma alanı sınırlarına göre kesilmiştir. Kullanılan Sentinel-2 görüntüleri, COPERNICUS/S2_SR_HARMONIZED (Sentinel-2 Surface Reflectance) veri setine ait olup, bu veriler Sen2Cor algoritması ile atmosferik düzeltme işleminden geçirilmiş yüzey yansıma değerlerini içermektedir.

2.2 Normalize Edilmiş Fark Su İndeksi

2020 ve 2024 Sentinel-2 görüntülerine ayrı ayrı NDWI analizi yapılmıştır. Su alanlarının tespiti ve değişim analizinde, özellikle kayıp su alanlarının hesaplanmasında NDWI değerleri kritik bir rol oynamaktadır. NDWI, su alanlarının belirlenmesi amacıyla kullanılan spektral bir indeks olup, bu indeks için üç farklı sınır değer tanımlanmıştır. Sıfırdan küçük değerler, su içermeyen alanları temsil ederken, 0 ile 0,2 arasındaki değerler sıg su alanlarını, 0,2'den büyük değerler ise su içeren alanları karakterize etmektedir (Akçin & Köse, 2023). Bu sınıflandırma, su kaynaklarının izlenmesi ve yönetimi açısından önemli bir veri sağlamaktadır. Normalleştirilmiş fark su indeksi oranı aşağıda Eşitlik 1'de verilmiştir (McFeeters, 1996).

$$NDWI = (YEŞİL - NIR) / (YEŞİL + NIR) \quad (1)$$

2.3 Değişim Analizi

Bu çalışmada, görüntü farkı alma tekniği kullanılarak değişim analizi yapılmıştır. İlk olarak 2020 ve 2024 yılı Sentinel-2 görüntülerine ayrı ayrı NDWI analizi uygulanmıştır. Görüntü farkı alma, iki farklı zaman periyodundan görüntü verilerinin karşılıklı piksellerinin çıkarılması ile gerçekleştirilmektedir. Özellikle, her iki görüntüdeki (x, y) koordinatlarındaki karşılık gelen pikseller için, daha önceki görüntünün (I1) dijital değerleri daha sonraki görüntüden (I2) çıkarılır. Bu süreç matematiksel olarak aşağıdaki denklemle gösterilir:

$$Id(x, y) = I2(x, y) - I1(x, y) \quad (2)$$

Burada:

$I1$, $t1$ (2020) zamanında NDWI analizine sahip Sentinel-2 görüntüsünü temsil eder.

$I2$, $t2$ (2024) zamanında NDWI analizine sahip Sentinel-2 görüntüsünü temsil eder.

(x, y) bir pikselin mekânsal koordinatlarını belirtir.

Id , iki zaman periyodu arasındaki değişiklikleri vurgulayan ortaya çıkan fark görüntüsünü temsil eder.

2.4 Destek Vektör Makineleri ile Sınıflandırma

Görüntü sınıflandırma işlemlerinde DVM yöntemi kullanılmıştır. DVM, uzaktan algılama alanında sıklıkla tercih edilen sınıflandırma algoritmalarından biridir (Saralioğlu & Vatandaşlar, 2022; Yousefi vd., 2022; Fragou vd., 2020). Başlangıçta iki sınıflı veri kümelerinin sınıflandırılması amacıyla geliştirilen bu yöntem, daha sonra çok sınıflı ve doğrusal olmayan veri kümelerinin sınıflandırılmasına yönelik olarak genişletilmiştir. DVM algoritmasının temel prensibi, sınıfları birbirinden en iyi şekilde ayıran optimal hiperdüzlemin belirlenmesine dayanmaktadır. Algoritma, eğitim verileri üzerinde gerçekleştirilen çok sayıda iterasyon aracılığıyla, sınıflar arasındaki ayrımı en üst düzeye çıkaran hiperdüzlem sınırlarını belirlemeye çalışmaktadır. Oluşturulan modeller, daha sonra bağımsız değerlendirme verileri kullanılarak test edilmektedir. Bu çalışmada, doğrusal olarak ayrılamayan sınıfların etkin biçimde sınıflandırılabilmesi ve model karmaşıklığını kontrol eden parametre sayısının az olması nedeniyle, çekirdek fonksiyonu olarak Radyal Tabanlı Fonksiyon (Radial Basis Function - RBF) tercih edilmiştir. Bu kapsamda, Sentinel-2 uydusuna ait 2020 ve 2024 yıllarına ilişkin görüntüler, GEE platformu üzerinde DVM yöntemi kullanılarak sınıflandırılmıştır.

Sınıflandırma için GEE platformunda sınıflandırmada kullanılacak arazi örtüsü sınıfları için (Su, Orman, Yeşil Alan, Toprak, Kentsel Alan, Gölge, Kar, Toprak_2, Toprak_3, Kentsel Alan_2) eğitim ve doğruluk değerlendirmede kullanılmak üzere 46623 piksel etiketli veri hazırlanmıştır. Verilerin dağılımı Tablo 1'deki gibidir.

Tablo 1. Sınıflandırma için etiketli veri seti

Sınıf Rengi	Sınıf Adı	Piksel Sayısı
	Su	7854
	Orman	5017
	Yeşil Alan	7455
	Toprak	4676
	Kentsel Alan	252
	Gölge	444
	Kar	2313
	Toprak_2	13590
	Toprak_3	4763
	Kentsel Alan_2	259

2.5. Doğruluk Değerlendirme

Üretilen arazi örtüsü sınıflandırma haritalarının doğruluğunu ve güvenilirliğini kantitatif olarak değerlendirmek amacıyla, uzaktan algılama literatüründe yaygın olarak kabul gören çeşitli performans metrikleri kullanılmıştır. Bu metrikler, sınıflandırma sonuçlarının referans (doğrulama) verileriyle karşılaştırılması sonucu oluşturulan hata matrisine (confusion matrix) dayanmaktadır. Hata matrisi, her bir sınıf için Doğru Pozitif (DP) (True Positive: doğru olarak sınıflandırılan pikseller), Doğru Negatif (DN) (True Negative: ilgili sınıfa ait olmayan ve doğru olarak sınıflandırılmayan pikseller), Yanlış Pozitif (FP) (False Positive: ilgili sınıfa ait olmadığı halde o sınıfa atanmış pikseller) ve Yanlış Negatif (FN) (False Negative: ilgili sınıfa ait olduğu halde başka bir sınıfa atanmış pikseller) değerlerini içerir. Bu çalışmada kullanılan temel doğruluk metrikleri şunlardır:

Genel Doğruluk (Overall Accuracy): Tüm sınıflar için doğru sınıflandırılan toplam piksel sayısının (hata matrisinin köşegenindeki değerler toplamı) toplam piksel sayısına oranıdır. Sınıflandırmanın genel performansını özetler.

$$\text{Genel Doğruluk} = (DP + DN) / (DP + DN + FP + FN) \quad (3)$$

Kesinlik (Precision): Belirli bir sınıfa atanan piksellerden kaçının gerçekten o sınıfa ait olduğunu gösterir. Yüksek kesinlik, modelin o sınıfı tahmin ettiğinde ne kadar isabetli olduğunu belirtir.

$$Kesinlik = DP / (DP + FP) \quad (4)$$

Duyarlılık (Recall): Belirli bir sınıfa ait olan piksellerden kaçının model tarafından doğru bir şekilde o sınıfa atandığını gösterir. Yüksek duyarlılık, modelin ilgili sınıfı ne kadar iyi tespit edebildiğini belirtir.

$$Duyarlılık = DP / (DP + FN) \quad (5)$$

F1 Skoru: Kesinlik ve Duyarlılık metriklerinin harmonik ortalamasıdır. Bu iki metrik arasında bir denge kurar ve özellikle sınıf dağılımlarının dengesiz olduğu durumlarda kullanışlıdır.

$$F1 \text{ Skoru} = 2 \times (Kesinlik \times Duyarlılık) / (Kesinlik + Duyarlılık) \quad (6)$$


Kappa Katsayısı (κ): Sınıflandırma doğruluğunun, rastgele sınıflandırma ile elde edilecek doğruluğa göre ne kadar daha iyi olduğunu ölçer.

$$\kappa = \frac{Po - Pe}{1 - Pe} \quad (7)$$

Burada Po gözlenen doğruluğu (Genel Doğruluk) ve Pe ise beklenen doğruluğu temsil eder. Bu değerler hata matrisinden hesaplanır.


3. Bulgular ve İrdeleme

NDWI analizi sonrası Şekil 3'de görüldüğü gibi bu projede kullanılan renk paleti, farklı yüzey tiplerini temsil etmektedir. Mavi renk, yüksek NDWI değerlerine sahip bölgeleri gösterir ve genellikle su kütlelerini (göller, nehirler, barajlar) ifade eder. NDWI değeri 1'e yakın olan alanlar mavi renkte görülmektedir. Beyaz renk, NDWI değeri yaklaşık 0 civarında olan geçiş bölgelerini temsil eder. Yeşil renk ise düşük NDWI değerlerine sahip kara alanlarını ifade eder. NDWI değeri -1'e yakın olan bölgeler yeşil renkte gösterilir ve genellikle bitki örtüsü alanlarını, tarım arazilerini veya kurak zeminleri temsil eder. Özetle, mavi renk su alanlarını (0.5 - 1 aralığı), beyaz renk geçiş bölgelerini (yaklaşık 0 civarı) ve yeşil renk ise kara alanlarını (-1 ile 0 arası) göstermektedir. Şekil 3'de 2024 yılı Çoruh nehrinde meydana gelen yüzey alanı artışı belli olmaktadır.




Şekil 3. a) 2020 Sentinel-2 görüntüsü NDWI analizi, b) 2024 Sentinel-2 görüntüsü NDWI analizi

Çoruh Nehri değişimini tespit edebilmek amacıyla NDWI görüntülerine 0.3 eşik değeri uygulanmıştır. Çoruh Nehri değişimi Şekil 4'deki gibidir.




Şekil 4. NDWI değişim analizi (2024-2020)

Sınıflandırma aşamasında etiketli eğitim verisi %80'i eğitim aşamasında ve %20'si doğruluk değerlendirme aşamasında kullanılmak üzere bölünmüştür. Şekil 5 ve Şekil 6'da sırasıyla 2020 ve 2024 yılı Sentinel-2 görüntülerine ait sınıflandırma sonrası üretilen görüntüler gösterilmektedir.



Şekil 5. DVM ile Sentinel-2 2020 yılı görüntüsünün sınıflandırılması



Şekil 6. DVM ile Sentinel-2 2024 yılı görüntüsünün sınıflandırılması

Her iki yılı ait görüntüler üzerinde yapılan sınıflandırma doğrulukları Tablo 2 ve Tablo 3’de gösterilmektedir.

Tablo 2. 2024 Yılı Sentinel-2 görüntüsü DVM ile sınıflandırma doğruluk değerlendirmeleri

Sınıf	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Score
Su	0.98	0.97	0.98
Orman	0.84	0.98	0.90
Yeşil Alan	0.93	0.84	0.88
Toprak	0.77	0.89	0.83
Kentsel Alan	1	0.54	0.70
Gölge	1	0.96	0.98
Kar	0.93	0.90	0.92
Toprak_2	0.97	0.96	0.97
Toprak_3	0.95	0.89	0.92
Kentsel Alan_2	1	0.62	0.76

Ayrıca 2024 yılı görüntüsüne ait sınıflandırma genel doğruluğu %92.36 ve kappa katsayısı 0.91 olarak hesaplanmıştır. 2024 yılına ait sınıflandırma sonucunda, arazi örtüsü sınıfları için genel doğruluk (accuracy) %92,36 olarak hesaplanmıştır. Ayrıca, Cohen's Kappa katsayısı 0,91 olarak bulunmuş ve sınıflandırma modelinin başarılı bir performans sergilediği ortaya konmuştur. Her bir sınıf için hesaplanan metrikler, modelin farklı arazi örtüsü türlerini ayırt etme yeteneğini göstermektedir. Özellikle, Su, Gölge ve Toprak_2 sınıflarında yüksek Kesinlik ve Duyarlılık değerleri elde edilmiştir. Bu durum, modelin bu sınıfları doğru bir şekilde tanımlayabildiğini ve yanlış sınıflandırma oranının düşük olduğunu göstermektedir. Örneğin, Su sınıfı için F1-Score değeri 0,98 olarak hesaplanmış ve bu sınıfın sınıflandırma performansının oldukça yüksek olduğu görülmüştür. Benzer şekilde, Gölge sınıfında F1-Score 0,98 olarak bulunmuş ve bu sınıfın da yüksek doğrulukta sınıflandırıldığı tespit edilmiştir. Bununla birlikte, bazı sınıflarda modelin performansında görece düşüşler gözlemlenmiştir. Özellikle, Kentsel Alan ve Kentsel Alan_2 sınıflarında Duyarlılık değerlerinin diğer sınıflara kıyasla daha düşük olduğu görülmüştür. Bu durum, bu sınıfların diğer arazi örtüsü türleriyle karışma eğiliminde olduğunu ve modelin bu sınıfları ayırt etmekte zorlandığını göstermektedir. Ancak, bu sınıflar için Kesinlik değerlerinin yüksek olması, modelin bu sınıfları tahmin ederken genellikle doğru tahminlerde bulunduğunu ortaya koymaktadır.


Genel olarak, DVM yöntemi ile yapılan sınıflandırma, Sentinel-2 görüntüsünden elde edilen arazi örtüsü türlerini ayırt etmede başarılı bir performans sergilemiştir. Yüksek doğruluk ve Kappa değerleri, modelin güvenilirliğini ve doğruluğunu desteklemektedir. 2020 yılına ait Sentinel-2 görüntüsün DVM ile sınıflandırma doğrulukları Tablo 3’deki gibidir.

Tablo 3. 2020 Yılı Sentinel-2 görüntüsü DVM ile sınıflandırma doğruluk değerlendirmeleri

Sınıf	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Score
Su	0.99	0.97	0.98
Orman	0.86	0.96	0.91
Yeşil Alan	0.98	0.91	0.94
Toprak	0.86	0.89	0.88
Kentsel Alan	0.95	0.72	0.82
Gölge	0.99	0.76	0.86
Kar	0.85	0.92	0.88
Toprak_2	0.95	0.96	0.96
Toprak_3	0.96	0.91	0.94
Kentsel Alan_2	0.78	0.77	0.78

Sentinel-2 2020 yılı görüntüsüne ait sınıflandırma genel doğruluğu %93.73 ve kappa katsayısı 0.92 olarak hesaplanmıştır. 2020 yılına ait DVM ile sınıflandırma sonucunda, arazi örtüsü sınıfları için genel doğruluk (accuracy) %93,74 olarak hesaplanmıştır. Ayrıca, Cohen's Kappa katsayısı 0,92 olarak bulunmuştur. Her bir sınıf için hesaplanan metrikler, modelin farklı arazi örtüsü türlerini ayırt etme yeteneğini göstermektedir. Su, Yeşil Alan, Toprak_2 ve Toprak_3 sınıflarında yüksek Kesinlik ve Duyarlılık değerleri elde edilmiştir. Örneğin, Su sınıfı için F1-Score değeri 0,98 olarak hesaplanmış ve bu sınıfın sınıflandırma performansının oldukça yüksek olduğu görülmüştür. Genel olarak, DVM yöntemi ile yapılan sınıflandırma, Sentinel-2 görüntüsünden elde edilen arazi örtüsü türlerini ayırt etmede başarılı bir performans sergilemiştir.

Yapılan değişim analizleri sonucunda, çalışma bölgesi içerisinde kalan Çoruh Nehri’nin yüzey alanında, 2020-2024 yılları arasında 2632,11 ha’lık artış tespit edilmiştir (Şekil 7) Su altında kalan en büyük alanı orman toprağı, kayalık ve taşlık alanlar ile iskân alanlarının oluşturduğu görülmektedir (Tablo 4).



Şekil 7. Çoruh Nehri yüzey alanı değişimi (2020-2024)

Yusufeli Barajı'nın inşası ve su tutma işlemi sonrasında Çoruh Nehri havzasında su altında kalan alanların Artvin Orman Bölge Müdürlüğü'nden alınan meşcere veri katmanındaki arazi kullanım sınıflarına göre dağılımı analiz edilmiştir. Bu analiz, bölgedeki arazi kullanım türlerinin ve doğal kaynakların etkilene düzeyini ortaya koymaktadır. Tablo 4'de, su altında kalan alanların dağılımı hektar (ha) cinsinden verilmiştir.


Tablo 4. Su altında kalan alanların meşcere veri katmanındaki arazi kullanım sınıfları ile karşılaştırılması

Sınıf	Alan (ha)
Orman	68.12
Kum	11.53
Orman Toprağı	873.65
Sulak Alan	136.22
Kayalık, Taşlık	685.18
Ziraat	567.78
Ziraat ve İskan Alanları	233.43
İskan	56.21


Tablo 4'de görüldüğü üzere, su altında kalan alanların en büyük kısmını orman toprağı (873.65 ha) oluşturmaktadır. Bu durum, barajın inşası sırasında orman ekosistemlerinin önemli ölçüde etkilendiğini göstermektedir. Orman toprağını, kayalık ve taşlık alanlar (685.18 ha) takip etmektedir. Bu alanlar, genellikle bitki örtüsünün sınırlı olduğu ve ekolojik olarak daha az üretken bölgeler olarak değerlendirilebilir.

Ziraat alanları (567.78 ha), ziraat ve iskan alanları (233.43 ha) da su altında kalan önemli arazi türleri arasında yer almaktadır. Bu durum, barajın tarımsal üretim ve yerleşim alanları üzerinde de kayda değer bir etki oluşturduğunu göstermektedir. Özellikle tarımsal alanların su altında kalması, bölgedeki ekonomik faaliyetlerin yeniden düzenlenmesini gerektirmiştir.

İskan alanları (56.21 ha) ve kum alanları (11.53 ha) ise su altında kalan en küçük alanları oluşturmaktadır. İskan alanlarının su altında kalması, yerel halkın yer değiştirmesi ve yeniden yerleşim süreçlerini zorunlu kılmıştır. Genel olarak, Yusufeli Barajı'nın inşası, bölgedeki arazi kullanım türlerini ve doğal kaynakları etkilemiştir. Yusufeli merkezinde 2020 ve 2024 yılı Çoruh Nehri yüzey değişimi sırasıyla Şekil 8 ve Şekil 9'da gösterilmektedir.




Şekil 8. Yusufeli merkezi 2020 yılı Çoruh Nehri



Şekil 9. Yusufeli merkezi 2024 yılı Çoruh Nehri

Şekil 10'da Artvin Orman Bölge Müdürlüğü'nden temin edilen toprak verisi özneteliklerinden elde edilen AKK sınıfları renklendirilerek gösterilmektedir. AKK verisinde, erozyona yol açmaksızın en verimli, en kolay ve en ekonomik şekilde tarımsal üretime olanak sağlayan araziler birinci sınıfta yer alırken; hiçbir tarımsal faaliyete uygun olmayan, çayır veya orman olarak dahi değerlendirilemeyen, yalnızca doğal yaşam alanı olarak işlev görebilen ya da insanlar tarafından dinlenme alanı ve milli park olarak kullanılabilen araziler son sınıf olan sekizinci sınıfta yer almaktadır. Birinci sınıftan sekizinci sınıfa doğru arazinin tarımsal verimliliği azalan skalada devam edecek şekildedir. I, II, III, IV sınıfları toprak işlemeli tarıma elverişli arazileri oluştururken; V, VI ve VII. sınıflar toprak işlemeli tarıma elverişsiz arazileri oluşturmaktadır. Son olarak VIII. sınıf araziler tarıma elverişsiz arazilerdir.




Şekil 10. Yusufeli AKK sınıfları

Tablo 5. Yusufeli Bölgesi AKK Sınıfları

AKK	Alan (ha)
II	1182.48
III	349.92
IV	4508.37
VI	37666.21
VII	144628.06
VIII	42385.23

Su altında kalan alanlar ile AKK sınıfları karşılaştırılarak su altında kalan alanların arazi kullanım sınıfları incelenmiştir (Şekil 11).



Şekil 11. Su altında kalan alanların AKK sınıfları

Tablo 6. Su altında kalan yerlerin AKK alanları

AKK	Alan (ha)
II	614.14
III	67.27
IV	104.05
VI	38.89
VII	302.15
VIII	1322.46

Yusufeli ilçesinin arazi kullanım sınıflarına ilişkin genel dağılımı ve Yusufeli Barajı'nın inşası sonrası su altında kalan alanların arazi kullanım sınıflarına etkisi Tablo 5 ve Tablo 6'da özetlenmiştir. Tablo 5'e göre, Yusufeli ilçesinin toplam arazi kullanım sınıfları içinde en büyük alanı VII. sınıf (144628,06 ha) kaplamaktadır. Bu sınıfı, VIII. sınıf (42.385,23 ha) ve VI. sınıf (37666,21 ha) takip etmektedir. Daha düşük alanlara sahip olan sınıflar ise IV. sınıf (4508,37 ha), II. sınıf (1182,48 ha) ve III. sınıf (349,92 ha) olarak sıralanmaktadır. Bu veriler, Yusufeli ilçesinin büyük bir kısmının tarımsal üretim açısından düşük potansiyele sahip, eğimli ve erozyona duyarlı alanlardan oluştuğunu göstermektedir. Tablo 6'da ise Yusufeli Barajı'nın inşası sonrası su altında kalan alanların arazi kullanım sınıflarına göre dağılımı verilmiştir. Buna göre, su altında kalan alanlar içinde en büyük pay VIII. sınıfa (1322,46 ha) aittir. Bunu sırasıyla II. sınıf (614,14 ha), VII. sınıf (302,15 ha), IV. sınıf (104,05 ha), III. sınıf (67,27 ha) ve VI. sınıf (38,89 ha) izlemektedir. Bu durum, barajın inşasıyla birlikte özellikle VIII. sınıf arazilerin önemli bir kısmının su altında kaldığını göstermektedir. Ayrıca, II. sınıf gibi tarımsal üretim açısından daha yüksek potansiyele sahip alanların da su altında kaldığı görülmektedir. AKK II sınıfı arazilerin %51,94'ünün su altında kalması, bölgedeki tarımsal üretim potansiyeli açısından önemli bir kaybı işaret etmektedir. AKK II sınıfı, tarımsal faaliyetler için en uygun alanlardan biri olarak değerlendirildiğinden, bu alanların yarısından fazlasının baraj inşasıyla su altında kalması, bölgedeki tarımsal üretim kapasitesini etkileyebilir.

4. Sonuçlar

Bu çalışma, Türkiye'nin en yüksek barajı olan Yusufeli Barajı'nın su tutma süreci sonrası meydana gelen arazi örtüsü değişimlerini uzaktan algılama teknikleri ve GEE platformu kullanarak analiz etmiştir. Çalışmada, 2020 ve 2024 yıllarına ait Sentinel-2 uydu görüntüleri kullanılarak NDWI, DVM algoritması ile arazi örtüsü sınıflandırması, değişim analizi ve çakıştırma analizleri gerçekleştirilmiştir. Arazi sınıflandırma işlemleri, sırasıyla %93.74 ve %92.36 genel doğruluk oranları ile tamamlanmıştır.

Elde edilen sonuçlar, Çoruh Nehri'nin yüzey alanında 2020-2024 yılları arasında 2632.11 hektarlık bir artış olduğunu göstermiştir. Su altında kalan alanların büyük bir kısmını ormanlık alanlar, kayalık ve taşlık bölgeler ile yerleşim alanları oluşturduğu tespit edilmiştir. Ayrıca, tarımsal üretim açısından yüksek potansiyele sahip II. sınıf arazilerin %51.94'ünün su altında kaldığı tespit edilmiştir. Bu durum, bölgedeki tarımsal üretim kapasitesinde önemli bir kayba işaret etmektedir.

GEE'nin sunduğu en önemli avantajlardan biri, büyük miktarda uydu verisine hızlı ve kolay erişim sağlamasıdır. Bu çalışmada, Sentinel uydu görüntüleri kullanılarak, Yusufeli Barajı'nın çevresel etkileri detaylı bir şekilde analiz edilmiştir. GEE'nin bulut tabanlı yapısı sayesinde, büyük veri setlerinin işlenmesi ve analiz edilmesi için güçlü bir donanım altyapısına ihtiyaç duyulmamıştır. Ayrıca, GEE'nin sunduğu geniş veri arşivi, farklı zaman dilimlerine ait görüntülerin kolayca karşılaştırılmasına olanak tanımıştır. Bu sayede, barajın su tutması öncesi ve sonrası arazi örtüsü değişiklikleri detaylı bir şekilde incelenebilmiştir. GEE'nin zaman serisi analizleri yapabilme yeteneği, bu tür çevresel değişimlerin dinamik bir şekilde izlenmesini mümkün kılmıştır. GEE'nin bir diğer önemli avantajı, kullanıcı dostu arayüzü ve güçlü programlama altyapısıdır. JavaScript tabanlı kodlama ortamı, araştırmacıların karmaşık analizleri kolayca gerçekleştirmesine olanak tanımıştır. Bu çalışmada, arazi örtüsü değişim analizi, sınıflandırma ve doğruluk değerlendirme gibi işlemler hızlı ve etkili bir şekilde gerçekleştirilmiştir. Ayrıca, GEE'nin sunduğu görselleştirme araçları, analiz sonuçlarının kolayca yorumlanmasını ve paylaşılmasını sağlamıştır. Doğruluk değerlendirme çalışmaları için Google Earth platformundaki yüksek çözünürlüklü görüntülerin kullanılması, GEE'nin diğer veri kaynaklarıyla entegrasyon yeteneğini göstermiştir. Bu entegrasyon, analizlerin doğruluğunu artırmış ve sonuçların güvenilirliğini sağlamıştır.

Sonuç olarak, GEE'nin sağladığı bu avantajlar, Yusufeli Barajı'nın çevresel etkilerinin detaylı bir şekilde incelenmesini mümkün kılmıştır. Bu çalışma, GEE'nin çevresel değişim analizlerinde ne kadar etkili bir araç olduğunu bir kez daha ortaya koymuştur. GEE'nin sunduğu hızlı, maliyet etkin ve kullanıcı dostu analiz ortamı, benzer çalışmalar için bir model oluşturmakta ve uzaktan algılama tekniklerinin etkin bir şekilde kullanılabileceğini göstermektedir.

Teşekkür

Bu çalışma TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında TBTK-0031-1091 nolu Proje ile desteklenmektedir. Bu kapsamda TÜBİTAK'a desteklerinden dolayı teşekkür ederiz.

Kaynaklar

- Aghlmand, M., Kalkan, K., Onur, M. İ., Öztürk, G., & Ulutak, E. (2021). Google Earth Engine ile arazi kullanımı haritalarının üretimi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(1), 38–47.
- Akar, Ö., Saralioğlu, E., Güngör, O., & Bayata, H. F. (2024). Semantic segmentation of very-high spatial resolution satellite images: A comparative analysis of 3D-CNN and traditional machine learning algorithms for automatic vineyard detection. *International Journal of Engineering and Geosciences*, 9(1), 12–24. <https://doi.org/10.26833/ijeg.1252298>
- Akçın, H., & Tercan Köse, R. (2023). Tarım arazilerinde değişime neden olan parametrelerin Google Earth Engine veri madenciliği ve WebCBS uygulaması ile değerlendirilmesi. *Journal of the Institute of Science and Technology*, 13(2), 1363–1376. <https://doi.org/10.21597/jist.1192622>
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M., Moghaddam, S. H. A., Mahdavi, S., Ghahremanloo, M., Parsian, S., Wu, Q., & Brisco, B. (2020). Google Earth Engine cloud computing platform for remote sensing big data applications: A comprehensive review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5326–5350. <https://doi.org/10.1109/JSTARS.2020.3021052>
- Danacioğlu, Ş., & Öngül, H. C. (2023). Güzelhisar Havzasında Endüstriyel Gelişmenin Arazi Kullanımı ve Arazi Örtüsü Özellikleri Üzerindeki Etkisinin Bulut Tabanlı Makine Öğrenme Teknikleri ile Değerlendirilmesi. *Ege Coğrafya Dergisi*, 32(1), 135-150.
- Eid, A. N. M., Olatubara, C. O., Ewemoje, T. A., El-Hennawy, M. T., & Farouk, H. (2020). Inland wetland time-series digital change detection based on SAVI and NDWI indices: Wadi El-Rayan lakes, Egypt. *Remote Sensing Applications: Society and Environment*, 19, Article 100347. <https://doi.org/10.1016/j.rsase.2020.100347>

- Fragou, S., Kalogeropoulos, K., Stathopoulos, N., Louka, P., Srivastava, P. K., Karpouzas, S., Kalivas, D. P., & Petropoulos, G. P. (2020). Quantifying land cover changes in a Mediterranean environment using Landsat TM and support vector machines. *Forests*, 11(7), Article 750. <https://doi.org/10.3390/f11070750>
- Guan, J., Zhang, H., Han, T., Cao, W., Wang, J., & Li, D. (2025). High-resolution mapping of shallow water bathymetry based on the scale-invariant effect using Sentinel-2 and GF-1 satellite remote sensing data. *Remote Sensing*, 17(4), Article 640. <https://doi.org/10.3390/rs17040640>
- Guha, S., Govil, H., & Besoya, M. (2020). An investigation on seasonal variability between LST and NDWI in an urban environment using Landsat satellite data. *Geomatics, Natural Hazards and Risk*, 11(1), 1319–1345. <https://doi.org/10.1080/19475705.2020.1789762>
- Halder, S., & Bose, S. (2024). Sustainable flood hazard mapping with GLOF: A Google Earth Engine approach. *Natural Hazards Research*, 4(4), 573–578. <https://doi.org/10.1016/j.nhres.2024.01.002>
- He, M., Kimball, J., Maneta, M., Maxwell, B., Moreno, A., Beguería, S., & Wu, X. (2018). Regional crop gross primary productivity and yield estimation using fused Landsat–MODIS data. *Remote Sensing*, 10, Article 372. <https://doi.org/10.3390/rs10030372>
- Kadavi, P. R., & Lee, C. W. (2018). Land cover classification analysis of volcanic island in Aleutian Arc using an artificial neural network (ANN) and a support vector machine (SVM) from Landsat imagery. *Geosciences Journal*, 22, 653–665. <https://doi.org/10.1007/s12303-018-0023-2>
- Kavzoğlu, T., & Çölkesen, İ. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), 352–359. <https://doi.org/10.1016/j.jag.2009.06.002>
- Khalil, M., & Kumar, J. S. (2025). Assessing Urban Heat Island Intensity in Damascus City Using Google Earth Engine and Landsat 8 and 9: a Comparative Analysis. *Remote Sensing in Earth Systems Sciences*, 8, 576–592.
- Koday, Z., & Erhan, K. (2010). Yusufeli ilçesinin idari coğrafya analizi. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 14(2), 231–241.
- Liang, J., Gong, J., & Li, W. (2018). Applications and impacts of Google Earth: A decadal review (2006–2016). *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 91–107. <https://doi.org/10.1016/j.isprsjprs.2018.08.019>
- Maulik, U., & Chakraborty, D. (2017). Remote sensing image classification: A survey of support-vector-machine-based advanced techniques. *IEEE Geoscience and Remote Sensing Magazine*, 5(1), 33–52.
- Melgani, F., & Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), 1778–1790.
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
- Mutanga, O., & Kumar, L. (2019). Google Earth Engine applications. *Remote Sensing*, 11(5), Article 591. <https://doi.org/10.3390/rs11050591>
- Özalp, M., Erdoğan Yüksel, E., & Yıldırım, S. (2012, 16–19 Ekim). CBS yardımı ile Çoruh Nehri üzerinde planlanan baraj ve yol projelerinin neden olacağı arazi kullanım değişiminin ve arazi tahribatının belirlenmesi [Bildiri sunumu]. IV. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZAL-CBS), Zonguldak, Türkiye.
- Özelkan, E. (2020). Water body detection analysis using NDWI indices derived from Landsat-8 OLI. *Polish Journal of Environmental Studies*, 29(2), 1759–1769. <https://doi.org/10.15244/pjoes/110447>
- Pande, C. B., Srivastava, A., Moharir, K. N., Radwan, N., Mohd Sidek, L., Alshehri, F., ... Zhran, M. (2024). Characterizing land use/land cover change dynamics by an enhanced random forest machine learning model: A Google Earth Engine implementation. *Environmental Sciences Europe*, 36(1), Article 84. <https://doi.org/10.1186/s12302-024-00901-0>
- Parente, L., & Ferreira, L. (2018). Assessing the spatial and occupation dynamics of the Brazilian pasturelands based on the automated classification of MODIS images from 2000 to 2016. *Remote Sensing*, 10(4), Article 606. <https://doi.org/10.3390/rs10040606>
- Polat, P. (2023). Yusufeli’nde (Artvin) baraj öncesi doğal çevre özelliklerinin CBS yöntemleri ile belirlenmesi ve ekolojik hassasiyet, NDVI, NDMI analizleri. *MANAS Sosyal Araştırmalar Dergisi*, 12(1), 1–24.
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 data for land cover/use mapping: A review. *Remote sensing*, 12(14), Article 2291. <https://doi.org/10.3390/rs12142291>
- Saralioğlu, E., & Gungor, O. (2022). Semantic segmentation of land cover from high-resolution multispectral satellite images by spectral-spatial convolutional neural network. *Geocarto International*, 37(2), 657–677. <https://doi.org/10.1080/10106049.2020.1734871>
- Saralioğlu, E., & Vatandaslar, C. (2022). Land use/land cover classification with Landsat-8 and Landsat-9 satellite images: A comparative analysis between forest- and agriculture-dominated landscapes using different machine learning methods. *Acta Geodaetica et Geophysica*, 57(4), 695–716. <https://doi.org/10.1007/s40328-022-00400-9>

- Srivastava, P. K., Han, D., Rico-Ramirez, M. A., Bray, M., & Islam, T. (2012). Selection of classification techniques for land use/land cover change investigation. *Advances in Space Research*, 50(9), 1250–1265. <https://doi.org/10.1016/j.asr.2012.06.032>
- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., & Brisco, B. (2020). Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 152–170. <https://doi.org/10.1016/j.isprsjprs.2020.04.001>
- Immitzer, M., Vuolo, F., & Atzberger, C. (2016). First experience with Sentinel-2 data for crop and tree species classifications in Central Europe. *Remote Sensing*, 8(3), Article 166. <https://doi.org/10.3390/rs8030166>
- Loukika, K. N., Keesara, V. R., & Sridhar, V. (2021). Analysis of land use and land cover using machine learning algorithms on Google Earth Engine for Munneru River Basin, India. *Sustainability*, 13(24), Article 13758. <https://doi.org/10.3390/su132413758>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247–259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Sefrin, O., Riese, F. M., & Keller, S. (2021). Deep learning for land cover change detection. *Remote Sensing*, 13(1), Article 78. <https://doi.org/10.3390/rs13010078>
- Torun, A. (2021). Batık kentin hatırası: Yusufeli kent kimliğindeki değişimler. *Kent ve Çevre Araştırmaları Dergisi*, 3(2), 56–80. <https://doi.org/10.48118/yykentcevre.1021841>
- Turan, E., & Bayrakdar, E. (2020). Türkiye'nin su yönetim politikaları: Ulusal güvenlik açısından bir değerlendirme. *Uluslararası Politik Araştırmalar Dergisi*, 6(2), 1–19. <https://doi.org/10.25272/j.2149-8539.2020.6.2.01>
- Tüfekçioğlu, M., & Yavuz, M. (2016). Yusufeli mikro havzasında (Artvin) yüzey erozyonu toprak kaybının tahmin edilmesi ve erozyon risk haritasının oluşturulması. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, 17(2), 188–199. <https://doi.org/10.17474/acuofd.47342>
- Tsai, Y. H., Stow, D., Chen, H. L., Lewison, R., An, L., & Shi, L. (2018). Mapping vegetation and land use types in Fanjingshan National Nature Reserve using Google Earth Engine. *Remote Sensing*, 10(6), Article 927. <https://doi.org/10.3390/rs10060927>
- Vali, A., Comai, S., & Matteucci, M. (2020). Deep learning for land use and land cover classification based on hyperspectral and multispectral earth observation data: A review. *Remote Sensing*, 12(15), Article 2495. <https://doi.org/10.3390/rs12152495>
- Yilgan, F., Miháliková, M., Kara, R. S., & Ustuner, M. (2025). Analysis of the forest fire in the 'Bohemian Switzerland' National Park using Landsat-8 and Sentinel-5P in Google Earth Engine. *Natural Hazards*, 121(5), 6133–6154. <https://doi.org/10.1007/s11069-024-07052-8>
- Yousefi, S., Mirzaee, S., Almohamad, H., Al Dughairi, A. A., Gomez, C., Siamian, N., Alrasheedi, M., & Abdo, H. G. (2022). Image classification and land cover mapping using Sentinel-2 imagery: Optimization of SVM parameters. *Land*, 11(7), Article 993. <https://doi.org/10.3390/land11070993>
- Zhao, S., Tu, K., Ye, S., Tang, H., Hu, Y., & Xie, C. (2023). Land use and land cover classification meets deep learning: A review. *Sensors*, 23(21), Article 8966. <https://doi.org/10.3390/s23218966>
- Zhang, C., Zeren, Z., Li, J., Zheng, H., Raval, S., Ding, Y., & Ma, Y. (2025). An index-based approach to evaluate ecological environment in various surface coal mines using Google Earth Engine. *Journal of Cleaner Production*, 490, Article 144746. <https://doi.org/10.1016/j.jclepro.2025.144746>
- Zhao, Z., Islam, F., Waseem, L. A., Tariq, A., Nawaz, M., Islam, I. U., Bibi, T., Rehman, N. U., Ahmad, W., Aslam, R. W., Raza, D., & Hatamleh, W. A. (2024). Comparison of three machine learning algorithms using Google Earth Engine for land use land cover classification. *Rangeland Ecology & Management*, 92(1), 129–137. <https://doi.org/10.1016/j.rama.2023.10.007>
- Zhao, S., Tu, K., Ye, S., Tang, H., Hu, Y., & Xie, C. (2023). Land use and land cover classification meets deep learning: A review. *Sensors*, 23(21), Article 8966. <https://doi.org/10.3390/s23218966>