



2020

Turkish Journal of
Remote Sensing and GIS

Turkish Journal of Remote Sensing and GIS

Türk Uzaktan Algılama
ve CBS Dergisi



Baş Editör / Editor in Chief

Prof. Dr. Halil AKINCI, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Yardımcı Editörler / Associate Editors

Doç. Dr. Mustafa ZEYBEK, Selçuk Üniversitesi, Konya, Türkiye.
Doç. Dr. Volkan YILMAZ, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.

Yabancı Dil Editörü / Language Editor

Doç. Dr. Volkan YILMAZ, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.

Sorumlu Yazı İşleri Müdürü / Managing Editor

Prof. Dr. Ayşe YAVUZ ÖZALP, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Yayın Kurulu / Publishing Board

Prof. Dr. Çetin CÖMERT, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.
Prof. Dr. Dursun Zafer ŞEKER, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
Prof. Dr. İbrahim Öztuğ BİLDİRİCİ, Konya Teknik Üniversitesi, Konya, Türkiye.
Prof. Dr. Mustafa TÜRKER, Hacettepe Üniversitesi, Ankara, Türkiye.
Prof. Dr. Oğuz GÜNGÖR, Ankara Üniversitesi, Ankara, Türkiye.
Doç. Dr. Sedat DOĞAN, Ondokuz Mayıs Üniversitesi, Samsun, Türkiye.

Editör Kurulu / Editorial Board

Prof. Dr. Ali Melih BAŞARANER, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.
Prof. Dr. Arzu ÇÖLTEKİN, University of Applied Sciences and Arts Northwestern Switzerland.
Prof. Dr. Arzu ERENER, Kocaeli Üniversitesi, Kocaeli, Türkiye.
Prof. Dr. Bülent BAYRAM, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.
Prof. Dr. Çetin CÖMERT, Karadeniz Teknik Üniversitesi, Türkiye.
Prof. Dr. Çiğdem GÖKSEL, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
Prof. Dr. Derya ÖZTÜRK, Ondokuz Mayıs Üniversitesi, Samsun, Türkiye.
Prof. Dr. Dursun Zafer ŞEKER, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
Prof. Dr. Fevzi KARSLI, Karadeniz Teknik Üniversitesi, Türkiye.
Prof. Dr. Füsun Balık ŞANLI, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.
Prof. Dr. İbrahim Öztuğ BİLDİRİCİ, Konya Teknik Üniversitesi, Konya, Türkiye.
Prof. Dr. İsmail Rakıp KARAAŞ, Karabük Üniversitesi, Türkiye.
Prof. Dr. Mehmet Ali YÜCEL, Çanakkale Onsekiz Mart Üniversitesi, Çanakkale, Türkiye.
Prof. Dr. Mehmet ALKAN, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.
Prof. Dr. Mehmet Devrim AKÇA, Işık Üniversitesi, İstanbul, Türkiye.
Prof. Dr. Mustafa TÜRKER, Hacettepe Üniversitesi, Ankara, Türkiye.
Prof. Dr. Nesibe Necla ULUĞTEKİN, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
Prof. Dr. Oğuz GÜNGÖR, Ankara Üniversitesi, Ankara, Türkiye.
Prof. Dr. Sultan KOCAMAN GÖKÇEOĞLU, Hacettepe Üniversitesi, Ankara, Türkiye.
Prof. Dr. Süleyman Savaş DURDURAN, Necmettin Erbakan Üniversitesi, Konya, Türkiye.
Prof. Dr. Tarık TÜRK, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye.
Prof. Dr. Umut Güneş SEFERCİK, Gebze Teknik Üniversitesi, Gebze, Kocaeli, Türkiye.
Doç. Dr. Ahmet Özgür DOĞRU, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
Doç. Dr. Caner GÜNEY, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
Doç. Dr. Ekrem SARALIOĞLU, Artvin Çoruh Üniversitesi, Artvin, Türkiye.
Doç. Dr. Esra TUNÇ GÖRMÜŞ, Karadeniz Teknik Üniversitesi, Türkiye.
Doç. Dr. İsmail Ercüment AYAZLI, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye.



Editör Kurulu / Editorial Board

- Doç. Dr. Krzysztof STERENCZAK, Instytut Badawczy Leśnictwa, Poland.
Doç. Dr. Nusret DEMİR, Akdeniz Üniversitesi, Antalya, Türkiye.
Doç. Dr. Özlem AKAR, Erzincan Binali Yıldırım Üniversitesi, Erzincan, Türkiye.
Doç. Dr. Saygın ABDİKAN, Hacettepe Üniversitesi, Ankara, Türkiye.
Doç. Dr. Uğur ALGANCI, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
Dr. Öğr. Üyesi Deniztan ULUTAŞ KARAKOL, Karadeniz Teknik Üniversitesi, Türkiye.
Dr. Öğr. Üyesi Gülten KARA, Karadeniz Teknik Üniversitesi, Türkiye.
Dr. Öğr. Üyesi Hasan Tahsin BOSTANCI, Gümüşhane Üniversitesi, Gümüşhane, Türkiye.
Dr. Öğr. Üyesi Mustafa ÜSTÜNER, Artvin Çoruh Üniversitesi, Artvin, Türkiye.
Dr. Öğr. Üyesi Resul ÇÖMERT, Eskişehir Teknik Üniversitesi, Eskişehir, Türkiye.
Dr. Öğr. Üyesi Ziya USTA, Artvin Çoruh Üniversitesi, Artvin, Türkiye.
Dr. Abdulla M. AL-RAWABDEH, Yarmouk University, Irbid, Jordan.
Dr. Aikaterini KARAGIANNI, Aristotle University of Thessaloniki, Greece.
Dr. Davod POREH, University of Napoli Federico II, Napoli, Italy.
Dr. Manohar YADAV, Motilal Nehru National Institute of Technology (MNNIT) Allahabad Prayagraj, India.
Dr. Mohammed DABBOOR, Environment and Climate Change Canada.
Dr. Serkan URAL, ETH Zurich- Computational Physics, Switzerland.
Dr. Yasemin KUZU SINRAM, Hexagon Geospatial Ltd. USA.



İÇİNDEKİLER / CONTENTS

ARAŞTIRMA MAKALELERİ RESEARCH ARTICLES

- Sentinel-2A MSI Verisinin Makine Öğrenmesi Tabanlı Destek Vektör Makinesi, Rastgele Orman ve En Büyük Olasılık Algoritmalarını Kullanarak Piksel Tabanlı Kontrollü Sınıflandırılmadaki Etkilerinin Araştırılması
Investigation of the Effects of Machine Learning-Based Support Vector Machine, Random Forest and Maximum Likelihood Algorithms on Pixel-Based Supervised Classification of Sentinel-2A MSI Data
Nursaç Serda Kaya, Orhan Deniz.....138 - 157
- NDVI ve LST Faktörlerinin Kentsel Alanlarda Gayrimenkul Değeri Üzerindeki Etkisinin Araştırılması: Ankara, İstanbul, İzmir ve Mersin Örneği
Investigating the Impact of NDVI and LST Factors on Real Estate Values in Urban Areas: Ankara, Istanbul, Izmir and Mersin Cases
Selin Uyar, Muzaffer Can İban.....158 - 171
- Landsat 8 Görüntüleri ile Cheney Rezervuarında Bulanıklık Tahmini: Regresyon, MARS ve TreeNet Yöntemlerinin Karşılaştırılması
Estimation of Turbidity in the Cheney Reservoir Using Landsat 8 Images: A Comparison of Regression, MARS, and TreeNet Methods
Ömer Dilmen, Sinan Nacar, Esra Tunç Görmüş, Adem Bayram172 - 185
- Meteorolojik Parametrelerin GNSS Yansıma Sinyallerine Etkisinin İncelenmesi
Investigating the Effect of Meteorological Parameters on GNSS Reflection Signals
Cansu Beşel Hatipoğlu, Emine Tanır Kayıkcı186 - 198
- İstanbul Kent Atmosferindeki Aerosollerin Spektral, Konumsal ve Zamansal Analizi
Spectral, Spatial and Temporal Analysis of Aerosol over İstanbul Urban Atmosphere
Funda Yüzlükoğlu, Kazım Kaba, Cahit Yeşilyaprak199 - 210
- FORMOSAT-7/COSMIC-2 GNSS Radyo Okültasyon Tekniği İle Elde Edilen Atmosferik Parametrelerinin Değerlendirilmesi
Assessment of Atmospheric Parameters Obtained with FORMOSAT-7/COSMIC-2 GNSS Radio Occultation Technique
Seldanur Çelik Tunçer, Emine Tanır Kayıkcı 211 - 221
- Kentsel Yeşil Alanların Yeterliliği ve Erişilebilirliğinin Değerlendirilmesi: Tarsus (Mersin) Örneği
Evaluation of the Adequacy and Accessibility of Urban Green Areas: The Case of Tarsus (Mersin)
Aşır Yüksel Kaya.....222 - 239
- Kentsel Heyelanlara Bir Örnek: Alkaya Heyelanı (Tekirdağ)
An Example to the Urban Landslides: Alkaya Landslide (Tekirdağ)
Emre Özşahin, Mikayil Öztürk 240 - 253
- 2015-2023 Yılları Arasında Kadıköy Barajı Su Yüzey Alanının OTSU Yöntemiyle Sentinel-2 Multispektral Görüntülerinden Operasyonel Olarak Belirlenmesi
Operational Estimation of Kadıköy Dam Surface Water Extent from Sentinel-2 Multispectral Imagery Using OTSU Method between 2015 and 2023
Suphi Öztürk, Ali Levent Yağcı 254 - 271

Sentinel-2A MSI Verisinin Makine Öğrenmesi Tabanlı Destek Vektör Makinesi, Rastgele Orman ve En Büyük Olasılık Algoritmalarını Kullanarak Pksel Tabanlı Kontrollü Sınıflandırılmadaki Etkilerinin Araştırılması

Investigation of the Effects of Machine Learning-Based Support Vector Machine, Random Forest and Maximum Likelihood Algorithms on Pixel-Based Supervised Classification of Sentinel-2A MSI Data

Nursaç Serda Kaya^{1*} , Orhan Dengiz¹ 

¹Ondokuz Mayıs Üniversitesi, Ziraat Fakültesi, Toprak Bilimi ve Bitki Besleme Bölümü, 55139, Samsun/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Nursaç Serda Kaya
nursackaya@gmail.com

doi: 10.48123/rsgis.1410250

Yayın süreci

Geliş tarihi: 26.12.2023
Kabul tarihi: 02.06.2024
Basım tarihi: 26.09.2024

Özet

Bu araştırma makalesinde, Sinop havzasına yönelik 03.05.2023 tarihli Sentinel-2A MSI verisinin destek vektör makinesi (DVM), rastgele orman (RO) ve en büyük olasılık (EBO) algoritmalarını kullanarak piksel tabanlı kontrollü sınıflandırılması ve daha sonra her bir sınıflandırma algoritmasına ait genel doğruluk değerlerinin belirlenmesi ile her bir arazi kullanımı/arazi örtüsü sınıfı için üretici doğruluğu, kullanıcı doğruluğu, doğruluk, kesinlik, hassasiyet, F1-skoru ve ROC-AUC (İşlem Karakteristik Eğrisi-Eğri Altında Kalan Alan) metriklerine ait değerlerin kıyaslanması amaçlanmıştır. Elde edilen sonuçlar DVM ve RO algoritmalarının EBO yöntemine göre daha yüksek ve benzer genel doğruluk değerleri verdiğini göstermiştir (0.88). Her bir sınıflandırma algoritması için su kütleleri ve mera sınıflarının en yüksek doğruluk, kesinlik, hassasiyet ve F1-skoru değerlerine sahip olduğu gözlemlenmiştir. Ancak düşük AUC değerleri, eğitim setinin oluşturulduğu aşamada bazı arazi kullanımı/arazi örtüsü sınıfları için çok sayıda piksel toplanırken bazı sınıfların ise daha az piksel kullanılarak temsil edilmesi ya da yüksek doğruluk değerlerine rağmen düşük hassasiyet ve kesinlik değerlerinin varlığı gibi durumlar veri setlerindeki dengesizliği ortaya koymuştur.

Anahtar kelimeler: Uzaktan algılama, Destek vektör makinesi, Rastgele orman, En büyük olasılık, Kontrollü sınıflandırma

Abstract

In this research paper, we aimed to compare different machine learning algorithms such as Support Vector Machine (SVM), Random Forest (RF), and Maximum Likelihood for pixel-based supervised classification of Sentinel-2A MSI data from the Sinop basin on May 3, 2023. We evaluated the overall accuracy values and compared various metrics (producer accuracy, user accuracy, accuracy, precision, sensitivity, F1-score, and ROC-AUC (Receiver Operating Characteristic-Area Under Curve) for each land use/land cover class. The results showed that the SVM and RF algorithms gave higher and similar overall accuracy values than the Maximum Likelihood method (0.88). For each classification algorithm, water and pasture classes had the highest accuracy, precision, sensitivity and F1-score values. However, low AUC values, the fact that many pixels were collected for some land use/land cover classes while others were represented by fewer pixels at the stage of training set creation, or the presence of low precision and accuracy values despite high accuracy values revealed the imbalance in the datasets.

Keywords: Remote sensing, Support vector machine, Random forest, Maximum likelihood, Supervised classification

1. Giriş

Arazi kullanımı/arazi örtüsünde meydana gelen değişikliklerin tespiti ile ilişkili gerçekleştirilen bilimsel çalışmalarda genel amaçlar arasında, gözleme dayalı kentsel ve bölgesel planlamalar (Hashem & Balakrishnan, 2015), çevresel hassasiyet ve etki değerlendirmeleri (Liou vd., 2017; Nguyen vd., 2016; Nguyen & Liou, 2019; Pal & Talukdar, 2018), doğal felaketler ve zararlarının izlenmesi (Che vd., 2014; Dao & Liou, 2015; Liou vd., 2008; Liou vd., 2011; Zhang vd., 2019; Talukdar & Pal, 2019), toprak erozyonu ve toprak tuzluluğunun belirlenmesi (Talukdar vd., 2020; Chen vd., 2019; Braun & Hochschild, 2017; Nguyen vd., 2020) gibi konular yer almaktadır. Arazi kullanımı/arazi örtüsü hakkında detaylı bilgi sahibi olunması, çevre koruma ve mekânsal planlamalara yönelik ticari, politik ve idari amaçların yerine getirilmesinde bir önem teşkil eder. Çevre çalışmalarında bir girdi olarak kullanılması ya da iklim değişikliğine yönelik modellerin oluşturulmasında arazi kullanımı/arazi örtüsünün sınıflandırılması çok önemlidir (Disperati vd., 2015). Arazi kullanımı/arazi örtüsünün birlikte kombinasyonu, jeolojik, biyofiziksel ve sosyoekonomik sistem davranışları hakkında kapsamlı bilgi sahibi olunmasında etkilidir (Moran vd., 2004).

Arazi kullanımı/arazi örtüsü hakkında bilgi sahibi olunmasını sağlamak adına uzaktan algılama ve coğrafi bilgi sistemleri tekniklerinin birlikte kullanılması çok yararlıdır. Uzaktan algılama, coğrafi bilgi sistemleri analizlerinde kritik olan arazi kullanımı/arazi örtüsü karakteristiklerini içeren çeşitli tematik veriler için temel bir kaynaktır. Uydu görüntüleri, arazi örtüsü dağılımlarının değerlendirilmesinde ve mevcut coğrafi özelliklerin güncellenmesinde sıklıkla kullanılan bir envanterdir. Uzaktan algılama sistemleri ve görüntü işlemeye yönelik yazılımların kullanılması, uzaktan algılama ve coğrafi bilgi sistemlerinin popüleritesinin artırılmasında çok önemlidir (Merchant & Narumalani, 2009). Uzaktan algılama verilerinin ve teknolojilerinin kullanımının artması, coğrafi süreçlerin daha hızlı ve güçlü ilerlemesine fayda sağlamasıyla birlikte artan hata olasılıklarını da beraberinde getirmiştir (Murty & Tiwari, 2015). Daha önceki görüntü sınıflandırma çalışmalarında doğruluğun değerlendirilmesi bir öncelik teşkil etmiyordu. Ancak, dijital sınıflandırmanın beraberinde getirdiği hata olasılıklarının artması nedeniyle doğruluk değerlerinin hesaplandığı metriklerin kullanılması hayati bir öneme sahip olmuştur (Congalton, 1991).

Uzaktan algılama teknolojileri kullanarak gerçekleştirilen çalışmaların tarım politikalarına yönelik değerli görüşlerin bildirilmesine katkı sağlamasının yanı sıra, tarım alanlarının izlenmesi ve etkin kullanımında çok önemli bir yeri vardır. Uydu verileri, tarım, doğal arazi örtüsü ve ormancılık amaçlarına yönelik tasarlanmış ve geliştirilmiştir (Üstüner vd., 2014). CBS, bilgisayar tabanlı sistemler olup, mekânsal verilerin eldesi, izlenmesi ve görüntülenmesi amacıyla tasarlanmıştır. CBS ve UA, tarım (Demir vd., 2018), ekoloji (Selim & Demir, 2018), planlama, ulaşım ve jeolojinin (Orhan vd., 2020) de dahil olduğu birçok alan ve disiplinde kullanılır. Literatürde, arazi kullanımı/arazi örtüsünün belirlenmesine yönelik kullanılan sınıflandırma metotları kontrollü ve kontrolsüz sınıflandırma olmak üzere ikiye ayrılmıştır. Son 20 yıl içerisinde, kontrollü sınıflandırma yöntemlerinden olan *K*-en yakın komşu (Samaniego vd., 2008), rastgele orman (Breiman, 2001), sinir ağları (Civco, 1993), regresyon ağacı ve destek vektör makinesi (Melgani & Bruzzone, 2004) gibi ileri metotlar arazi kullanımı/arazi örtüsü belirleme çalışmalarında kullanılmaya başlanmıştır (Carranza-García vd., 2019).

Görüntü işleme, genellikle arazi kullanımı/arazi örtüsünü belirlemede yaygın olarak kullanılan bir süreçtir. Günümüzde gelişen bilgisayar teknolojileri ve yazılımlar ile birlikte artan işlem gücü, makine öğrenmesi metotlarını popüler hale getirmiştir. İnsansız hava araçları kullanılarak hiper spektral görüntü sınıflandırmasında ya da uydu görüntülerinin sınıflandırılmasında destek vektör makinesi (DVM), rastgele orman (RO), yapay sinir ağları ya da en büyük olasılık (EBO) gibi makine öğrenmesi yöntemlerinden yararlanılır. Yapay sinir ağlarıyla kıyaslandığında, küçük veri setlerinde bile DVM algoritmasının daha başarılı sonuçlar verdiği görülmektedir (Bromová vd., 2014; Gao vd., 2015; Su vd., 2017; Zhang vd., 2017). Bu özelliklere ek olarak DVM ile daha ucuz, iş gücü gerektirmeyen ve zamandan tasarruf edilen çalışmaların gerçekleştirilebilmesi, onu hassas tarım uygulamalarının vazgeçilmez bir parçası haline getirmiştir. Görüntü sınıflandırma çalışmalarında kullanılan ve oldukça popüler bir algoritma olan RO, esnek bir topluluk öğrenme metodudur (Guo vd., 2011; Rodriguez-Galiano vd., 2012; Tian vd., 2016). RO, aşırı uyuma mahal vermeden yüksek boyutlu ya da gürültülü veri kümelerini işlemede çok etkilidir (Dietterich, 2000; Breiman, 2001) ve DVM ve EBO gibi diğer sınıflandırıcılara göre daha başarılı doğruluk sonuçları verebilir (Nitze vd., 2012; Rodriguez-Galiano vd., 2012). Üstelik RO algoritması için karmaşık hiper parametre ayarlamalarının yapılması da gerekmez. EBO ise uzaktan algılama uygulamalarında kullanılan en yaygın kontrollü sınıflandırma yöntemidir. Parametrik bir istatistiksel metot olan EBO yönteminde (Lillesand vd., 2004; SEOS, 2018), veriye dayalı olarak en uygun model parametreleri bulunmaya çalışılır. Bu parametreler, veri setinin gözlemlenme olasılığını maksimize eden değerlerdir. Sınıflandırma problemlerinde EBO yöntemi, hangi sınıfa ait olduğu tahmin edilmek istenen bir veri noktasının en olası sınıfını belirlemek için kullanılır. Bu yöntem, veriye en uygun modeli seçmek için kullanılan bir optimizasyon tekniğidir. Bu gibi çeşitli özellikleri bünyelerinde barındırmalarından dolayı bu araştırma makalesinde, Sentinel-2A uydu görüntüsünün piksel tabanlı olarak analiz edilmesinde kontrollü öğrenme yöntemlerinden olan EBO, RO ve DVM'den yararlanılmıştır.


Bu çalışmada, Sinop ili Sarıkum havzası için arazi kullanımı/arazi örtüsü sınıflarını oluşturmaya yönelik 03.05.2023 tarihli Sentinel-2A MSI verisinin makine öğrenmesi tabanlı destek vektör makinesi, rastgele orman ve en büyük olasılık algoritmalarını kullanarak piksel tabanlı kontrollü sınıflandırılması ve daha sonra her bir sınıflandırma algoritmasına ait

genel doğruluk değerlerinin belirlenmesi ile her bir arazi kullanımı/razi örtüsü sınıfı için doğruluk (accuracy), kesinlik (precision), hassasiyet (sensitivity), F1-skoru ve ROC-AUC metriklerine ait değerlerin kıyaslanması amaçlanmıştır. Çalışmada DVM, RO ve EBO algoritmalarının birlikte Sentinel-2A uydu görüntüsünün sınıflandırılmasında kullanılması ve elde edilen her bir arazi kullanımı/razi örtüsü sınıfının çeşitli metriklerden yararlanılarak kapsamlı bir şekilde değerlendirilmesi gibi yönlerinden dolayı bu araştırma makalesinin literatüre bir katkı sunacağı görüşündeyiz.

2. Materyal ve Metot

2.1. Araştırma Alanının Genel Özellikleri

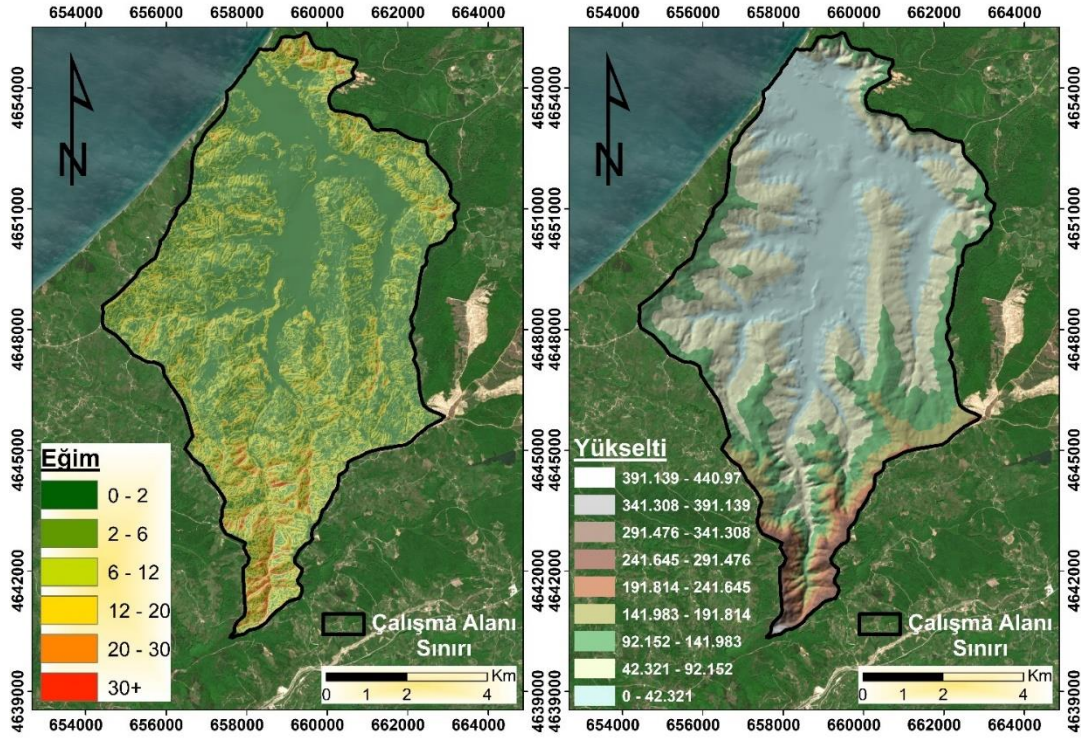
Araştırma alanı, Orta Karadeniz Bölgesi'nde yer alan Sinop ilinin kuzeyinde konumlanmış Sarıkum havzası olup, 654000-664000 D ile 4642000-4654000 K (36 Zone, UTM, WGS-84 m) koordinatları içerisinde yer almaktadır. Havza 6773.7 ha alana sahip olup, havza alanı içerisinde Sarıkum, Başaran, Gümüşsuyu, Tekke ve İncepınar köyleri yer almaktadır. Çalışma alanına ait lokasyon haritası Şekil 1'de verilmiştir.



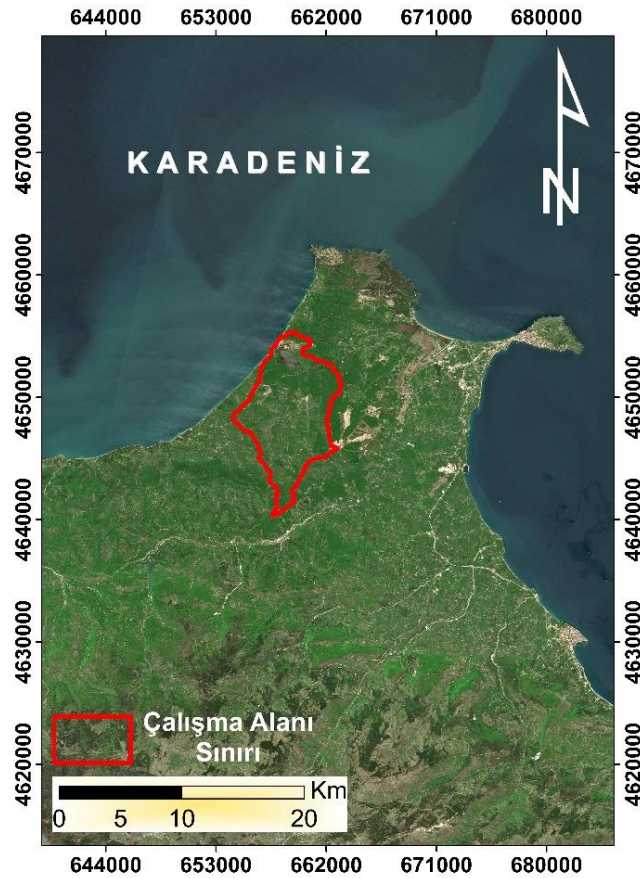
Şekil 1. Çalışma alanına ait lokasyon haritası

Yükselti haritasına göre (Şekil 2) çalışma alanı deniz seviyesinden 0 ile 440 m arasında değişen yüksekliğe sahiptir. Yükselti kuzeyden doğuya doğru gidildikçe artmaktadır. Havzaya ait eğim haritası Şekil 2'de verilmiştir. Havzanın %25.7'lik kısmı düz ya da hafif eğimli alanlardan oluşurken %46.2'si ise dik ve sarp yamaçlar üzerinde konumlanmıştır. Çalışmada kullanılan yükselti ve eğim haritaları, arazi kullanımı/razi örtüsü sınıflarının oluşturulmasında kullanılan yardımcı CBS verilerdir. Nitekim Soyaslan ve Hepdeniz (2016), CBS ve UA teknolojilerini kullanarak Burdur ilindeki arazi kullanımının zamansal değişimini çevre açısından değerlendirmeyi amaçladıkları bir çalışmada eğim, sayısal yükselti haritası ve kabartı haritalarından gerek arazi kullanımı/razi örtüsü sınıflarının oluşturulmasında gerekse de sınıflandırma hassasiyetini artırmada yararlanmışlardır.

Sınıflandırma performansını artıracağı düşünüldüğünden bu çalışmada 4 bandında 10 m, 6 bandında 20 m ve 3 bandında 60 m mekansal çözünürlüğe sahip olan 03.05.2023 tarihli Sentinel-2A MSI verisinde bulunan toplam 13 bandın tamamı kullanılarak arazi kullanımı/razi örtüsü sınıfları belirlenmeye çalışılmıştır. Nitekim Zhang vd. (2019) hassas tarımda sınıflandırma problemlerine yönelik potansiyel Sentinel-2A bantlarını inceledikleri bir çalışmada, Sentinel-2A MSI verisinde yer alan toplam 13 bandın birlikte kullanıldığında genel doğruluğu artırdığını gözlemleyerek sınıflandırma performansını iyileştirdiğini rapor etmişlerdir. Çalışmada kullanılan 03.05.2023 tarihli Sentinel-2A uydu görüntüsü Şekil 3'te verilmiştir. Sentinel-2A görüntüsü, Copernicus açık erişim merkezinden (<https://scihub.copernicus.eu/>) temin edilmiştir. Sentinel-2A uydu sensörüne ait özellikler Tablo 1'de verilmiştir. Literatürde Sentinel-2A verisinden yararlanılarak piksel tabanlı kontrollü sınıflandırmanın gerçekleştirildiği pek çok çalışma bulunmaktadır (Topaloğlu vd., 2016; ED Chaves vd., 2020; Phiri vd., 2020; Eskandari vd., 2022; Rauf vd., 2022).



Şekil 2. Çalışma alanına ait yükselti ve eğim haritaları



Şekil 3. 03.05.2023 tarihli Sentinel-2A uydu görüntüsü

Tablo 1. Sentinel-2A uydu sensörünün özellikleri

Bant	Bant Adı	Dalga Boyu (nm)	Bant Geniliği (nm)	Mekânsal Çözünürlüğü (m)
B1	Kıyı aerosol	443	20	60
B2	Mavi	490	65	10
B3	Yeşil	560	35	10
B4	Kırmızı	665	30	10
B5	Vejetasyon kırmızı-kenar	705	15	20
B6	Vejetasyon kırmızı-kenar	740	15	20
B7	Vejetasyon kırmızı-kenar	783	20	20
B8	Kızıl ötesi	842	115	10
B8A	Vejetasyon kırmızı-kenar	865	20	20
B9	Su buharı	945	20	60
B10	Sirrus	1380	30	60
B11	Kısa dalga kızıl ötesi (SWIR) 1	1610	90	20
B12	SWIR2	2190	180	20


2.2. Eğitim Setinin Oluşturulması

Yüksek doğruluk değerleri elde edebilmek için geniş setlerin oluşturulmasından ziyade, eşit dağılmış örnekleme noktalarından oluşan bir eğitim setinin hazırlanması daha önemlidir (Gumma vd., 2020). Bu çalışmada her bir sınıf için 40 adet olmak üzere toplam 200 adet örnekleme noktası, Google Earth Pro kullanılarak temin edilmiştir. Bu verilerin %75'i ArcGIS 10.7v yazılımından yararlanılarak rastgele ayrılmış ve 'tarım alanları', 'su kütleleri', 'orman', 'mera' ve 'yapay yüzeyler' olmak üzere toplam 5 farklı arazi kullanımı/arazi örtüsü sınıfından oluşan bir eğitim seti oluşturulmuştur.

Arazi kullanımı/arazi örtüsü sınıfları ve sınıf değerleri Tablo 2'de verilirken, eğitim setinin oluşturulmasında kullanılan örnekleme noktaları ise Şekil 4'te verilmiştir. Eğitim seti kullanılarak makine öğrenmesi tabanlı destek vektör makinesi, rastgele orman ve en büyük olasılık algoritmalarına yönelik eğitilmiş sınıflandırmanın yapılabilmesinde ArcGIS 10.7v yazılımından yararlanılmıştır. Eğitim seti oluşturulurken her bir arazi kullanımı/arazi örtüsü sınıfı için belirli bir sayıda piksel seçilir. Bu seçilen piksellerin sayısı, her bir sınıf için temsil edilen kaç tane örnek pikselin olduğunu belirtir. Eğitim seti için kullanılan her bir arazi kullanımı/arazi örtüsü sınıfına ait piksel sayıları Tablo 3'te verilmiştir.

Tablo 2. Arazi kullanımı/arazi örtüsü sınıfları

Sınıf Değerleri	Arazi Kullanımı/Arazi Örtüsü Sınıfları
0	Su kütleleri
1	Orman
2	Yapay yüzeyler
3	Tarım alanları
4	Mera



Şekil 4. Eğitim setlerinin oluşturulmasında kullanılan örnekleme noktaları

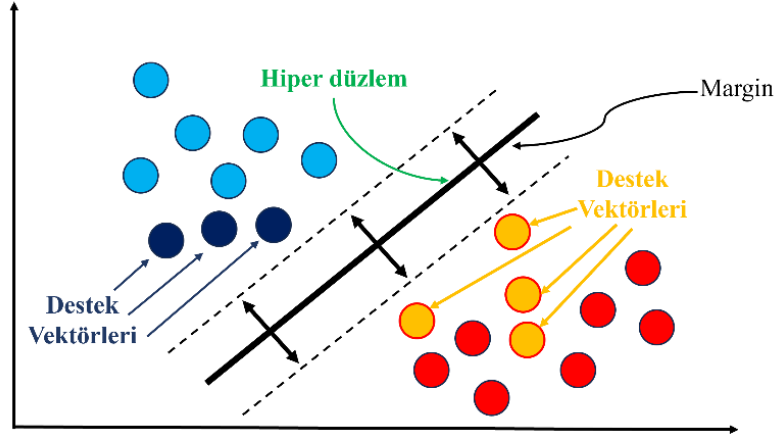
Tablo 3. Arazi kullanımı/arazi örtüsü sınıflarına ait piksel sayıları

Arazi kullanımı/arazi örtüsü sınıfı	Eğitim seti
Su kütleleri	934
Orman	4531
Yapay yüzeyler	649
Tarım alanları	1632
Mera	670
Toplam	8416

2.3. Sınıflandırma Algoritmaları

2.3.1. Destek Vektör Makinesi (DVM)

Destek vektör makinesi, istatistiksel öğrenme teorisine ve yapısal risk minimizasyonuna dayalı bir regresyon ve kontrollü öğrenme algoritmasıdır (Tehrany vd., 2015). DVM, genelleştirme hatasının üst sınırının minimize edilmesi prensibiyle çalışan bir istatistiksel öğrenme teorisidir. Kullanıcı tahmininin üst sınırını minimize etmeyi amaçlayarak eğitim ve kapasite arasında bir denge kurmaya çalışır. Destek vektör makinesindeki çekirdek yaklaşımı, iki sınıf arasındaki en iyi ayrımın sağlanmasına yönelik bir hiper düzlem tanımlar (Şekil 5) (Eşitlik 1). Bu sınıflandırma algoritması, iki sınıf kümesi arasındaki çok boyutlu boşluğun maksimize edilmesini amaçlar. Bu hiper düzlem, eğitim seti olarak bilinen bir alt kümenin kullanılmasıyla geliştirilmiştir ve genelleme yeteneği test verisi adı verilen bir bağımsız alt kümenin kullanılarak doğrulanır. Literatürde DVM algoritmasının görüntü sınıflandırma problemlerinde kullanıldığı pek çok çalışma bulunmaktadır (Kavzoğlu & Çölkesen, 2009, 2010; Okwuashi & Ndehedehe, 2020; Sheykhmousa vd., 2020; Bawa vd., 2023).



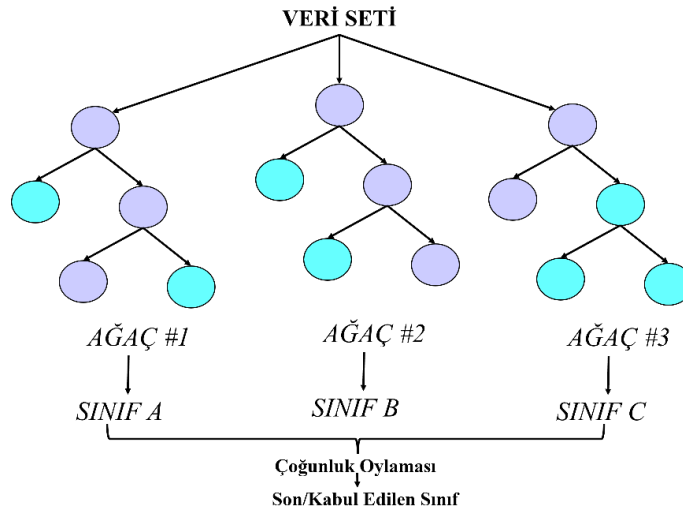
Şekil 5. Verinin destek vektör makinesi kullanılarak sınıflandırılması (Tao vd., 2006)

$$f(x) = \text{sgn}(\sum_{i=1}^n \alpha_i y_i (x_i \cdot x) + b) \quad (1)$$

Eşitlikte, $f(x)$ bir karar fonksiyonu olup, veri noktası x 'in hangi sınıfa ait olduğunu, α_i bir Lagrange çarpanı olup, her bir veri seti için hesaplanan katsayıyı, y_i veri noktasının sınıf etiketlerini, x_i eğitim veri setindeki veri noktalarını ve x sınıflandırılacak olan yeni veri noktasını belirlerken; b bias terimi olup, modelin eğitimi sırasında belirlenen bir sabiti ifade etmektedir.

2.3.1. Rastgele Orman (RO)

Kontrollü öğrenme ve regresyon görevleri açısından rastgele orman, oldukça tanınmış bir makine öğrenmesi algoritmasıdır ve popülaritesi her geçen gün daha da artmaktadır (Cunningham vd., 2008). Metot, sınıflandırma modellerinde performans artıran ve daha karmaşık problemlerin çözümünde önemli bir rol oynayan topluluk öğrenmesine dayanır. RO, özellikle spesifik bir veri setinin farklı bölümlerinde eğitilmiş karar ağaçlarından elde edilen sonuçların ortalamasını alan bir sınıflandırma yöntemidir (Rodriguez-Galiano vd., 2012). RO, her bir karar ağacına ait tahminleri toplar ve son tahmin olarak, tek bir ağaca bağlı olmak yerine, en çok oyu alan karar ağacını baz alır (Şekil 6) (Eşitlik 2).



Şekil 6. Verinin rastgele orman algoritması kullanılarak sınıflandırılması (Öztürk, 2022)

RO, üstün tahmin doğruluğu sağlar ve ezberlemeyi en aza indirir (Pouyan vd., 2021). RO algoritmalarının çok yönlülüğü, kategorizasyon problemlerinde mükemmel performans sağlar. Arazi örtüsü/arazi kullanımının belirlenmesinde rastgele orman metodunun kullanıldığı pek çok çalışma bulunmaktadır (Pal, 2005; Gislason vd., 2006; Akar & Güngör, 2012; Ghansah vd., 2021; Nakach vd., 2022; Osenberg vd., 2023).

$$\hat{y}(x) = \frac{1}{n} \sum_{i=1}^n \hat{y}_i(x) \quad (2)$$

Yukarıdaki eşitlikte, $\hat{y}(x)$ RO modelin x girdisi için yaptığı nihai tahmini, n RO içindeki toplam karar ağacı sayısını, $\hat{y}_i(x)$ i -inci bağımsız karar ağacının x girdisi için yaptığı tahmini ve i ise her bir karar ağacını temsil etmektedir.

Bu çalışmada kontrollü sınıflandırma işlemi gerçekleştirilirken RO ve DVM algoritmaları için kullanılan hiper parametreler ArcGIS 10.7v yazılımı bünyesinde bulunan ve varsayılan (default) hiper parametreler olup, açıklamalarıyla birlikte Tablo 4'te verilmiştir. Python programlama dili gibi daha güncel yazılımların farklı optimizasyon tekniklerini sunmaları, makine öğrenmesi algoritmalarına ait hiper parametre optimizasyonlarının yapılmasını daha pratik kılacaktır. Örneğin Muslim (2020), destek vektör makinesine ait hiper parametrelerin optimize edilmesinde örgü arama (grid search) yöntemini kullanıldığı bir çalışmada, Python 3.8 programlama dilinden yararlanmıştır. Benzer şekilde Tiwari vd. (2022) makine öğrenmesi algoritmalarının optimize edilmesine yönelik bir çalışmalarında, Python 3.7 yazılımını tercih etmiştir.

Tablo 4. Kontrollü sınıflandırmada kullanılan RO ve DVM algoritmaları için kullanılan varsayılan (default) hiper parametreler

Algoritma	Hiper parametre	Açıklama
RO	MaxNumTrees=50	Maksimum ağaç sayısı belirler.
	MaxTreeDepth=30	Her bir ağacın maksimum derinliğini belirler.
	MaxSampleClass=1000	Bir sınıfın maksimum örnek sayısını belirler.
DVM	Maximum Number of Samples Per Class=500	Her sınıf için maksimum örnek sayısı belirler.

2.3.1. En Büyük Olasılık (EBO)

Sınıflandırma problemlerinde sıklıkla kullanılan bir yöntem olan en büyük olasılık metodu, istatistiksel öğrenmeye dayalı bir algoritmadır. Ortalama değerleri baz almasının yanında, varyans ve kovaryans değerleri de bu sınıflandırma algoritmasında dikkate alınır. Sınıf kümesine ait verilerin normal bir dağılıma sahip olduğu varsayılan bu sınıflandırma algoritmasında, olasılık yoğunluk fonksiyonları Eşitlik (3) kullanılarak hesaplanmaktadır. Sınıflandırılacak pikseller, üyelik olasılığı en yüksek olan sınıflara atanır. Eğer pikseller için hesaplanan sınıflara ait olma olasılık değerleri, önceden belirlenen eşik değerinden düşükse, bu pikseller ilgili sınıflar açısından belirsiz olarak sınıflandırılmaktadır (Myung, 2003; Çölkesen, 2009; Günlü, 2012; Topaloğlu vd., 2016).

$$P(x) = \ln(a_c) - [0.5x \ln(|S_x|)] - [0.5x(x - M_c)^T x (S_x^{-1}) x (x - M_c)] \quad (3)$$

Eşitlikte, P olasılık değeri, C örnek bir sınıfı, x aday pikselin ölçüm vektörü, M sınıfın ortalaması, a aday pikselin sınıfa ait olma yüzdesi ve S_x varyans-kovaryans matrisidir.

2.4. Yer Doğrulama Verileri ve Doğruluk Analizi

Bu çalışmada örnekleme noktalarının %25'i ArcGIS 10.7v yazılımından yararlanılarak rastgele ayrılmış ve yer doğrulama verilerinin oluşturulmasında kullanılmıştır. Eğitim verileri kullanılarak sınıflandırılmış görüntülerin doğruluk analizlerinin gerçekleştirilmesinde yer doğrulama verilerinden yararlanılmıştır. Doğruluk analizi ya da doğrulama, sınıflandırılmış uzaktan algılama verilerinin değerlendirilmesinde çok önemli bir adımdır. Sınıflandırılmış uydu görüntüsü hakkında değerli bilgilerin sağlanması adına hata metriklerinin hesaplanması bir gerekliliktir. Uzaktan algılama verisinin verimli bir şekilde kullanılması ancak o verinin kalitesi hakkında bilgi sahibi olunmasıyla mümkün olur. Sınıflandırılmış görüntüden elde edilen genel doğruluk değeri, bir sınıflandırma modelinin ne kadar iyi performans gösterdiğini değerlendiren temel bir ölçüttür.

Genel doğruluk, her bir arazi kullanımı/razi örtüsü sınıfı için doğru olarak sınıflandırılmış piksellerin, bu piksellere karşılık gelen yer doğrulama verileri ile karşılaştırılmasıyla elde edilir. Genel doğruluğun hesaplanmasına yönelik formül Eşitlik (4)'te verilmiştir.

$$\text{Genel Doğruluk} = \frac{\sum_{k=1}^q n_{kk}}{n} \times 100 \quad (4)$$

Üretici doğruluğu, her sınıf için doğru sınıflandırılmış piksellerin sayısının bu sınıf için kullanılan referans piksellerinin sayısına bölünmesiyle bulunur. Üretici doğruluğu, referans piksellerinin ne kadar doğru sınıflandırılabilirdiğini gösterir. Üretici doğruluğunun hesaplanmasına yönelik formül Eşitlik (5)'te verilmiştir.

$$\text{Üretici Doğruluğu} = \frac{n_{ii}}{n_{ki}} \quad (5)$$

Burada n_{ii} , doğru olarak sınıflandırılmış piksel ve n_{ki} , o sınıf için seçilen gerçek örtü tipi örnekleme sayısı toplamı anlamına gelmektedir.

Kullanıcı doğruluğu, her sınıf için doğru sınıflandırılmış piksel sayısının, o sınıfa atanan piksellerin toplamına bölünmesiyle bulunur (Yan, 2006). Kullanıcı doğruluğu, her sınıf için atanan piksellerin o sınıfı gerçekte temsil etme olasılığını gösterir (Congalton, 1991; Campbell and Wynne, 2002; Jensen, 2005). Kullanıcı doğruluğunun hesaplanmasında kullanılan formül Eşitlik (6)'da verilmiştir.

$$\text{Kullanıcı Doğruluğu} = \frac{n_{ii}}{n_{ik}} \quad (6)$$

Burada n_{ii} , sınıflandırılmış piksel ve n_{ik} , sınıflandırılan toplam piksel anlamına gelmektedir. Sınıflandırmanın başarısının ölçülmesinde genel doğruluğun hesaplanması her zaman tek başına yeterli olmayabilir. Özellikle dengesiz dağılan sınıf koşullarında sınıflandırma performansını değerlendirmek için, doğruluk (accuracy), kesinlik (precision), hassasiyet (sensitivity/recall) ve F1-skoru gibi metrikler kullanılır. Bu hata metrikleri, sınıflar arasındaki dengesizlikleri hesaba katarak daha kapsamlı bir doğruluk analizi sağlar. Doğruluk, kesinlik, hassasiyet ve F1-skorunun nasıl hesaplandığına dair formüller, sırasıyla Eşitlik (7), Eşitlik (8), Eşitlik (9) ve Eşitlik (10)'da verilmiştir.

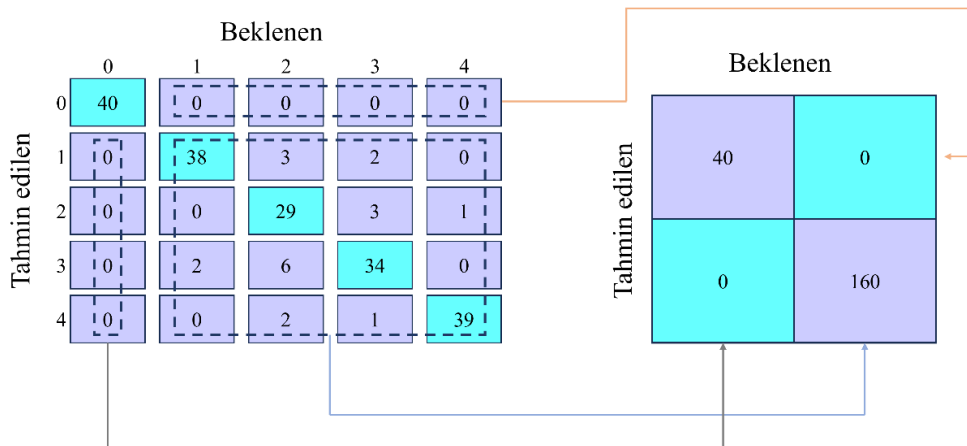
$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN} \quad (7)$$

$$\text{Kesinlik} = \frac{(DP)}{(DP+FP)} \quad (8)$$


$$\text{Hassasiyet} = \frac{(DP)}{(DP+FN)} \quad (9)$$

$$\text{F1 - skoru} = 2 * \frac{(\text{Kesinlik} \times \text{Hassasiyet})}{(\text{Kesinlik} + \text{Hassasiyet})} \quad (10)$$


Şekil 7 ve Şekil 8'de her bir sınıflandırma algoritmasına yönelik doğruluk (accuracy), kesinlik (precision), hassasiyet (sensitivity/recall) ve F1-skorunun hesaplanması amacıyla 5x5'lik karışıklık matrisinden bire-karşı-hepsi yöntemi kullanılarak Şekil 9'daki 2x2'lik karışıklık matrisi elde edilmiştir. Her bir sınıflandırma algoritmasına yönelik oluşturulan arazi kullanımı/arazi örtüsü sınıfları için bire-karşı-hepsi yöntemi kullanılarak elde edilmiş 2x2'lik karışıklık matrisleri ise Şekil 10'da verilmiştir.



Şekil 7. Destek vektör makinesi, rastgele orman ve en büyük olasılık algoritmaları için çok sınıflı bir karışıklık matrisinin bire-karşı-hepsi (sınıf 0 için) matrisine dönüştürülmesi (örnek gösterim) (Kundu, 2022)




Şekil 8. Destek vektör makinesi, rastgele orman ve en büyük olasılık algoritmaları için çok sınıflı bir karışıklık matrisinin bire-karşı-hepsi (sınıf 1 için) matrisine dönüştürülmesi (örnek gösterim) (Kundu, 2022)



Şekil 9. 2x2'lik karışıklık matrisi (Kundu, 2022)

Doğru pozitif: Model pozitif olarak sınıflandırır ve gerçek etiket de pozitiftir. Yanlış pozitif: Model pozitif olarak sınıflandırır, ancak gerçek etiket negatiftir. Doğru negatif: Model negatif olarak sınıflandırır ve gerçek etiket de negatiftir. Yanlış negatif: Model negatif olarak sınıflandırır ancak etiket aslında pozitiftir.



Şekil 10. Her bir sınıflandırma algoritmasına yönelik oluşturulan arazi kullanımı/arazi örtüsü sınıfları için bire-karşı-hepsi yöntemi kullanılarak elde edilmiş nihai 2x2'lik karışıklık matrisleri

Burada; DVM: Destek vektör makinesi, RO: Rastgele orman; EBO: En büyük olasılık, 0: Su kütleleri, 1: Orman, 2: Yapay yüzeyler, 3: Tarım alanları ve 4: Mera sınıfını ifade etmektedir. Şekil 10'da verilen 2x2'lik karışıklık matrisleri, doğruluk analizlerinin gerçekleştirilmesinde kullanılan yer doğrulama verilerinden elde edilmiştir.

İşlem Karakteristik Eğrisi (Receiver Operating Characteristic) (ROC), hassasiyet ve özgülük ile birlikte kullanılarak modelin başarı oranını hesaplamak için kullanılan bir başka ölçüt olup, eğri altındaki alan (Area Under Curve) (AUC) modelin gelecekteki olayları ne kadar iyi tahmin ettiğini gösterir. 0 ile 1 arasında değişen AUC değeri, modele dayalı performans değerlendirmesini Hanley ve McNail (1982)'e göre zayıf (<0.6), orta (<0.7), iyi (0.7-0.8), çok iyi (0.8-0.9) ve mükemmel (> 0.9) olmak üzere kategorilere ayırır.

Daha yüksek bir AUC değeri, sınıflar arasında daha güçlü bir ayırım yapma yeteneğini ifade eder (Miao & Zhu, 2022). Bu çalışmada, her bir sınıflandırma algoritmasına yönelik ROC eğrileri, Python 3.8 programlama dili, geliştirme ortamı olarak Anaconda3 ve kod düzenleyici olarak Spyder 5.2.2 kullanılarak elde edilmiştir.

3. Bulgular ve Tartışma

Çalışmada 2023 tarihli Sentinel-2A uydu görüntüsü çeşitli makine öğrenmesi tabanlı algoritmalar kullanılarak sınıflandırılmış ve her bir sınıflandırma algoritması için genel doğruluk değerleri belirlenmiştir. Buna ek olarak sınıflandırma sonuçlarının daha kapsamlı yorumlanması adına, arazi kullanımı/arazi örtüsü sınıflarına ait doğruluk, kesinlik, hassasiyet ve F1-skoru değerleri tüm sınıflandırma yöntemleri için ayrı ayrı hesaplanmıştır. Bu doğrultuda, destek vektör makinesi ve rastgele orman algoritmalarının, en büyük olasılık yöntemine göre daha yüksek ve benzer genel doğruluk değerleri verdiği gözlemlenmiştir (0.88) (Tablo 5).

Tablo 5. Yer doğrulama verilerine dayalı karışıklık matrisleri ve sınıflandırma metodlarının doğruluğu

Destek Vektör Makinesi							
Sınıflar	Su kütleleri	Orman	Yapay yüzeyler	Tarım alanları	Mera	Genel toplam	KD, %
Su kütleleri	11	0	0	0	0	11	100.00
Orman	0	9	1	0	0	10	90.00
Yapay yüzeyler	0	0	7	2	0	9	77.78
Tarım alanları	0	1	0	5	0	6	83.33
Mera	0	0	2	0	12	14	85.71
Genel toplam	11	10	10	7	12	50	
ÜD, %	100.00	90.00	70.00	71.43	100.00		
Genel doğruluk (%)	88						
Rastgele Orman							
Sınıflar	Su kütleleri	Orman	Yapay yüzeyler	Tarım alanları	Mera	Genel toplam	KD, %
Su kütleleri	11	0	0	0	0	11	100.00
Orman	0	9	1	0	1	11	81.82
Yapay yüzeyler	0	0	8	2	0	10	80.00
Tarım alanları	0	1	1	5	0	7	71.43
Mera	0	0	0	0	11	11	100.00
Genel toplam	11	10	10	7	12	50	
ÜD, %	100.00	90.00	80.00	71.43	91.67		
Genel doğruluk (%)	88						
En Büyük Olasılık							
Sınıflar	Su kütleleri	Orman	Yapay yüzeyler	Tarım alanları	Mera	Genel toplam	KD, %
Su kütleleri	10	0	0	0	0	10	100.00
Orman	0	9	1	1	0	11	81.82
Yapay yüzeyler	1	0	5	1	0	7	71.43
Tarım alanları	0	1	1	4	0	6	66.67
Mera	0	0	3	1	12	16	75.00
Genel toplam	11	10	10	7	12	50	
ÜD, %	90.91	90.00	50.00	57.14	100.00		
Genel doğruluk (%)	80						

Burada, KD: Kullanıcı doğruluğunu ve ÜD: Üretici doğruluğunu ifade etmektedir.

DVM ve RO algoritmaları, günümüzde yaygın olarak kullanılan bilgisayar destekli makine öğrenmesi yöntemlerindedir (Rana & Suryanarayana, 2020). Adam vd. (2014), arazi kullanımı/arazi örtüsü sınıflarını destek vektör makinesi ve rastgele orman algoritmalarını kullanarak belirledikleri bir çalışmada, her iki sınıf için de benzer genel doğruluk değerleri elde ettiklerini rapor etmiştir. Rimal vd. (2020), kentsel alanları destek vektör makinesi ve en büyük olasılık yöntemlerinden faydalanarak haritaladıkları bir araştırmasında, destek vektör makinesinin en büyük olasılık yöntemine göre daha iyi bir sınıflandırma performansı gösterdiğini gözlemlenmiştir. Benzer şekilde Halder vd. (2023), en büyük olasılık yönteminin popüler bir yöntem olduğunu, ancak günümüzde destek vektör makinesinin arazi

kullanımı/arazi örtüsü sınıflarının belirlendiği çalışmalarda daha başarılı doğruluk değerleri verdiğini belirtmiştir. Sentinel-1 ve Sentinel-2 uydularından yararlanılarak rastgele orman ve en büyük olasılık algoritmalarının sel hasarı tespitinde kullanıldığı bir çalışmada Billah vd. (2023), rastgele orman algoritmasının (%90) en büyük olasılık yöntemine göre (%74) daha başarılı bir sonuç verdiğini rapor etmiştir. Sınıflandırma problemlerinde hataları en aza indirme yetenekleri, DVM ve RO algoritmalarını en büyük olasılık gibi parametrik yöntemlerden daha üstün kılmaktadır (Huang vd., 2002; Foody & Mathur, 2004; Pal & Mather, 2005; Schneider vd., 2012; Rimal vd., 2020). Bir çalışmada Mather & Tso, (2016), RO ve DVM modellerinin benzer ve yüksek sonuçlar vermesinin, onları en popüler makine öğrenmesi sınıflandırıcıları arasına soktuğunu belirtmiştir.

Tablo 5'te yer alan destek vektör makinesine ait kullanıcı doğruluğu değerleri incelendiğinde, su kütleleri, orman, yapay yüzeyler, tarım alanları ve meranın sırasıyla %100, %90.00, %77.78, %83.33 ve %85.71'lik oranlarla sınıflandırıldığını görmekteyiz. Diğer yandan, rastgele orman algoritmasına ait kullanıcı değerleri sırasıyla su kütleleri, orman, yapay yüzeyler, tarım alanları ve mera sınıfları için %100.00, %81.82, %80.00, %71.43 ve %100.00 olarak sınıflandırılmıştır. En büyük olasılık algoritması için su kütleleri, orman, yapay yüzeyler, tarım alanları ve mera arazi kullanım/arazi örtüsüne ait sınıflar ise sırasıyla %100.00, %81.82, %71.43, %66.67 ve %75.00'lik oranlarla sınıflandırılmıştır.

Üretici doğruluğu değerlerine baktığımızda, su kütleleri, orman, yapay yüzeyler, tarım alanları ve mera sınıfları destek vektör makinesi için sırasıyla %100.00, %90.00, %70.00, %71.43 ve %100.00 doğrulukla sınıflandırılmıştır. Rastgele orman algoritmasına ait üretici doğruluğu değerleri, su kütleleri, orman, yapay yüzeyler, tarım alanları ve mera için sırasıyla %100.00, %90.00, %80.00, %71.43 ve %91.67 şeklinde sınıflandırılmıştır. Son olarak, en büyük olasılık algoritmasıyla sınıflandırılan arazi kullanım/arazi örtüsü sınıflarından su kütleleri, orman, yapay yüzeyler, tarım alanları ve mera ise sırasıyla %90.91, %90.00, %50.00, %57.14 ve %100.00 doğrulukla sınıflandırılmıştır.

Tablo 6'ya göre, DVM, RO ve EBO algoritmaları için orman sınıfı, sırasıyla %50.56, %51.08 ve %51.62'lik oranlarla çalışma alanında en fazla dağılım gösteren arazi kullanım/arazi örtüsü sınıfı olmuştur. Su kütleleri ise, %1.84, %1.85 ve %1.64'lük oranlarla sırasıyla DVM, RO ve EBO algoritmaları için çalışma alanında en az dağılım gösteren arazi kullanım/arazi örtüsü sınıfı olmuştur.

Tablo 6. Arazi kullanım/arazi örtüsü sınıflarının alansal dağılımları

Sınıflar	DVM		RO		EBO	
	Alan (ha)	Yüzde (%)	Alan (ha)	Yüzde (%)	Alan (ha)	Yüzde (%)
Su Kütleleri	124.55	1.84	125.08	1.85	110.77	1.64
Orman	3417.17	50.56	3452.5	51.08	3488.81	51.62
Yapay Yüzeyler	349.93	5.18	359.95	5.33	316.01	4.68
Tarım Alanları	2646.91	39.16	2615.26	38.70	2598.21	38.44
Mera	219.84	3.25	205.61	3.04	244.6	3.62
Toplam	6758.4	100	6758.4	100	6758.4	100

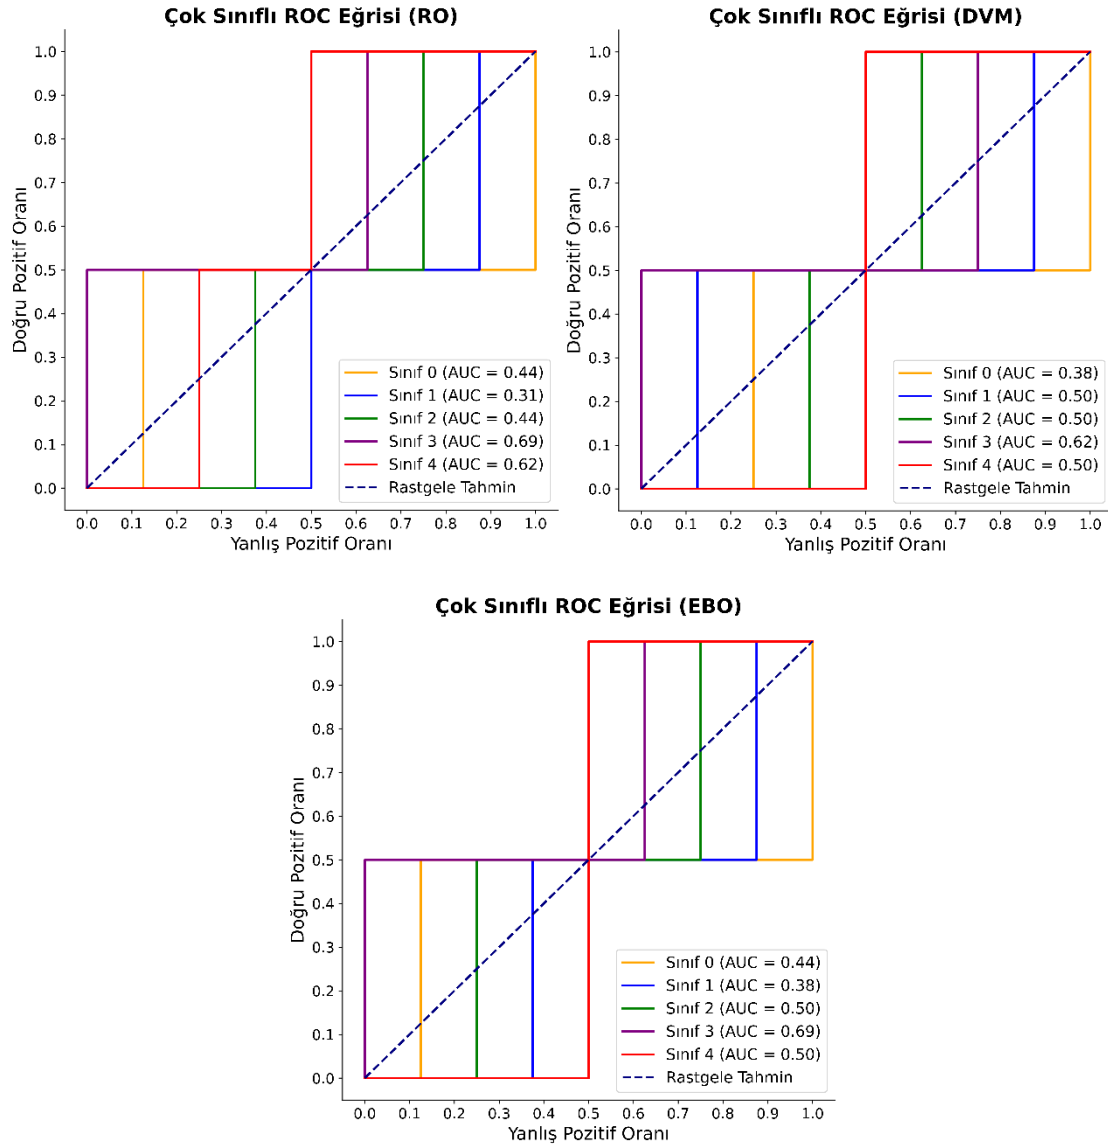
Tablo 7 incelendiğinde, su kütleleri sınıfına ait F1-skoru değerleri, DVM, RO ve EBO algoritmaları için en yüksek sonuçlara ulaşmıştır. En düşük değer, 0.50 ile yapay yüzeyler sınıfına ait hassasiyet metriğinde tespit edilmiştir.

F1-skoru, kesinlik ve hassasiyet metrislerinin harmonik bir ortalamasıdır ve 0 ve 1 arasında değişkenlik göstermektedir. F1-skoru için 0.7 değeri, modelin iyi bir performans gösterdiğini işaret eder (Goutte & Gaussier, 2005). F1-skorunun 1'e yaklaşması, bu hata matrisinin daha başarılı sonuçlar verdiği anlamına gelir. Bununla birlikte iyi bir F1-skoru değeri, sınıflandırıcının daha az oranda yanlış tahmin edilen pozitif örneklere ve yanlış tahmin edilen negatif örneklere sahip olduğu anlamına gelir (Alakus & Turkoglu, 2020).

Tablo 7. Arazi kullanım/arazi örtüsü sınıfları için DVM, RO ve EBO sınıflandırma algoritmalarının karşılaştırılması

Sınıflar	Doğruluk			Kesinlik			Hassasiyet			F1-skoru		
	DVM	RO	EBO	DVM	RO	EBO	DVM	RO	EBO	DVM	RO	EBO
Su Kütleleri	1.00	1.00	0.98	1.00	1.00	1.00	1.00	1.00	0.91	1.00	1.00	0.95
Orman	0.96	0.94	0.94	0.90	0.82	0.82	0.90	0.90	0.90	0.90	0.86	0.86
Yapay Yüzeyler	0.90	0.92	0.86	0.78	0.80	0.71	0.70	0.80	0.50	0.74	0.80	0.59
Tarım Alanları	0.94	0.92	0.90	0.83	0.71	0.67	0.71	0.71	0.57	0.77	0.71	0.62
Mera	0.96	0.98	0.92	0.86	0.85	0.75	1.00	0.92	1.00	0.92	0.88	0.86

Bu çalışmada, DVM, RO ve EBO algoritmaları kullanılarak sınıflandırılmış arazi kullanımı/arazi örtüsü sınıflarına yönelik ait ROC eğrileri oluşturulmuş ve ROC eğrisi altında kalan en yüksek AUC değerinin 0.69 ile tarım alanları sınıfı için RO ve EBO algoritmalarında elde edildiği gözlemlenmiştir. En düşük AUC değerleri ise 0.31 ile orman sınıfı için RO algoritmasında tespit edilmiştir. En büyük olasılık ve rastgele orman algoritması kullanılarak sınıflandırılmış uydu görüntüsünde tarım alanları sınıfına ait AUC değerleri hariç, diğer sınıflandırma algoritmaları ile sınıflandırılmış arazi kullanımı/arazi örtüsü sınıflarına yönelik AUC değerlerinin 0.6'dan düşük olması nedeniyle modele dayalı performansları 'zayıf' kategorisinde değerlendirilmiştir (Hanley & McNail, 1982). Bu AUC değerlerine göre, sınıflandırma algoritmalarına ait arazi kullanımı/arazi örtüsü sınıfları arasında çok güçlü bir ayırım yapılamadığı sonucuna varılmıştır (Miao & Zhu, 2022). DVM, RO ve EBO algoritmalarına yönelik oluşturulan ROC eğrileri Şekil 11'de verilmiştir.



Şekil 11. RO, DVM ve EBO algoritmaları için ROC eğrileri

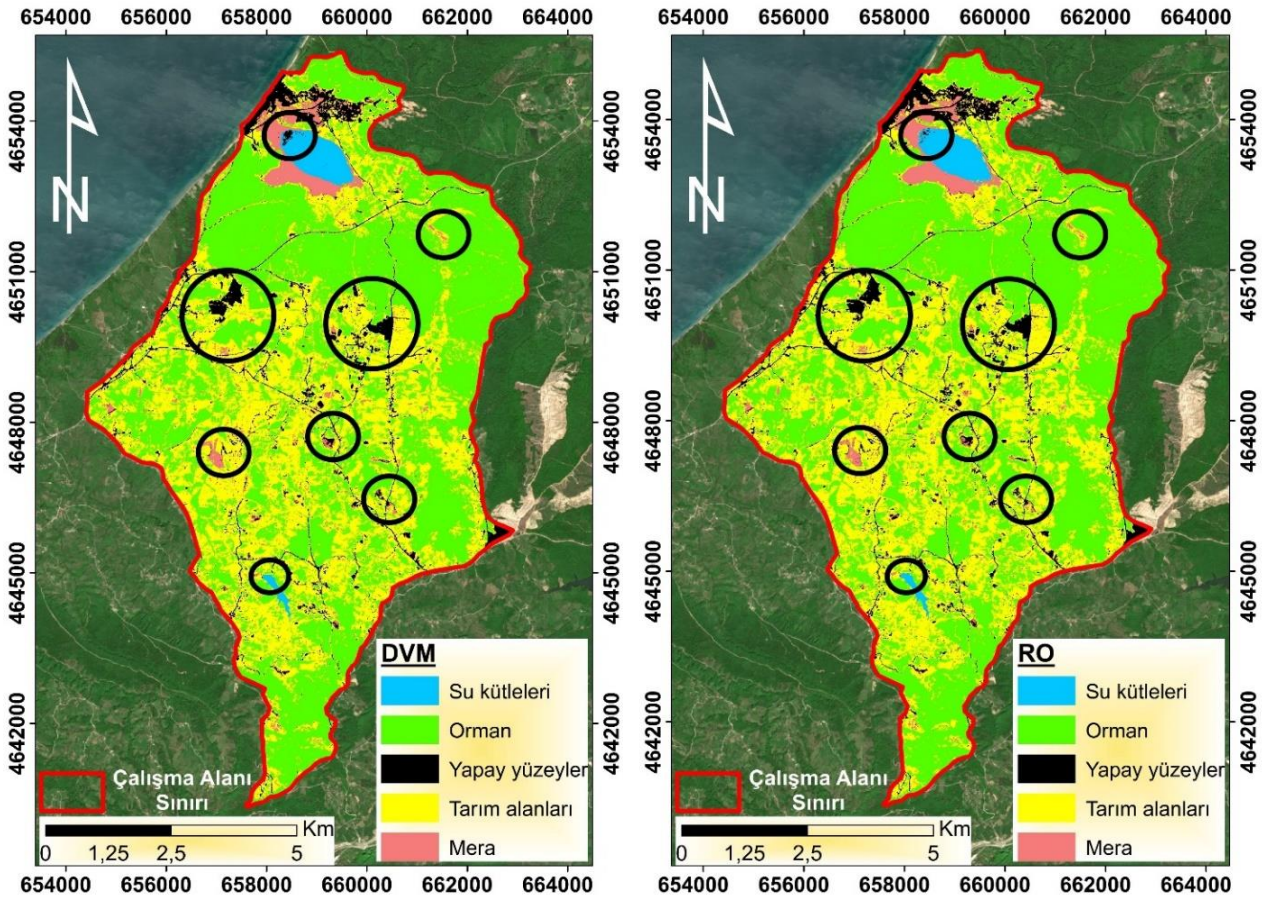
Şekil 11'e baktığımızda AUC değerlerinin, her bir sınıflandırma sistemine yönelik nerdeyse bütün arazi kullanımı/arazi örtüsü sınıfları için 'zayıf' olarak kategorize edildiğini görmekteyiz (<0.6) (Hanley & McNail, 1982). Şekildeki grafiklerde yer alan çapraz şerit çizgi 'rastgele bir tahmin' anlamına gelir ve model tarafından anlamsız kabul edilir. Eğri sol üst köşeye yaklaştıkça modelin performansı önemli ölçüde artar. Çapraz çizginin altındaki herhangi bir eğri, performansın rastgele bir tahminden daha kötü olduğunu gösterir.

Eğitim setlerinin oluşturulmasında kullanılan örnekleme noktalarının her ne kadar çalışma alanında eşit dağılmış olmasına dikkat edilse de elde edilen AUC değerlerinin nerdeyse bütün arazi kullanımı/arazi örtüsü sınıfları için düşük olması, veri setlerinde bir dengesizlik olduğunu göstermektedir.

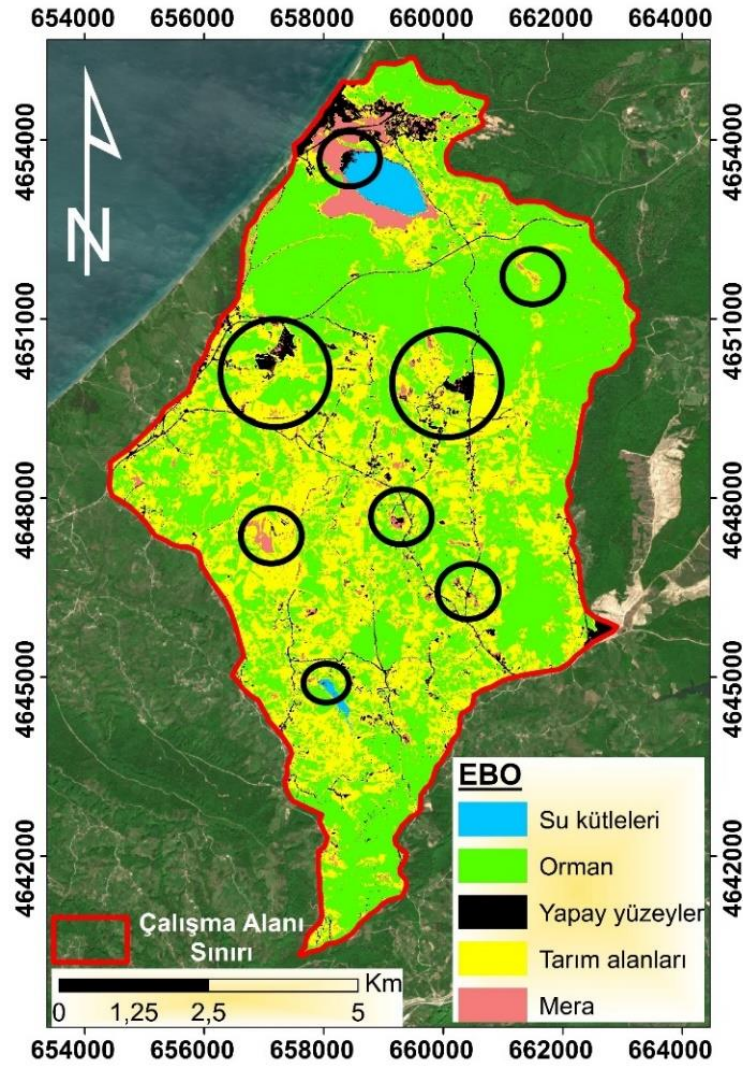
Eğitim setinin oluşturulduğu aşamada bazı arazi kullanımı/arazi örtüsü sınıfları için çok sayıda piksel toplanırken bazı sınıfların ise daha az piksel kullanılarak temsil edildiği durumlar oluşabilir. Eşit olmayan piksel dağılımı, sınıflandırma modelinin bazı sınıfları diğerlerine göre daha az temsil etmesine yol açabilir (Üstüner vd., 2018). Bu durumda, modelin daha çok temsil edilen sınıflara karşı daha iyi performans göstermesi muhtemeldir, ancak daha az temsil edilen sınıflar için performans düşebilir.

Düşük AUC değerleriyle birlikte, karışıklık matrislerindeki pozitif ve negatif olarak tahmin edilen örneklerdeki farklılıkların fazla olması, yani pozitif olarak tahmin edilen örneklerin negatif olarak tahmin edilenlerden yüksek olması ya da tam tersi durumun olması gibi nedenlerden dolayı veri setlerinin dengesiz dağıldığı durumlar veri setindeki dengesizliğe işaret etmektedir (Saito & Rehmsmeier, 2015). Aynı zamanda bazı sınıflar için doğruluk (accuracy) değeri yüksekken, hassasiyet (sensitivity) ya da kesinlik (precision) değerlerinin düşük olması da dengesiz bir verinin varlığına diğer bir kanıttır. Eşit olmayan sınıf dağılımı durumunun normal bir durum olduğu ve gerçek olan veri setlerinde karşılaşılabilecek bir durum olduğu birçok bilimsel çalışmada belirtilmiştir (Chawla vd., 2002; Chawla vd., 2004; Rao vd., 2006; Kubat vd., 1998; Khan vd., 2017; Dong vd., 2018; Wang vd., 2021).

Destek vektör makinesi, rastgele orman ve en büyük olasılık algoritmaları kullanılarak kontrollü sınıflandırılmış Sentinel-2A MSI uydu görüntüleri Şekil 12 ve Şekil 13'de verilmiştir. Şekil 12 ve Şekil 13'de verilen haritalar incelendiğinde, farklı algoritmalar kullanılarak sınıflandırılan uydu görüntüleri arasında çok küçük farklılıkların bulunduğu görülmektedir ve bu farklılıklar sınıflandırılmış uydu görüntülerinde siyah daire içerisine alınmıştır. Özellikle yapay yüzeyler sınıfının her bir sınıflandırılmış uydu görüntüsü üzerindeki farklı dağılımı dikkat çekicidir.



Şekil 12. DVM ve RO algoritmaları kullanılarak kontrollü sınıflandırılmış Sentinel-2A MSI uydu görüntüleri



Şekil 13. En büyük olasılık algoritması kullanılarak kontrollü sınıflandırılmış Sentinel-2A MSI uydu görüntüsü

4. Sonuç ve Öneriler

Bu çalışmada, Sinop havzasına yönelik arazi kullanımı/arazi örtüsü sınıflarının makine öğrenmesi tabanlı destek vektör makinesi, rastgele orman ve en büyük olasılık algoritmaları kullanılarak piksel tabanlı kontrollü sınıflandırılması ve tüm sınıflandırma algoritmalarına yönelik genel doğruluk (overall accuracy) değerleri ile, her bir arazi kullanımı/arazi sınıfına ait üretici doğruluğu (producer accuracy), kullanıcı doğruluğu (user accuracy), kesinlik (precision), doğruluk (accuracy), hassasiyet (sensitivity) ve F1-skoru metriklerine ait değerlerin kıyaslanması amaçlanmıştır.

Arazi kullanımı/arazi örtüsü hakkında detaylı bilgi sahibi olunması, çevre koruma, mekânsal planlama, ticari, politik ve idari amaçların yerine getirilmesinde önemli bir rol oynamaktadır. Bu bağlamda, uzaktan algılama ve coğrafi bilgi sistemleri tekniklerinin birlikte kullanılması, tematik verilerin elde edilmesinde kritik bir kaynaktır. Elde edilen sonuçlar DVM ve RO algoritmalarının EBO yöntemine göre daha yüksek ve benzer genel doğruluk değerleri verdiğini göstermiştir (0.88). Her bir sınıflandırma algoritması için su kütleleri ve mera sınıflarının en yüksek doğruluk, kesinlik, hassasiyet ve F1-skoru değerlerine sahip olduğu gözlemlenmiştir. Python programlama dilinden faydalanılarak oluşturulan ROC eğrileri ve bu eğrilerin altında kalan AUC değerleri incelendiğinde rastgele orman algoritmasıyla sınıflandırılan tarım alanları sınıfının, diğer arazi kullanımı/arazi örtüsü sınıflarına göre daha yüksek bir performans gösterdiği sonucuna varılmıştır. Ancak, dengesiz veri seti dağılımının çoğu arazi kullanımı/arazi örtüsü sınıfı için düşük AUC değerlerine yol açtığı ve bu durumun model performanslarını olumsuz yönde etkilediği görülmüştür. Bu sorunun, eğitim seti oluşturulurken bazı sınıflar için çok sayıda piksel toplanırken diğerlerinin daha az piksel ile temsil edilmesinden kaynaklanabileceği ve modelin bazı sınıfları diğerlerinden daha iyi tanımasına yol açabileceğinden ileri geldiği araştırmacılar tarafından ortaya konmuştur.

Bu çalışmada kullanılan her bir hata metriğinin kendine özgü avantajları ve dezavantajları bulunmaktadır. Veri setindeki dengesizliğin giderilmesi adına, daha fazla verinin toplanması, az örnekleme (undersampling) ya da aşırı örnekleme (oversampling) gibi çözüm yollarından faydalanılabilir.

Her bir metrik, verilerin dengeli ya da dengesiz dağılımına bağlı olarak farklılık gösterebileceğinden, gelecekte yapılacak çalışmalarda verilere ait sınıf dağılımlarının dikkate alınması ve en uygun hata metriğinin sınıflandırma algoritmasının doğruluğunun değerlendirilmesinde kullanılması araştırmacılar tarafından önerilmektedir. Bu çalışmada, ArcGIS 10.7v yazılımının bünyesinde bulundurduğu destek vektör makinesi, rastgele orman ve en büyük olasılık algoritmalarının sahip oldukları varsayılan (default) parametreler ile sınıflandırma işlemleri gerçekleştirilmiştir. Python programlama dili ya da Python ile entegre çalışabilen QGIS gibi açık kaynaklı bir yazılım, sınıflandırmada kullanılacak destek vektör makinesi ya da rastgele orman algoritmalarına ait parametrelerin optimizasyonunda kullanılarak daha sağlıklı doğruluk (accuracy) ya da AUC değerleri elde edilebilir.

Sonuç itibarıyla, uzaktan algılama ve coğrafi bilgi sistemleri teknolojilerinden faydalanılarak elde edilen bu çalışma ile farklı sınıflandırma algoritmalarının karşılaştırılması ve performans analizlerinin belirlenmesinin, bu alanda ileriye dönük yapılacak araştırmalara rehberlik edebilecek bir kaynak olacağı düşünülmektedir.

Kaynaklar

- Adam, E., Mutanga, O., Odindi, J., & Abdel-Rahman, E. M. (2014). Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing*, 35(10), 3440-3458.
- Akar, Ö., & Güngör, O. (2012). Classification of multispectral images using Random Forest algorithm. *Journal of Geodesy and Geoinformation*, 1(2), 105-112.
- Alakus, T. B., & Turkoglu, I. (2020). Comparison of deep learning approaches to predict COVID-19 infection. *Chaos, Solitons & Fractals*, 140, Article 110120. <https://doi.org/10.1016/j.chaos.2020.110120>
- Bawa, A., Samanta, S., Himanshu, S. K., Singh, J., Kim, J., Zhang, T., ... & Ale, S. (2023). A support vector machine and image processing based approach for counting open cotton bolls and estimating lint yield from UAV imagery. *Smart Agricultural Technology*, 3, Article 100140. <https://doi.org/10.1016/j.atech.2022.100140>
- Billah, M., Islam, A. S., Mamoon, W. B., & Rahman, M. R. (2023). Random forest classifications for landuse mapping to assess rapid flood damage using Sentinel-1 and Sentinel-2 data. *Remote Sensing Applications: Society and Environment*, 30, Article 100947. <https://doi.org/10.1016/j.rsase.2023.100947>
- Braun, A., & Hochschild, V. (2017). A SAR-based index for landscape changes in African savannas. *Remote Sensing*, 9(4), Article 359. <https://doi.org/10.3390/rs9040359>
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Bromová, P., Škoda, P., & Vážný, J. (2014). Classification of spectra of emission line stars using machine learning techniques. *International Journal of Automation and Computing*, 11(3), 265-273.
- Campbell, J. B., & Wynne, R. H. (2002). *Introduction to remote sensing*. Guilford Press.
- Campbell, J. B., & Wynne, R. H. (2011). *Introduction to remote sensing*. Guilford Press.
- Carranza-García, M., García-Gutiérrez, J., & Riquelme, J. C. (2019). A framework for evaluating land use and land cover classification using convolutional neural networks. *Remote Sensing*, 11(3), Article 274. <https://doi.org/10.3390/rs11030274>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321-357.
- Chawla, N. V., Japkowicz, N., & Kotcz, A. (2004). Special issue on learning from imbalanced data sets. *ACM SIGKDD explorations newsletter*, 6(1), 1-6. <https://doi.org/10.1145/1007730.1007733>
- Che, T., Xiao, L., & Liou, Y. A. (2014). Changes in glaciers and glacial lakes and the identification of dangerous glacial lakes in the Pumqu River Basin, Xizang (Tibet). *Advances in meteorology*, 2014, Article ID 903709. <http://dx.doi.org/10.1155/2014/903709>
- Chen, Z., Wang, L., Wei, A., Gao, J., Lu, Y., & Zhou, J. (2019). Land-use change from arable lands to orchards reduced soil erosion and increased nutrient loss in a small catchment. *Science of the Total Environment*, 648, 1097-1104.
- Civco, D. L. (1993). Artificial neural networks for land-cover classification and mapping. *International journal of geographical information science*, 7(2), 173-186.
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote sensing of environment*, 37(1), 35-46.
- Cunningham, P., Cord, M., & Delany, S. J. (2008). Supervised learning, machine learning techniques for multimedia. *Springer-Verlag Berlin, Heidelberg*.
- Çölkesen, İ. (2009). *Uzaktan algılamada ileri sınıflandırma tekniklerinin karşılaştırılması ve analizi* [Yüksek lisans tezi, Gebze Yüksek Teknoloji Enstitüsü]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>

- Dao, P. D., & Liou, Y. A. (2015). Object-based flood mapping and affected rice field estimation with Landsat 8 OLI and MODIS data. *Remote Sensing*, 7(5), 5077-5097.
- Demir, N., Sonmez, N.K., Akar, T., Ünal, S., (2018). Automated Measurement of Plant Height of Wheat Genotypes Using a DSM Derived from UAV Imagery. *Proceedings of the 2nd International Electronic Conference on Remote Sensing* 2(7), Article 350. <https://doi.org/10.3390/ecrs-2-05163>.
- Dietterich, T. G. (2020). An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. *Machine Learning*, 40, 139–157.
- Disperati, L., & Virdis, S. G. P. (2015). Assessment of land-use and land-cover changes from 1965 to 2014 in Tam Giang-Cau Hai Lagoon, central Vietnam. *Applied Geography*, 58, 48-64.
- Dong, R., Zhang, Y., & Zhao, J. (2018). How green are the streets within the sixth ring road of Beijing? An analysis based on tencent street view pictures and the green view index. *International journal of environmental research and public health*, 15(7), Article 1367. <https://doi.org/10.3390/ijerph15071367>
- ED Chaves, M., CA Picoli, M., & D. Sanches, I. (2020). Recent applications of Landsat 8/OLI and Sentinel-2/MSI for land use and land cover mapping: A systematic review. *Remote Sensing*, 12(18), Article 3062. <https://doi.org/10.3390/rs12183062>
- Eskandari, S., Sarab, S. A. M., Pourhashemi, M., & Ahmadloo, F. (2022). Selection of the best pixel-based algorithm for land cover mapping in Zagros forests of Iran using Sentinel-2A data: A case study in Khuzestan province. In H. R. Pourghasemi (Ed.), *Computers in Earth and Environmental Sciences* (pp. 181-190). Elsevier.
- Foody, G. M., & Mathur, A. (2004). Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification. *Remote Sensing of Environment*, 93(1-2), 107-117.
- Gao, Z., Cecati, C., & Ding, S. X. (2015). A survey of fault diagnosis and fault-tolerant techniques—Part I: Fault diagnosis with model-based and signal-based approaches. *IEEE transactions on industrial electronics*, 62(6), 3757-3767.
- Ghansah, B., Nyamekye, C., Owusu, S., & Agyapong, E. (2021). Mapping flood prone and Hazards Areas in rural landscape using landsat images and random forest classification: Case study of Nasia watershed in Ghana. *Cogent Engineering*, 8(1), Article 1923384. <https://doi.org/10.1080/23311916.2021.1923384>
- Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern recognition letters*, 27(4), 294-300.
- Goutte, C., & Gaussier, E. (2005). A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In D. E. Losada & J. M. Fernández-Luna (Eds.), *Advances in Information Retrieval* (pp. 345-359). Springer Berlin Heidelberg.
- Gumma, M. K., Thenkabail, P. S., Teluguntla, P. G., Oliphant, A., Xiong, J., Giri, C., ... & Whitbread, A. M. (2020). Agricultural cropland extent and areas of South Asia derived using Landsat satellite 30-m time-series big-data using random forest machine learning algorithms on the Google Earth Engine cloud. *GIScience & Remote Sensing*, 57(3), 302-322.
- Guo, L., Chehata, N., Mallet, C., & Boukir, S. (2011). Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(1), 56-66.
- Günlü, A. (2012). Landsat TM uydu görüntüsü yardımıyla bazı meşçere parametreleri (gelişim çağı ve kapalılık) ve arazi kullanım sınıflarının belirlenmesi. *Kastamonu University Journal of Forestry Faculty*, 12(1), 71-79.
- Halder, S., Das, S., & Basu, S. (2023). Use of support vector machine and cellular automata methods to evaluate impact of irrigation project on LULC. *Environmental Monitoring and Assessment*, 195(1), Article 3. <https://doi.org/10.1007/s10661-022-10588-6>
- Hanley, J. A., & McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 143(1), 29-36.
- Hashem, N., & Balakrishnan, P. (2015). Change analysis of land use/land cover and modelling urban growth in Greater Doha, Qatar. *Annals of GIS*, 21(3), 233-247.
- Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of remote sensing*, 23(4), 725-749.
- Jensen, J. R. (2005). *Digital image processing: a remote sensing perspective* (3rd ed.). Prentice Hall.
- 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.
- Kavzoğlu, T., & Çölkesen, İ. (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.
- Khan, S. H., Hayat, M., Bennamoun, M., Soheli, F. A., & Togneri, R. (2017). Cost-sensitive learning of deep feature representations from imbalanced data. *IEEE transactions on neural networks and learning systems*, 29(8), 3573-3587.
- Kubat, M., Holte, R. C., & Matwin, S. (1998). Machine learning for the detection of oil spills in satellite radar images. *Machine learning*, 30, 195-215.

- Kundu, R. (2022, September 13). *Confusion Matrix: How To Use It & Interpret Results*. V7 Labs. <https://www.v7labs.com/blog/confusion-matrix-guide>
- Lillesand T., Kiefer R., & Chipman, J. (2004). *Remote Sensing and Image Interpretation*. John Wiley and Sons.
- Liou, Y. A., Nguyen, A. K., & Li, M. H. (2017). Assessing spatiotemporal eco-environmental vulnerability by Landsat data. *Ecological Indicators*, 80, 52-65.
- Mather, P., & Tso, B. (2016). *Classification methods for remotely sensed data*. CRC press.
- 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.
- Merchant, J. W., & Narumalani, S. (2009). Integrating remote sensing and geographic information systems. In T.A. Warner, M. D. Nellis & G. M. Foody (Eds.), *The SAGE handbook of remote sensing* (pp. 257-268). SAGE Publications.
- Miao, J., & Zhu, W. (2022). Precision–recall curve (PRC) classification trees. *Evolutionary intelligence*, 15(3), 1545-1569. <https://doi.org/10.1007/s12065-021-00565-2>
- Moran, E. F., Skole, D. L., & Turner, B. L. (2004). The development of the international land-use and land-cover change (LUCC) research program and its links to NASA's Land-Cover and Land-Use Change (LCLUC) Initiative. In G. Gutman, A. C. Janetos, C. O. Justice, E. F. Moran, J. F. Mustard, R. R. Rindfuss D. Skole, B. L. Turner & M. A. Cochrane (Eds.), *Land Change Science: Observing, Monitoring and Understanding Trajectories of Change on the Earth's Surface* (Vol. 6, pp. 1-15). Springer. https://doi.org/10.1007/978-1-4020-2562-4_1
- Murty, P. S., & Tiwari, H. (2015). Accuracy assessment of land use classification—a case study of Ken Basin. *Journal of Civil Engineering and Architecture Research*, 2(12), 1199-1206.
- Muslim, M. A. (2020). Support vector machine (svm) optimization using grid search and unigram to improve e-commerce review accuracy. *Journal of Soft Computing Exploration*, 1(1), 8-15.
- Myung, I. J. (2003). Tutorial on maximum likelihood estimation. *Journal of mathematical Psychology*, 47(1), 90-100.
- Nakach, F. Z., Zerouaoui, H., & Idri, A. (2022). Random forest based deep hybrid architecture for histopathological breast cancer images classification. In O. Gervasi, B. Burgante, E. M. T. Hendrix, D. Taniar & B. O. Apduhan (Eds.), *Computational Science and Its Applications* (Vol. 13376, pp. 3-18). Springer.
- Nguyen, A. K., Liou, Y. A., Li, M. H., & Tran, T. A. (2016). Zoning eco-environmental vulnerability for environmental management and protection. *Ecological Indicators*, 69, 100-117.
- Nguyen, K. A., & Liou, Y. A. (2019). Global mapping of eco-environmental vulnerability from human and nature disturbances. *Science of The Total Environment*, 664, 995-1004.
- Nguyen, K. A., Liou, Y. A., Tran, H. P., Hoang, P. P., & Nguyen, T. H. (2020). Soil salinity assessment by using near-infrared channel and Vegetation Soil Salinity Index derived from Landsat 8 OLI data: a case study in the Tra Vinh Province, Mekong Delta, Vietnam. *Progress in Earth and Planetary Science*, 7, 1-16.
- Nitze, I., Schulthess, U., & Asche, H. (2012, May 7-9). *Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification* [Conference paper]. 4th International conference on Geographic Object-Based Image Analysis (GEOBIA), Rio de Janeiro, Brazil.
- Okwuashi, O., & Ndehedehe, C. E. (2020). Deep support vector machine for hyperspectral image classification. *Pattern Recognition*, 103, Article 107298. <https://doi.org/10.1016/j.patcog.2020.107298>
- Orhan, O., Kirtiloğlu, O. S., & Yakar, M. (2020). Konya kapalı havzası obruk envanter bilgi sisteminin oluşturulması. *Geomatik*, 5(2), 81-90.
- Osenberg, M., Hilger, A., Neumann, M., Wagner, A., Bohn, N., Binder, J. R., ... & Manke, I. (2023). Classification of FIB/SEM-tomography images for highly porous multiphase materials using random forest classifiers. *Journal of Power Sources*, 570, Article 233030. <https://doi.org/10.1016/j.jpowsour.2023.233030>
- Öztürk, M. (2022, April 13). *Python ile Sınıflandırma Analizleri – Rastgele Orman (Random Forest) Algoritması*. <https://miracozturk.com/python-ile-siniflandirma-analizleri-rastgele-orman-random-forest-algoritmasi>
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International journal of remote sensing*, 26(1), 217-222.
- Pal, M., & Mather, P. M. (2005). Support vector machines for classification in remote sensing. *International journal of remote sensing*, 26(5), 1007-1011.
- Pal, S., & Talukdar, S. (2018). Drivers of vulnerability to wetlands in Punarbhaba river basin of India-Bangladesh. *Ecological Indicators*, 93, 612-626.
- 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>
- Pouyan, S., Pourghasemi, H. R., Bordbar, M., Rahmanian, S., & Clague, J. J. (2021). A multi-hazard map-based flooding, gully erosion, forest fires, and earthquakes in Iran. *Scientific Reports*, 11(1), Article 14889. <https://doi.org/10.1038/s41598-021-94266-6>

- Rana, V. K., & Suryanarayana, T. M. V. (2020). Performance evaluation of MLE, RF and SVM classification algorithms for watershed scale land use/land cover mapping using sentinel 2 bands. *Remote Sensing Applications: Society and Environment*, 19, Article 100351. <https://doi.org/10.1016/j.rsase.2020.100351>
- Rao, R. B., Krishnan, S., & Niculescu, R. S. (2006). Data mining for improved cardiac care. *Acm Sigkdd Explorations Newsletter*, 8(1), 3-10.
- Rauf, U., Qureshi, W. S., Jabbar, H., Zeb, A., Mirza, A., Alanazi, E., ... & Rashid, N. (2022). A new method for pixel classification for rice variety identification using spectral and time series data from Sentinel-2 satellite imagery. *Computers and Electronics in Agriculture*, 193, Article 106731. <https://doi.org/10.1016/j.compag.2022.106731>
- Rimal, B., Rijal, S., & Kunwar, R. (2020). Comparing support vector machines and maximum likelihood classifiers for mapping of urbanization. *Journal of the Indian Society of Remote Sensing*, 48(1), 71-79.
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS journal of photogrammetry and remote sensing*, 67, 93-104.
- Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS one*, 10(3), Article e0118432. <https://doi.org/10.1371/journal.pone.0118432>
- Samaniego, L., Bárdossy, A., & Schulz, K. (2008). Supervised classification of remotely sensed imagery using a modified k -NN technique. *IEEE Transactions on Geoscience and Remote Sensing*, 46(7), 2112-2125.
- Schneider, C. A., Rasband, W. S., & Eliceiri, K. W. (2012). NIH Image to ImageJ: 25 years of image analysis. *Nature methods*, 9(7), 671-675.
- Selim, S., & Demir, N. (2018). Analysis of landscape patterns and connectivity between tree clusters derived from LIDAR data. *Fresenius Environmental Bulletin*, 27(5A), 3512-3520.
- SEOS, (2018). *Introduction to Remote Sensing*. <https://seos-project.eu/remotesensing/remotesensing-c00-p02.html>
- Sheykhou, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325.
- Soyaslan, İ., & Hepdeniz, K. (2016). Coğrafi bilgi sistemleri ve uzaktan algılama kullanılarak Burdur ili arazi kullanımının zamansal değişiminin belirlenmesi. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 7(2), 94-101.
- Su, J., Yi, D., Liu, C., Guo, L., & Chen, W. H. (2017). Dimension reduction aided hyperspectral image classification with a small-sized training dataset: experimental comparisons. *Sensors*, 17(12), Article 2726. <https://doi.org/10.3390/s17122726>
- Talukdar, S., & Pal, S. (2019). Effects of damming on the hydrological regime of Punarbhaba river basin wetlands. *Ecological Engineering*, 135, 61-74.
- Talukdar, S., Singha, P., Mahato, S., Praveen, B., & Rahman, A. (2020). Dynamics of ecosystem services (ESs) in response to land use land cover (LU/LC) changes in the lower Gangetic plain of India. *Ecological Indicators*, 112, Article 106121. <https://doi.org/10.1016/j.ecolind.2020.106121>
- Tao, D., Tang, X., Li, X., & Wu, X. (2006). Asymmetric bagging and random subspace for support vector machines-based relevance feedback in image retrieval. *IEEE transactions on pattern analysis and machine intelligence*, 28(7), 1088-1099.
- Tehrany, M. S., Pradhan, B., Mansor, S., & Ahmad, N. (2015). Flood susceptibility assessment using GIS-based support vector machine model with different kernel types. *Catena*, 125, 91-101.
- Tian, S., Zhang, X., Tian, J., & Sun, Q. (2016). Random forest classification of wetland landcovers from multi-sensor data in the arid region of Xinjiang, China. *Remote Sensing*, 8(11), Article 954. <https://doi.org/10.3390/rs8110954>
- Tiwari, R., Sharma, R., & Dubey, R. (2022, September). Microstrip Patch Antenna Parameter Optimization Prediction Model using Machine Learning Techniques. *International Journal on Recent and Innovation Trends in Computing and Communication*, 10(9), 53-59.
- Topaloğlu, R. H., Sertel, E., & Musaoğlu, N. (2016, July 12-19). *Assessment of classification accuracies of Sentinel-2 and Landsat-8 data for land cover/use mapping* [Conference paper]. The International archives of the photogrammetry, remote sensing and spatial information sciences, Prague, Czech Republic.
- Üstüner, M., Balık Şanlı, F., & Abdikan, S. (2014, 14-17 Ekim). *Kırmızı-Kenar Ve Yakın Kızılötesi Bantlarının Ürün Deseni Sınıflandırma Doğruluğuna Olan Etkisinin Araştırılması* [Tam metin bildirisi]. V. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, Türkiye.
- Üstüner, M., Gökdağ, Ü., Bilgin, G., & Şanlı, F. B. (2018, May 2-5). *Comparing the classification performances of supervised classifiers with balanced and imbalanced SAR data sets* [Conference paper]. 26th Signal Processing and Communications Applications Conference, İzmir, Türkiye.

- Wang, L., Zhang, L., Qi, X., & Yi, Z. (2021). Deep attention-based imbalanced image classification. *IEEE transactions on neural networks and learning systems*, 33(8), 3320-3330.
- Yan, G., Mas, J. F., Maathuis, B. H. P., Xiangmin, Z., & Van Dijk, P. M. (2006). Comparison of pixel-based and object-oriented image classification approaches—a case study in a coal fire area, Wuda, Inner Mongolia, China. *International Journal of Remote Sensing*, 27(18), 4039-4055.
- Zhang, T. X., Su, J. Y., Liu, C. J., & Chen, W. H. (2019). Potential bands of sentinel-2A satellite for classification problems in precision agriculture. *International Journal of Automation and Computing*, 16, 16-26.
- Zhang, T., Su, J., Liu, C., Chen, W. H., Liu, H., & Liu, G. (2017, September 7-8). *Band selection in sentinel-2 satellite for agriculture applications* [Conference paper]. 23rd International Conference on Automation and Computing, Huddersfield, UK.
- Zhang, Y., Ge, T., Tian, W., & Liou, Y. A. (2019). Debris flow susceptibility mapping using machine-learning techniques in Shigatse area, China. *Remote Sensing*, 11(23), Article 2801. <https://doi.org/10.3390/rs11232801>

NDVI ve LST Faktörlerinin Kentsel Alanlarda Gayrimenkul Değeri Üzerindeki Etkisinin Araştırılması: Ankara, İstanbul, İzmir ve Mersin Örneği

Investigating the Impact of NDVI and LST Factors on Real Estate Values in Urban Areas: Ankara, Istanbul, Izmir and Mersin Cases

Selin Uyar^{1*}, Muzaffer Can İban²

¹Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı, 33343, Mersin/Türkiye.

²Mersin Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 33343, Mersin/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Selin Uyar
slnuyarr@gmail.com

doi: 10.48123/rsgis.1423218

Yayın süreci

Geliş tarihi: 21.01.2024
Kabul tarihi: 06.05.2024
Basım tarihi: 26.09.2024

Özet

Bu çalışma, Ankara, İstanbul, İzmir ve Mersin kentlerinin merkezi ilçelerindeki ortalama konut satış fiyatları ile bu kentlerdeki Arazi Yüzey Sıcaklığı (LST) ve Normalleştirilmiş Bitki Örtüsü İndeksi (NDVI) arasındaki ilişkiyi bir regresyon analizi yöntemi ile incelemektedir. Temel amaç, farklı arazi kullanımı ve iklim koşullarına sahip kentler arasındaki NDVI ve LST değerlerindeki farklılıkları gözlemlemek ve bu değişkenlerin gayrimenkul fiyatlarına nasıl katkıda bulunduğunu anlamaktır. Mahallelere ait ortalama konut satış değerleri Endeksa.com sitesinden, NDVI ve LST değerleri ise Landsat 8 uydu görüntülerinden elde edilmiştir. Kentlere ait mahallelerin ortalama satış değeri ile NDVI ve LST arasında anlamlı bir ilişkinin olup olmadığını denetlemek için R^2 skoru ve p-değer ölçütleri kullanılarak regresyon analizi gerçekleştirilmiştir. NDVI ve LST'nin İstanbul'un Eyüp, Bahçelievler ve Çekmeköy ilçelerinde konut satış fiyatları üzerinde güçlü etkileri olduğu ($R^2 > 0,7$), Ankara'nın Çankaya ve İzmir'in Güzelbahçe ilçesinde ise daha hafif bir etkisi olduğu, Mersin Yenişehir ilçesinde ise diğer ilçelere göre daha yüksek etkisi olduğu tespit edilmiştir. Çalışmanın bulguları, kentlerdeki gayrimenkul piyasasına yeşil alan varlığının ve termal konforun nasıl etki ettiğini mahalle ölçeğinde tespit ederek, kentsel araştırmalara katkı sağlamaktadır.

Anahtar kelimeler: Gayrimenkul değeri, LST, NDVI, Regresyon, Kentsel iklim

Abstract

This study examines the relationship between average housing prices in central districts of Ankara, Istanbul, Izmir, and Mersin and Land Surface Temperature (LST) and Normalized Difference Vegetation Index (NDVI) in these cities through a regression analysis method. The primary aim is to observe differences in NDVI and LST values among cities with different land uses and climatic conditions and understand how these variables contribute to real estate prices. Average housing sales values for neighborhoods were obtained from Endeksa.com website, while NDVI and LST values were derived from Landsat 8 satellite images. Regression analysis was performed using R^2 scores and p-values as criteria to examine whether there is a significant relationship between average neighborhood sales values and NDVI and LST. The study found that NDVI and LST have a strong impact on housing prices in Istanbul's Eyüp, Bahçelievler, and Çekmeköy districts ($R^2 > 0.7$), a milder effect in Ankara's Çankaya and Izmir's Güzelbahçe districts, and a higher impact in Mersin's Yenişehir district compared to other districts. The findings of the study contribute to urban research by identifying how the presence of green spaces and thermal comfort affects real estate market at the neighborhood level in cities.

Keywords: Real estate price, LST, NDVI, Regression, Urban climate

1. Giriş

Nüfusun hızla arttığı ve imar faaliyetlerinin yoğunlaştığı günümüz kentlerinde, açık ve yeşil alanların azalması nedeniyle kentsel ısı adalarının (KIA) oluşumunda artış gözlemlenmektedir. Bu durum, kent sakinlerinin termal konforunu olumsuz yönde etkilemektedir (Zengin vd., 2019). Kentlerdeki farklı niteliklere sahip arazi kullanımlarının oluşturduğu termal konfor seviyesini belirlemek amacıyla çok sayıda çalışma yapılmıştır. Bu çalışmaların bulgularına göre kentler yoğunlaştıkça yeşil alan miktarında azalma ve yer yüzey sıcaklığında artış olduğu tespit edilmiştir (Diem vd., 2023). Dolayısıyla, kent sakinlerinin termal konforunun azalması ve gayrimenkul geliştirme faaliyetleri paralel bir seyir izlemiştir. Ancak, termal konfora etki eden yeşil alan miktarı ve yer yüzeyi sıcaklığı faktörlerinin, kentlerimizdeki gayrimenkul piyasasına ve gayrimenkul değerine etkisini belirleyen çalışmalar kısıtlıdır.

Termal konfor, insanın maruz kaldığı sıcaklık değerlerinden memnuniyeti ve insan ile onu çevreleyen ortam arasındaki ısı denge durumunu betimlemektedir (Molenaar vd., 2016). Termal konforu olumsuz yönde etkileyen en önemli unsur KIA'ların varlığıdır. Kent merkezlerinde kırsal alanlara göre daha yüksek sıcaklıklar gözlemlenir. Dolayısıyla, KIA'lar enerji tüketimini, hava kalitesini ve kent sakinlerinin sağlık ve refahını etkilemektedir (Tan vd., 2012). Kentlerin yapısal olarak ısıyı tutması ve havalandırmayı azaltan morfolojisi bu durumun sebepleri arasındadır (Taleghani vd., 2013). KIA'ların varlığı, bölgenin yer yüzeyi sıcaklığı (LST – *İng. Land Surface Temperature*) ile tespit edilmektedir. Yapılan çalışmaların bulguları göstermektedir ki, geçirimsiz yüzeylerin yoğunlaştığı ve yeşil alanların azaldığı kent bölgelerinde LST değerleri daha yüksektir. Kentlerdeki yeşil alanların ve ağaçların yoğunluğu ise KIA oluşumunu azaltmaktadır. (Mashhoodi, 2021). Yapılan çalışmalar açık bir şekilde, LST ile kentlerdeki yeşil alan yoğunluğu arasında ters orantılı bir ilişki olduğunu göstermektedir (Tan vd., 2012).

LST değerleri ve yeşil alanların dağılımı, uzaktan algılama uydularından elde edilen görüntülerden hesaplanabilmektedir. Uzaktan algılama uydularındaki termal bantlar sayesinde çalışma bölgelerine ait LST değerleri yüksek doğrulukla ve yeterli bir konumsal çözünürlükle ölçülebilmektedir. Bunun yanı sıra, sağlıklı bitki örtüsünün varlığını tespit etmek için Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI – *İng. Normalized Difference Vegetation Index*) kullanılmaktadır. LST ve NDVI verilerinin bütüncül bir şekilde kullanılması, kişilerin kent genelinde nerelerde yüksek sıcaklığa maruz kaldığını ve nerelerde sağlıklı yeşil alanlara erişip erişemeyeceğini tespit etmeye yardımcı olmaktadır (Jiao vd., 2017). Yapılan çalışmalar, NDVI ve LST değerleri arasında anlamlı bir ilişkinin var olduğunu belirlemiştir. Örneğin Erdem Okumus ve Terzi (2021), İstanbul kent genelinde LST değerleri ile NDVI değerleri arasında negatif bir korelasyon seyrettiğini tespit etmiştir. Ayrıca, İstanbul'da zayıf bitki örtüsünün KIA'ların oluşumuna doğrudan katkı sağladığını gözlemlemişlerdir. Bunu destekleyecek şekilde, Şekertekin ve Zadbagher (2021), Zonguldak kenti için gerçekleştirdikleri çalışmada Landsat verileri ile elde edilen LST ve NDVI değerleri arasında güçlü bir negatif korelasyon (-0.90) bulmuşlardır. Hidalgo Garcia vd. (2023), Kuzey Kıbrıs'ta kentleşme faaliyetlerinin artmasıyla, NDVI değerlerinin azaldığı bölgelerde LST değerlerinin yıllar içerisinde yükseldiği çıkarımında bulunmuşlardır.

NDVI ve LST değerlerinin gayrimenkul piyasalarına etkisi, çeşitli ülkelerdeki araştırmacılar tarafından ele alınmıştır. Örneğin Jiao vd. (2017), Çin'in Wuhan kenti için Landsat verilerinden elde edilen NDVI ve LST değerleri ile gayrimenkul satış değerleri arasında gerçekleştirdikleri regresyon analizinde, sıcaklıktaki %1'lik artışın ortalama m² satış değerlerinde 55 Yuan'lık (8.3 \$) bir azalış karşılık geldiğini; yüksek NDVI değerlerine sahip bölgelerde ise diğer bölgelere göre daha yüksek ortalama konut satış değeri gözlemlendiğini tespit etmiştir. Holt ve Borsuk (2020), ABD geneli 6000 mahalleye ait medyan konut satış değerlerini derleyerek, NDVI-değer ilişkisi üzerine bir regresyon analizi gerçekleştirmişlerdir. Yazarlar, park ve gölgeli alanların medyan konut satış değerlerine olumlu yönde katkı sağladığını gözlemlemişlerdir. Liebelt vd. (2018) ve Zambrano – Monserrate vd. (2021) ise çalışmalarında, kent sakinlerinin kent ormanlarına, parklara ve diğer tipteki yeşil alanlara erişimi kolay olan gayrimenkullere daha fazla fiyat ödeyebileceği sonucuna ulaşmışlardır.

Tüm bu literatürün ışığında bu çalışmanın amacı, açık erişimli ve mahalle ölçeğinde sunulan Ortalama Konut Satış Değerleri (OKSD) ile o mahallelere ait yaz aylarında elde edilmiş uydu görüntülerinden derlenen ortalama LST ve NDVI değerleri arasındaki ilişkiyi Türkiye'deki dört seçilmiş kent ölçeğinde anlamaktır. Bu ilişkinin araştırılması, konut piyasası üzerinde çevresel faktörlerin etkisini belirlemeye yönelik olup, bölgesel ölçekte konut satış fiyatlarındaki değişikliklerin, çevresel değişkenlerdeki farklılıklara nasıl bağlı olduğunu analiz etmeyi amaçlamaktadır.

Bu kapsamda seçilen dört kent (Ankara, İstanbul, İzmir ve Mersin) kentsel yerleşim alanı olarak kullanılan mahallelerinde, ortalama LST ve NDVI değerlerinin OKSD'ye olan etkisi görselleştirilmiş ve tartışılmıştır.

2. Materyal ve Metot

2.1. Çalışma Alanı

Çalışma alanları olarak Ankara, İstanbul, İzmir ve Mersin kentleri seçilmiştir. Bu kentlerin farklı coğrafi bölgelerde bulunmasından dolayı, iklimsel, kentsel ve demografik özellikleri de farklıdır.

Ankara kenti, ülkenin nüfus bakımından en kalabalık şehirlerinden biridir ve bulunduğu konum gereği kış aylarında düşük sıcaklık ortalamalarına sahiptir. Kent merkezinde yoğun bir yapılaşma söz konusudur. Son yıllarda artan nüfus, yapılaşmanın kent merkezinin etrafına doğru genişlemesine sebep olmuştur.

İstanbul, Karadeniz ve Marmara Denizi'ne kıyısında bulunan ve ülkenin en kalabalık nüfusunu barındıran kenttir. Yazlar sıcak ve nemli, kış ayları ise soğuk, yağışlı ve bazen kar yağışlı geçmektedir. Kentte doğu – batı yönünde düzensiz ve yoğun bir yapılaşma söz konusudur. İstanbul'da artan göçler sebebiyle nüfus yoğunluğu 2000-2017 yılları arasında %54 artmış ve yerleşim alanları doğu – batı yönünde %10'luk bir genişleme göstermiş, aynı zamanda kuzey yönündeki orman alanlarına doğru da kaymaya başlamıştır (Zorlu & Yoloğlu, 2022).

İzmir, Ege Bölgesi'nde yer alan, yaz mevsimi sıcak ve kurak, kış mevsimi ılık ve yağışlı geçen bir şehirdir. Ülkenin nüfus bakımından en kalabalık üçüncü şehridir. 2018 verilerine göre İzmir, nüfus yoğunluğu, kent nüfusu oranı ve nüfus artışı açısından Türkiye ortalamasının üzerinde değerlere sahiptir. İzmir'de homojen olarak dağılmayan yüksek bir yapılaşma gözlemlenmektedir (Ünal, 2020).

Mersin, Akdeniz Bölgesi'nde yer alan, İzmir gibi yaz ayları sıcak ve kurak, kış ayları ise ılık ve yağışlı geçen bir şehirdir. Mersin; İstanbul, Ankara ve İzmir'e kıyasla daha düşük yeşil alan yoğunluğuna sahiptir (Alkan & Uslu, 2016). Kent, doğu – batı yönünde sahil şeridi boyunca yüksek ve yoğun yapılaşmaya sahiptir. Mersin kenti ticari, sanayi ve ılıman iklim özelliklerinden dolayı çevre illerden ve bölgelerden göç almaktadır (Doğan & Özdemir, 2021). Bunun sonucunda, son yıllarda kent kuzey yönüne doğru büyümeye başlamıştır.

2.2. Kullanılan Veri Kaynakları

2.2.1. Mahallelerin Ortalama Konut Satış Değer Eldesi

Çalışma kapsamında, bu dört kentin seçiminde iklimsel, kentsel ve demografik özelliklerin farklı oluşu etkili olmuştur. Bu kentler özelinde yapılan regresyon analizi mahalle ölçeğinde gerçekleştirilmiştir. Dolayısıyla, bu kentlerin güncel mahalle sınırlarının bulunduğu vektör veriler yerel yönetimlerden temin edilmiştir. Bu kentlerin yoğun nüfus ve yapılaşma barındıran mahalleleri analiz kapsamında kullanılmış ve kırsal özellikli mahalleleri hariç bırakılmıştır. Sonuç olarak, İstanbul'da 39 ilçe, Ankara'da 8 ilçe, İzmir'de 11 ilçe ve Mersin'de 4 ilçe dahilinde OKSD verileri mahalle ölçeğinde elde edilmiştir.

Bahsi geçen tüm ilçelere ait mahallelerin OKSD verileri, Endeksa.com adlı web sitesinin açık erişimli verilerinden manuel olarak derlenmiştir. Endeksa, büyük veri analizi ve makine öğrenmesi yöntemlerini kullanarak, tüm Türkiye için gayrimenkul değeri, lokasyon veri analizi ve öngörülerini sunan ticari bir girişimdir. Veri toplama işleminde, Kasım 2022 tarihli değerler kullanılmıştır (Endeksa, 2023). Endeksa sitesinde değer verisi bulunmayan mahalleler boş bırakılmıştır. Nihayetinde, bu dört kente ait mahalle sınırlarını içeren ve Coğrafi Bilgi Sistemi (CBS) yazılımlarında kullanılmaya hazır .shp formatındaki vektör verilere, derlenen OKSD verileri öznitelik olarak eklenmiştir. Belediyelerden gelen mahalle isimleri ile Endeksa.com'daki isimler arasında uyumsuzluk söz konusu olduğunda, belediyelerden temin edilen verilerdeki mahalle isimleri esas alınmıştır. Aynı isimdeki mahallelerin ayırt edilebilmesi için, her bir mahalleye tekil kod ataması da gerçekleştirilmiştir.

2.2.2. Landsat 8 Görüntülerinin Eldesi

OKSD'leri tespit edilen dört şehre ait mahallelerin ortalama NDVI ve LST değerleri, 2022 yaz aylarına ait Landsat 8 OLI ve TIRS sensörlerinden elde edilen uzaktan algılama verileri ile derlenmiştir. Çalışma alanına ait NDVI ve LST verileri, Google Earth Engine (GEE) platformunda derlenerek bilgisayar ortamına aktarılmıştır. GEE, bulut tabanlı olarak kullanılan jeomekansal bir web platformudur. Çok fazla sayıda, farklı türlerdeki veri setine erişmeyi, bu verileri yönetmeyi ve üzerinde analiz yapmayı sağlayan GEE, son yıllarda yaygın bir şekilde kullanılmaktadır (Gorelick vd, 2017; İban & Şahin, 2022)

Seçilen kentlerin mahalle sınırlarını gösteren vektör veriler GEE platformuna yüklenmiştir. Sonrasında, her bir kentin tamamını kapsayan ve 2022 yaz aylarına ait atmosferik düzeltmesi yapılmış Landsat 8 yüzey yansıtım sahnelerine erişilmiştir. Tarih seçimi için GEE platformundaki tarih filtresi fonksiyonu (filterDate) kullanılarak hedef döneme ait görüntüler ayıklanmıştır. Maksimum bulut örtüsü %10 olarak ayarlanmasına karşın, eser miktarda bulunan bulutlu ve boş pikseller, Landsat koleksiyonunda bulunan *cfmask* bandı ile filtrelenmiştir. Tablo 1, seçilen bu görüntülere ilişkin bilgi sunmaktadır.

Tablo 1. Çalışmada kullanılan uydu görüntüleri

Çalışma Bölgesi	Kullanılan Görüntü ID	Kullanılan Bantlar	Tile/Row	Tarih
Mersin	LANDSAT/LC08/C02/T1_L2/LC08_175034_20220712	B4, B5, B10	175/34	12.07.2022
Ankara	LANDSAT/LC08/C02/T1_L2/LC08_177032_20220726	B4, B5, B10	177/32	26.07.2022
İzmir	LANDSAT/LC08/C02/T1_L2/LC08_180033_20220715	B4, B5, B10	180/33	15.07.2022
İstanbul	LANDSAT/LC08/C02/T1_L2/LC08_180034_20220731	B4, B5, B10	180/34	31.07.2022
	LANDSAT/LC08/C02/T1_L2/LC08_180033_20220731		180/33	

2.3. NDVI ve LST Değerlerinin Hesaplanması

Seçilen görüntülere ait NDVI değerlerinin hesaplanması için Denklem 1’de gösterilen formül kullanılmıştır.

$$(NIR - R) / (NIR + R) \quad (1)$$

Bu formülde, *NIR* Landsat 8’in yakın kızılötesi 5. bandıdır. *R* ise, kırmızı 4. bandıdır. Oluşturulan NDVI görüntüleri, Google Drive’a vektör verilerle aynı projeksiyon sistemine dönüştürülerek, 30 metre konumsal çözünürlükle GEOTIFF formatında aktarılmıştır.

LST değerleri Landsat 8’in 100 metre konumsal çözünürlüklü 10. bandı (TIR1) kullanılarak hesaplanmıştır. LST değerlerinin eldesinde NDVI temelli yayımlılık (emissivity) yöntemi kullanılmıştır (Sobrino vd., 2008). NDVI değerlerinin hesaplanmasında Denklem 1’deki NDVI formülünden elde edilen sayısal değerler göz önünde bulundurulmuştur.

LST değerlerinin hesabında her bir pikselin sayısal değeri atmosferik spektral radyans (L_λ) değerine Denklem 2’de gösterilen formüle göre dönüştürülmüştür.

$$L_\lambda = (M_L) * (DN) + (A_L) \quad (2)$$

Burada M_L ve A_L bantlara özel radyans yeniden ölçekleme faktör değerleridir. Daha sonra elde edilen L_λ değerleri parlaklık sıcaklığının (*BT*) hesaplanmasında kullanılmıştır. Bu *BT* değerleri Landsat 8 sensörleri tarafından yayımlılığın 1’e eşit olduğu varsayılarak kaydedilmiş, gerçek yer yüzeyi sıcaklığıdır ve Denklem 3’de gösterilen formüle göre hesaplanır.

$$BT = \frac{K_2}{\ln\left(\frac{K_1}{L_\lambda} + 1\right)} - 273.15 \quad (3)$$

Denklem 3’te, K_1 ve K_2 Landsat 8’in meta verilerinden derlenen kalibrasyon katsayılarıdır. ($K_1 = 774.89, K_2 = 1321.08$). Sıcaklıkların °C birimine dönüştürülmesi için mutlak sıfır değeri (-273.15 °C) eklenmiştir.

Arazi yüzeyinin farklı kompozisyonu, pürüzlülüğü ve yapısal özellikleri, arazi yüzeyi yayımlılığını doğrudan etkilemektedir. Dolayısıyla, bir spektral yayımlılık düzeltme katsayısının (ε), arazi örtüsü tipine göre uygulanması şarttır. Bu çalışmada, bitki örtüsü varlığına odaklanıldığı için, Denklem 4’de gösterilen NDVI temelli (ε) düzeltme katsayısı uygulanmıştır.

$$\varepsilon = \begin{cases} 0.979 - 0.046 * \rho_{RED}, & NDVI < 0.2 \\ 0.987 * P_v + 0.971 * (1 - P_v), & 0.2 \leq NDVI \leq 0.5 \\ 0.987, & NDVI > 0.5 \end{cases} \quad (4)$$

Burada P_v , NDVI değerlerinden elde edilen bitki örtüsü fraksiyonudur ve Denklem 5’de gösterilen formüle göre hesaplanır.

$$P_v = \left[\frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \right]^2 \quad (5)$$

Denklem 5’te, $NDVI_{max}$ 0.5’e, $NDVI_{min}$ ise 0.2’ye eşittir. Diğer bir yandan, Denklem 4’deki ρ_{RED} ise kırmızı bandın yansıtım değeridir. Sonuç olarak, arazi yüzeyi yayımlılık değerleri kullanılarak elde edilen LST değerleri, Denklem 6’da gösterilen formülle hesaplanır.

$$LST = \frac{BT}{1 + \left(\frac{\lambda * T * S}{h * c}\right) \ln \varepsilon} \quad (6)$$

Denklem 6'da λ , termal bandın etkili dalga boyudur (0.00115), s ise Boltzmann katsayısıdır ($1.38 * 10^{-23} JK^{-1}$), h Plank sabiti ($6.626 * 10^{-34} Js$), c ise ışık hızıdır ($2.998 * 10^8 ms^{-1}$) (Şekertekin & Bonafoni, 2020; Yazar vd., 2023).

Google Drive'dan bilgisayara indirilen görüntüler, QGIS CBS yazılımına aktarılarak, dört şehre ait kentsel tüm mahallelerin idari sınırlarını gösteren vektör dosyası üzerine iz düşürülmüştür. Her bir mahalleye denk gelen LST ve NDVI piksellerinin ortalaması QGIS'te hesaplanmıştır. Hesaplanan bu ortalama değerler, vektör veri setine yeni bir öznetelik olarak eklenmiş, nihayetinde analiz için kullanıma hazır coğrafi veri çerçevesi elde edilmiştir. Aynı zamanda, her mahalleye ait ortalama LST ve NDVI değerlerini gösteren haritalar da üretilmiştir.

2.3.1. Regresyon Analizi

Elde edilen veri çerçevesi .csv formatında QGIS'den export edilerek, Python temelli Scikit-learn kütüphanesine aktarılmış ve regresyon analizine hazır hale getirilmiştir. Regresyon analizinde OKSD tek bağımlı değişkendir. LST ve NDVI değerleri ise bağımsız değişkenlerdir. Veri çerçevemizde, 493 tanesi Ankara, 978 tanesi İstanbul, 286 tanesi İzmir ve 94 tanesi Mersin'e ait olmak üzere toplam 1851 adet mahalleye ait veri bulunmaktadır. Regresyon analizi, her kentin ilçeleri için ayrı ayrı olmak suretiyle gerçekleştirilmiştir. Bu kapsamda, seçilen ilçelerin OKSD – NDVI, OKSD – LST ve NDVI – LST ilişkisi irdelenmiştir. Aynı zamanda, üst, orta, alt OKSD gruplarını temsil eden mahallelerin LST ve NDVI değeri ile OKSD arasındaki ilişkisi ayrı bir şekilde incelenmiştir. Bunun için dört kentin her mahallesine ait OKSD verileri dört eşit çeyreklige bölünmüş ve her bir çeyreklik için ayrı ayrı regresyon analizi yapılmıştır. Bu bağlamda, her bir mahallenin OKSD ile NDVI ve LST değerleri arasında anlamlı ve korelasyonlu bir ilişkinin olup olmadığına dair denetleme sağlanmıştır. OKSD-LST ve OKSD-NDVI ilişkisinin lineer ve anlamlı bir bağıntıya sahip olup olmadığını denetlemek için, R^2 skoru ve p-değer ölçütleri kullanılmıştır. Gerçek değerler ile tahmin edilen değerler arasındaki ilişkiyi ifade eden R^2 skoru, 0-1 arasında değer almaktadır. R^2 değeri 1'e ne kadar yakınsa model o kadar hassas ve uyumlu demektir (Kalogirou, 2000). R^2 değeri Denklem 7'de gösterilen formülle hesaplanır. Formülde y , gerçek değer, \hat{y} tahmin edilen değer, y_m ise gerçek değerlerin ortalamasıdır.

$$R^2 = \left(\frac{\sum(y - \hat{y})^2}{\sum(y - y_m)^2} \right) \quad (7)$$

P-değer istatistiksel bir hipotez testidir ve araştırmacıların veri setleri arasındaki istatistiksel anlamlılığı belirlemesine yardımcı olur. Hesaplanan p-değer ve seçilen anlamlılık seviyesine göre araştırmacılar iki faktör arasındaki anlamlılık hipotezinin gerçekleşip gerçekleşmediğini belirlerler. P-değerinin hesaplanmasında, normal dağılım ya da t dağılımı kullanılır. Anlamlılık seviyesi (alfa) genellikle 0.05 ya da 0.01 olarak seçilir. Bu eşik seviyenin altında olan p-değerleri, istatistiksel olarak anlamlı olarak kabul edilir. Eğer p-değeri bu eşik değerin üzerinde ise sonuçlar istatistiksel olarak anlamlı bulunmaz ve üzerinde bir yorum yapılamaz. Dört büyükşehirdeki ilçeler bazında bu R^2 ve p-değer hesaplaması yapılarak, NDVI ve LST değerlerinin OKSD'ye olan etkisi yorumlanmıştır.

3. Bulgular

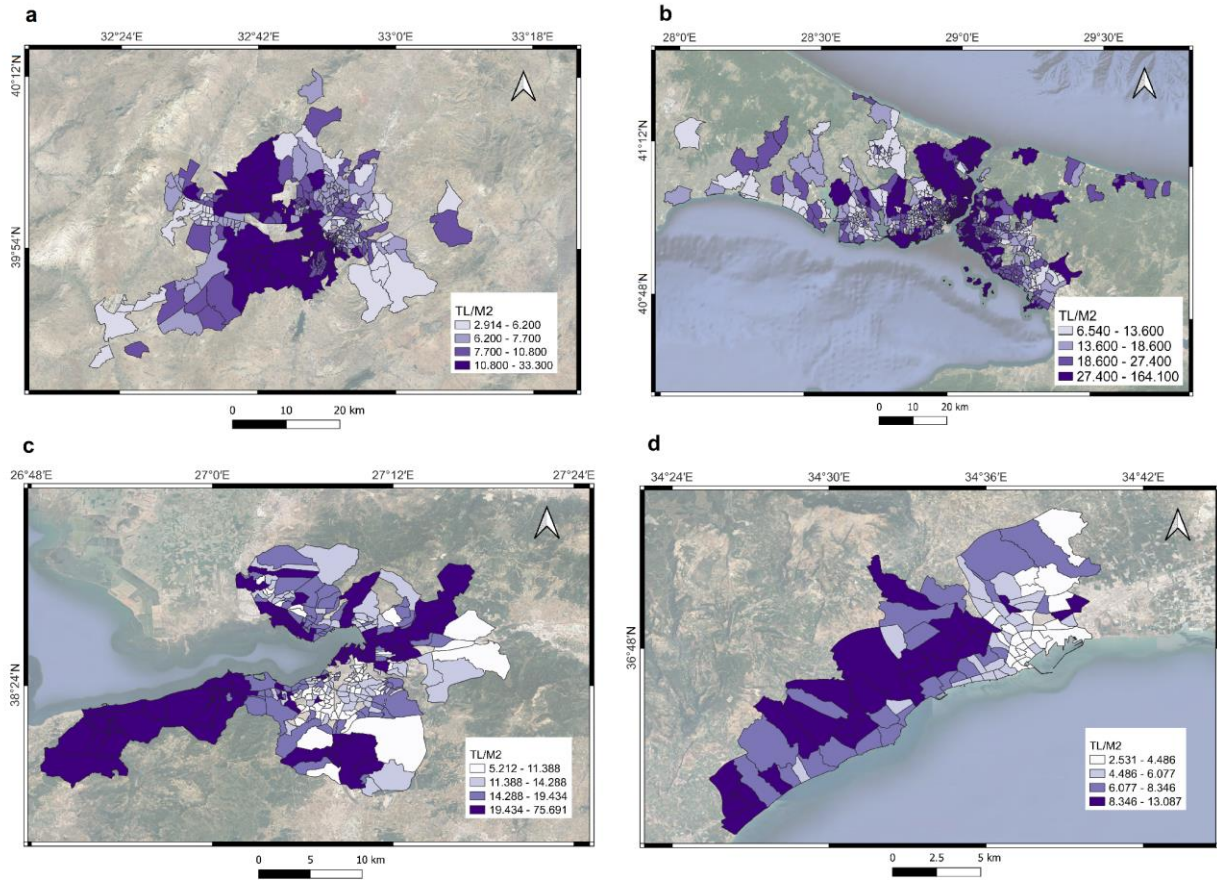
3.1. Elde Edilen Ortalama Konut Satış Değerleri

Ankara, İstanbul, İzmir ve Mersin'in kent merkezlerindeki mahallelerin OKSD'leri incelenmiş ve dört kent için ayrı ayrı OKSD haritaları elde edilmiştir. Kentlere ait OKSD haritaları Şekil 1'de gösterilmiştir. Bu haritaların lejantlarındaki renkler, her kent için ayrı ayrı olarak doğal kırılım yöntemi ile dört gruba ayrılan OKSD değerlerini göstermektedir. Ankara'da Çankaya ilçesinde Oran mahallesi en yüksek OKSD'ye ($33.300 TL/m^2$) sahipken, Altındağ ilçesinde Hacı Bayram mahallesi en düşük değere ($2.914 TL/m^2$) sahiptir. Ortalama konut satış birim değeri ise kent genelinde $10.073 TL/m^2$ 'dir. Batı-kuzeybatı eksenindeki mahallelerde daha yüksek OKSD değerleri gözlemlenmiştir.

İstanbul'da, Sarıyer ilçesinde Baltalı mahallesi en yüksek OKSD'ye ($164.100 TL/m^2$) sahipken, Pendik ilçesinde Sanayi mahallesi en düşük OKSD'ye ($6.540 TL/m^2$) sahiptir. Ortalama konut satış birim değeri ise kent genelinde $25.180 TL/m^2$ 'dir. Boğaza kıyısı olan güney-kuzey eksenindeki mahallelerde daha yüksek OKSD değerleri gözlemlenmiştir.

İzmir'de, Konak ilçesinde Akdeniz mahallesi en yüksek OKSD'ye ($75.691 TL/m^2$) sahipken, yine Konak ilçesinde Ferahlı mahallesi en düşük değere ($6.212 TL/m^2$) sahiptir. Ortalama konut satış birim değeri ise kent genelinde $16.967 TL/m^2$ 'dir. Kentin güneybatı, kuzeydoğu ve denize kıyısı olan mahallelerinde daha yüksek OKSD değerleri gözlemlenmiştir.

Mersin'de, Mezitli ilçesinde Merkez mahallesi en yüksek OKSD'ye ($13.087 TL/m^2$) sahipken, Akdeniz ilçesi Civanyaylağı mahallesi en düşük OKSD'ye ($2.531 TL/m^2$) sahiptir. Ortalama konut satış birim değeri ise kent genelinde $6.440 TL/m^2$ 'dir. Yeni gelişmiş ve batı-kuzey ekseninde bulunan mahallelerde daha yüksek OKSD değerlerine rastlanırken, doğu ve güneydoğu mahallelerinde nispeten daha düşük değerler gözlemlenmiştir.



Şekil 1. Ankara (a), İstanbul (b), İzmir (c), Mersin (d) kentlerine ait mahallelerin OKSD haritaları

3.2. Elde edilen NDVI değerleri


Dört kente ait mahallelerin ortalama NDVI değerleri, 2022 yaz aylarına ait Landsat 8 OLI sensöründen elde edilen uydu verileri ile üretilmiştir. Üretilen veri çerçevesi kullanılarak dört kentin her mahallesine ait ortalama NDVI değerlerini gösteren haritalar Şekil 2'de gösterilmektedir. Bu haritaların lejantlarındaki renkler, her kent için ayrı ayrı olarak doğal kırılım yöntemi ile dört gruba ayrılan NDVI değerlerini göstermektedir.

Ankara'da, ilçelere ait mahallelerin NDVI değerleri incelendiğinde, en yüksek ortalama NDVI değeri Çankaya ilçesindeki Mebusevleri mahallesine (0.427), en düşük ortalama NDVI değeri ise Sincan ilçesindeki Alçı OSB mahallesine (0.113) aittir. Kent merkezindeki mahallelerin ortalama NDVI değeri 0.224'tür. Kentin güneydoğu, güneybatı ve kuzeydoğusundaki mahallelerin daha yüksek NDVI değerlerine sahip olduğu görülmektedir.

İstanbul'da en yüksek ortalama NDVI değeri Sarıyer ilçesindeki Bahçeköy Merkez mahallesine (0.867), en düşük ortalama NDVI değeri ise Bayrampaşa ilçesindeki Vatan mahallesine (0.109) aittir. Kent merkezindeki mahallelerin ortalama NDVI değeri 0.318'dir. Kentin kuzeydoğu, kuzeybatı ve batısındaki mahallelerin daha yüksek NDVI değerlerine sahip olduğu görülmektedir.

İzmir'de en yüksek ortalama NDVI değeri Narlıdere ilçesindeki 2. İnönü mahallesine (0.639), en düşük ortalama NDVI değeri ise Buca ilçesindeki Seyhan mahallesine (0.089) aittir. İzmir kent merkezindeki mahallelerin ortalama NDVI değeri 0.244'tür. Kentin güney, kuzey ve doğusundaki mahallelerin daha yüksek NDVI değerlerine sahip olduğu görülmektedir.

Mersin'de en yüksek ortalama NDVI değeri Mezitli ilçesindeki Kaleköy mahallesine (0.618), en düşük ortalama NDVI değeri ise Akdeniz ilçesindeki Mesudiye mahallesine (0.097) aittir. Mersin kent merkezindeki mahallelerin ortalama NDVI değeri 0.266'dır. Kentin batı-kuzey eksenindeki mahallelerin daha yüksek NDVI değerlerine sahip olduğu, güneydoğusundaki mahallelerin ise düşük NDVI değerlerine sahip olduğu görülmektedir.



Şekil 2. Ankara (a), İstanbul (b), İzmir (c), Mersin (d) kentlerine ait mahallelerin ortalama NDVI haritaları

3.3. Elde edilen LST değerleri

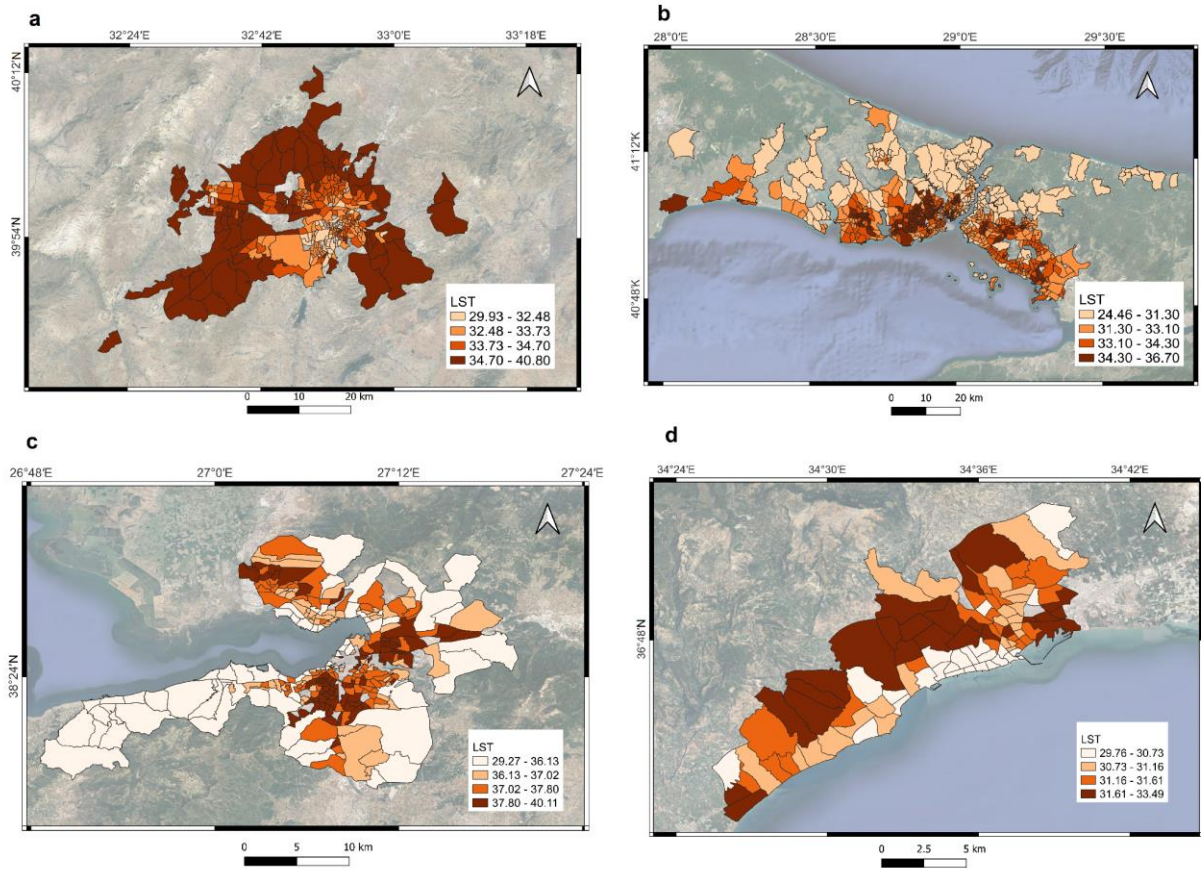
Dört kente ait mahallelerin ortalama LST değerleri, 2022 yaz aylarına ait Landsat 8 OLI ve TIRS sensörlerinden elde edilen uydu verileri ile üretilmiştir. Üretilen veri çerçevesi kullanılarak dört kentin her mahallesine ait ortalama LST değerlerini gösteren haritalar Şekil 3'de gösterilmektedir. Bu haritaların lejantlarındaki renkler, her kent için ayrı ayrı olarak doğal kırılım yöntemi ile dört gruba ayrılan LST değerlerini göstermektedir.

Ankara'da en yüksek ortalama LST değeri Sincan ilçesindeki Mevlana mahallesine (40.80°C), en düşük ortalama LST değeri ise Çankaya ilçesindeki Güzeltepe mahallesine (29.93 °C) aittir. Güzeltepe Mahallesi etrafında Portakal Çiçeği ve Dikmen Vadileri bulunduğu için bu sonucun elde edilmesi sürpriz değildir. Kent merkezindeki mahallelerin ortalama LST değeri 34.28°C'dir. Kentin güneydoğu, güneybatı ve kuzeydoğusunda bulunan mahallerinin daha yüksek LST değerlerine sahip olduğu açıktır.

İstanbul'da en yüksek ortalama LST değeri Esenler ilçesindeki Turgut Reis mahallesine (36.70°C), en düşük ortalama LST değeri ise Sarıyer ilçesindeki Bahçeköy Merkez mahallesine (24.46°C) aittir. Kent merkezindeki mahallelerin ortalama LST değeri 32.74°C'dir. Kentin kuzeydoğu, kuzeybatı ve batısındaki mahallelerin daha yüksek NDVI değerlerine sahip olduğu görülmektedir.

İzmir'de en yüksek ortalama LST değeri Çiğli ilçesindeki İzkent mahallesine (40.11°C), en düşük ortalama LST değeri ise Narlıdere ilçesindeki 2. İnönü mahallesine (29.27°C) aittir. İzmir kent merkezindeki mahallelerin ortalama LST değeri 36.68°C'dir. Kentin güney, kuzey ve doğusunda kent merkezine uzak olan mahallelerin daha düşük LST değerlerine sahip olduğu açıktır.

Mersin'de en yüksek ortalama LST değeri Yenişehir ilçesindeki Kocavilayet mahallesine (33.49°C), en düşük ortalama LST değeri ise Yenişehir ilçesinde Palmiye mahallesine (29.76°C) aittir. Mersin kent merkezindeki mahallelerin ortalama LST değeri 31.24 °C'dir. Kentin güneyinde bulunan mahallerde LST değerinin daha düşük olduğu, kuzeyinde bulunan mahallerde ise daha yüksek olduğu açıktır.



Şekil 3. Ankara (a), İstanbul (b), İzmir (c), Mersin (d) kentlerine ait mahallelerin ortalama LST haritaları

3.4. Regresyon Sonuçları

Dört kente ait mahallelerin OKSD'leri ile NDVI ve LST arasında anlamlı ve bağıntılı bir ilişkinin olup olmadığına dair denetleme sağlamak amacıyla R^2 skoru ve p-değeri ölçütleri kullanılarak regresyon analizi gerçekleştirilmiştir. Aynı zamanda, mahalleler OKSD değerlerine göre de dört adet çeyreklige bölünerek ayrı ayrı NDVI-OKSD, LST-OKSD ve NDVI-LST analizlerine tabi tutulmuştur. Böylelikle mahallerin konut piyasasındaki değer gruplarına göre, sahip olduğu bitki örtüsü varlığı ve arazi yüzey sıcaklığının konut satış değerine olan etkisinin anlaşılması sağlanmıştır.

Yapılan analizler sonucunda dört kentin ilçelerine ait NDVI – OKSD, LST – OKSD ve NDVI – LST ikililerinin R^2 skorları ve p-değeri ölçütleri Tablo 2'de, OKSD değerine göre dört adet çeyreklige bölünmüş mahallelere ait NDVI – OKSD, LST – OKSD ve NDVI – LST ikililerinin R^2 skorları Tablo 3'de verilmiştir.

Tablo 2. İstanbul, Ankara, Mersin, İzmir kentlerinin ilçelerine ait NDVI – OKSD, LST – OKSD, NDVI – LST ikililerinin R^2 skor ve p- değer tablosu

il	ilçe	NDVI- OKSD R^2	LST- OKSD R^2	NDVI-LST R^2	NDVI- OKSD P-değeri	LST-OKSD P- değeri
İstanbul	Adalar	0.00	0.34	0.30	0.3147	0.1481
	Arnavutköy	0.00	0.00	0.78	0.3754	0.3779
	Ataşehir	0.31	0.66	0.49	0.8886	0.0008****
	Avcılar	0.36	0.13	0.78	0.0328***	0.1523
	Bağcılar	0.34	0.39	0.56	0.3136	0.0910**
	Bahçelievler	0.67	0.78	0.78	0.5735	0.0381***
	Bakırköy	0.22	0.12	0.35	0.1753	0.7106
	Başakşehir	0.08	0.00	0.58	0.1373	0.2085
	Bayrampaşa	0.23	0.25	0.60	0.5952	0.4487
	Beşiktaş	0.41	0.35	0.90	0.1368	0.7672
	Beykoz	0.07	0.13	0.87	0.2541	0.0866**
	Beylikdüzü	0.14	0.00	0.56	0.0747**	0.1704

Tablo 2'nin devamı

İl	İlçe	NDVI- OKSD R ²	LST- OKSD R ²	NDVI-LST R ²	NDVI- OKSD P-değeri	LST-OKSD P- değeri
	Beyoğlu	0.33	0.00	0.18	0.1541	0.3492
	Büyükçekmece	0.76	0.14	0.60	0.4790	0.5419
	Çatalca	0.00	0.15	0.79	0.0553**	0.0329***
	Çekmeköy	0.62	0.61	0.98	0.4773	0.9321
	Esenler	0.14	0.20	0.56	0.7774	0.2623
	Esenyurt	0.33	0.51	0.67	0.8203	0.0002****
	Eyüp	0.76	0.79	0.98	0.6974	0.1175
	Fatih	0.17	0.00	0.32	0.0148***	0.2127
	Gaziosmanpaşa	0.13	0.14	0.76	0.7602	0.6238
	Güngören	0.41	0.49	0.92	0.6582	0.2050
	Kadıköy	0.21	0.51	0.66	0.1836	0.0009****
	Kağıthane	0.27	0.57	0.71	0.1526	0.0008****
	Kartal	0.04	0.00	0.86	0.0696**	0.1097
	Küçükçekmece	0.36	0.31	0.79	0.1932	0.7963
	Maltepe	0.28	0.54	0.61	0.6923	0.0079****
	Pendik	0.11	0.48	0.32	0.6082	0.0001****
	Sancaktepe	0.01	0.00	0.79	0.2839	0.3398
	Sarıyer	0.22	0.15	0.94	0.0170***	0.0803**
	Şile	0.06	0.15	0.81	0.4146	0.1963
	Silivri	0.31	0.52	0.75	0.5216	0.0404***
	Şişli	0.44	0.47	0.64	0.1847	0.0787**
	Sultanbeyli	0.17	0.01	0.44	0.0538**	0.2769
	Sultangazi	0.05	0.00	0.34	0.3687	0.3687
	Tuzla	0.16	0.13	0.30	0.3055	0.4732
	Ümraniye	0.01	0.34	0.67	0.0000****	0.0000****
	Üsküdar	0.43	0.37	0.71	0.0473***	0.4699
	Zeytinburnu	0.26	0.46	0.69	0.6077	0.0435***
Ankara	Çankaya	0.25	0.10	0.10	0.0000****	0.0035****
	Sincan	0.18	0.10	0.47	0.0175***	0.1790
	Etimesgut	0.15	0.03	0.24	0.0320***	0.8890
	Yenimahalle	0.06	0.01	0.06	0.0287***	0.1520
	Pursaklar	0.04	0.93	0.10	0.3217	0.0023****
	Altındağ	0.02	0.01	0.05	0.6377	0.8296
	Mamak	0.02	0.03	0.03	0.2291	0.1438
İzmir	Keçiören	0.00	0.02	0.00	0.7016	0.3629
	Buca	0.23	0.19	0.67	0.1060	0.5872
	Çiğli	0.22	0.23	0.31	0.1465	0.1312
	Güzelbahçe	0.19	0.46	0.75	0.1905	0.0202***
	Karabağlar	0.15	0.13	0.63	0.2279	0.5101
	Karşıyaka	0.07	0.11	0.06	0.4397	0.0052****
	Bağcıva	0.06	0.00	0.77	0.3284	0.4223
	Narlıdere	0.05	0.11	0.88	0.4569	0.2837
	Bayraklı	0.04	0.03	0.39	0.5592	0.7228
Gaziemir	0.01	0.00	0.81	0.1978	0.2096	
Mersin	Konak	0.01	0.00	0.14	0.3834	0.4400
	Bornova	0.01	0.00	0.76	0.3633	0.4887
	Yenişehir	0.15	0.20	0.26	0.3126	0.1179
	Akdeniz	0.12	0.19	0.17	0.1936	0.6476
	Toroslar	0.11	0.05	0.03	0.0195***	0.0052****
	Mezitli	0.02	0.01	0.04	0.5790	0.7009

**** : p – değeri ≤ 0.01 (yüksek anlamlılık)

*** : 0.01 < p – değeri ≤ 0.05 (anlamlılık)

** : 0.05 < p- değeri ≤ 0.01 (düşük anlamlılık)

yıldız yok: p – değeri > 0.1 (anlamlılık yok)

yüksek R² değerleri (R²> 0.7) koyu renk ile gösterilmiştir.

Tablo 3. İstanbul, Ankara, Mersin, İzmir kentlerinin mahallelerinin OKSD değerlerine göre bölünmüş dört adet çeyrekliğe ait NDVI – OKSD, LST – OKSD, NDVI – LST ikilileri R² skor tablosu

İl	Çeyreklik	NDVI - OKSD R ²	LST- OKSD R ²	NDVI- LST R ²
İstanbul	Q1	0.03	0.03	0.82
	Q2	0.04	0.03	0.82
	Q3	0.01	0.02	0.84
	Q4	0.02	0.02	0.87
Ankara	Q1	0.00	0.09	0.01
	Q2	0.00	0.01	0.07
	Q3	0.00	0.00	0.06
	Q4	0.12	0.01	0.29
İzmir	Q1	0.02	0.00	0.43
	Q2	0.00	0.03	0.42
	Q3	0.01	0.03	0.43
	Q4	0.00	0.01	0.44
Mersin	Q1	0.09	0.01	0.25
	Q2	0.00	0.01	0.00
	Q3	0.14	0.03	0.04
	Q4	0.00	0.01	0.11

Yüksek R² değerleri (R² > 0.7) koyu renk ile gösterilmiştir.

Ankara'da, Çankaya ilçesinin NDVI-OKSD ve LST-OKSD ikilileri arasında en yüksek R² değerleri gözlemlenmiştir. Aynı zamanda, Çankaya ilçesine ait p-değerinin de yüksek derecede anlamlılığa işaret ettiği görülmektedir. NDVI-LST analizi, en yüksek OKSD'ye sahip mahallelerde hafif bir tutarlılık göstermiştir. NDVI-OKSD arasındaki R² değerinin 0.25 olması, NDVI faktörünün gayrimenkul değeri üzerindeki varyansın %25'ini açıkladığını gösterir. Bu durum, NDVI faktörünün gayrimenkul değeri üzerinde sınırlı bir etkisinin olduğunu işaret eder. Ancak ilişkinin yüksek anlamlılığa sahip olması, Çankaya'da yeşil alanların varlığının gayrimenkul değerinin kestirimine yardımcı olabilecek bir faktör olduğunu ifade etmektedir. Yeterince yüksek olmayan R² değeri, Çankaya'da NDVI- OKSD ilişkisinin mahallelere özgü olarak güçlü veya zayıf olduğunu ve bölgesel farklılıkların varlığına işaret edebilir. Bu farklılıkların nedenleri üzerine mahalleler özelinde daha fazla araştırma yapılması önemlidir.

İstanbul Eyüp ilçesinde NDVI-OKSD, LST-OKSD ve NDVI-LST ikilileri arasında iyi bir R² değerinin (R² > 0.7) bulunduğu, ancak p-değeri düşünülürken bu ilişkinin anlamlılık göstermediği tespit edilmiştir. Yüksek R² değerleri iki değişken arasındaki ilişkinin büyük bir kısmının varyansının açıklandığını gösterir. Ancak anlamlı olmayan p değerleri, NDVI – OKSD ve LST- OKSD ikilileri arasındaki ilişkinin rastlantısal olabileceği veya diğer faktörlerin de bu ilişkide etkili olabileceği anlamına gelmektedir. Bu durumda, NDVI ve LST'nin gayrimenkul değerini açıklamadaki etkisi hakkında kesin bir sonuca varmak zor olabilir. LST ve NDVI faktörlerinin gayrimenkul değeri üzerindeki etkisini daha kapsamlı bir şekilde değerlendirmek için ek analizler yapılabilir. Bunlar arasında başka değişkenlerin dahil edilmesi, zaman serisi analizi veya farklı istatistiksel tekniklerin kullanılması bulunur. Arnavutköy, Beşiktaş, Beykoz, Bahçelievler, Çatalca, Çekmeköy, Eyüp, Gaziosmanpaşa, Güngören, Kağıthane, Kartal, Küçükçekmece, Sancaktepe, Sarıyer, Şile, Silivri ve Üsküdar ilçelerinin, NDVI – LST değerleri arasında iyi bir R² değeri (R² > 0.7) oluşturduğu görülmüştür. En yüksek ortalama OKSD'ye sahip mahallelerde NDVI – LST ikilisi arasındaki ilişki daha tutarlıdır. Ümraniye'de ise NDVI-OKSD arasında çok düşük bir R² skoru elde edilmesine rağmen, p-değeri çok yüksek anlamlılık göstermektedir. Bu durum, NDVI faktörünün gayrimenkul değeri üzerindeki etkisinin gerçek olduğunu, ancak bu etkinin başka faktörlerle birlikte çoklu regresyon modelinde daha etkili bir şekilde incelenmesi gerektiği sonucunu ortaya çıkarmaktadır. Çankaya'daki duruma benzer olarak, Ümraniye'de de NDVI faktörünün gayrimenkul değeri üzerindeki etkisi, diğer faktörlerin de analize dahil edilmesiyle birlikte daha fazla açıklanabilir veya mahalle özelindeki verilerle daha belirgin hale gelebilir.

İzmir'de, Güzelbahçe, Balçova, Narlıdere, Gaziemir, Bornova ilçeleri NDVI – LST arasında yüksek bir R² değerine (R² > 0.7) sahiptir. İlçeler bazında NDVI - OKSD ve LST – OKSD ikilileri arasında tutarlı bir ilişki gözlenmemiştir. NDVI-LST analizi, en yüksek ortalama değere sahip mahallelerde hafif bir tutarlılık göstermiştir.

Mersin'de, ilçeler bazında NDVI – OKSD, LST – OKSD ve NDVI - LST ikilileri arasında tutarlı bir ilişki gözlenmemiştir. NDVI-LST analizi, en düşük OKSD'ye sahip mahallelerde hafif bir tutarlılık göstermiştir.

Tablo 3'te OKSD'ye göre dört adet çeyrekliğe bölünmüş veri setlerinde NDVI-OKSD ve LST-OKSD arasında çok düşük R² değerlerinin elde edildiği gösterilmektedir. Bu durum, mahallelerin sahip olduğu OKSD'lerin pahalı ya da ucuz olmasının, NDVI ve LST'nin düşük ya da yüksek olmasıyla ilişkilendirilemeyeceği sonucunu doğrulamaktadır.

4. Tartışma

Bu çalışmada, Ankara, İstanbul, İzmir ve Mersin'in kentsel özellik gösteren ilçelerine bağlı mahallelerine ait OKSD, NDVI ve LST değerleri ayrı ayrı incelenmiştir. Elde edilen OKSD, NDVI, LST haritaları ve yapılan analizler sonucunda, bu dört kent arasında en yüksek OKSD'ye ve NDVI değerine sahip kentin İstanbul olduğu görülmüştür. Yapılan tutarlılık testleri sonucunda, İstanbul'da yüksek OKSD'ye sahip mahallelerin, yüksek NDVI değerleri ve düşük LST değerlerine sahip olduğu gözlemlenmiştir. Bunun sebebi, OKSD'nin kentin kuzeyine doğru gidildikçe nispeten daha yüksek olmasıdır. Kentin kuzeyinde bulunan yerleşim alanlarında, diğer ilçelere göre daha seyrek nüfus, yoğun olmayan yapılaşma ve daha fazla yeşil alan varlığı söz konusudur. Ancak yine de, kentin genelinde OKSD'nin yüksek olduğu ilçelerde NDVI değerlerinin nispeten daha yüksek olduğu, LST değerlerinin ise daha düşük olduğu söylenebilmektedir.

İstanbul'da, Eyüp ilçesinin NDVI – OKSD, LST - OKSD ve NDVI-LST ikilileri arasında iyi bir R^2 değeri oluşturduğu tespit edilmiştir. Eyüp ilçesinde kuzey yönünde bulunan ormanlar yeşil alan varlığını arttırmaktadır. Dolayısıyla, Kemerburgaz ve Göktürk gibi mahallelerde OKSD yükselmektedir. Aynı ilçenin güney tarafında bulunan yeşil alanlardan yoksun mahallelerde ise OKSD daha düşüktür. Dolayısıyla, bu ilçede NDVI ve LST değerlerinin OKSD'ye etkisinin yüksek olduğu söylenebilir. NDVI-OKSD ve LST – OKSD arasında en düşük R^2 değerleri Arnavutköy, Beykoz ve Şile gibi kent merkezinden uzak ilçelerde görülmüştür. Nüfus yoğunluğunun ve yapılaşmanın az, yeşil alan varlığının yoğun olduğu bu ilçelerde NDVI ve LST'nin OKSD'ye etkisi olmadığı açıktır. Ümraniye ilçesinin p-değeri kapsamında yüksek anlamlılığa sahip olduğu, fakat iyi R^2 değerlerine sahip olmadığı görülmüştür. Dolayısıyla, Ümraniye'de termal konfora etki eden başka faktörlerin de varlığı araştırılmalıdır.

Ankara'nın, dört kent arasında en düşük ortalama NDVI değerine sahip olduğu görülmüştür. Bunun sebebi, bölgenin bozkır bitki örtüsüne sahip olmasıdır. Ankara'da, NDVI – OKSD ilişkisinde en yüksek R^2 değeri Çankaya ilçesinde, LST – OKSD ilişkisinde en yüksek R^2 değeri Pursaklar ilçesinde görülmüştür. Çankaya ilçesi'nde genel olarak yüksek OKSD ve NDVI değerleri görülmektedir. İlçede yoğun yapılaşma faaliyetlerinin bulunmasına karşın, yeşil alan varlığının fazla olduğu ve LST değerlerinin kent ortalamasına göre daha düşük seyrettiği söylenebilir. Regresyon analizleri sonucunda, Çankaya'da NDVI değerlerinin OKSD'ye etkisinin olduğu söylenebilir. Pursaklar ilçesinde yapıların yoğun olduğu bölgelere bakıldığında LST değerlerinin yüksek, OKSD'nin düşük olduğu görülmüştür. Bunun sonucunda LST – OKSD arasında yüksek R^2 değeri elde edilmiştir. Ankara'nın analize dahil edilen diğer ilçelerinde NDVI-OKSD ve LST-OKSD ilişkisinde yüksek bir anlamlılık tespit edilememiştir.

İzmir'in, dört kent arasında en yüksek ortalama LST değerlerine sahip olduğu görülmüştür. Kentin güney yönündeki en yüksek OKSD'ye sahip mahallelerine bakıldığında NDVI değerlerinin yüksek, LST değerlerinin daha düşük seyrettiği görülmektedir. NDVI- OKSD ikilisinde en yüksek R^2 değeri Buca ilçesinde, LST – OKSD ikilisinde en yüksek R^2 değeri Güzelbahçe ilçesinde görülmüştür. Buca ilçesinde NDVI ve OKSD'nin kent ortalamasına yakın, LST değerinin ise ortalamadan üzerinde olduğu görülmektedir. İlçede yoğun yapılaşma söz konusudur fakat, doğu yönüne doğru gidildikçe yeşil alan varlığı artmaktadır. Özellikle NDVI değerlerinin yüksek seyrettiği mahallelerde OKSD değerinin kent ortalaması üzerinde olduğu görülmektedir. Buca ilçesinde NDVI değerinin OKSD'ye etkisinin olduğu söylenebilir. Güzelbahçe ilçesinde OKSD'nin kent ortalamasına göre yüksek olduğu, LST'nin ise daha düşük olduğu görülmüştür. Bu ilçede yapılaşmasının daha az ve kent geneline göre daha düzenli olduğu, yeşil alan varlığının da fazla olduğu görülmektedir. LST değerlerinin OKSD'ye etkisinin yüksek olduğu söylenebilir. Gaziemir, Konak, Bornova ilçelerinde NDVI ve LST değerlerinin OKSD'ye etkisinin olmadığı görülmüştür. Güzelbahçe ve Karşıyaka ilçelerinde p-değeri kapsamında LST – OKSD ikilisinde anlamlılık söz konusudur.

Mersin kentinin kuzey ve batı yönünde bulunan mahallelerinde OKSD ve NDVI değerlerinin daha yüksek seyrettiği görülmüştür. Analizler sonucunda NDVI-OKSD, LST-OKSD ve NDVI – LST ikilileri arasında iyi tutarlılıklar gözlemlenmemiştir. Ancak ilçeler arasında nispeten daha yüksek R^2 değerine sahip ilçenin Yenişehir olduğu söylenebilir. Bu ilçede yoğun yapılaşma ve daha az yeşil alan varlığı söz konusudur. İlçenin kuzey yönüne doğru gidildikçe yeni ve daha düzenli yapılaşma görülmektedir. Fakat yapılaşma oranına kıyasla, yeşil alan varlığının daha az olduğu görülmüştür. Yenişehir ilçesinin kuzeyinde bulunan mahallelerinin yüksek OKSD'ye sahip olduğu görülmektedir. Bu ilçede NDVI ve LST'nin OKSD'ye hafif bir etkisi olduğu söylenebilir. Toroslar ilçesinde ise NDVI – OKSD, LST – OKSD analizinde p-değeri kapsamında anlamlılık söz konusudur. Fakat Toroslar ilçesinin NDVI – OKSD, LST – OKSD ve NDVI - LST ikilileri kapsamında yüksek R^2 değerlerine sahip olmadığı görülmektedir.

Konut ortalama fiyatlarına göre çeyreklik gruplara ayrılıp gerçekleştirilen regresyon analizde ise (Tablo 3), konut değerlerinin belirlenmesinde NDVI ve LST gibi çevresel faktörlerin tek başına yeterli olmadığı ve başka faktörlerin, örneğin yerel ekonomik koşulların, ulaşım altyapısının, sosyo-demografik yapının da analize mutlaka dahil edilmesi gerektiği sonucuna ulaşılabilir.

Bu çalışma, termal konforun OKSD'ye etkisini NDVI ve LST faktörleri ile analiz etmeye çalışmıştır. NDVI ve LST faktörlerinin OKSD'ye etkisi dört kentin ilçelerinde farklı biçimlerde gözlemlenmiştir. Bir başka deyişle, termal konforu ilgilendiren NDVI ve LST faktörlerinin OKSD'ye her kent için ortak bir etkisi bulunmamıştır. Bu iki faktörün OKSD ile ilişkisi ilçeler özelinde kendine has bir eğilimde gözlemlenmiştir.

Dört kent için elde edilen bulgular sonucunda, İstanbul'da kent sakinlerinin belirli ilçelerdeki konut tercihinde yeşil alan varlığının daha çok etkisinin olduğu, sırasıyla Ankara ve İzmir'de bu etkinin azaldığı, Mersin kentinin Ankara ve İzmir'e göre daha yüksek ortalama NDVI değerine sahip olmasına rağmen, NDVI faktörünün OKSD'ye olan etkisinin diğer üç kente kıyasla çok az olduğu söylenebilir. Konut tercihinde LST'nin etkisine bakıldığında en göze çarpan yerin Ankara olduğu görülmektedir. İstanbul ve İzmir'de bu etkinin azaldığı, Mersin kentinin dört kente kıyasla en düşük ortalama LST değerlerine sahip olmasına rağmen, kentteki LST'nin OKSD'ye etkisinin çok az olduğu gözlemlenmiştir. Bu çalışma sonucunda anlaşılabilir ki, NDVI ve LST'nin kentlerdeki OKSD'ye etkisi çalışma alanının kentsel, iklimsel ve demografik özelliklerine göre farklılık göstermektedir. Kentsel ve demografik olarak benzer yapıda olan İstanbul ve Ankara, iklimsel olarak benzer özellikler gösteren Mersin ve İzmir'e göre daha tutarlı bulgular göstermiştir.

NDVI ve LST arasındaki ilişkinin kentsel alanlara olan etkisi üzerine araştırma yapan Halder vd. (2021) çalışmalarında, kentleşmenin bir alandaki LST değerlerini arttırdığı ve bitki örtüsü değerlerini azalttığı tespit edilmiştir. Benzer şekilde Çelik vd. (2019), İstanbul kenti için yaptıkları çalışmada, NDVI ile LST arasında negatif bir korelasyon olduğunu ve bitki örtüsü varlığının arazi yüzey sıcaklıklarında düşüşe neden olduğunu belirtmişlerdir. NDVI ve LST değerlerinin gayrimenkul piyasasına etkisini ele alan çalışmalar da mevcuttur. Örneğin Alkan ve Uslu, (2016) Mersin ilinin Yenişehir ilçesi için yaptıkları regresyon çalışmasında, konut fiyatları ile konutun sahip olduğu aktif yeşil alanlar arasında olumlu yönde bir ilişki olduğu sonucuna varmışlardır. Alan yazındaki bu bulgular ile bu çalışmanın bulguları birbiriyle örtüşmektedir. Yapılan bazı çalışmalar ise, yapı alanları etrafında bulunan yeşil bitki örtüsü varlığının konut fiyatları üzerinde önemli bir etkiye sahip olmadığını göstermektedir (Li vd., 2015; Li & Saphores, 2012). Bu çalışma ise, özellikle Çankaya ve Eyüp gibi örneklerde, yapı alanları etrafındaki yeşil bitki örtüsü varlığının konut fiyatları üzerindeki olumlu etkisini tespit ederek, alan yazına göre daha farklı bir sonucu ortaya çıkarmıştır. Dolayısıyla, kentlerde ilçelerin ve mahallelerin ihtiyacı doğrultusunda yeşil alanların potansiyel kullanımlarının ele alınarak yeşil alanların artırılması, yeni kentleşen bölgelerde yapı alanları oluşturulurken sahip olduğu yeşil alan miktarlarının dikkate alınması, bir kentteki konut piyasasının şekillenmesinde büyük rol oynayacaktır.

Çalışma alanı olarak seçilen dört kente ait OKSD verilerinin eldesi için kullanılan Endeksa.com adlı sitede, kentlerde seçilen ilçelere ait her mahallenin OKSD verisi bulunamamıştır. Bu nedenle veri elde edilemeyen mahallelerde OKSD verisi boş bırakılmak zorunda kalmıştır. OKSD verisi bulunan her bir mahallenin sınırları içerisinde kalan NDVI ve LST piksellerinin ortalaması hesaplanmıştır. Ancak, OKSD verisi elde edilemeyen mahallelerin NDVI ve LST piksellerinin ortalaması hesaplanmamış ve bu mahalleler regresyon analizlerine dahil edilememiştir. Bu kısıtlamayı gidermek için gelecekte yapılacak çalışmalarda, çalışma yapılacak kent, ilçe ya da mahalle için OKSD verisi bölgeye ait gayrimenkul piyasasının araştırılması yapılarak elde edilmelidir. Son olarak, bu tür bir çalışmaya yapı yoğunluğuna dair bilgi sunan uzaktan algılama verileri ve indeksleri de dahil edilerek, yapı yoğunluğunun bu çalışmada irdelenen faktörlerle ilişkisi de analiz edilebilir.

5. Sonuçlar

Bu çalışmada, Türkiye'de seçilen farklı iklimsel, kentsel ve demografik yapıya sahip dört kentte termal konforun, konut satış tercihlerine olan etkisinin anlaşılması hedeflenmiştir. Bu sayede, farklı özellikler taşıyan bu kentlerde gözlemlenen NDVI ve LST değerlerinin OKSD ile olan ilişkisini ayrı ayrı incelemek olanaklı olmuştur. Ankara, İstanbul, İzmir ve Mersin'in kentsel özellik taşıyan ilçelerindeki mahallelerin OKSD verileri ile Landsat-8 uydu görüntülerinden elde edilen LST ve NDVI değerleri arasındaki ilişkiyi değerlendirmek için regresyon analizi kullanılmıştır. Bu çalışmanın odak noktası, farklı arazi kullanımı ve iklim koşullarına sahip şehirlerde NDVI ve LST'deki varyasyonları anlamak ve bu değişkenlerin gayrimenkul piyasasındaki fiyatlarda gözlemlenen farklılıklara olan katkısını belirlemektir. Bu doğrultuda, mahallelerdeki ortalama LST ve NDVI değerlerinin konut satış değerlerine etkisi analiz edilmiş ve görselleştirilmiştir. Endeksa.com'un Kasım 2022 tarihli verileri kullanılarak mahallelere ait OKSD verileri elde edilmiştir. NDVI ve LST değerleri ise, 2022 yaz aylarına ait Landsat 8 OLI ve TIRS uydu sensörlerinden elde edilmiştir.

Çalışma, NDVI ve LST'nin konut satış değerleri üzerindeki etkisinin mahalleler, ilçeler ve kentlere göre değişkenlik gösterdiğini belirlemiştir. Bu etkinin özellikle İstanbul'da belirginken, Mersin ve İzmir gibi daha az yeşil alanlara sahip şehirlerde daha az belirgin olduğu sonucuna ulaşılmıştır. Sonuçlara göre, sıcak iklim özellikleri gösteren kentlerde konut satış fiyatlarını termal konfor ile ilişkilendirebilmek için yeşil alanların artırılması gerektiği söylenebilir.

Teşekkür

BİDEB 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında 1919B012221063 numaralı projeye ve bu makalede kaleme alınan araştırmaya verdiği destekten ötürü TÜBİTAK'a teşekkürlerimizi bir borç biliriz.

Kaynaklar

- Alkan, Y., & Uslu, C. (2016). Aktif yeşil alanların konut fiyatları üzerine etkisinin araştırılması: Mersin ili Yenişehir ilçesi örneği. *İnönü Üniversitesi Sanat ve Tasarım Dergisi*, 6(13),1-10.
- Celik, B., Kaya, S., Alganci, U., & Seker, D. Z. (2019). Assessment of the relationship between land use/cover changes and land surface temperatures: a case study of thermal remote sensing. *Fresenius Environmental Bulletin*, 28(2), 541-547.
- Diem, P. K., Nguyen, C. T., Diem, N. K., Diep, N. T. H., Thao, P. T. B., Hong, T. G., & Phan, T. N. (2023). Remote sensing for urban heat island research: Progress, current issues, and perspectives. *Remote Sensing Applications: Society and Environment*, 33, Article 101081. <https://doi.org/10.1016/j.rsase.2023.101081>
- Doğan, Ö. S., & Özdemir, F. (2021). Mersin’de (Akdeniz, Mezitli, Toroslar ve Yenişehir) Yaşayan Suriyeliler: Sosyo-Kültürel Yapı ve Entegrasyon Süreci. *Coğrafya Dergisi*, 42, 33-47.
- Endeksa. (2022, Kasım). *Evinizin kıymetini bilin*. <https://www.endeksa.com/tr/> adresinden alınmıştır.
- Erdem Okumus, D., & Terzi, F. (2021). Evaluating the role of urban fabric on surface urban heat island: The case of Istanbul. *Sustainable Cities and Society*, 73, Article 103128. <https://doi.org/10.1016/j.scs.2021.103128>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.
- Halder, B., Bandyopadhyay, J., & Banik, P. (2021). Evaluation of the climate change impact on urban heat island based on land surface temperature and geospatial indicators. *International Journal of Environmental Research*, 15, 819-835.
- Hidalgo García, D. H., Riza, M., & Díaz, J. A. (2023). Land Surface Temperature Relationship with the Land Use/Land Cover Indices Leading to Thermal Field Variation in the Turkish Republic of Northern Cyprus. *Earth Systems and Environment*, 7(2), 561-580.
- Holt, J. R., & Borsuk, M. E. (2020). Using Zillow data to value green space amenities at the neighborhood scale. *Urban Forestry & Urban Greening*, 56, Article 126794. <https://doi.org/10.1016/j.ufug.2020.126794>
- İban, M. C., & Şahin, E. (2022). Monitoring land use and land cover change near a nuclear power plant construction site: Akkuyu case, Turkey. *Environmental Monitoring and Assessment*, 194(10), Article 724. <https://doi.org/10.1007/s10661-022-10437-6>
- Jiao, L., Xu, G., Jin, J., Dong, T., Liu, J., Wu, Y., & Zhang, B. (2017). Remotely sensed urban environmental indices and their economic implications. *Habitat International*, 67, 22-32.
- Kalogirou, S. A. (2000). Applications of artificial neural-networks for energy systems. *Applied Energy*, 67(1-2), 17-35.
- Li, W., & Saphores, J. D. (2012). A spatial hedonic analysis of the value of urban land cover in the multifamily housing market in Los Angeles, CA. *Urban Studies*, 49(12), 2597-2615.
- Li, W., Saphores, J. D. M., & Gillespie, T. W. (2015). A comparison of the economic benefits of urban green spaces estimated with NDVI and with high-resolution land cover data. *Landscape and Urban Planning*, 133, 105-117.
- Liebelt, V., Bartke, S., & Schwarz, N. (2018). Hedonic pricing analysis of the influence of urban green spaces onto residential prices: the case of Leipzig, Germany. *European Planning Studies*, 26(1), 133-157.
- Mashhoodi, B. (2021). Environmental justice and surface temperature: Income, ethnic, gender, and age inequalities. *Sustainable Cities and Society*, 68, Article 102810. <https://doi.org/10.1016/j.scs.2021.102810>
- Molenaar, R. E., Heusinkveld, B. G., & Steeneveld, G. J. (2016). Projection of rural and urban human thermal comfort in The Netherlands for 2050. *International Journal of Climatology*, 36(4), 1708-1723.
- Sobrino, J. A., Jiménez-Muñoz, J. C., Sòria, G., Romaguera, M., Guanter, L., Moreno, J., ... & Martínez, P. (2008). Land surface emissivity retrieval from different VNIR and TIR sensors. *IEEE Transactions on Geoscience and Remote Sensing*, 46(2), 316-327.
- Şekertekin, A., & Bonafoni, S. (2020). Land surface temperature retrieval from Landsat 5, 7, and 8 over rural areas: Assessment of different retrieval algorithms and emissivity models and toolbox implementation. *Remote Sensing*, 12(2), Article 294. <https://doi.org/10.3390/rs12020294>
- Şekertekin, A., & Zadbagher, E. (2021). Simulation of future land surface temperature distribution and evaluating surface urban heat island based on impervious surface area. *Ecological Indicators*, 122, Article 107230. <https://doi.org/10.1016/j.ecolind.2020.107230>
- Taleghani, M., Tenpierik, M., Kurvers, S., & Van Den Dobbelaars, A. (2013). A review into thermal comfort in buildings. *Renewable and Sustainable Energy Reviews*, 26, 201-215.
- Tan, K. C., Lim, H. S., MatJafri, M. Z., & Abdullah, K. (2012). A comparison of radiometric correction techniques in the evaluation of the relationship between LST and NDVI in Landsat imagery. *Environmental Monitoring and Assessment*, 184(6), 3813-3829.
- Ünal, Ç. (2020) İzmir’ın göç analizi (2008-2018). *Doğu Coğrafya Dergisi*, 25(43), 195-208.

- Yazar, M., Cetinkaya, I. D., İban, M. C., & Bilgilioglu, S. S. (2023). The green divide and heat exposure: urban transformation projects in Istanbul. *Frontiers in Environmental Science*, 11, Article 1265332. <https://doi.org/10.3389/fenvs.2023.1265332>
- Zambrano-Monserrate, M. A., Ruano, M. A., Yoong-Parraga, C., & Silva, C. A. (2021). Urban green spaces and housing prices in developing countries: A Two-stage quantile spatial regression analysis. *Forest Policy and Economics*, 125, Article 102420. <https://doi.org/10.1016/j.forpol.2021.102420>
- Zengin, M., Yılmaz, S., & Mutlu, B. E. (2019). Mekansal Termal Konfor Açısından Atatürk Üniversitesi Yerleşkesi Termal Kamera Görüntülerinin Analizi. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 50(3), 239-247.
- Zorlu, F., & Yolođlu, A. C. (2022). İstanbul metropoliten alanında nüfus hareketliliğinin dinamikleri. *Megaron*, 17(2), 221–234. <https://doi.org/10.14744/MEGARON.2022.87854>

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

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

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

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

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

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

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

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Ömer Dilmen
omer.dilmen@agu.edu.tr

doi: 10.48123/rsgis.1451338

Yayın süreci

Geliş tarihi: 12.03.2024

Kabul tarihi: 13.06.2024

Basım tarihi: 26.09.2024

Özet

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

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

Abstract

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

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

1. Giriş

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

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

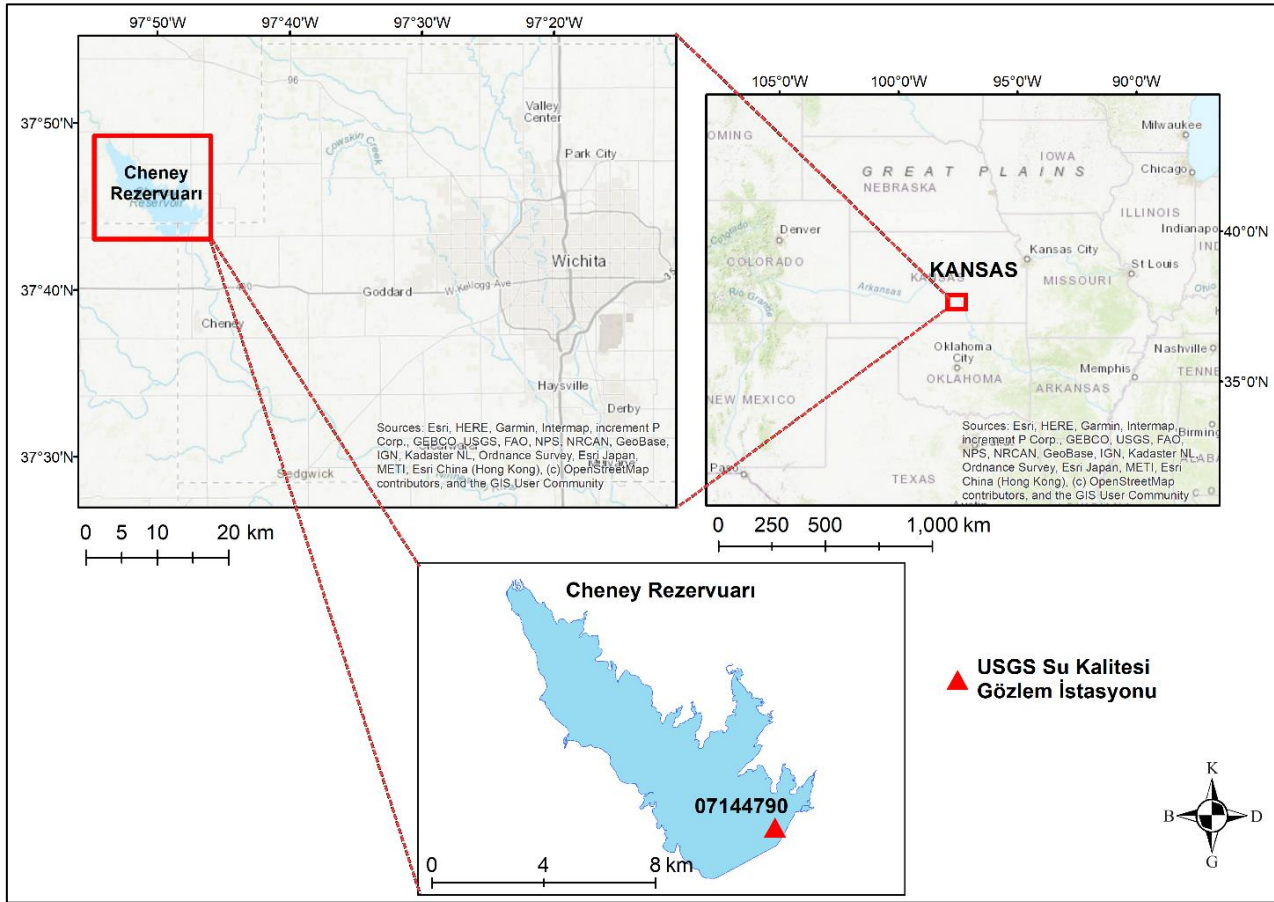
Uzaktan algılama ile bulanıklık tahmininde Landsat 5, Landsat 8 ve Sentinel 2 uyduları önceki çalışmalarda (Al-Fahdawi vd., 2015; Gholizadeh vd., 2016; Gonzalez-Marquez vd., 2018; Pizani vd., 2020) sıklıkla kullanılmıştır. Bu nedenle, bu çalışmada da yüksek performanslı bir bulanıklık tahmin modeli geliştirmek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

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

2. Kullanılan Veriler ve Yöntemler

2.1 Çalışma Alanı

Cheney Rezervuarı 1962 ile 1965 yılları arasında Wichita şehrinde (Kansas, ABD) inşa edilmiştir. Kansas eyaletinin en büyük şehri olan Wichita 396,192 nüfusa sahiptir (State of Kansas, 2023). Cheney Rezervuarı havzasındaki arazi çoğunlukla kırsal alan olmakla birlikte başta buğday yetiştirilen tarımsal alanlar, toplam arazinin yaklaşık %52'sine karşılık gelmektedir. Cheney Rezervuarını besleyen en önemli kol North Fork Ninnescah Nehri olup rezervuara giren su hacminin yaklaşık %70'ini oluşturmaktadır. Drenaj alanı 2420 km² olan rezervuar yaklaşık 38 km²'lik bir yüzey alanına sahiptir. Rezervuarda ortalama derinlik 5 m iken maksimum derinlik ise yaklaşık 13 m'dir (Christensen vd., 2006; Stone vd., 2015). Şekil 1'de görüldüğü üzere Cheney Rezervuarında 15 dakika aralıklarla su kalitesi takibi yapılan bir gözlem istasyonu (USGS 07144790) mevcuttur. Rezervuarda ölçülmüş bulanıklık verilerinin yanı sıra çalışma alanını kapsayan ve söz konusu verilerle neredeyse eş zamanlı olan uydu görüntülerinin mevcut olması Cheney Rezervuarının çalışma alanı olarak seçilmesinde etkili olmuştur.



Şekil 1. Cheney Rezervuarı, Kansas, Amerika Birleşik Devletleri

2.2 Verilerin Elde Edilmesi

Wichita şehri için sahip olduğu önem dolayısıyla Cheney Rezervuarında 1996 yılından beri USGS Kansas Su Bilimleri Merkezi ve Wichita Belediyesi iş birliğiyle çeşitli su kalitesi değişkeni izlenmekte olup 2007 yılından günümüze değin ölçülmüş bulanık verileri de mevcuttur. Bulanıklık verileri USGS web sitesinden (U.S. Geological Survey, 2023) formazin nefelometrik birimi (FNU) olarak temin edilmiştir. Çalışmada kullanılan Landsat 8 OLI görüntüleri yeryüzünde 185 km²'lik bir alan kapsamakta olup pankromatik bantta 15 m, spektral bantlarda ise 30 m'lik bir konumsal çözünürlüğe sahiptir (Wang vd., 2015). Landsat 8'in sahip olduğu bantlar ve görüntü çözünürlükleri Tablo 1'de verilmektedir.

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

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

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

2.3 Regresyon Analizi

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

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

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

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

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

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

2.4 Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (MARS)

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

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

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

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

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

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

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

2.5 TreeNet Gradyan Arttırma Makinesi (TreeNet)

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

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

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

3. Modelleme Çalışmaları

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

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

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

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

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

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

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

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

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

4. Bulgular ve İrdeleme

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

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

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

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


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

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

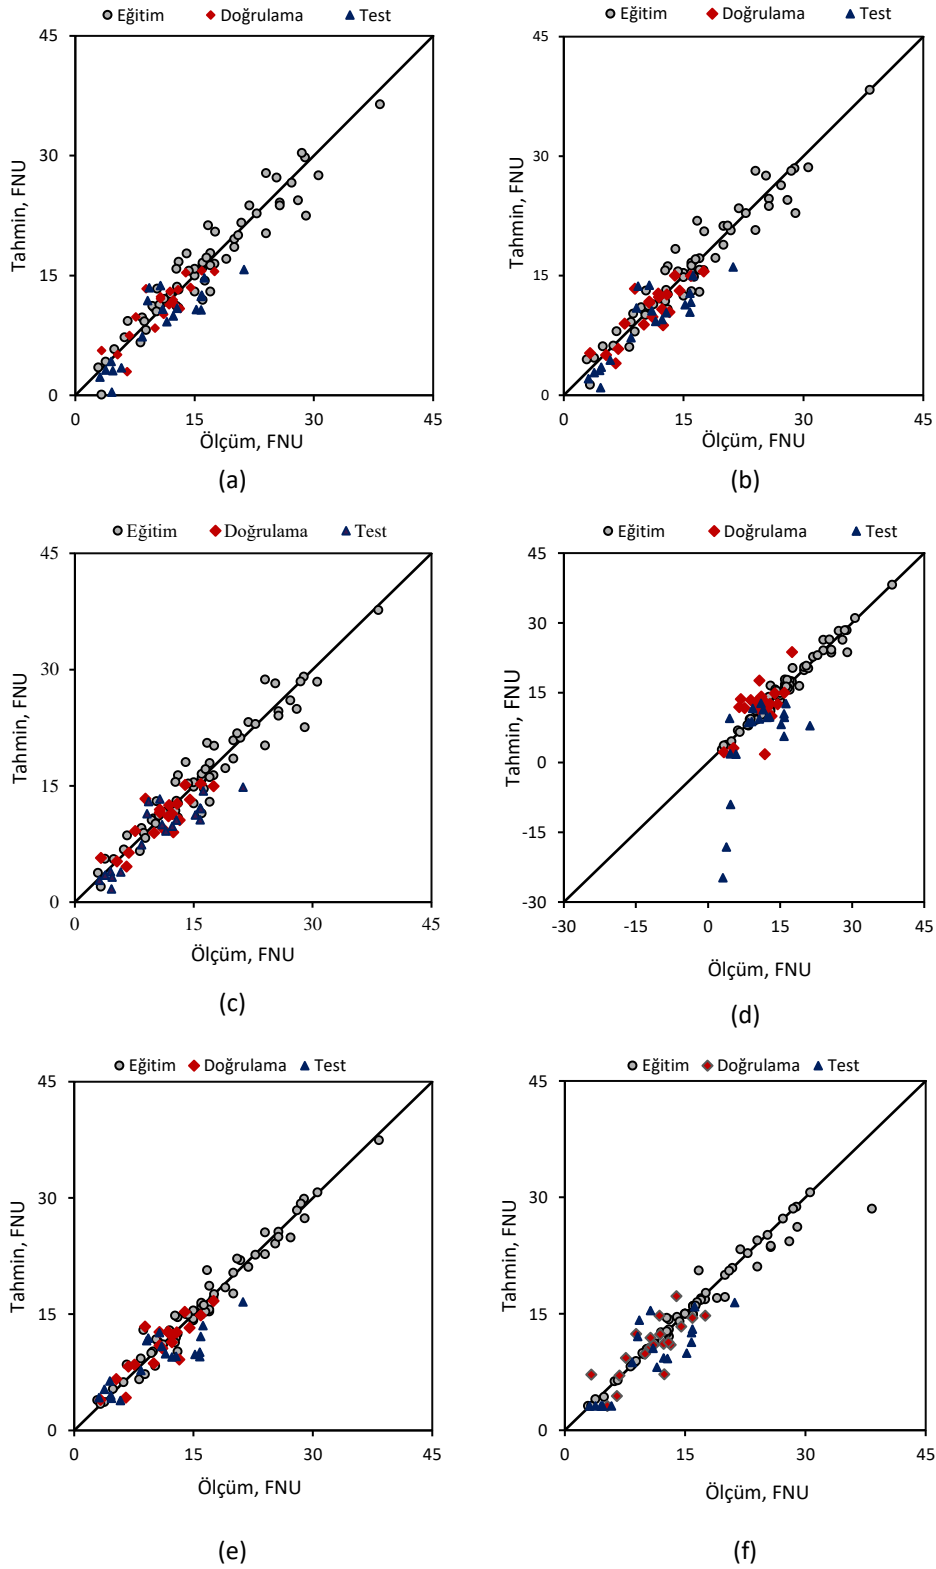
Tahmin modellerinin performansları, MSE, RMSE, MAE ve NS verimlilik katsayısı istatistikleri ile kıyaslanmıştır. Eğitim veri seti için Tablo 4 ve Şekil 2a'da görüldüğü üzere DF, ÜF ve EF için NS değerleri birbirine eşit ve diğer yöntemlere kıyasla başarısız sonuçlar (NS= 0.92) vermişlerdir. Ancak bu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

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

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



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



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

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


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

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

Tablo 5. MARS yöntemiyle elde edilen denkleme ait temel fonksiyonlar

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

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



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

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

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

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

4. Sonuçlar ve Öneriler

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

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

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

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

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

Teşekkür

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

Kaynaklar

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

- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232.
- Friedman, J. H. (1991). Multivariate adaptive regression splines. *Annals of Statistics*, 19(1), 1-67.
- Gholizadeh, M. H., Melesse, A. M., & Reddi, L. (2016). A comprehensive review on water quality parameters estimation using remote sensing techniques. *Sensors*, 16(8), Article 1298. <https://doi.org/10.3390/s16081298>
- Gonzalez-Marquez, L. C., Torres-Bejarano, F. M., Rodriguez-Cuevas, C., Torregroza-Espinosa, A. C., & Sandoval-Romero, J. A. (2018). Estimation of water quality parameters using Landsat 8 images: application to Playa Colorada Bay, Sinaloa, Mexico. *Applied Geomatics*, 10, 147-158.
- Hossain, A. A., Mathias, C., & Blanton, R. (2021). Remote sensing of turbidity in the Tennessee River using Landsat 8 satellite. *Remote Sensing*, 13(18), Article 3785. <https://doi.org/10.3390/rs13183785>
- Hossen, H., Mahmud, W. E., Negm, A., & Nakamura, T. (2022). Assessing water quality parameters in Burullus Lake using Sentinel-2 satellite images. *Water Resources*, 49(2), 321-331.
- Khalid, H. W., Khalil, R. M. Z., & Qureshi, M. A. (2021). Evaluating spectral indices for water bodies extraction in western Tibetan Plateau. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3), 619-634.
- Liu, L. W., & Wang, Y. M. (2019). Modelling reservoir turbidity using Landsat 8 satellite imagery by gene expression programming. *Water*, 11(7), Article 1479. <https://doi.org/10.3390/w11071479>
- Mann, A. G., Tam, C. C., Higgins, C. D., & Rodrigues, L. C. (2007). The association between drinking water turbidity and gastrointestinal illness: a systematic review. *BMC Public Health*, 7(1), Article 256. <https://doi.org/10.1186/1471-2458-7-256>
- Meng, H., Zhang, J., & Zheng, Z. (2022). Retrieving inland reservoir water quality parameters using Landsat 8-9 OLI and Sentinel-2 MSI sensors with empirical multivariate regression. *International Journal of Environmental Research and Public Health*, 19(13), Article 7725. <https://doi.org/10.3390/ijerph19137725>
- Moore, G. K. (1980). Satellite remote sensing of water turbidity. *Hydrological Sciences Journal*, 25(4), 407-421.
- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900.
- Mortula, M., Ali, T., Bachir, A., Elaksher, A., & Abouleish, M. (2020). Towards monitoring of nutrient pollution in coastal lake using remote sensing and regression analysis. *Water*, 12(7), Article 1954. <https://doi.org/10.3390/w12071954>
- Nacar, S., Mete, B., & Bayram, A. (2020a). Estimation of daily dissolved oxygen concentration for river water quality using conventional regression analysis, multivariate adaptive regression splines, and TreeNet techniques. *Environmental Monitoring and Assessment*, 192(12), Article 752. <https://doi.org/10.1007/s10661-020-08649-9>
- Nacar, S., Mete, B., & Bayram, A. (2020b). Günlük çözünmüş oksijen konsantrasyonunun çok değişkenli uyarlanabilir regresyon eğrileri ile tahmin edilmesi. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 25(3), 1479-1498.
- Nacar, S., Şan, M., Kankal, M., & Okkan, U. (2024). Innovative polygonal trend analysis (IPTA) in detecting the seasonal trend behavior of statistically downscaled precipitation for the Eastern Black Sea Basin of Turkey. *Urban Water Journal*, 21(4), 406-418.
- Pinto, C. T., Jing, X., & Leigh, L. (2020). Evaluation analysis of Landsat level-1 and level-2 data products using in situ measurements. *Remote sensing*, 12(16), Article 2597. <https://doi.org/10.3390/rs12162597>
- Pizani, F. M., Maillard, P., Ferreira, A. F., & de Amorim, C. C. (2020). Estimation of water quality in a reservoir from Sentinel-2 MSI and Landsat-8 OLI sensors. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3, 401-408.
- Rodriguez-Lopez, L., Duran-Llacer, I., Gonzalez-Rodriguez, L., Cardenas, R., & Urrutia, R. (2021). Retrieving water turbidity in Araucanian lakes (South-central Chile) based on multispectral Landsat imagery. *Remote Sensing*, 13(16), Article 3133. <https://doi.org/10.3390/rs13163133>
- Sharaf El Din, E., Zhang, Y., & Suliman, A. (2017). Mapping concentrations of surface water quality parameters using a novel remote sensing and artificial intelligence framework. *International Journal of Remote Sensing*, 38(4), 1023-1042.
- Sharda, V. N., Prasher, S. O., Patel, R. M., Ojasvi, P. R., & Prakash, C. (2008). Performance of multivariate adaptive regression splines (MARS) in predicting runoff in mid-Himalayan micro-watersheds with limited data. *Hydrological Sciences Journal*, 53(6), 1165-1175.
- Sun, X., Zhang, Y., Shi, K., Zhang, Y., Li, N., Wang, W., Huang, X., & Qin, B. (2022). Monitoring water quality using proximal remote sensing technology. *Science of the Total Environment*, 803, Article 149805. <https://doi.org/10.1016/j.scitotenv.2021.149805>
- Surisetty, V. V. A. K., Sahay, A., Ramakrishnan, R., Samal, R. N., & Rajawat, A. S. (2018). Improved turbidity estimates in complex inland waters using combined NIR-SWIR atmospheric correction approach for Landsat 8 OLI data. *International Journal of Remote Sensing*, 39(21), 7463-7482.

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

Meteorolojik Parametrelerin GNSS Yansıma Sinyallerine Etkisinin İncelenmesi

Investigating the Effect of Meteorological Parameters on GNSS Reflection Signals

Cansu Beşel Hatipoğlu^{1*}, Emine Tanır Kayıkcı²

¹Sinop Üniversitesi, Mühendislik ve Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, 57000, Sinop/Türkiye.

²Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 61080, Trabzon/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Cansu Beşel Hatipoğlu
cbesel@sinop.edu.tr

doi: 10.48123/rsgis.1487035

Yayın süreci

Geliş tarihi: 20.05.2024
Kabul tarihi: 02.09.2024
Basım tarihi: 26.09.2024

Özet

Günümüzde yaklaşık altı yüz milyon insan kıyıya yakın alanlarda yaşam sürdürmektedir. Bu nedenle deniz seviyesi değişiminin izlenmesi ve meydana gelebilecek olayların değerlendirilmesi son derece önemli olmaktadır. Deniz seviyesi değişiminin izlenmesinde yersel ve uydu tabanlı olmak üzere farklı yöntemler kullanılmaktadır. Yansıyan GNSS sinyallerini kullanarak deniz seviyesi değişiminin izlenmesine olanak sağlayan Küresel Navigasyon Uydu Sistemleri İnterferometrik Reflektometri (GNSS-IR) tekniği de bu yöntemlerden biridir. Bu çalışma ile deniz yüzeyinden yansıyan GNSS sinyallerine meteorolojik parametrelerin etkisi araştırılmıştır. Çalışma kapsamında, Sinyal Gürültü Oranı (Signal-to-Noise Ratio-SNR) verisi ve hava basıncı, rüzgar ve sıcaklık meteorolojik parametreleri kullanılmıştır. SNR verisi, Türkiye Ulusal Deniz Seviyesi İzleme Servisi'ne (TUDES) bağlı mareograf istasyonu ile ortak yerleşkeli TRBZ sabit GNSS istasyonundan sağlanmıştır. Hava basıncı verisi TUDES üzerinden alınmış olup sıcaklık ve rüzgar hızı verileri ERA5 veri setinden alınmıştır. Meteorolojik parametrelerin yansıyan sinyaller üzerindeki etkisini incelemek için hava basıncı, rüzgar hızı ve sıcaklık parametreleri ile trendden arındırılmış SNR genlikleri Basit Doğrusal Regresyon ve Mann-Kendall testi kullanılarak karşılaştırılmıştır. Elde edilen sonuçlara bakıldığında; sıcaklık ve rüzgar hızı parametreleri ile trendden arındırılmış SNR genliklerinin aynı yönde eğilime sahip olduğu görülmüştür.

Anahtar kelimeler: Deniz seviyesi değişimi, Sinyal gürültü oranı, Meteorolojik parametreler, Basit doğrusal regresyon, Mann-Kendall test

Abstract

Today, about six hundred million people live in coastal areas. Hence, it is extremely important to monitor sea level changes and assess possible events. Sea level changes are monitored using different methods both on the ground-based and satellite-based. One such method is the Global Navigation Satellite System Interferometric Reflectometry (GNSS-IR) technique, which uses reflected GNSS signals to monitor sea level changes. This study investigates the impact of meteorological parameters on GNSS signals reflected from the sea surface. Signal-to-noise ratio (SNR) data and meteorological parameters of air pressure, wind, and temperature are used in this study. SNR data are provided from the TRBZ co-located GNSS station operated by the Turkish National Sea Level Monitoring System (TUDES). The air pressure data are obtained from TUDES, while the temperature and wind speed data are from the ERA5 dataset. To examine the effect of meteorological parameters on the reflected signals, air pressure, wind speed, and temperature parameters and detrended SNR amplitudes are compared using Simple Linear Regression and the Mann-Kendall test. As a result of the study, it was observed that temperature and wind speed parameters and detrended SNR amplitudes had the same trend.

Keywords: Sea level changes, Signal-to-noise ratio, Meteorological parameters, Simple linear regression, Mann-Kendall test

1. Giriş

Küresel Navigasyon Uydu Sistemleri (Global Navigation Satellite Systems, GNSS) antenleri uydudan gelen doğrudan sinyalleri almak ve istasyonun etrafından gelen beklenmedik yansıyan sinyalleri bastırmak üzere tasarlanmıştır. Fakat yansıyan GNSS sinyallerinin bir kısmı antene ulaşarak doğrudan gelen sinyal ile girişim yapmaktadır. Bunun sonucunda ise sinyal yansıma etkisi (multipath) ortaya çıkmaktadır. GNSS sinyal yansıması açık görüş hattından (Line-of-Sight, LOS) gelen sinyal ve bir veya birden fazla kez yakınlardaki engellerden yansıyarak gelen sinyallerin (Non-Line-of-Sight, NLOS) bileşkesi olmaktadır (Braasch, 2017). Sinyal yansıma etkisi yüksek doğruluklu konumlamada büyük hata kaynaklarından biri olup GNSS gözlemlerinin bozulmasına neden olmaktadır. Bu etkinin azaltılması ve modellenmesine yönelik birçok çalışma gerçekleştirilmektedir (Georgiadou & Kleusberg, 1988; Elosegui vd., 1995; Bilich vd., 2008; Lu vd., 2021; Moradi vd., 2015).

Zaman içerisinde, sinyal yansıma etkisinin yeryüzünün uzaktan algılanmasında yararlı olabileceği görülmüştür. Martin-Neira (1993), Pasif Reflektometri ve İnterferometri Sistemi (Passive Reflectometry and Interferometry System, PARIS) için yansıyan GNSS sinyallerinin okyanusların uzaktan algılanmasında kullanılmasını göstermiştir. Böylece yersel ve uydu tabanlı GNSS Reflektometri (GNSS-R) araştırma alanının gelişmesinin temelleri atılmıştır. Katzberg ve Garrison (1996), okyanuslarda daha iyi bir iyonosferik düzeltme sağlamak için Küresel Konumlama Sistemi (Global Positioning System, GPS) sinyal yansımalarının kullanılmasını önermiştir. Ayrıca Katzberg vd. (1999) okyanus yüzeyi üzerindeki hava araçlarının yüksekliğini tahmin etmek için GPS sinyal yansımalarından bazı örnekler sunmuştur. Uydu tabanlı GNSS-R uygulamalarının yanı sıra tek jeodezik alıcı ile yersel tabanlı çalışmalar da yapılmaktadır. Burada, doğrudan gelen sinyal ile yansıyan sinyal tek jeodezik alıcıda birleştiğinden GNSS İnterferometrik Reflektometri (GNSS-IR) kavramı kullanılmaktadır. GNSS-IR tekniğinin farklı kullanım alanları mevcuttur. Başlıca; (1) deniz seviyesi değişimi (Beşel & Tanır Kayıkçı, 2022; Altuntaş & Tunalıoğlu, 2022; Geremia-Nievinski vd., 2020; Larson vd., 2013; Larson vd., 2017; Tabibi vd., 2021; Wang vd., 2018), (2) kar kalınlığı (Durand vd., 2019; Larson & Nievinski, 2013; Zhang vd., 2021), (3) toprak nemi (Larson vd., 2008; Vey vd., 2016), (4) buz kalınlığı (Ghiasi vd., 2020) ve (5) ekstrem doğa olaylarının belirlenmesi (Karegar vd., 2020; Kim & Park, 2021; Larson vd., 2021) gibi alanlarda kullanılmaktadır. Deniz seviyesi değişiminin belirlenmesinde yer merkezli GNSS-IR kullanımı ise ilk kez Larson vd. (2013) tarafından SNR verilerini kullanarak rölatif deniz seviyesi değişimini belirlemek için sunulmuştur.

GNSS-IR ile deniz seviyesi değişiminin izlenmesinde yansıma sinyallerini etkileyen faktörler önemlidir. Deniz yüzeyi pürüzlülüğü, yansıma sinyallerini etkileyen faktörlerden biridir (Asgarimehr vd., 2018; Ghiasi vd., 2021). Diğer yandan sıcaklık, rüzgar hızı, atmosferik basınç gibi meteorolojik parametreler deniz seviyesi değişimi üzerinde etkiye sahiptir. GNSS tabanlı deniz seviyesi değişimi açısından bakıldığında, bu meteorolojik parametrelerin oluşturacağı pürüzlülük yansıyan GNSS sinyalini etkileyen bir faktör olarak görülebilir. Dolayısıyla GNSS tabanlı deniz seviyesi kestirimi de bu durumdan etkilenmektedir. Meteorolojik parametrelerin yansıyan sinyal üzerindeki etkilerine bakıldığında; sıcaklığın artması ile birlikte deniz suyu sıcaklığı da artarak genişmekte ve deniz seviyesi yükselmekte olup çoğunlukla sıcaklıktaki artış SNR genliklerinin artmasına neden olmaktadır. Rüzgar hızı ise temelde suyun sürüklenmesine neden olup deniz yüzeyindeki sürüklenme kuvveti deniz seviyesini değiştirmektedir. Aynı zamanda deniz pürüzlülüğüne neden olması sebebiyle GNSS yansıyan sinyal üzerinde bir etkiye sahiptir. Diğer yandan atmosferik basınç deniz seviyesini etkileyen birinci faktör olup ters yönlü bir etkiye neden olmaktadır. Literatürde, meteorolojik parametrelerin yansıyan GNSS sinyali üzerindeki etkisinin incelenmesine yönelik oldukça az çalışmaya rastlanmıştır. Ghiasi vd. (2021), GNSS-IR ile buz kalınlığının belirlenmesinde sıcaklığın yansıyan GNSS sinyali üzerindeki etkisini araştırmıştır. Sıcaklık arttıkça saçılımın arttığı ve antene doğru yansımanın azalması sebebiyle SNR genliğinin de azaldığını görmüştür. GNSS-IR tekniği ile deniz seviyesi değişiminin belirlenmesinde meteorolojik parametrelerin yansıyan GNSS sinyali üzerindeki etkisini inceleyen bir çalışmaya henüz rastlanmamıştır.

Bu çalışma ile deniz seviyesi değişimini etkileyen sıcaklık, rüzgar hızı ve atmosferik basınç meteorolojik parametrelerinin GNSS yansıma sinyali üzerindeki etkisinin belirlenmesi amaçlanmıştır. Çalışma kapsamında iki tür veri kullanılmıştır. Birinci tür veri SNR olup TUDES ağında mareograf istasyonu ile ortak yerleşkeli TRBZ sabit GNSS istasyonundan alınmıştır. İkinci tür veri ise meteorolojik parametrelerdir. Burada hava basıncı verisi TUDES üzerinden, sıcaklık ve rüzgar hızı verisi ise ERA5 veri setinden sağlanmıştır. Meteorolojik parametrelerin GNSS yansıma sinyalleri üzerindeki etkisini incelemek için trendden arındırılmış SNR genlikleri ile meteorolojik parametrelerin zaman içerisinde göstermiş olduğu eğilim belirlenmiş olup elde edilen sonuçlar karşılaştırılmıştır. Bunun için, Basit Doğrusal Regresyon ve Mann-Kendall trend testleri uygulanmıştır. Çalışmada son olarak TRBZ istasyonunda GNSS-IR tekniğine dayalı deniz seviyesi değişimi belirlenmiş olup hem GNSS-IR hem de mareograf deniz seviyesi verileri ile meteorolojik parametreler arasındaki ilişki incelenmiştir. Böylelikle yansıyan GNSS sinyali ve bu sinyal kullanılarak elde edilen GNSS-IR tekniğine dayalı deniz seviyesi ile meteorolojik parametrelerin ilişkisi birlikte değerlendirilmiştir.

2. Yöntem

Çalışma kapsamında trendden arındırılmış SNR genlikleri ile meteorolojik parametrelerin karşılaştırılmasında Basit Doğrusal Regresyon ve Mann-Kendall trend testleri kullanılmıştır. Aşağıda yöntemlere ait detaylar verilmiştir.

2.1. Basit Doğrusal Regresyon

Basit doğrusal regresyon modeli, x bağımsız değişkeni ile y bağımlı değişkeni arasındaki ilişkiyi doğrusal bir fonksiyonla ifade etmektedir. Regresyon modeli,

$$y_i + v_i = a_0 + a_1x_i \quad (1)$$

şeklinindedir. Burada; a_1 ; eğim, a_0 ; kesişim sabiti ve v_i ($i = 1, 2, \dots, n$) bağımlı değişkenin gerçek değeri ile modelden elde edilen değer arasındaki farkı ifade eden düzeltme parametresini ifade etmektedir. n sayıda veri için Eşitlik (1),

$$\begin{aligned} y_1 + v_1 &= a_0 + a_1x_1 \\ y_2 + v_2 &= a_0 + a_1x_2 \\ y_3 + v_3 &= a_0 + a_1x_3 \\ &\vdots \\ y_n + v_n &= a_0 + a_1x_n \end{aligned} \quad (2)$$

şeklinde ifade edilir. Eşitlik (2)'nin matris gösterimi,

$$V = Ax - y \quad (3)$$

şeklinindedir. Eşitlik(3)'te, A katsayılar matrisi,

$$A = \begin{bmatrix} x_1 & 1 \\ x_2 & 1 \\ x_3 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{bmatrix} \quad (4)$$

Bilinmeyenler vektörü,

$$x = \begin{bmatrix} a_1 \\ a_0 \end{bmatrix} \quad (5)$$

Sabitler vektörü,

$$y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_n \end{bmatrix} \quad (6)$$

Düzeltilmeler vektörü,

$$V = \begin{bmatrix} v_1 \\ v_2 \\ v_3 \\ \vdots \\ v_n \end{bmatrix} \quad (7)$$

şeklinde gösterilmektedir. En Küçük Kareler (EKK) ilkesine göre,

$$x = (A^T A)^{-1} A^T y \quad (8)$$

olarak elde edilen simetrik katsayılı denklem sisteminin çözümünden x bilinmeyenler vektörünün elemanları,

$$\begin{aligned} a_1 &= x(1) \\ a_0 &= x(2) \end{aligned} \quad (9)$$

şeklinde hesaplanır (Öztürk & Şerbetçi, 1992; Beşel, 2017).

2.2. Mann-Kendall Testi

Parametrik olmayan yöntemlerden biri olan Mann-Kendall testi, hidroloji ve klimatoloji gibi alanlarda zaman serilerindeki trendin belirlenmesinde sıklıkla kullanılmaktadır. Uygulanan hipotez testi ile zaman serisindeki trend varlığı ve yönü araştırılmaktadır. Mann-Kendall test değeri,

$$S = \sum_{k=1}^{n-1} \sum_{j=k+1}^n \text{sgn}(x_j - x_k) \quad (10)$$

olarak hesaplanır. Burada, n ; ölçü sayısını ifade etmekte olup sgn işaret fonksiyonudur. Mann-Kendall testi x_k ($k = 1, \dots, n - 1$) ve x_j ($j = i + 1, \dots, n$) veri setlerine uygulanır. Eşitlik (10)'daki sgn işaret fonksiyonu değeri x_j ve x_k değerlerinin,

$$\text{sgn}(x_j - x_k) = \begin{cases} 1; & x_j > x_k \\ 0; & x_j = x_k \\ -1; & x_j < x_k \end{cases} \quad (11)$$

şeklinde kıyaslanması ile bulunur. S değerinin varyansı,

$$\text{Var}(S) = \frac{n(n-1)(2n+5)}{18} \quad (12)$$

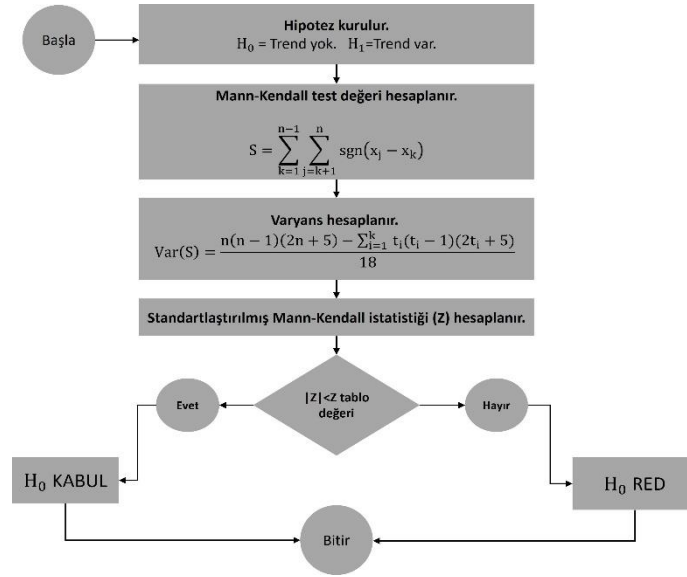
olarak hesaplanır. Diğer yandan, seride aynı değere sahip veriler mevcut ise varyans,

$$\text{Var}(S) = \frac{n(n-1)(2n+5) - \sum_{i=1}^k t_i(t_i-1)(2t_i+5)}{18} \quad (13)$$

şeklinde hesaplanır. Eşitlik (13)'de k ; veri setindeki bağıl grupların sayısı, t_i değeri ise i uzunluğundaki bir seride bağı gözlemlerdir. Standartlaştırılmış Mann-Kendall istatistiği Z ise,

$$Z = \begin{cases} \frac{S-1}{\sqrt{\text{Var}(S)}}; & S > 0 \\ 0; & S = 0 \\ \frac{S+1}{\sqrt{\text{Var}(S)}}; & S < 0 \end{cases} \quad (14)$$

şeklinde hesaplanır. Ardından, %95 istatistik güvenle ($Z_{(1-\alpha/2)}$) hesaplanan standart normal dağılım tablo değeri (Z_{tablo}) ile Standartlaştırılmış Mann-Kendall istatistiği (Z) karşılaştırılır. Buna göre; $|Z| < Z_{\text{tablo}}$ ise H_0 hipotezi kabul edilir. Yani seride trend yoktur. Eğer $|Z| > Z_{\text{tablo}}$ ise H_0 hipotezi reddedilir. Bu durumda serinin trende sahip olduğu sonucuna varılır. Eğer S değeri pozitif ise artan yönde trend, negatif ise azalan yönde trend mevcuttur (Mann, 1945; Kendall, 1975; Beşel & Tanır Kayıkcı, 2019). Şekil 1'de Mann-Kendall testine ait iş akış şeması sunulmuştur.



Şekil 1. Mann-Kendall testi iş akış şeması

3. Uygulama

3.1. Çalışma Alanı ve Veri

Bu çalışmada; TUDES ağında mareograf istasyonu ile ortak yerleşkeli Doğu Karadeniz kıyısı, Trabzon ilinde bulunan TRBZ sabit GNSS istasyonu kullanılmıştır (Şekil 2). TRBZ istasyonu; Trimble alıcı ve TRM39105.00 anten donanımına sahiptir. Çalışma kapsamında GPS L1 sinyaline ait SNR verileri kullanılmış olup veri zaman aralığı Temmuz 2019 - Ağustos 2020 olarak seçilmiştir. Veri kayıt aralığı ise 30 saniyedir.



Şekil 2. a) İstasyon konumu, b) TRBZ istasyonu

Yansıyan GNSS sinyalleri üzerindeki meteorolojik parametrelerin etkisini incelemek için hava basıncı, sıcaklık ve rüzgar hızı verileri kullanılmıştır. Hava basıncı verisi TUDES (TUDES, 2022) üzerinden sağlanmış olup veri kayıt aralığı 15 dakikadır. Sıcaklık ve rüzgar hızı verileri ise ERA5 veri seti (Climate Data Store, 2021) üzerinden saatlik olarak alınmıştır. Doğrulama verisi olarak kullanılan TRBZ istasyonuna ortak yerleşkeli ve radar sensörlü sisteme sahip olan Trabzon mareograf istasyonu verileri TUDES (TUDES, 2022) üzerinden 15 dakika veri kayıt aralığı ile temin edilmiştir.

3.2. Veri Analizi

Çalışmada öncelikle TRBZ sabit GNSS istasyonunun bulunduğu bölgede sadece denizden yansıyan sinyalleri almak amacıyla denizel alanı kapsayacak şekilde uydu yükseklik açısı ve azimut aralıkları belirlenmiştir (Tablo 1). Bu nedenle uydu yükseklik açısı aralığı 5°-15°, azimut aralığı ise 85°-160° olarak seçilmiştir.

Belirlenen aralıklardaki tüm uydular yükselen ve alçalan uydu geçişleri olmak üzere iki gruba ayrılmıştır. Ardından bu gruplarda bulunan tüm uydu izlerine ait SNR verileri analiz edilmiştir.

Tablo 1. TRBZ istasyonu azimut ve uydu yükseklik açısı aralıkları

	TRBZ
Azimut (derece)	85-160
Yükseklik açısı (derece)	5-15

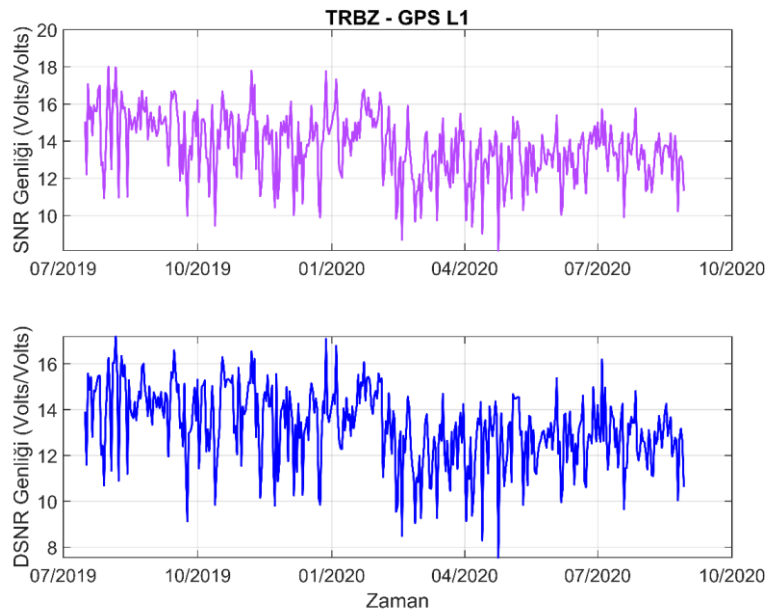
SNR, sinyal gücünün gürültü gücüne oranı olarak tanımlanmakta olup,

$$SNR = \frac{C/N_0}{B} \quad (15)$$

şeklinde hesaplanır. GNSS antenleri genellikle doğrudan gelen sinyali daha güçlü, yansıyan sinyali ise daha zayıf olacak şekilde tasarlanmıştır. Dolayısıyla SNR gözlemlerinde doğrudan gelen sinyalin katkısı, yansıyan sinyalin katkısına göre daha büyüktür. Bu nedenle doğrudan gelen sinyalin etkisinin kaldırılması gerekmektedir. Bu etkiyi kaldırmak ve sadece yansıyan GNSS sinyalini kullanmak için SNR verisine düşük dereceli polinom uygulanarak doğrudan gelen GNSS sinyalinin etkisi veri setinden çıkarılmaktadır. Bunun sonucunda trendden arındırılmış SNR verileri (δ SNR) elde edilmektedir. δ SNR için sinyal yansıma etkisi salınımları,

$$\delta SNR = A \cos\left(\frac{4\pi h}{\lambda} \sin(\theta) + \phi\right) \quad (16)$$


şeklinde dir. Eşitlik (16)'da, A; genlik, h; anten faz merkezi ile yansıma yüzeyi arasındaki düşey mesafe (reflektör yüksekliği), λ ; GNSS taşıyıcı dalga boyu, θ ; uydu yükseklik açısını, ϕ ; faz ofsetidir (Larson vd., 2013). Şekil 3'te TRBZ sabit GNSS istasyonuna ait SNR ve δ SNR genlikleri gösterilmiştir. Şekil 3'e göre, SNR genliği 8.1112 Volts/Volts ile 18.0069 Volts/Volts arasında değişmekte iken δ SNR genliği 7.5446 Volts/Volts ile 17.1824 Volts/Volts arasındadır.




Şekil 3. SNR ve δ SNR genlikleri

δ SNR genliği hesaplandıktan sonra hava basıncı, rüzgar hızı ve sıcaklık parametreleri ile ilişkisi incelenmiştir. Bu aşamada hava basıncı, rüzgar hızı ve sıcaklık verileri günlük verilere dönüştürülmüştür. Aşağıda öncelikle Basit Doğrusal Regresyon analizinden elde edilen sonuçlar verilmiştir.

Şekil 4'te δ SNR genliği ve hava basıncı arasındaki ilişki gösterilmiştir. Hava basıncı verisi ~1002 mbar ila 1032 mbar arasında değişmektedir. Burada zaman serisinin genel seyrine bakıldığında artan ve azalan yönde trendler içerdiği görülmüştür. Bu nedenle seri iki ayrı parçaya bölünerek parçalı trend analizi ile ayrı ayrı değerlendirmeye alınmıştır (Şekil 5).

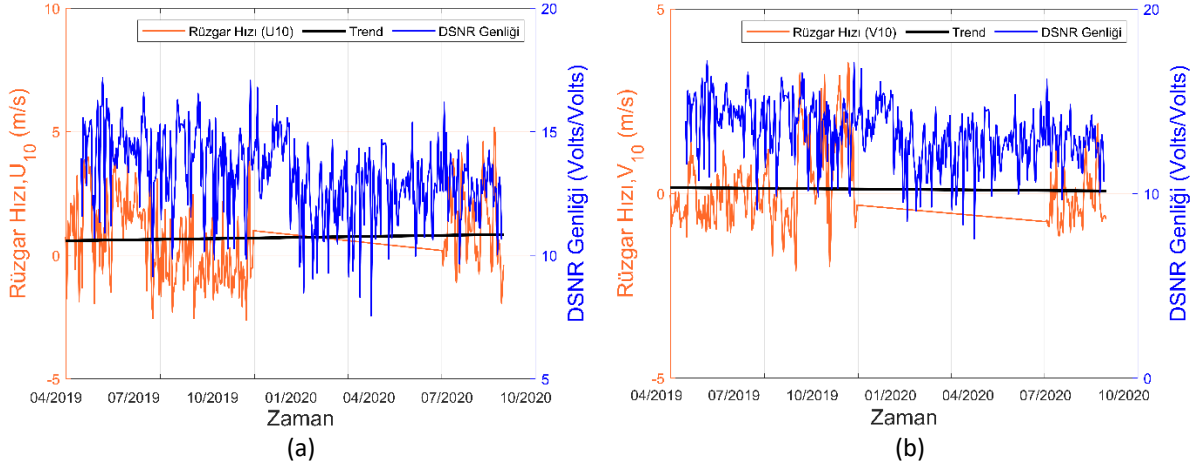


Şekil 4. δ SNR genliği ve hava basıncı ilişkisi



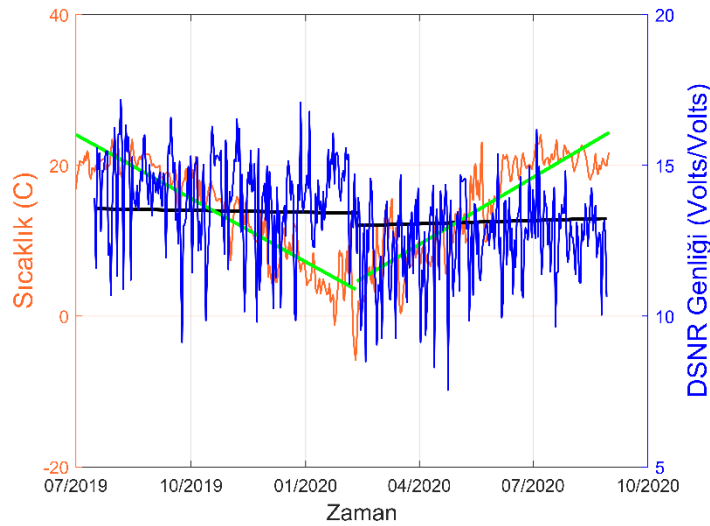
Şekil 5. δ SNR genliği ve hava basıncı ilişkisi: (a) birinci dönem, (b) ikinci dönem

Şekil 5(a)'ya bakıldığında, Temmuz 2019-Şubat 2020 döneminde hava basıncında artan yönde trend, δ SNR genliğinde ise azalan yönde trend gözlemlenmiştir. Şekil 5(b)'de ise Şubat 2020-Eylül 2020 dönemine gelindiğinde ise hava basıncında azalan yönde trend mevcutken δ SNR genliğinde artan yönde trend mevcuttur.



Şekil 6. δSNR genliği ve rüzgar hızı ilişkisi: a) doğu yönündeki rüzgar hızı, b) kuzey yönündeki rüzgar hızı

Şekil 6'da doğu yönündeki (U10) ve kuzey yönündeki (V10) rüzgar hızları ile δSNR ilişkisi sunulmuştur. Buna göre, doğu yönündeki rüzgar hızı (U10) ile δSNR genliği arasında aynı yönde bir eğilim vardır. Diğer yandan kuzey yönündeki rüzgar hızında ise trend yoktur.



Şekil 7. δSNR genliği ve sıcaklık ilişkisi

Son olarak δSNR genliği ile sıcaklık ilişkisi incelenmiştir (Şekil 7). Burada zaman serisi iki ayrı döneme bölünerek parçalı trend analizi yapılmıştır. Buna göre; Temmuz 2019-Şubat 2020 döneminde sıcaklık ve δSNR genliğinde azalan yönde trend varken Şubat 2020-Eylül 2020 döneminde ise sıcaklık ve δSNR genliğinde artan yönde trend vardır.

Diğer yandan meteorolojik parametrelerinin zaman içerisinde gösterdiği eğilim ile δSNR genliği arasındaki ilişkiye Mann-Kendall trend analizi kullanılarak bakılmıştır. Mann-Kendall trend analizinde öncelikle Mann-Kendall test değeri (Z) hesaplanmış olup %95 istatistik güvenle elde edilen standart normal dağılım tablo değeri ile karşılaştırılarak trend olup olmadığı belirlenmiştir. Aşağıda her bir meteorolojik parametre ile elde edilen sonuçlar verilmiştir.

Tablo 2. δ SNR ve hava basıncı Mann-Kendall trend analizi

	Veri	Standartlaştırılmış Mann-Kendall İstatistiği (Z)	Standart Normal Dağılım Tablo Değeri ($\alpha=0.05$)	Trend	Trend Yönü
1. DÖNEM	Hava basıncı	-2.0315	1.96	Trend var	Artan
	δ SNR	-2.7796	1.96	Trend var	Azalan
2. DÖNEM	Hava basıncı	2.2118	1.96	Trend var	Azalan
	δ SNR	2.2711	1.96	Trend var	Artan

Tablo 2’de hava basıncı ve δ SNR verilerine uygulanan Mann-Kendall trend analizi sonuçları verilmiştir. Birinci dönemde hava basıncında artan yönde trend varken δ SNR verilerinde azalan yönde trend, ikinci dönemde ise hava basıncında azalan yönde trend, δ SNR genliğinde ise artan yönde trend görülmüştür.

Tablo 3. δ SNR ve rüzgar hızı Mann-Kendall trend analizi

Veri	Standartlaştırılmış Mann-Kendall İstatistiği (Z)	Standart Normal Dağılım Tablo Değeri ($\alpha=0.05$)	Trend	Trend Yönü
Rüzgar Hızı (V10)	1.8757	1.96	Trend yok	-
Rüzgar Hızı (U10)	-2.0848	1.96	Trend var	Azalan
δ SNR	-8.3576	1.96	Trend var	Azalan

Tablo 3’te rüzgar hızı ve δ SNR verilerine uygulanan Mann-Kendall trend analizi sonuçları gösterilmiştir. Burada, kuzeye bakan rüzgar hızında (V10) herhangi bir trend yok iken doğuya bakan rüzgar hızında (U10) azalan yönde trend görülmüştür. Aynı şekilde δ SNR genliği de zaman içerisinde azalan yönde bir eğilim göstermiştir.

Tablo 4. δ SNR ve sıcaklık Mann-Kendall trend analizi


	Veri	Standartlaştırılmış Mann-Kendall İstatistiği (Z)	Standart Normal Dağılım Tablo Değeri ($\alpha=0.05$)	Trend	Trend Yönü
1. DÖNEM	Sıcaklık	-14.6121	1.96	Trend var	Azalan
	δ SNR	-2.7796	1.96	Trend var	Azalan
2. DÖNEM	Sıcaklık	15.5262	1.96	Trend var	Artan
	δ SNR	2.2711	1.96	Trend var	Artan

Tablo 4’te sıcaklık ve δ SNR verilerine uygulanan Mann-Kendall trend analizi sonuçları sunulmuştur. Burada, birinci dönemde sıcaklık ve δ SNR verilerinde azalan yönde trend mevcutken ikinci dönemde ise artan yönde trend mevcuttur. Mann-Kendall trend analizinde trend büyüklüğünün belirleyicisi olan Standartlaştırılmış Mann-Kendall İstatistiğine (Z)

bakıldığında, en büyük Z değeri 15.5262 ile ikinci dönem sıcaklık verilerinde elde edilmiştir. En küçük Z değeri ise kuzeye bakan rüzgar hızında (V10) görülmüştür.

Çalışmada her bir meteorolojik parametre ve δ SNR verilerine uygulanan Basit Doğrusal Regresyon ve Mann-Kendall testleri ile elde edilen trendlerin genel olarak aynı yönde olduğu görülmüştür. Her iki yöntemde sıcaklık arttıkça δ SNR genliği de artan yönde eğilim göstermiştir. Tersi durumda da benzer sonuçlar elde edilmiştir. Rüzgar hızında ise; doğuya bakan rüzgar hızında (U10) Basit Doğrusal Regresyon analizinde artan yönde Mann-Kendall testinde ise azalan yönde trend bulunmuştur. δ SNR genliği trendleri de her iki yöntemde doğuya bakan rüzgar hızı (U10) ile aynı yönde eğilim göstermiştir. Kuzeye bakan rüzgar hızında (V10) ise her iki yöntemde de trend bulunamamıştır. Hava basıncı parametresine bakıldığında, her iki yöntemde de aynı yönde trendler elde edilmiştir.

Yansıyan GNSS sinyali ile meteorolojik parametrelerin eğilimleri incelendikten sonra yine yansıyan GNSS sinyalleri kullanılarak hesaplanan GNSS-IR tekniğine dayalı deniz seviyesi verileri ile karşılaştırma yapılmıştır. Bunun için TRBZ istasyonu δ SNR verilerine uygulanan Lomb-Scargle periyodogramı ile en yüksek spektral güce karşılık gelen baskın frekans belirlenerek ve $H = \frac{\lambda f}{2}$ kullanılarak anten faz merkezi ile yansıma yüzeyi arasındaki düşey mesafe (reflektör yüksekliği) hesaplanmıştır. Burada λ ; GNSS taşıyıcı dalga boyu, f ; frekansı ifade etmektedir. Reflektör yüksekliklerinin GNSS antenin ortometrik yüksekliğinden farkı alınarak GNSS-IR tekniğine dayalı deniz seviyesi belirlenmiştir. Şekil 8'de GNSS-IR tekniğine dayalı deniz seviyesi ve meteorolojik parametreler ilişkisi gösterilmiştir. Meteorolojik parametrelerin deniz seviyesi değişimi üzerindeki etkisinden Bölüm 1'de bahsedilmiş olup burada da destekler nitelikte sonuçlar elde edilmiştir. Özellikle sıcaklık ve hava basıncı ile olan ilişki açıkça görülmektedir. Sıcaklık azaldıkça GNSS-IR deniz seviyesi değişiminin azalmış olup tersi durumda da aynı yönde bir değişim göstermiştir. Hava basıncı ile ters yönlü bir ilişki olduğu görülmüştür.



Şekil 8. GNSS-IR deniz seviyesi ve meteorolojik parametreler (a) sıcaklık, b) hava basıncı, c) rüzgar hızı U₁₀; d) rüzgar hızı V₁₀)

Çalışmada GNSS-IR tekniğine dayalı olarak elde edilen deniz seviyesi verilerinin yanında doğrulama yapmak için mareograf verileri de kullanılmış olup meteorolojik parametrelerin her iki veri seti ile arasındaki ilişki belirlenmiştir. Bunun için Pearson ve Spearman korelasyon katsayıları hesaplanmıştır. Pearson korelasyon katsayısı,

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)\sigma_x\sigma_y} \quad (17)$$

şeklinde hesaplanmıştır. Burada, n ; veri çiftlerini (x_i, y_i) , \bar{x} ve \bar{y} ; değişkenlerin ortalamalarını, σ_x ve σ_y ise değişkenlerin standart sapmalarını ifade etmektedir (Tüysüz & Yaylalı Abanuz, 2012). Spearman korelasyon katsayısı,

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (18)$$

olarak hesaplanmıştır. Burada, d_i ; x_i ve y_i değişkenlerinin küçükten büyüğe doğru sıra sayıları arasındaki farklarının kareleri, n ; veri sayısıdır (Gamgam & Altunkaynak, 2013). Tablo 5'te sırasıyla GNSS-IR ve mareograf deniz seviyesi verileri ile meteorolojik parametreler arasında hesaplanan korelasyon katsayıları verilmiştir.

Tablo 5. GNSS-IR ve mareograf deniz seviyesi ile meteorolojik parametreler ilişkisi

Deniz Seviyesi	Korelasyon	Sıcaklık		Hava Basıncı		Rüzgar Hızı	
		1.Dönem	2.Dönem	1.Dönem	2.Dönem	U10	V10
GNSS-IR	Pearson	0.42	0.52	-0.24	-0.29	0.56	-0.30
	Spearman	0.38	0.39	-0.27	-0.32	0.56	-0.23
Mareograf	Pearson	0.43	0.53	-0.21	-0.30	0.56	-0.31
	Spearman	0.44	0.43	-0.26	-0.33	0.55	-0.25

Tablo 5'e bakıldığında, hem GNSS-IR hem de mareograf verilerinin sıcaklık verileri ile orta düzeyde ilişkide olduğu görülmüştür. En yüksek korelasyon 0.53 Pearson korelasyonu katsayısı ile mareograf ve sıcaklık arasında 2. dönemde hesaplanmıştır. En düşük korelasyon ise 0.38 Spearman korelasyon katsayısı ile GNSS-IR deniz seviyesi ve sıcaklık arasında 1.dönemde elde edilmiştir. Hava basıncı verileri ile hem GNSS-IR hem de mareograf verilerinin negatif yönde ve düşük düzeyde ilişkide olduğu görülmüştür. GNSS-IR ve mareograf deniz seviyesi verilerinin doğu yönündeki (U10) rüzgar hızı ile orta düzeyde, kuzey yönündeki (V10) rüzgar hızı ile negatif yönde ve düşük düzeyde ilişkide olduğu görülmüştür. En yüksek korelasyon hem GNSS-IR hem de mareograf verileri ile 0.56 ile doğu yönündeki (U10) rüzgar hızında elde edilmiştir. Bu çalışmada Temmuz 2019 - Ağustos 2020 periyodundaki deniz seviyesi verileri ile meteorolojik parametreler arasında hesaplanan korelasyonlara bakıldığında yüksek düzeyde bir ilişki bulunmamıştır.

4. Sonuçlar

GNSS-IR tekniğinin deniz seviyesi değişiminde kullanımı, sağladığı avantajlar dolayısıyla kıymetlidir. Bununla birlikte teknik geliştirilmeye de açıktır. GNSS-IR tekniğinin deniz seviyesi değişiminde kullanımı; düşey yer kabuğu hareketinden etkilenmemesi, kurulum ve bakım maliyeti, mareograf istasyonuna göre kıydan itibaren daha geniş bir bölgedeki deniz seviyesini algılama potansiyeli ve Uluslararası Yersel Referans Ağı'na (ITRF) göre deniz seviyesi değişiminin belirlenmesine imkan sağlaması gibi birtakım avantajları dolayısıyla önemli olmakla beraber deniz seviyesi değişiminin izlenmesinde bir potansiyeldir. Dolayısıyla elde edilen sonuçların doğruluk ve güvenilirliğini artırmak için GNSS-IR tekniğine etki eden faktörlerin belirlenmesi önemlidir. Yüze pürüzlülüğü yansıyan GNSS sinyali etkileyen bir faktördür. Bu çalışmada TRBZ sabit GNSS istasyonunun bulunduğu alanda pürüzlülüğe neden olabilecek hava basıncı, sıcaklık ve rüzgar hızı meteorolojik parametrelerinin yansıyan GNSS sinyali üzerindeki etkisi araştırılmıştır. Basit Doğrusal Regresyon ve Mann-Kendall trend analizi yöntemleri uygulanarak meteorolojik parametreler ve δ SNR genliğinin zaman içerisinde gösterdiği eğilim değerlendirilmiştir. Elde edilen sonuçlara bakıldığında, sıcaklık arttıkça δ SNR genliğinin arttığı görülmüştür. Bu durum artan sıcaklıkla beraber saçınım arttığı ve antene doğru olan yansımaların azaldığı şeklinde yorumlanabilir. Diğer yandan hava basıncındaki azalma ile de δ SNR genliğinin arttığı tespit edilmiştir. Son olarak GNSS-IR ve mareograf deniz seviyesi ile meteorolojik parametreler arasındaki ilişki Pearson ve Spearman korelasyonları hesaplanarak incelenmiş olup parametreler arasında orta düzeyde ilişkiler bulunmuştur. Bu çalışmada meteorolojik parametreler ve yansıyan GNSS sinyalleri arasındaki ilişki bölgesel olarak değerlendirilmiştir. Elde edilen sonuçlara bakıldığında aralarında kesin bir ilişki görülmemiştir. Bu nedenle kesin bir etkiden de bahsedilmesi mümkün olmamaktadır. İleride yapılacak olan daha kapsamlı çalışmalarla bu ilişkinin derinlemesine incelenmesi mümkündür.

Teşekkür

Bu çalışmada kullanılan TRBZ sabit GNSS istasyonu verileri Karadeniz Teknik Üniversitesi ve Harita Genel Müdürlüğü arasında yürütülen “Karadeniz Kıyılarındaki Deniz Seviyesi Değişiminin GNSS-IR Tekniği ile Araştırılması” başlıklı ortak araştırma projesi kapsamında temin edilmiştir. Harita Genel Müdürlüğü, Jeodezi Dairesine ve Türkiye Ulusal Deniz Seviyesi İzleme Sistemi'ne teşekkür ederiz. Şekil 2(b), TUDES (<https://tudes.harita.gov.tr/Portal/>) üzerinden temin edilmiştir.

Kaynaklar

- Altuntaş, C., & Tunalıoğlu, N. (2022). Deniz seviyesi değişimlerinin belirlenmesinde GNSS-IR yönteminin kullanımı ve doğruluk analizi üzerine bir araştırma. *Geomatik*, 7(3), 187-196.
- Asgarimehr, M., Zavorotny, V., Wickert, J., & Reich, S. (2018). Can GNSS reflectometry detect precipitation over oceans?. *Geophysical Research Letters*, 45(22), 585-592.
- Beşel, C., & Kayıkçı, E. T. (2022). Determination of sea level variations in Turkish Mediterranean coast using GNSS reflectometry. *Survey Review*, 54(385), 310–319. <https://doi.org/10.1080/00396265.2021.1939589>
- Beşel, C., & Tanır Kayıkçı, E. (2019). Serisel korelasyonun toplam zenit gecikmesi zaman serilerinde parametrik olmayan trend belirleme üzerindeki etkisi. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 9(1), 180-188.
- Beşel, C. (2017). *IGS istasyonları zenit troposferik gecikme parametresi zaman serilerinde trend ve mevsimsel etki analizleri* [Yüksek lisans tezi, Karadeniz Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Bilich, A., Larson, K. M., & Axelrad, P. (2008). Modeling GPS phase multipath with SNR: case study from the Salar de Uyuni, Boliva. *Journal of Geophysical Research: Solid Earth*, 113(B4), Article B04401. <https://doi.org/10.1029/2007JB005194>
- Braasch, M.S. (2017). *Multipath*. Springer Handbook of Global Navigation Satellite Systems.
- Climate Data Store. (2022, July). *Temperature and wind speed data*. Climate Data Store (CDS). <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=overview>
- Durand, M., Rivera, A., Nievinski, F., Lenzano, M. G., Monico, J. F. G., Paredes, P., & Lenzano, L. (2019). GPS reflectometry study detecting snow height changes in the Southern Patagonia Icefield. *Cold Regions Science and Technology*, 166, Article 102840. <https://doi.org/10.1016/j.coldregions.2019.102840>
- Elosegui, P., Davis, J. L., Jaldehag, R. T. K., Johansson, J. M., Niell, A. E., & Shapiro, I. I. (1995). Geodesy using the Global Positioning System: the effects of signal scattering on estimates of site position. *Journal of Geophysical Research*, 100(6), 2156-2202.
- Gamgam, H., & Altunkaynak, B. (2013). *SPSS uygulamalı parametrik olmayan yöntemler*. Seçkin Yayıncılık.
- Georgiadou, P.Y., & Kleusberg, A. (1988). On carrier signal multipath effects in relative GPS positioning. *Manuscripta Geodaetica*, 13(3),172-179.
- Geremia-Nievinski, F., Hobiger, T., Haas, R., Liu, W., Strandberg, J., Tabibi, S., Vey, S., Wickert, J., & Williams, S. (2020). SNR-based GNSS reflectometry for coastal sea-level altimetry: results from the first IAG inter-comparison campaign. *Journal of Geodesy*, 94(8), Article 70. <https://doi.org/10.1007/s00190-020-01387-3>
- Ghiasi, Y., Duguay, C. R., Murfitt, J., van der Sanden, J. J., Thompson, A., Drouin, H., & Prévost, C. (2020). Application of GNSS interferometric reflectometry for the estimation of lake ice thickness. *Remote Sensing*, 12(17), Article 2721. <https://doi.org/10.3390/RS12172721>
- Ghiasi, Y., Duguay, C., & Murfitt, J. (2021, March 29-31). *Temperature effect on reflected GNSS signals from mid-latitude lake ice* [Conference presentation]. The first workshop of the Inter-Commission Committee on Geodesy for Climate Research (ICCC), Potsdam, Germany.
- Karegar, M. A., Larson, K. M., Kusche, J., & Dixon, T. H. (2020). Novel quantification of shallow sediment compaction by GPS Interferometric Reflectometry and implications for flood susceptibility. *Geophysical Research Letters*, 47(14), Article e2020GL087807. <https://doi.org/10.1029/2020GL087807>
- Katzberg, S. J., & Garrison, J. L. (1996). *Utilizing GPS to determine ionospheric delay over the ocean* (Report Number NASA-TM-4750). NASA Langley Research Center. <https://ntrs.nasa.gov/citations/19970005019>
- Katzberg, S. J., Garrison, J., & Howell, C. (1999, September 14-17). *Simple over-water altimeter using GPS reflections* [Meeting presentation], 12th International Technical Meeting of the Satellite Division of The Institute of Navigation, Nashville, Tennessee.
- Kendall, M.G., (1975). *Rank correlation methods*. Charles Griffin.
- Kim, S. K., & Park, J. (2021). Monitoring a storm surge during Hurricane Harvey using multi-constellation GNSS-Reflectometry. *GPS Solutions*, 25(2), Article 63. <https://doi.org/10.1007/s10291-021-01105-2>

- Larson, K. M., Lay, T., Yamazaki, Y., Cheung, K. F., Ye, L., Williams, S. D. P., & Davis, J. L. (2021). Dynamic sea level variation from GNSS: 2020 Shumagin earthquake tsunami resonance and hurricane Laura. *Geophysical Research Letters*, 48(4), Article e2020GL091378. <https://doi.org/10.1029/2020GL091378>
- Larson, K. M., Ray, R. D., & Williams, S. D. P. (2017). A 10-year comparison of water levels measured with a geodetic GPS receiver versus a conventional tide gauge. *Journal of Atmospheric and Oceanic Technology*, 34(2), 295–307.
- Larson, K. M., Ray, R. D., Nievinski, F. G., & Freymueller, J. T. (2013). The accidental tide gauge: a GPS reflection case study from Kachemak bay, Alaska. *IEEE Geoscience and Remote Sensing Letters*, 10(5), 1200-1204.
- Larson, K. M., Löfgren, J. S., & Haas, R. (2013). Coastal sea level measurements using a single geodetic GPS receiver. *Advances in Space Research*, 51(8), 1301–1310. <https://doi.org/10.1016/j.asr.2012.04.017>
- Larson, K. M., & Nievinski, F. G. (2013). GPS snow sensing: Results from the EarthScope plate boundary observatory. *GPS Solutions*, 17(1), 41–52. <https://doi.org/10.1007/s10291-012-0259-7>
- Larson, K. M., Small, E. E., Gutmann, E., Bilich, A., Axelrad, P., & Braun, J. (2008). Using GPS multipath to measure soil moisture fluctuations: Initial results. *GPS Solutions*, 12(3), 173–177. <https://doi.org/10.1007/s10291-007-0076-6>
- Lu, R., Chen, W., Dong, D., Wang, Z., Zhang, C., Peng, Y., & Yu, C. (2021). Multipath mitigation in GNSS precise point positioning based on trend-surface analysis and multipath hemispherical map. *GPS Solutions*, 25(3), Article 119. <https://doi.org/10.1007/s10291-021-01156-5>
- Mann, H. B. (1945). Non-parametric tests against trend. *The Econometric Society*, 3, 245-259.
- Martin-Neira, M. (1993). A Passive Reflectometry and Interferometry System (PARIS): application to ocean altimetry. *ESA Journal*, 17(4), 331-355.
- Moradi, R., Schuster, W., Feng, S., Jokinen, A., & Ochieng, W. (2015). The carrier-multipath observable: a new carrier-phase multipath mitigation technique. *GPS Solutions*, 19(1), 73-82.
- Öztürk, E., & Şerbetçi, M. (1992). *Dengeleme Hesabı III* (Yayın No. 144). Karadeniz Teknik Üniversitesi.
- Tabibi, S., Sauveur, R., Guerrier, K., Metayer, G., & Francis, O. (2021). SNR-based GNSS-R for coastal sea-level altimetry. *Geosciences*, 11(9), Article 391. <https://doi.org/10.3390/geosciences11090391>
- Tüysüz, N., & Yaylalı Abanuz, G. (2012). *Jeoistatistik: Kavramlar ve Bilgisayarlı Uygulamalar*. Karadeniz Teknik Üniversitesi Matbaası.
- TUDES. (2022, Haziran). *Deniz seviyesi*. Türkiye Ulusal Deniz Seviyesi İzleme Sistemi (TUDES). <https://tudes.harita.gov.tr/Portal/VeriSorgula>
- Vey, S., Güntner, A., Wickert, J., Blume, T., & Ramatschi, M. (2016). Long-term soil moisture dynamics derived from GNSS interferometric reflectometry: a case study for Sutherland, South Africa. *GPS Solutions*, 20(4), 641–654.
- Wang, X., Zhang, Q., & Zhang, S. (2018). Water levels measured with SNR using wavelet decomposition and Lomb–Scargle periodogram. *GPS Solutions*, 22(1), Article 22. <https://doi.org/10.1007/s10291-017-0684-8>
- Zhang, S., Zhang, C., Zhao, Y., Li, H., Liu, Q., & Pang, X. (2021). Snow depth estimation based on GNSS-IR cluster analysis. *Measurement Science and Technology*, 32(9), Article 095801. <https://doi.org/10.1088/1361-6501/abee54>

İstanbul Kent Atmosferindeki Aerosollerin Spektral, Konumsal ve Zamansal Analizi

Spectral, Spatial and Temporal Analysis of Aerosol over İstanbul Urban Atmosphere

Funda Yüzlükoğlu^{1,2*}, Kazım Kaba³, Cahit Yeşilyaprak³

¹Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Astronomi ve Astrofizik Anabilim Dalı, 25100, Erzurum /Türkiye.

²Manisa Celal Bayar Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Fizik Bölümü, 45140, Manisa /Türkiye.

³Atatürk Üniversitesi, Fen Fakültesi, Astronomi ve Uzay Bilimleri Bölümü, 25100, Erzurum /Türkiye.

ARAŞTIRMA MAKALESİ

***Sorumlu yazar:**

Funda Yüzlükoğlu
funda.yuzlukoglu@cbu.edu.tr

doi: 10.48123/rsgis.1489463

Yayın süreci

Geliş tarihi: 24.05.2024
Kabul tarihi: 20.08.2024
Basım tarihi: 26.09.2024

Özet

Atmosferde akışkan hava içinde sıvı ve/veya katı halde asılı bulunan parçacıklar "Atmosferik Aerosol" olarak tanımlanmaktadır. Aerosol hava, iklim, iklim değişikliği, hava kalitesi, halk sağlığı ve astronomi gibi pek çok disiplini etkileyen önemli bir olgudur. Bu çalışmada uzaktan algılama verileriyle İstanbul ili için atmosferik aerosollerin konumsal, zamansal ve spektral özellikleri incelenmiştir. Bu kapsamda İstanbul'un uzun dönem ortalama Aerosol Optik Derinliği (AOD), Angstrom Katsayısı, spektral AOD ve zamansal (aylık, mevsimlik ve yıllık) haritaları üretilerek konumsal, spektral ve zamansal değerlendirmeler yapılmıştır. Çalışmada Suomi-NPP uydusundaki VIIRS algılayıcısından elde edilen aerosol verileri kullanılmıştır. Bu çalışma ile İstanbul için nispeten fazla detay içeren yüksek çözünürlükte, alansal ve zamansal sürekliliğe sahip, en güncel ve pek çok disiplinde yapılan çalışmalara katkı sağlayacak AOD haritaları sunulmuştur. İstanbul ilinin yüksek AOD değerleri kentin güneyinde Marmara Denizi kıyı şeritleri ve nüfus yoğunluğunun yüksek olduğu kıyıya yakın yerler ile Kuzeyde Sarıyer kıyıları ve nispeten Karadeniz'in kara ile buluştuğu kıyı kesimleridir. Kara üzerinde kentin nüfus yoğunluğu ve bitki örtüsü ile ilintili bir AOD değişimi vardır.

Anahtar kelimeler: Aerosol optik derinlik, Mekânsal değişim, Spektral değişim

Abstract

Particles suspended in liquid and/or solid form in the fluid air in the atmosphere are defined as "Atmospheric Aerosol". Aerosol is an important phenomenon that affects many disciplines such as weather climate, climate change, air quality, public health and astronomy. In this study, spatial, temporal and spectral characteristics of atmospheric aerosols for İstanbul province were examined with remote sensing data. In this regard, long-term average, Aerosol Optical Depth (AOD) map, Angstrom exponent map, spectral AOD maps and temporal (monthly, seasonal and annual) maps of İstanbul were produced and spatial, spectral and temporal evaluations were performed. Aerosol data obtained from the VIIRS sensor on the Suomi-NPP satellite was used in this study. AOD maps for İstanbul, which contain relatively more detail, are high resolution, have spatial and temporal continuity, are the most up-to-date and will contribute to studies in many disciplines, have been presented. The high AOD values of İstanbul province are the Marmara Sea coastlines in the south of the city and the places close to the coast where the population density is high, and the Sarıyer coasts in the north and the coastal areas where the Black Sea meets the land. There is an AOD change on land related to the city's population density and vegetation.

Keywords: Aerosol optical depth, Spatial variation, Spectral variation

1. Giriş

Aerosol, bir akışkan içinde asılı bulunan sıvı veya katı parçacıklı yapılar olarak tanımlanmıştır. Aerosoller, fiziksel durumlarına göre sıvı ve katı parçacıklı, boyutlarına göre ise; kaba (coarse), ince (fine) ve ultra ince (ultra fine) olarak tanımlanırlar. Çapı 2.5 µm'den büyük olan parçacıklar kaba, çapı 0.1 - 2.5 µm aralığında olanlar ince ve çapı 0.1 µm'den küçük olan parçacıklar da ultra ince parçacıklı aerosoller olarak tanımlanırlar (Tomasi & Lupi, 2017; Hinds, 1999).

Atmosferde akışkan hava içinde sıvı ve katı halde asılı bulunan parçacıklar "Atmosferik Aerosol (AA)" olarak tanımlanmaktadır. Bu parçacıklı maddeler kaynaklarına göre; doğal ve insan kaynaklı (antropojenik) olarak ikiye ayrılmaktadır (Tomasi & Lupi, 2017). Denizler, çöl alanları, orman yangınları ve volkanlar doğal aerosol kaynakları iken, endüstriyel faaliyetler, ulaştırma, tarım ve madencilik gibi insan kaynaklı faaliyetler ise antropojenik kaynaklardır. Atmosferdeki partikül maddeler kaynağı, boyutları, fiziksel ve kimyasal özelliklerine bağlı olarak olumlu veya olumsuz etkilere sahiptir. Doğal kaynaklı aerosoller gezegenimizde yaşamın devamı için gerekli olan süreçlerin (bulut oluşumu ve dolayısıyla yağış oluşumu ile saçılmaya neden olarak yer yüzünün enerji dengesine olumlu katkı yapması gibi) devamını sağlarken yapay kaynaklı aerosoller (genellikle doğal kaynaklı aerosollerden daha küçüktür) başta doğa ve insan sağlığı olmak üzere pek çok olumsuz etkilere sahiptir (Tomasi & Lupi, 2017).

Aerosoller atmosferimize yerden yükselen parçacıkların girmesiyle, atmosfer dışından gelen kozmik parçacıklar nedeniyle ve atmosferdeki kimyasal süreçler vasıtasıyla meydana gelir. Atmosfere doğrudan giren aerosoller birincil ve atmosferde kimyasal yolla üretilen aerosoller ise ikincil olarak adlandırılır (Tomasi & Lupi, 2017).

Aerosol optik derinlik (AOD) kısaca belli bir dalga boyundaki elektromanyetik enerjinin aerosollar nedeniyle azalması olarak tanımlanır. Başka bir ifadeyle AOD, atmosferik aerosollerin sönmüleme (saçılma ve soğurma) nedeniyle ışığın iletimini ne kadar engellediğini ifade eden bir parametredir. AOD küresel ölçekte 0-5 arasında değer alabilen (uydu verileri bu ölçektir), ancak sıklıkla 0-1 arasında ve toz kaynakları ve toz taşınımı gibi aşırı meteorolojik hadiseler nedeniyle 1 (bir) üzerinde değer alabilen birimsiz bir niceliktir (MGM, 2023). AOD değerleri yer yüzeyinden atmosferin üzerine uzanan dikey sütun boyunca aerosol miktarının bir ölçüsüdür. AOD değerlerinin büyük olması atmosferdeki aerosol miktarının yüksek olduğunu ve küçük olması (sıfıra yaklaşması) partikül madde açısından temiz bir atmosferin varlığını gösterir. Bir alanda kuvvetli veya çok kuvvetli kum ve toz fırtınaları yaşandığında, AOD değerleri 1'in üzerinde görülebilmektedir (Meteoroloji Genel Müdürlüğü, 2023). Angstrom katsayısı (AE) ışığın çeşitli dalga boyuna göre AOD'nin nasıl değiştiğinin bir ölçüsüdür ("spektral bağımlılık" olarak bilinir). AE, aerosol partikül boyutu ile ilgilidir. Kabaca söylemek gerekirse, 1'den küçük AE değerleri, kaba parçacıkların (örn. toz, kül, deniz tuzu/spreyi) optik baskınlığını gösterirken, 1'den büyük değerler ince parçacıkların (örn. duman, endüstriyel kirlilik) baskınlığını gösterir. Aerosol boyutlarının değerlendirilmesi için AE parametresi kullanılmaktadır. AE'nin küçük olması, toz gibi büyük çaplı parçacıkların ortamda daha baskın olduğunu göstermektedir. AE'nin yüksek değerleri ise küçük çaplı aerosollerin ortamda baskın olduğunu ifade eder. Ayrıca AE değerleri kullanılarak belli bir dalga boyunda (örneğin 550 nm) bilenen AOD verisi ölçümü yapılmayan (örneğin 500 nm) başka bir dalga boyuna interpolasyonu yapılarak yeni aerosol bilgisi elde edilebilir (Meteoroloji Genel Müdürlüğü, 2023).

Aerosol iklim, iklim değişikliği, hava kalitesi, halk sağlığı ve astronomi gibi pek çok disiplini etkileyen önemli bir olgudur. Bu nedenle Türkiye ve Dünya genelinde farklı disiplinlerde aerosol ile ilgili çeşitli çalışmalar geçmişten günümüze devam etmektedir. Ayrıca son zamanlarda etkileri önemli derecede ortaya çıkan iklim değişikliği de aerosol konusundaki çalışmaların önemini artırmıştır. Bu çalışma İstanbul ilinin aerosol miktarını kapsaması nedeniyle ülkemizde yapılan başlıca aerosol çalışmalarına burada yer verilmiştir. Güllü vd. (1998) Karadeniz aerosolü ve uzak mesafeli atmosferik taşınımını araştırma gemilerinden toplanan verilerle incelemişlerdir. Kabataş vd. (2014) Sahra çöl tozunun Türkiye'deki partikül madde (PM10) değerlerine katkısını inceleyen çalışma yapmışlardır. Zeydan vd. (2019) "Moderate Resolution Imaging Spectroradiometer" (MODIS) AOD verilerini kullanarak Türkiye'de PM2.5 miktarını tahmin etmişlerdir. Tuygun vd. (2020) Türkiye genelinde MODIS veri koleksiyonlarını değerlendiren çalışma yapmışlardır. Tuygun vd. (2020) Türkiye'nin güney kıyı bölgesinde, yer ve uydu tabanlı aerosol miktarının yeryüzü sınır tabaka yüksekliği ile ilişkisinin uzun vadeli zamansal analizini yapmışlardır. Özkan vd. (2021) yaptığı çalışmada, Sahra ve Ortadoğu kaynaklı çöl tozlarının Türkiye'deki ekosistemlere etkisini incelemiştir. Karslıoğlu vd. (2022) ve Tezcan vd. (2022) yapılan çalışmalarda Türkiye'de MODIS AOD değerlerinin ve Türkiye ve yakın çevresinde Güneş fotometreleri ile elde edilen AOD verilerinin zamansal ve alansal değişimini incelemişlerdir. Coşkun vd. (2022) Covid 19 sürecinde Karabük il merkezi ve Zonguldak'ın Ereğli ilçesinde AOD analizini yapmışlardır. Gündoğdu vd. (2022) VIIRS aerosol ürününden günlük PM2.5 miktarını tahmin eden çalışmalarını sunmuşlardır. Tuygun ve Elbir (2023) MODIS AOD verilerini kullanarak makine öğrenme yöntemiyle partikül madde konsantrasyonunu tahmin etmişlerdir. Zeydan vd. (2023) Türkiye için AOD değerlerinin uzun dönem trendini ve AOD ile meteorolojik parametreler ve bitki örtüsü arasındaki ilişkiyi araştırmışlardır. Türkiye ve/veya illeri için yapılan bu çalışmalar oldukça önemli olmakla birlikte Türkiye'nin konumunu düşündüğümüzde farklı aerosol kaynaklarına (çöl ve deniz gibi) yakın olması ve iklim değişikliği nedeniyle aerosol konusundaki çalışmalar periyodik olarak tekrarlanmalı ve yapılan çalışmaların sayısı artırılmalıdır.

Bu çalışmada uzaktan algılama verileriyle İstanbul ili için atmosferik aerosolün konumsal, zamansal ve spektral analizleri yapılmıştır. Bu kapsamda farklı dalga boylarında İstanbul'un uzun dönem ortalama, AOD haritaları, Angstrom Katsayısı haritası ve zamansal (aylık, mevsimlik ve yıllık) haritaları üretilerek konumsal, spektral ve zamansal değerlendirmeler yapılmıştır. Çalışmada uzaktan algılama alanında önemli bir yere sahip olan, Suomi-National Polar-Orbiting Partnership (NPP) uydusundaki Visible Infrared Imaging Radiometer Suite (VIIRS) algılayıcısından elde edilen aerosol verileri kullanılmıştır. Veriler Mart/2012–2023 yılları arasını ve İstanbul ilini kapsamaktadır.

Bu çalışma ile İstanbul ili için detaylı, yüksek çözünürlükte, alansal ve zamansal sürekliliğe sahip, en güncel ve pek çok disiplinde yapılan çalışmalara katkı sunacak AOD haritaları ve AE haritası sunulmuştur. Literatürde nispeten daha düşük piksel çözünürlüklü Türkiye AOD haritaları (genelde MODIS verileri) bulunmakla birlikte İstanbul gibi önemli bir kent için aerosol bilgisi sağlayan haritalar ne MGM kaynaklarında ne de akademik çalışmalarda bulunmamaktadır. Türkiye AOD haritaları önemli bilgiler sunmakla birlikte ülkenin çeşitli bölgelerindeki yerel toz kaynakları için daha detaylı haritalara ihtiyaç vardır. Bu çalışma ise İstanbul aerosol desenini detaylı bir şekilde ortaya koymaktadır. Ayrıca VIIRS, MODIS yerini alacak şekilde tasarlanmış daha gelişmiş algoritmalar ile veri sağlayan bir algılayıcıdır. Bu nedenlerle bu çalışmanın önemli bir eksikliği gidermesi amaçlanmaktadır.

2. Materyal ve Metot

Bu çalışma da Suomi-NPP uydusundaki VIIRS algılayıcısından elde edilen aerosol ürünü kullanılmıştır. İstanbul ili için AOD değerleri spektral, mekânsal ve zamansal ve AE değerleri de konumsal olarak analiz edilmiştir. Uzaktan algılama alanında yer, atmosfer ve buzullar ile ilgili çalışmalara MODIS algılayıcısı 1999'dan beri veri sağlayan ve çeşitli disiplinlerde sıklıkla kullanılan önemli bir cihazdır. Bu algılayıcıdan aerosol verileri de üretilmesine karşın konumsal kapsama ve yersel çözünürlük dezavantaj oluşturmaktadır. MODIS aerosol ürünlerindeki eksiklerin üstesinden gelmek için 6 km yersel çözünürlüğe sahip olan Suomi-NPP uydusundaki VIIRS algılayıcısından elde edilen aerosol ürünü (AERDB_L2_VIIRS_SNPP) çalışmada kullanılmıştır. Bu ürün 2012'den günümüze sağlanmaktadır. Konumsal ve zamansal kapsama ile yersel çözünürlük dikkate alındığında bu ürünün kullanımı uygun bir seçim olmuştur.

Kutupsal yörüngeli Suomi-NPP uydusu NASA için uzaya fırlatılacak gelecek nesil uydu sisteminin kritik bir ilk adımıdır. NASA tarafından geliştirilen ve NOAA (National Oceanic and Atmospheric Administration) tarafından yönetilen uydu 28 Ekim 2011'de Vandenberg tesisinden Delta-2 roketi ile fırlatılmıştır. Suomi-NPP uydusu çıkış evresi için (ascending node) ekvatoru yerel saat ile 13.30'da geçmektedir. Bu uydu dünyanın etrafındaki yörüngesinden (824 km) günde yaklaşık 14 defa geçiş yapar ve neredeyse yer yüzeyinin tamamına yakınına kayıt eder (STAR Calibration Center, 2023). Suomi-NPP uydusunun taşıdığı cihazlardan biri de VIIRS algılayıcısıdır. Bu cihaz 22 spektral kanala sahip olup 0.412 ile 12.012 μm arasında kayıt yapmaktadır. Bu kanallar M (Moderate resolution), I (Imaging resolution) ve DNB (Day/Night band) olmak üzere üç gruba ayrılmıştır. 16 M kanalı, beş I kanalı ve bir tane de DNB kanalı mevcuttur. M kanalları ve DNB kanalı 750 m yersel çözünürlüğe sahip iken I kanalları 375 m yersel çözünürlüğe sahiptir. M kanalları 11 solar ve 5 termal kanaldan, I kanalları ise 3 solar ve 2 termal kanaldan oluşmaktadır. DNB pankromatik kanalı 0.50 ile 0.90 μm spektral genişlikte gece-gündüz kayıt yapan kanaldır (STAR Calibration Center, 2023). AERDB_L2_VIIRS_SNPP ürünü Suomi-NPP VIIRS algılayıcısından elde edilen çeşitli veri setlerine sahip aerosol ürünüdür (LAADS DAAC, 2024). Bu ürün küresel ölçekte, uydu alt noktasında 6 km yersel çözünürlükte, kara yüzeyinde DB (Deep Blue) ve su yüzeyinde SOAR (Satellite Ocean Aerosol Retrieval) algoritmalarıyla, 550 nm referans dalga boyunda ve 6 dakikalık kayıtlar olarak üretilmektedir (Sayer vd., 2018). Ürün çalışma alanını ve 2012-2023 yılları arasını kapsayacak şekilde LAADS DAAC (Level-1 and Atmosphere Archive and Distribution System - Distributed Active Archive Center) sisteminden temin edilmiştir.


Proje çalışma alanı -17 ve 99 derece boylamları arası ile 13-55 derece kuzey enlemleri arasını kapsamaktadır. Türkiye etrafındaki farklı kaynakların ürettiği aerosollerin hava akımlarıyla taşınması nedeniyle geniş alanların incelenmesi aerosol takibi ve yönetimi hakkında daha kapsamlı bilgi sağlayacaktır. Öte yandan bu durum daha küçük alanlar için detay kaybına neden olacaktır. Bu nedenle bu çalışma geniş alan için üretilen aerosol verilerinden daha ayrıntılı bir analiz için bu alan içinde kalan nispeten küçük alan olan İstanbul ili ve çevresi için hazırlanmıştır. AERDB_L2_VIIRS_SNPP ürünü 2012 Mart ayından günümüze kadar veri sağlamaktadır. Bu çalışma için ise Mart/2012 – 2023 tarihleri arasını ve çalışma alanını kapsayan 6 dakikalık kayıtlardan oluşan veriler kullanılmıştır. Çalışmada 6 dakikalık görüntülerden her gün için 20 – 30 arası görüntü koordinatlandırılarak (georeferencing) ve birleştirilerek (image mosaicing) çalışma alanını (-17 ve 99 derece boylamları arası ile 13-55 derece kuzey enlemleri arası) kapsayan görüntüler GeoTIFF dosya formatında hazırlanmıştır. Bu görüntüler 6 km (0.054 derece) yersel piksel çözünürlüğünde, Coğrafi koordinat sisteminde, Coğrafi enlem-boylam projeksiyonunda ve WGS84 datum ve elipsoidinde olacak şekilde üretilmiştir.

Kentleşme, arazi kullanımı, bitki örtüsü ve diğer birçok konuda zaman içinde çeşitli değişiklikler meydana gelebilir. Bu değişikliklerin tespiti ve elde edilen çıkarımlar oldukça önemlidir. Çalışılan alan içindeki değişiklikleri gösteren farklı veri yapılarının ve tematik değişikliklerin ölçülmesine değişim tespiti denir (Ramachandra & Kumar, 2004). Değişim analizindeki temel ilke, görüntülerin farklı tarihlerde olması ve aynı mevsimsel dönem ve meteorolojik koşullarda algılanmasıdır (Sarıyılmaz, 2012).

Bir alandaki değişimin tespiti, zaman serisindeki iki görüntü arasındaki görüntü farklılıkları veya sınıflandırma sonrası karşılaştırma gibi teknikler kullanılarak gerçekleştirilebilir (Jensen, 1996). Çeşitli yöntemlerle elde edilen verilerin kronolojik sıraya göre toplanması bilgi edinmede oldukça önemlidir. Günlük fiyat verilerinden ay ve yıl bazında fiyat değişimleri, günlük sıcaklık verilerinden yıl cinsinden ortalama sıcaklık, satış rakamlarından yıllık ihracat miktarı gibi bilgiler alınabilir. Belirli aralıklarla elde edilen gözlem verilerinden alan değişimini analiz etmek mümkündür (Cryer & Chan, 2008). Belirli bir zaman içerisinde kronolojik olarak verilerin toplanması sonucunda oluşan kümeye zaman serisi denir. Zaman serisinin amacı, zaman içindeki değişimi anlamak ve geleceğe yönelik verileri en doğru şekilde tahmin etmektir (Allen, 1964). Bu çalışmada da konumsal ve zamansal değişim tespiti için bu yöntemlerden faydalanılmıştır.

3. Bulgular

Çalışma kapsamında AOD ve AE değerlerinin alansal analiz için uzun dönem ortalama haritalar üretilmiştir. Bu kapsamda İstanbul'un 550 nm referans dalga boyunda uzun dönem (2012-2023) ortalama AOD (üst) ve uzun dönem (2012-2023) ortalama AE (alt) haritası Şekil 1'de verilmiştir. Uzun dönem ortalama AOD haritasında minimum, maksimum, ortalama, medyan ve standart sapma değerleri 0,1531, 0,2554, 0,1894, 0,1840 ve 0,0191 olarak gerçekleşmiştir. AOD haritasında kentin yüksek (kırmızı renkler) ve düşük (mavi renkler) aerosol içeren alanları görülebilir. İstanbul ilinin yüksek AOD değerleri kentin Güneyinde Marmara Denizi kıyı şeritleri ve nüfus yoğunluğunun yüksek olduğu kıyıya yakın yerler ile Kuzeyde Sarıyer kıyıları ve nispeten Karadeniz'in tüm İstanbul kara sınırı ile buluştuğu kıyıya paralel (haritada turkuaz/yeşil renkli şerit) kesimleridir. Düşük AOD değerleri ise Çatalca ve Şile (Güney batısı hariç) ilçeleri olarak hesaplanmıştır. Kara üzerinde ise kentin nüfus yoğunluğu ve bitki örtüsü ile ilintili bir AOD değişimi vardır.




Şekil 1. İstanbul'un uzun dönem (2012-2023) ortalama AOD (üst) ve AE (alt) haritaları

AOD kara üzerinde kentin nüfus yoğunluğu (<https://www.beylikduzu.istanbul/BBIImages/Slider/Image/2020-yili-i%CC%87lc%CC%A7elere-go%CC%88re-nu%CC%88fus-yog%CC%86unlug%CC%86u.pdf>) ile doğru orantılı, bitki örtüsü (Okumuş & Terzi, 2021) ile ters orantılıdır. Su üzerinde Marmara denizinde Karadeniz'den daha yüksek değerler görülmektedir. Uzun dönem ortalama AE haritasında minimum, maksimum, ortalama, medyan ve standart sapma değerleri 1,0802, 1,5195, 1,2579, 1,2399 ve 0,1308 olarak gerçekleşmiştir. AE haritasında kentin yüksek (kırmızı renkler) ve düşük (mavi renkler) AE değerleri içeren alanları görülebilir. İstanbul ilinin yüksek AE değerleri batıda Tekirdağ – Silivri sınırına yakın alanlar, İstanbul boğazının çevresi ve doğuda İstanbul-Kocaeli sınırı çevresi olarak hesaplanmıştır. Düşük AE değerleri ise su yüzeyinde (Marmara ve Karadeniz) ve sahil/kıyı kesimlerinde görülmektedir. Genel olarak 1'den küçük AE değerleri su yüzeyinde ve 1'den büyük AE değerleri kara yüzeyinde hesaplanmıştır. İki harita birlikte incelendiğinde kara yüzeyinde genelde düşük AOD değeri olan alanlarda büyük AE değerleri olduğu görülür. Bu ise aerosol parçacıklarının küçük boyutlu ve antropojenik olduğunu gösterir. Yüksek AOD değeri olan Sarıyer çevresinde nispeten düşük AE değerleri görülmektedir. Boğazın Marmara denizi tarafında ise hem yüksek AOD hem de AE değerleri görülmektedir. Bu alanda çok miktarda küçük boyutlu parçacıklardan oluşan aerosol olduğu anlaşılır.

Uydu görüntülerinden türetilen veya yer tabanlı AOD ürünü ile yer tabanlı ölçümlerden elde edilen PM10 değerleri arasında zamana ve bölgeye bağlı olarak değişik şiddette (zayıf, orta ve güçlü) ilişki görülmektedir (Kong vd., 2016). Ünal vd. (2011) İstanbul için 2005 – 2009 yıllarını kapsayan PM10 konsantrasyonlarının mekânsal ve zamansal değişimleri üzerinde meteorolojik faktörlerin ve emisyon kaynaklarının etkisini ele aldıkları çalışmada şehir genelinde PM10 değerlerinin önemli değişimler gösterdiğini belirtmişlerdir. Ayrıca çalışmada trafik ve sanayi bölgelerinde PM10 değerlerinin hava kalitesi sınırını aştığı bilgisi verilmektedir. Çalışmadaki PM10 dağılımına benzer durumlar, veriler farklı zaman dilimini kapsıyor olsa da bu çalışmadaki İstanbul AOD değerlerinde de görülmektedir. Hatzianastassiou vd. (2009) Doğu Akdeniz için yaptıkları çalışma İstanbul'u kapsamakta ve 1980 – 2005 yılları arasındaki uydu verilerinden (TOMS ve MODIS algılayıcılarından elde edilen) konumsal ve zamansal analiz sunmaktadır. Çalışmada İstanbul'un düşük aerosol değerlerinin sebebini fazla yağış ve hâkim rüzgâr etkisi nedeniyle olduğu belirtilmiştir. Ayrıca çalışmada örnek bir toz taşınım analizi sonucunda Kuzey Afrika'dan yayılan tozun bu olayda İstanbul'u etkilemediği tespit edilmiştir.

Çetin vd. (2017) İstanbul için poliklorlu bifeniller (PCB'ler) ve polisiklik aromatik hidrokarbonlar (PAH'lar) gibi organik kirleticilerin konumsal ve zamansal dağılımını araştırdıkları çalışmalarında kent trafiğinin ve nüfus artışının organik kirleticiler ve insan sağlığına etkileri açısından daha fazla çalışılması gerektiğini belirtmişlerdir. Karaca vd. (2010) İstanbul'da yol (TEM ve E5) yakınlarındaki kurşun konsantrasyonlarını ele aldıkları çalışmada, kurşunsuz yakıtların kullanımıyla havadaki kurşun miktarının düştüğünü belirtmişlerdir. Aerosol çalışmaları da benzer şekilde birçok disiplinin için önemli bilgiler sunmakta ve periyodik olarak tekrarlanmalıdır çünkü zamansal ve alansal değişim süreklilik göstermektedir.



Şekil 2. İstanbul'un farklı dalga boylarında (412, 488, 550 ve 670 nm) uzun dönem (2012-2023) ortalama AOD haritaları

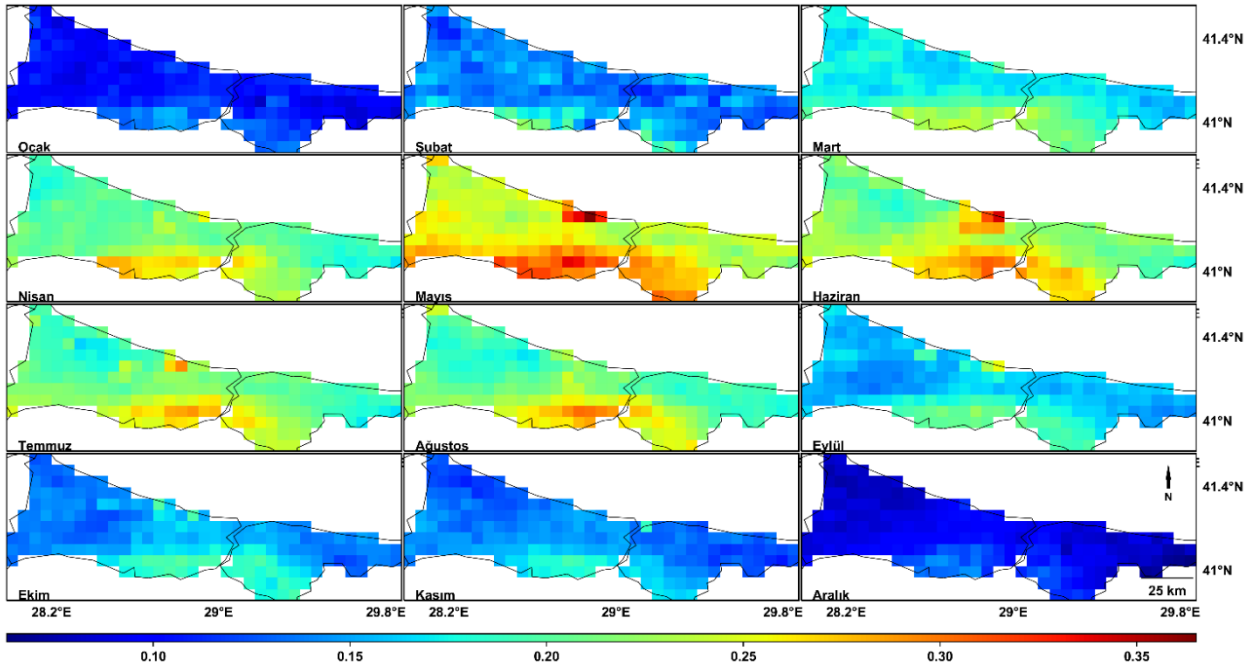
İstanbul'un kara yüzeyi için dört farklı dalga boyunda (412, 488, 550 ve 670 nm) uzun yıllık ortalama AOD haritaları Şekil 2'de ve bu haritaların temel istatistik değerleri de Tablo 1'de verilmiştir. Haritalardan ortalama AOD değerleri spektral olarak karşılaştırılabilir. Haritalar incelendiğinde tüm dalga boyları için kara yüzeyinde yüksek ve düşük aerosol bölgeleri görülebilir. Haritalarda AOD değerleri her bir dalga boyunda farklı şiddette olsa da haritalar benzer değişim deseni göstermiştir. Spektral açıdan aerosol miktarı dalga boyu ile ters orantılıdır.

Dalga boyu arttıkça aerosol tespitinin azaldığı görülmektedir (Şekil 2). Bu durum Tablo 1'deki nicel değerlerden net olarak görülebilir. 412 nm dalga boyu için ortalama AOD 0,2871 iken 488 nm için 0,2221, 550 nm için 0,1902 ve 670 nm için 0,1419 olarak hesaplanmıştır. Tablodan medyan değerlerin ise 412 nm dalga boyu için 0,2727, 488 nm için 0,2137, 550 nm için 0,1830 ve 670 nm için 0,1399 olduğu görülebilir. Spektrumun kısa dalga boyu bölgesinde saçılma baskın iken dalga boyu arttıkça soğurma etkisi de artar. Spektrumun farklı bölgelerini konu alan çalışmalar için bu kritik öneme sahiptir. Bu nedenle aerosolün spektral tespiti disiplinler arası çalışmalar için önemli katkı sunacaktır. Örneğin iklim değişikliği çalışmalarında aerosolün güneş ışınımını saçması ve soğurması dünyanın enerji bütçesi için olumlu ve olumsuz (artı ve eksi) katkı yapar. Bu nedenle bu etkinin birlikte değerlendirilmesi için dalga boyu dikkate alınarak yapılan çalışmalar daha doğru sonuç verecektir.

Tablo 1. İstanbul'un farklı dalga boylarında uzun dönem (2012-2023) ortalama AOD temel istatistik değerleri

Dalga boyu	Minimum	Maksimum	Ortalama	Medyan	Standart sapma
412 nm	0,2377	0,4092	0,2871	0,2727	0,0411
488 nm	0,1828	0,3121	0,2221	0,2137	0,0306
550 nm	0,1559	0,2554	0,1902	0,1830	0,0226
670 nm	0,1151	0,1926	0,1419	0,1399	0,0184


VIIRS 550 nm dalga boyunda kara ve su yüzeyi için aerosol bilgisi sağlaması, geleneksel olarak aerosol çalışmalarında bu spektral bandın yaygın kullanılması ve uydu veri/ürün sağlayıcıları tarafından yaygın bir referans dalga boyu olması nedeniyle aylık, mevsimlik ve yıllık haritaların üretilmesinde bu dalga boyunda sağlanan AOD verileri kullanılmıştır. Şekil 3'te İstanbul ili için uzun dönem aylık ortalama AOD haritaları verilmiştir. Bu haritaların istatistiksel değerleri de Tablo 2'de verilmiştir. Günlük uydu görüntülerinden ortalama alınarak türetilen veri setinin kutu grafiği de Şekil 4'te verilmiştir. Şekil 3 ve Tablo 2'den İstanbul için uzun dönem aylık haritalarda tüm aylar dikkate alındığında İstanbul kara yüzeyinde ortalama AOD 0,0962 (Aralık) ile 0,2601 (Mayıs) aralığında değişmektedir. En yüksek ortalama AOD değerleri sırasıyla Mayıs, Haziran, Temmuz, Ağustos ve Nisan aylarında iken en düşük ortalama AOD değerleri sırasıyla Aralık, Ocak, Kasım ve Şubat aylarında hesaplanmıştır. İstanbul için Mayıs ayı aerosol miktarının en yüksek olduğu ay olup Haziran-Ağustos aylarında yüksek aerosol konsantrasyonu görülürken Eylül ve Ekim ayları aerosol miktarının düşüğe geçtiği ve Aralık ile Ocak ayları en küçük değerlerin hesaplandığı aylardır. Aerosol miktarının yüksek olduğu aylarda çevredeki doğal aerosol kaynaklarının (çöller, denizler, orman yangınları vb.) daha aktif ve insan faaliyetlerinin (gezi, seyahat, ulaşım gibi) daha yoğun olduğu aylardır. Öte yandan aerosol miktarının düşük olduğu aylarda ise hem aerosol kaynaklarının etkinliği azalmakta hem de yağışların bu aylarda sık olması aerosol miktarının düşük kalmasını açıklar. Şekil 4'ten aylık verilerin dağılımı, medyan değerleri ve aykırı değerler karşılaştırılabilir.




Şekil 3. İstanbul'un uzun dönem (2012-2023) aylık ortalama AOD haritaları

Tablo 2. İstanbul'un uzun dönem (2012-2023) aylık ortalama AOD temel istatistik değerleri

Aylar	Minimum	Maksimum	Ortalama	Medyan	Standart sapma
1	0,0811	0,1551	0,1087	0,1059	0,0152
2	0,1091	0,2225	0,1441	0,1419	0,0193
3	0,1466	0,2433	0,1829	0,1753	0,0219
4	0,1680	0,2815	0,2129	0,2064	0,0247
5	0,2107	0,3651	0,2601	0,2547	0,0277
6	0,1781	0,3425	0,2329	0,2255	0,0307
7	0,1643	0,2941	0,2153	0,2110	0,0272
8	0,1687	0,3033	0,2144	0,2058	0,0301
9	0,1339	0,2561	0,1665	0,1618	0,0205
10	0,1184	0,2016	0,1530	0,1483	0,0205
11	0,1075	0,1940	0,1426	0,1410	0,0174
12	0,0627	0,1451	0,0962	0,0918	0,0165

**Şekil 4.** İstanbul'un aylık ortalama AOD değerleri

Şekil 5'te İstanbul kara yüzeyi için uzun yıllık mevsimsel ortalama AOD haritaları verilmiştir. Bu haritaların istatistiksel değerleri de Tablo 3'te verilmiştir. İlkbahar ve yaz mevsimlerinde diğer mevsimlere göre daha yüksek aerosol içeriği haritalardan görülmektedir. Haritalardan kış ve sonbahar mevsimlerinde aerosol miktarının daha az olduğu görülür. Tablo 3'ten bu haritaların sayısal değerlerine bakıldığında ortalama AOD değerleri büyükten küçüğe ilkbahar, yaz, sonbahar ve kış şeklinde sıralanır. AOD değerlerinin mevsimsel değişimi böyle iken Ünal vd. (2011) İstanbul için PM10 konsantrasyonlarının genel zamansal deseni için kışın yüksek ve yazın ise düşük konsantrasyonlarda olduğunu belirtmişlerdir. Başlıca aerosol kaynağı olan çöllerin ilk bahar ve yazın daha aktif olması ve PM10 kaynaklarının ise diğer mevsimlerde etkin olması bu farklılığı oluşturmuştur. Bu ise iki veri arasındaki korelasyonu düşüren bir etkidir. Hatzianastassiou vd. (2009) İstanbul için maksimum aerosol değerlerinin ilkbahar ve yaz mevsimlerinde minimum değerlerin ise kış mevsiminde olduğu belirtilmiştir. Bu bulgular bu çalışma ile uyum göstermektedir. Ayrıca, o çalışmada antropojenik etkinin göstergesi olarak kullanılan sülfat seviyeleri ile AOD mevsimsel değişimi arasında önemli korelasyon bulunduğu belirtilmiştir.

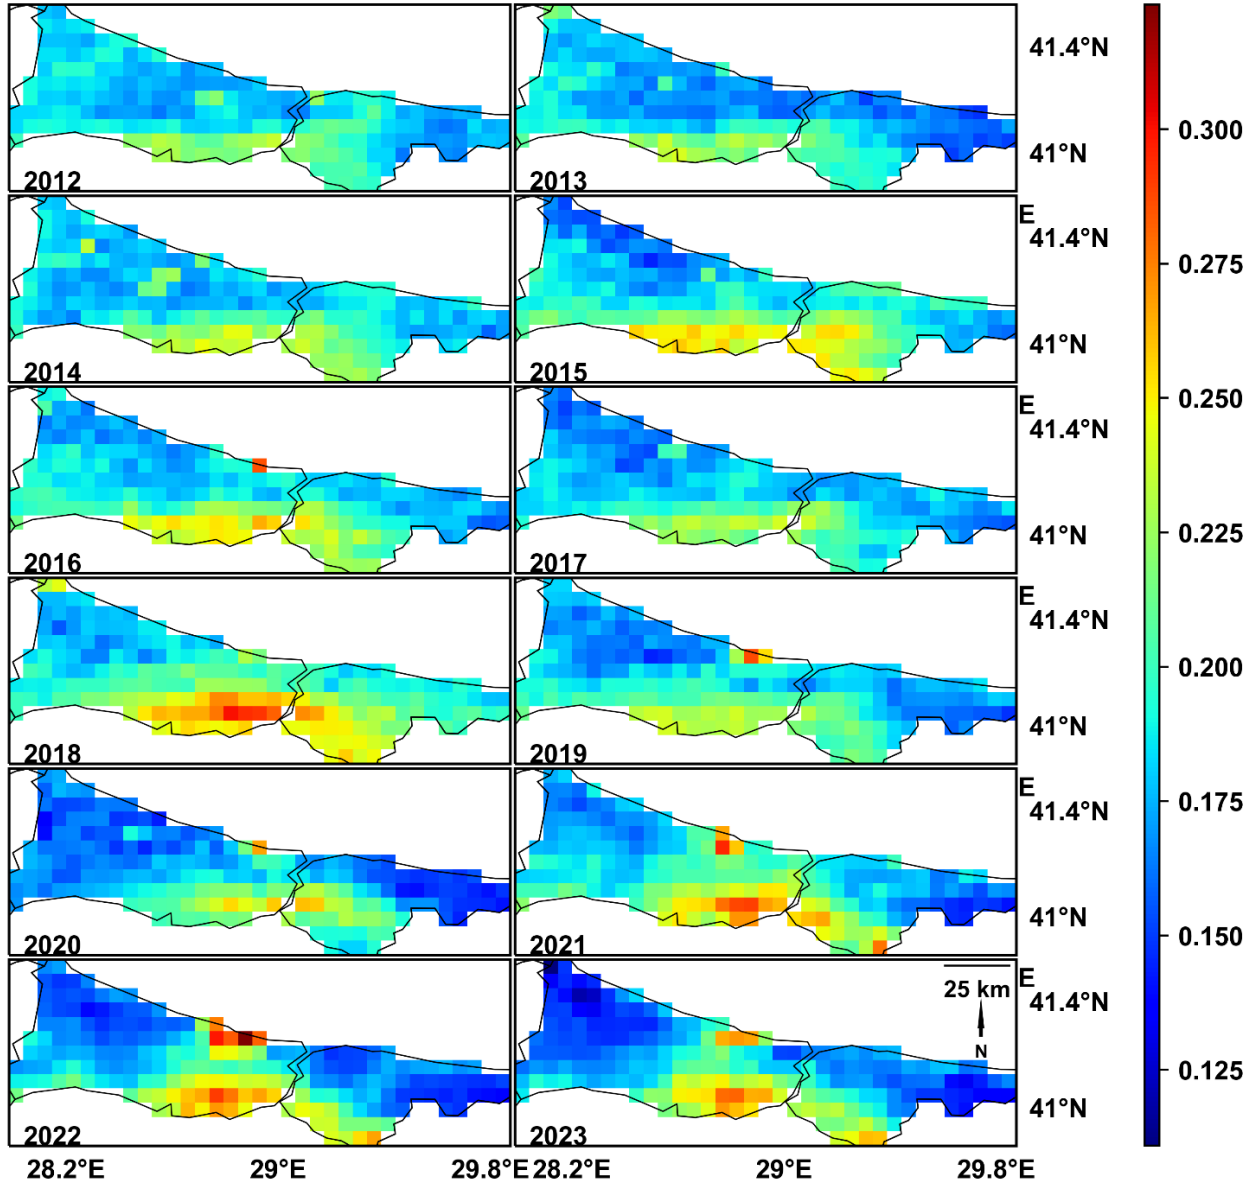


Şekil 5. İstanbul'un uzun dönem (2012-2023) mevsimlik ortalama AOD haritaları

Tablo 3. İstanbul'un uzun dönem (2012-2023) mevsimlik ortalama AOD istatistik değerleri

Mevsimler	Minimum	Maksimum	Ortalama	Medyan	Standart sapma
Kış	0,0909	0,1643	0,1158	0,1125	0,0146
İlkbahar	0,1840	0,2854	0,2210	0,2127	0,0236
Yaz	0,1762	0,2988	0,2207	0,2149	0,0278
Sonbahar	0,1315	0,2072	0,1557	0,1504	0,0180


Şekil 6'da İstanbul için yıllık ortalama AOD haritaları verilmiştir. Bu haritaların istatistiksel değerleri de Tablo 4 ve Şekil 7'de verilmiştir. İstanbul kara yüzeyi için alansal aerosol dağılımı haritalardan açıkça görülebilir. Tablo 4 ve Şekil 7'den İstanbul için ortalama ve medyan AOD değerleri (üst panel) zamansal olarak yıllar içinde kararlı bir dağılım göstermiştir. Ancak 2018 yılında aerosol miktarının nispeten daha yüksek hesaplandığı görülmektedir. İstanbul kara yüzeyinde ortalama AOD 0,1794 (2020) ile 0,2086 (2018) aralığında değişmektedir. Medyan AOD değerleri de ortalama değerlere benzer değişim göstermektedir. Şekil 7'de İstanbul AOD değerlerinin minimum, maksimum ve bunların farkı (alt panel) incelendiğinde, maksimum değerleri artış eğilimi ve minimum değerler azalma eğilimi göstermiştir. Bu fark grafiğinden daha açık görülebilir. Bu grafiklere göre İstanbul AOD değerleri daha geniş bir değer aralığında değişim göstermektedir. Ayrıca yıllar içinde yüksek aerosol içeren alanların aerosol miktarı artarken düşük aerosol içeren bölgelerde de aerosol miktarının azaldığı anlaşılmaktadır.



Şekil 6. İstanbul'un yıllık ortalama AOD haritaları

Tablo 4. İstanbul'un yıllık ortalama AOD temel istatistik değerleri

Yıllar	Minimum	Maksimum	Ortalama	Medyan	Standart sapma
2012	0,1618	0,2369	0,1872	0,1839	0,0157
2013	0,1479	0,2378	0,1807	0,1768	0,0183
2014	0,1556	0,2468	0,1905	0,1844	0,0196
2015	0,1445	0,2663	0,1964	0,1906	0,0279
2016	0,1549	0,3083	0,1946	0,1870	0,0260
2017	0,1508	0,2446	0,1842	0,1799	0,0194
2018	0,1562	0,3002	0,2086	0,2002	0,0306
2019	0,1442	0,2875	0,1881	0,1827	0,0229
2020	0,1373	0,2670	0,1794	0,1710	0,0281
2021	0,1409	0,2956	0,1977	0,1893	0,0325
2022	0,1359	0,3232	0,1897	0,1748	0,0388
2023	0,1109	0,2810	0,1835	0,1738	0,0365



Şekil 7. İstanbul'un yıllık ortalama AOD temel istatistik değerleri (Tablo 4 ile aynı)

4. Sonuçlar

Bu çalışmada uzaktan algılama verileriyle İstanbul ili için atmosferik aerosol özelliklerinin konumsal, zamansal ve spektral analizleri yapılmıştır. Bu kapsamda İstanbul'un AOD ve AE değerleri incelenmiştir. Çalışmada elde edilen sonuçlar önceki bölümde detaylı verilmiş ve bu bölümde de aşağıda özet bir listesi sunulmuştur.

- İstanbul ilinin yüksek AOD değerleri kentin Güneyinde Marmara Denizi kıyı şeritleri ve nüfus yoğunluğunun yüksek olduğu kıyıya yakın yerler ile Kuzeyde Sarıyer kıyıları ve nispeten Karadeniz'in kara ile buluştuğu kıyı kesimleridir. Düşük AOD değerleri ise Çatalca ve Şile (Güney batısı hariç) ilçeleri olarak hesaplanmıştır.
- Kara üzerinde ise kentin nüfus yoğunluğu ve bitki örtüsü ile ilintili bir AOD değişimi vardır. AOD kara üzerinde kentin nüfus yoğunluğu ile doğru orantılı, bitki örtüsü ile ters orantılıdır. Su üzerinde Marmara denizinde Karadeniz'den daha yüksek değerler görülmektedir.

- İstanbul ilinin yüksek AE değerleri batıda Tekirdağ – Silivri sınırına yakın alanlar, İstanbul boğazının çevresi ve doğuda İstanbul-Kocaeli sınırı çevresi olarak hesaplanmıştır. Düşük AE değerleri ise su yüzeyinde (Marmara ve Karadeniz) ve kıyı kesimlerinde görülmektedir.
- Spektral açıdan aerosol miktarı dalga boyu ile ters orantılı olup dalga boyu arttıkça aerosol tespitinin azaldığı görülmüştür.
- İstanbul aerosol değerleri zamansal olarak incelendiğinde yüksek AOD değerleri sırasıyla Mayıs, Haziran, Temmuz, Ağustos ve Nisan aylarında iken en düşük AOD değerleri sırasıyla Aralık, Ocak, Kasım ve Şubat aylarında hesaplanmıştır.
- İstanbul için Mayıs ayı aerosol miktarının en yüksek olduğu ay olup Haziran-Ağustos aylarında yüksek aerosol konsantrasyonu görülürken Eylül ve Ekim ayları aerosol miktarının düşüğe geçtiği ve Aralık ile Ocak ayları en küçük değerlerin hesaplandığı aylardır.
- Mevsimsel anlamda İstanbul için yüksek AOD değerleri ilkbahar ve yaz mevsimlerinde ve düşük AOD değerleri kış ve sonbahar mevsimlerinde görülmektedir.
- İstanbul için aerosol miktarı yıllar içinde kararlı bir dağılım göstermiştir. Ancak 2018 yılında aerosol miktarı nispeten daha yüksek hesaplanmıştır.
- İstanbul maksimum AOD değerleri artış eğilimi ve minimum değerler azalma eğilimi göstermiştir. Böylece İstanbul AOD değerleri daha geniş bir değer aralığında değişim göstermiştir.

Teşekkür

Bu çalışma Atatürk Üniversitesi Astrofizik Araştırma ve Uygulama Merkezi (ATASAM), Doğu Anadolu Gözlemevi (DAG) Projesi (Proje No: 2011K120230) ve Türkiye Bilimsel ve Teknolojik Araştırmalar Kurumu (TÜBİTAK) 2218 Programı (Proje No: 118C467) kapsamında desteklenmiştir. ATASAM, DAG ve TÜBİTAK'a teşekkür ederiz.

Kaynaklar

- Allen, R. G. D. (1964). Sampling for current economic statistics. *Journal of the Royal Statistical Society Series A (General)*, 127(1), 76-88.
- Coşkun, M., Şahiner, H., & Canbulat, O. (2022). Covid 19 Sürecinde Coğrafi Özellikler ve Atmosfer Kararlılığına Göre Karabük İl Merkezi ve Zonguldak'ın Ereğli İlçesinde Aerosol Optik Derinlik Analizi. *International Journal of Geography and Geography Education*, 45, 380-403.
- Cryer, J. D. & Chan, K. S. (2008). *Time Series Analysis: With Applications in R*. Springer.
- Çetin, B., Ozturk, F., Keles, M., & Yurdakul, S. (2017). PAHs and PCBs in an Eastern Mediterranean megacity, Istanbul: Their spatial and temporal distributions, air-soil exchange and toxicological effects. *Environmental Pollution*, 220, 1322-1332. <https://doi.org/10.1016/j.envpol.2016.11.002>
- Güllü, G., Ulutaş, F., Belli, D., Erduran, S., Keskin, S., & Tuncel, G. (1998). The Black Sea aerosol a long range atmospheric transport. *Turkish Journal of Engineering and Environmental Sciences*, 22(4), 289-303.
- Gündoğdu, S., Tuygun, G. T., Li, Z., Wei, J., & Elbir, T. (2022). Estimating daily PM_{2.5} concentrations using an extreme gradient boosting model based on VIIRS aerosol products over southeastern Europe. *Air Quality, Atmosphere & Health*, 15(12), 2185-2198.
- Hatzianastassiou, N., Gkikas, A., Mihalopoulos, N., Torres, O., & Katsoulis, B. D. (2009). Natural versus anthropogenic aerosols in the eastern Mediterranean basin derived from multiyear TOMS and MODIS satellite data. *Journal of Geophysical Research: Atmospheres*, 114(D24), Article D24202. <https://doi.org/10.1029/2009JD011982>
- Hinds, W. C. (1999). *Aerosol technology: properties, behavior, and measurement of airborne particles* (1st Edition). John Wiley & Sons.
- Jensen, J. R. (1996). *Introductory Digital Image Processing: A Remote Sensing Perspective* (Second Edition). Prentice Hall.
- Kabataş, B., Unal, A., Pierce, R. B., Kindap, T., & Pozzoli, L. (2014). The contribution of Saharan dust in PM₁₀ concentration levels in Anatolian Peninsula of Turkey. *Science of the Total Environment*, 488, 413-421.
- Karaca, F., Alagha, O., & Erturk, F. (2010). Atmospheric lead concentrations near roadways in a suburban part of Istanbul. *International Journal of Environment and Pollution*, 41(1-2), 38-50. <https://doi.org/10.1504/IJEP.2010.032244>
- Karslıoğlu, S., Tezcan, E., Tuygun, G. T., & Elbir, T. (2022). Türkiye'de Terra ve Aqua MODIS uydularından elde edilen aerosol optik derinliğinin zamansal ve mekansal değişimi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 24(70), 303-316.
- Kong, L., Xin, J., Zhang, W., & Wang, Y. (2016). The empirical correlations between PM_{2.5}, PM₁₀ and AOD in the Beijing metropolitan region and the PM_{2.5}, PM₁₀ distributions retrieved by MODIS. *Environmental pollution*, 216, 350-360. <https://doi.org/10.1016/j.envpol.2016.05.085>

- LAADS DAAC. (2024). *AERDB_L2_VIIRS_SNPP - VIIRS/SNPP Deep Blue Aerosol L2 6-Min Swath 6 km*. 23 Mayıs 2024'te https://ladsweb.modaps.eosdis.nasa.gov/missions-and-measurements/products/AERDB_L2_VIIRS_SNPP adresinden alındı.
- Meteoroloji Genel Müdürlüğü. (2023). *Araştırma Raporu: Türkiye ve Çevresi Aerosol (Toz Taşınımı) Analizleri 2003-2022*. 20 Mayıs 2024'de https://mgm.gov.tr/FILES/genel/raporlar/BatiAsya_2003_2022_TOZ_Degerlendirme_20230202.pdf adresinden alındı.
- Okumuş, D. E., & Terzi, F. (2021). Evaluating the role of urban fabric on surface urban heat island: The case of Istanbul. *Sustainable Cities and Society*, 73, Article 103128. <https://doi.org/10.1016/j.scs.2021.103128>
- Özkan, S. (2021). Sahra ve Ortadoğu Kaynaklı Çöl Tozlarının Türkiye'deki Ekosistemlere Etkisi. *Avrasya Uluslararası Araştırmalar Dergisi*, 9(28), 413-426.
- Ramachandra, T. V., & Kumar, U. (2004, September 12-14). *Geographic Resources Decision Support System for land use, land cover dynamics analysis* [Conference presentation]. FOSS/GRASS Users Conference, Bangkok, Thailand.
- Sarıyılmaz, F. B. (2012). *Zaman Serileri ile Değişim Analizi: İstanbul Sarıyer Örneği* [Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Sayer, A. M., Hsu, N. C., Lee, J., Bettenhausen, C., Kim, W. V., & Smirnov, A. J. J. O. G. R. A. (2018). Satellite Ocean Aerosol Retrieval (SOAR) algorithm extension to S-NPP VIIRS as part of the "Deep Blue" aerosol project. *Journal of Geophysical Research: Atmospheres*, 123(1), 380-400.
- STAR Calibration Center. (2023). 23 Mayıs 2024'te <https://ncc.nesdis.noaa.gov/VIIRS/> adresinden alındı.
- Tezcan, E., Karslıoğlu, S., Tuygun, G. T., & Elbir, T. (2022). Türkiye ve Yakın Çevresinde Güneş Fotometreleri ile Elde Edilen Aerosol Optik Derinliği Verisinin Zamansal ve Mekansal Değişimi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 10(3), 1241-1254.
- Tomasi, C., & Lupi, A. (2017). Primary and secondary sources of atmospheric aerosol. In C. Tomasi, S. Fuzzi & A. Kokhanovsky (Eds.), *Atmospheric Aerosols: Life Cycles and Effects on Air Quality and Climate* (pp. 1-86). Wiley. <https://doi.org/10.1002/9783527336449.ch1>
- Tuygun, G. T., & Elbir, T. (2020). Long-term temporal analysis of the columnar and surface aerosol relationship with planetary boundary layer height at a southern coastal site of Turkey. *Atmospheric Pollution Research*, 11(12), 2259-2269.
- Tuygun, G. T., Ozdemir, E., & Elbir, T. (2020). Evaluation of MODIS C6 and C6. 1 Dark Target AOD products over Turkey based on NDVI and aerosol type. *Atmospheric Pollution Research*, 11(12), 2335-2349.
- Tuygun, G. T., & Elbir, T. (2023). Estimation of particulate matter concentrations in Türkiye using a random forest model based on satellite AOD retrievals. *Stochastic Environmental Research and Risk Assessment*, 37(9), 3469-3491.
- Ünal, Y. S., Toros, H., Deniz, A., & Incecik, S. (2011). Influence of meteorological factors and emission sources on spatial and temporal variations of PM10 concentrations in Istanbul metropolitan area. *Atmospheric Environment*, 45(31), 5504-5513. <https://doi.org/10.1016/j.atmosenv.2011.06.039>
- Zeydan, Ö., & Wang, Y. (2019). Using MODIS derived aerosol optical depth to estimate ground-level PM2. 5 concentrations over Turkey. *Atmospheric Pollution Research*, 10(5), 1565-1576.
- Zeydan, Ö., Tariq, S., Qayyum, F., Mehmood, U., & Ul-Haq, Z. (2023). Investigating the long-term trends in aerosol optical depth and its association with meteorological parameters and enhanced vegetation index over Turkey. *Environmental Science and Pollution Research*, 30(8), 20337-20356.

FORMOSAT-7/COSMIC-2 GNSS Radyo Okültasyon Tekniği İle Elde Edilen Atmosferik Parametrelerinin Değerlendirilmesi

Assessment of Atmospheric Parameters Obtained with FORMOSAT-7/COSMIC-2 GNSS Radio Occultation Technique

Seldanur Çelik Tunçer^{1*}, Emine Tanır Kayıkcı²

¹Hitit Üniversitesi, Teknik Bilimler MYO, Mimarlık ve Şehir Planlama Bölümü, 19169, Çorum/Türkiye.

²Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 61080, Trabzon/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Seldanur Çelik Tunçer
seldanurcelik@hitit.edu.tr

doi: 10.48123/rsgis.1489595

Yayın süreci

Geliş tarihi: 24.05.2024
Kabul tarihi: 07.09.2024
Basım tarihi: 26.09.2024

Özet

Küresel Navigasyon Uydu Sistemi - Radyo Okültasyon (GNSS-RO), hava olaylarının tahmin edilmesi ve iklimsel değişimlerin izlenmesi için önemli potansiyele sahip uzay tabanlı bir gözlem tekniğidir. GNSS-RO tekniğinde, yüksek yörüngedeki uydulardan iletilen radyo sinyaller, alçak yörüngedeki uydulara yerleştirilmiş alıcılar tarafından ölçülür. GNSS alıcılarında kaydedilen radyo sinyaller, atmosferik geri kazanım süreçlerine göre işlenerek sıcaklık, basınç, su buharı ve elektron yoğunluğu gibi profiller elde edilir. GNSS-RO tekniği, kalibrasyon gereksinimi olmadan her türlü hava koşulunda çalışabilir. Ayrıca, küresel kapsama alanında yüksek dikey çözünürlükte zengin veriler sağlar. GPS, Galileo ve GLONASS gibi uydulardan sinyal alabilen FORMOSAT-7/COSMIC-2 uyduları, $\pm 45^\circ$ enlem bölgesinde günlük 4000'den fazla yüksek kaliteli RO ölçümü sağlayabilir. 2019 yılında alçak yörüngeye başarıyla fırlatılan bu uydunun ana hedeflerinden biri, alt ve orta troposferde GNSS-RO ölçüm kalitesini artırmak olmuştur. Bu çalışmada, FORMOSAT-7/COSMIC-2 RO ile elde edilen atmosferik profilleri değerlendirmek ve doğrulamak için radyosonda profillerinden yararlanılmıştır. Karşılaştırmada, 5-25 km arasında değişen irtifalardaki sıcaklık, su buharı basıncı, özgül nem ve kırınım profilleri esas alınmıştır. Çalışma sonucunda, RO ve radyosonda profilleri arasında iyi bir uyum gözlenmiştir.

Anahtar kelimeler: GNSS, Radyo okültasyon, COSMIC-2, Radyosonda

Abstract

Global Navigation Satellite System - Radio Occultation (GNSS-RO) is a space-based observation technique with significant potential for predicting weather events and monitoring climatic changes. In GNSS-RO technique, radio signals transmitted from high-orbit satellites are measured by receivers placed on low-orbit satellites. The radio signals recorded in GNSS receivers are processed according to atmospheric retrieval processes to obtain profiles such as temperature, pressure, water vapor, and electron density. The GNSS-RO technique can operate in all weather conditions without the need for calibration and provides rich data with high vertical resolution on a global scale. FORMOSAT-7/COSMIC-2 satellites, which can receive signals from satellites such as GPS, Galileo, and GLONASS, can provide over 4000 high-quality RO measurements daily in the $\pm 45^\circ$ latitude region. Launched into low Earth orbit in 2019, one of the primary goals of this satellite has been to improve GNSS-RO measurement quality in the lower and middle troposphere. In this study, radiosonde profiles were utilized to evaluate and validate atmospheric profiles obtained with FORMOSAT-7/COSMIC-2 RO. The comparison focused on temperature, water vapor pressure, specific humidity, and refraction profiles at altitudes ranging from 5-25 km. The study found a good agreement between RO and radiosonde profiles.

Keywords: GNSS, Radio occultation, COSMIC-2, Radiosonde

1. Giriş

Hava tahminleri ve iklimsel analizler için sıcaklık, basınç, nem, rüzgar gibi atmosferik gözlemlere gereksinim duyulmaktadır (Fu, 2011; Zhang vd., 2011). Radyosonda balonlarındaki sensörler, atmosferik gözlemlerin toplanmasında uzun süre kullanılan yer tabanlı etkili bir geleneksel yöntemdir. Dünya çapında 1500'den fazla radyosonda istasyonu (Radiosonde Station, RS) bulunmaktadır. Her istasyondan 00:00 Evrensel Zaman (Coordinated Universal Time, UTC) ve 12:00 UTC olmak üzere günde iki kez fırlatılan radyosonda balonları, yeryüzünden yaklaşık 20-30 km yüksekliğe kadar dikey atmosferik profil verileri sağlamaktadır. Sayısal Hava Tahmini (Numerical Weather Prediction, NWP) modellerine girdi sağlayan bu yöntem, üst atmosfer gözlem sisteminin temel bir parçasıdır. Ancak, sınırlı bir kapsama alanına ve düşük bir konumsal-zamansal çözünürlüğe sahiptir. İstasyonların çoğu kuzey yarımkürede bulunmakla birlikte okyanus, çöl ve dağlık bölgelerde sayıları oldukça azdır. Dünyaya homojen şekilde dağılmamış radyosonda istasyonlarının bazı bölgelerde sınırlı sayıda olması, sensörlerin performans ve hassasiyetlerinin hava koşullarından etkilenebilmesi, bakım maliyetlerinin yüksek olması meteorolojik alandaki bilimsel çalışmaları etkilemektedir (Syndergaard, 1999; Fu, 2011; Zhang vd., 2011).

Uydu çağı ile atmosferin uzaktan algılanması, atmosfer bilimleri ve hava durumu tahminleri için daha iyi bir küresel kapsama alanı sağlamıştır. Uydu uzaktan algılama teknolojileri genel olarak daha yüksek yatay çözünürlük ve yer tabanlı yöntemlere kıyasla daha iyi bir küresel kapsama alanı sağlamasına rağmen en büyük dezavantajı düşük düzey çözünürlüktür (Syndergaard, 1999; Fu, 2011; Li vd., 2015). Son yıllarda geliştirilen Küresel Navigasyon Uydu Sistemi-Radyo Okültasyon (Global Navigation Satellite System - Radio Occultation, GNSS-RO) tekniği, yüksek düzey çözünürlükte ölçümler sağlayarak bu husustaki eksiliği tamamlamıştır. Ayrıca, GNSS-RO tekniği; kalibrasyon gerektirmez, her türlü hava koşulunda çalışabilir, diğer uzaktan algılama standartlarına göre nispeten ucuzdur (Jin, 2012; Awange, 2018). GNSS-RO tekniğinin sağladığı birçok fayda nedeniyle Meteoroloji Ofisi (Meteorological Office, Met Office), Avrupa Orta Vadeli Hava Tahminleri Merkezi (European Centre for Medium-Range Weather Forecasts, ECMWF), Ulusal Çevresel Tahmin Merkezleri (National Centers for Environmental Prediction, NCEP) gibi birçok NWP merkezi RO verilerini asimilasyon sistemlerine dahil etmeye başlamış ve hava tahminleri üzerinde olumlu etkiler gözlemlemiştir (Healy vd., 2005; Kwon vd., 2014).

GNSS-RO tekniği, Yakın Yörünge (Low Earth Orbit, LEO) uyduları üzerine yerleştirilen alıcıların, GNSS uydularından gelen sinyalleri uzaktan algılama tekniklerine göre ölçerek ve analiz ederek sıcaklık, basınç ve su buharı gibi atmosferik parametrelerin elde edilmesine olanak sağlamaktadır. Meteoroloji, İyonosfer ve İklim İçin Gözlem Sistemi Takımı Yıldız-1 (Constellation Observing System for Meteorology, Ionosphere and Climate-1, COSMIC-1)/Formosa Uydusu-3 (Formosa Satellite-3, Formosat-3), Küresel Konumlama Sistemi (Global Positioning System, GPS)-RO teknolojisini neredeyse gerçek zamanlı olarak sağlayan ilk operasyonel LEO uydusudur. Zorlu Mini Uydu Yüklü (CHALLENGING Minisatellite Payload, CHAMP), Yerçekimi İyileştirme ve İklim Deneyi (Gravity Recovery and Climate Experiment, GRACE), Meteorolojik Operasyonel Uydusu (Meteorological Operational Satellite, METOP), Kore Çok Amaçlı Uydu-5 (Korea Multi-Purpose Satellite-5, KOMPSAT-5), Bilimsel Uygulamalar Uydusu-C (Satellite de Aplicaciones Cientificas-C, SAC-C), İletişim/Navigasyon Kesintisi Tahmin Sistemi (Communications/Navigation Outage Forecasting System, C/NOFS), Sentinel gibi çeşitli LEO uyduları da RO gözlemleri sağlamak amacıyla piyasaya sürülmüştür (Beyerle vd., 2005; Anthes vd., 2008; Wickert vd., 2009; Choi vd., 2010; Vryonides & Haralambous, 2013; Yue vd., 2014). Yeni nesil bir LEO uydusu olan ve 2019 yılında göreve başlayan COSMIC-2/ FORMOSAT-7; GPS, GALILEO ve GLONASS'dan gelen sinyalleri alarak yeryüzünden yaklaşık 500-700 km uzaklıkta, 24° eğim açısı ile orta ve düşük enlem bölgeleri için daha fazla sayıda RO gözlem verisi sağlamaktadır (Fong vd., 2012; Cook vd., 2013; Yue vd., 2014; Schreiner vd., 2020).

GNSS-RO gözlem profillerini doğrulamak için genellikle radyosonda atmosferik profillerinden yararlanılmaktadır. Çünkü, radyosonda verileri, doğrudan atmosferin belirli yüksekliklerinde yapılan ölçümlerle elde edilmektedir (Yadav vd., 2020). Ayrıca, radyosonda verilerinin atmosferik çalışmalarda uzun yıllardır kullanılması, bu verilerin iyi anlaşılmasını ve kalibrasyon süreçleriyle ilgili güçlü bir deneyim kazanılmasını sağlamıştır. Dolayısıyla radyosonda verileri, GNSS-RO tekniği verilerinin kalitesini değerlendirmek için sağlam bir temel oluşturmaktadır. Nitekim, literatürde çeşitli LEO uydu misyonları tarafından gözlenen RO atmosferik profillerin, radyosonda profilleri ile karşılaştırıldığı çeşitli çalışmalar mevcuttur. Rossiter (2003), RO sıcaklık, su buharı basıncı ve kırımım parametrelerinin doğruluğunu geleneksel radyosonda ölçümleriyle karşılaştırarak değerlendirmiştir. Wickert (2004), CHAMP RO ölçümlerini radyosonda ağından elde edilen verilerle karşılaştırmıştır. Kuo vd. (2005), CHAMP RO kırılma profillerini, her biri farklı tipte bir radyosonda kullanan beş coğrafi alandaki radyosonda profillerinden hesaplanan değerler ile karşılaştırmıştır. Karşılaştırma, RO sondajlarının en doğru olduğu 5-25 km irtifalar arasında yapılmıştır. Zhang vd. (2007), CHAMP uydu misyonundan elde edilen sıcaklık ve su buharı profillerini, Batı Avustralya'daki radyosonda sondajlarından hesaplanan verilerle karşılaştırmıştır. Fu vd. (2009), Avustralya ve Antarktika bölgesinde radyosonda gözlemlerini kullanarak COSMIC atmosferik ürünlerini değerlendiren istatistiksel çalışmalar yapmıştır. Zhang vd. (2011), Avustralya bölgesi için COSMIC ve CHAMP RO sıcaklık profillerini, radyosonda profilleri ile karşılaştırmıştır. Wang vd. (2013), COSMIC RO profillerini radyosonda profilleri karşılaştırmıştır.

Norman vd. (2014), Avustralya bölgesi için FORMOSAT-3/COSMIC-1 RO sıcaklık ve basınç profillerini, radyosonda profilleri ile karşılaştırmıştır. Li vd. (2020), Wegener İklim ve Küresel Değişim Merkezi (Wegener Center, WEGC), Radyo Okültasyon Meteoroloji Uydu Uygulama Tesisi (Radio Occultation Meteorology Satellite Application Facility, ROM SAF) ve Atmosfer Araştırmaları için Üniversite Kurumu (University Corporation for Atmospheric Research, UCAR) RO veri işleme merkezlerinden alınan sıcaklık ve özgül nem profillerini farklı enlemlerde seçilmiş radyosonda profilleri ile karşılaştırarak değerlendirmiştir. Shao vd. (2021), COSMIC-2 RO nem ve sıcaklık verilerini radyosonda verileri ile karşılaştırmıştır. Ahmed vd. (2022), Mısır bölgesinde COSMIC, GRACE, C/NOFS uydu misyonlarından elde edilen RO atmosferik profillerini; radyosonda basınç, sıcaklık, su buharı basıncı ve kırınım profilleri ile karşılaştırmıştır. RO ve radyosonda verilerinin analizinde 3 ila 25 km arasında değişen irtifalara sahip karşılaştırmalı profiller kullanmıştır. Literatürde yer alan bu çalışmalarda, RO ve radyosonda atmosferik profillerin uyumlu olduğu belirlenmiştir.


Bu çalışmada, Türkiye ve Avrupa bölgesinden GNSS-RO tekniğinden elde edilen profilleri test etmek ve doğrulamak için radyosonda gözlem profillerinden yararlanılmıştır. Çalışma için İtalya'dan 37.92° kuzey enlemi ve 12.50° doğu boylamındaki Trapani/Birgi (16429) istasyonu ve Türkiye'den 38.69° kuzey enlemi ve 35.50° doğu boylamındaki Kayseri (17196) ve 41.28° kuzey enlemi ve 36.33° doğu boylamındaki Samsun (17030) RS seçilmiştir. Trapani/Birgi RS için yaklaşık 100 km-1 saat, Kayseri RS için yaklaşık 200 km-2 saat ve Samsun RS için yaklaşık 300 km-3 saat konumsal ve zamansal fark içerisinde bulunan RO gözlem dosyaları analiz edilmiştir. COSMIC-2 RO profilleri, 5-25 km arasında değişen irtifalardaki radyosonda sıcaklık, su buharı basıncı, özgül nem ve kırınım profilleri ile karşılaştırılmıştır.

2. Yöntem

2.1 GNSS Radyo Okültasyon Tekniği

GNSS-RO, atmosferik profil oluşturma ve meteorolojik uygulamalar için önemli bilgiler sağlayan uzay tabanlı bir Dünya gözlem tekniğidir. GNSS-RO tekniğinde, GNSS uydularından iletilen radyo sinyalleri ölçmek için üzerinde GNSS alıcısı bulunan LEO uydularına gereksinim duyulur. Yüksek yörüngedeki GNSS uydularından iletilen radyo sinyaller LEO uydu alıcılarına ulaşmak için atmosferin farklı katmanlarından geçer. Sinyaller atmosferden geçerken elektron yoğunluğu, sıcaklık, basınç, su buharı gibi içerikler tarafından etkilenir ve gecikerek farklı derecede bükülür (Stupar, 2015; Awange, 2018).

Bir GNSS-RO olayı geometrisinde, uydu cihaz görüş hattının dünya yüzeyine en yakın noktasına teğet nokta ve bu noktanın Dünya jeoidi üzerindeki yüksekliğine teğet yükseklik denir. Teğet yarıçapı, merkezden teğet noktasına olan radyal mesafedir. Bununla birlikte, ışın asimptotları arasında kalan açı, bükülme açısıdır. Dünya'nın merkezi ile GNSS veya LEO uydusundaki ışın asimptotu arasındaki dikey mesafe etki parametresi olarak tanımlanır (Bormann & Healy, 2005; Sioris vd., 2014) (Şekil 1).



Şekil 1. GNSS-RO geometrisi

Atmosferik RO geri kazanım işleminin temel adımları; hassas yörünge belirleme, fazla faz gecikme tahmini, bükülme açısının tahmini ve kırınım bilgilerinden kuru ve nemli hava bilgilerinin elde edilmesini kapsar (Kursinski, 1997). GNSS uydularından iletilen sinyaller atmosferde bükülmeye maruz kaldığı için sinyallerin frekansları ve fazında değişimler meydana gelir. LEO uydularında bulunan alıcılar, sinyallerin fazında ve zamanında meydana gelen gecikmeleri de ölçerler. Alıcılardan gelen faz verileri, GNSS ve LEO uydularının yörünge bilgileri kullanılarak bükülme açıları belirlenir.

Bükülme açısına Abel dönüşümü uygulandığında atmosferik kırılma profili elde edilir. Bükülme açısı ve kırılma indisi arasındaki ilişki,

$$\alpha(a) = -2 \int_{r_t}^{\infty} d\alpha = -2a \int_{r_t}^{\infty} \frac{1}{\sqrt{r^2 n^2 - a^2}} \frac{d \ln(n)}{dr} dr \quad (1)$$

eşitliğindeki gibi ifade edilebilir. Burada α ışının bükülme açısı, a etki parametresi ve r_t ışının teğet noktasının yarıçapıdır. Eşitlik (1), $x=nr$, değişken değişimi ile

$$\alpha(a) = -2a \int_a^{\infty} \frac{1}{\sqrt{x^2 - a^2}} \frac{d \ln(n)}{dx} dx \quad (2)$$

eşitliğindeki gibi yeniden yazılabilir. Bükülme açısına ters Abel dönüşümü uygulanarak kırılma profili,

$$n(r) = \exp \left[\frac{1}{\pi} \int_x^{\infty} \frac{\alpha(a)}{\sqrt{a^2 - x^2}} da \right] \quad (3)$$

eşitliği ile hesaplanabilir. Bu eşitlikler küresel olarak simetrik bir atmosfer varsayımı altında formüle edilir (Lewis, 2008; Wee, 2018). Kırılma ve kırılma indisi arasındaki ilişki,

$$N = (1 - n)10^6 \quad (4)$$

eşitliği ile ifade edilebilir. Burada; N , kırılma ve n , kırılma indisidir. Nötr atmosferde N ,

$$N = 77.6 \frac{P}{T} + 3.73 * 10^5 \frac{e}{T^2} \quad (5)$$

eşitliğindeki gibi ifade edilir. P , toplam atmosfer basıncı; T , sıcaklık; e , kısmi su buharı basıncıdır. Bu eşitlikte, ilk terim kuru atmosferi, ikinci terim ise su buharı katkısını temsil eder. RO sondajları için genellikle atmosferik saçılma ihmal edilebilir. İyonosferik etkilerin ise bükülme açılarının iyonosferik düzeltmesi gibi ön işleme sırasında ortadan kaldırıldığı varsayılır (Lewis, 2008; Wee, 2018).

2.2 Radyosonda Tekniği

Radyosonda, bir balon yardımıyla atmosferde yükselen ve sensörler yardımıyla yeryüzünden yaklaşık 20-30 km yüksekliğe kadar dikey çözünürlükte basınç, sıcaklık ve nem bilgilerini eş zamanlı ölçen cihazdır. Radyosonda istasyonlarından 00:00 UTC ve 12:00 UTC olmak üzere günde iki kez radyosonda balonu fırlatır ve veri temini sağlar. Radyosonda balonları doğrudan atmosferde yükselerek ölçüm yapar (Yadav vd., 2020). Atmosferin çeşitli basınç düzeylerinde ölçülen veriler, alıcı yer istasyonlarına gönderilir ve bilgisayarlar tarafından işlenerek meteorolojik parametrelere dönüştürülür (Potter & Colman, 2003). Radyosonda sistemi, su buharının neredeyse tamamını içeren troposfer katmanının verilerini toplamak için kullanılan yüksek hassasiyetli bir yöntemdir.

2.3 Atmosferik Parametrelerin Değerlendirilmesi

GNSS-RO tekniği ve radyosonda tekniği atmosferik profilleri, Mutlak Ortalama Hata (Mean Absolute Error, MAE) ve Karesel Ortalama Hata (Mean Squared Error, MSE) ile değerlendirilmiştir. MAE ve MSE değerleri,

$$MAE = \frac{\sum_{i=1}^n (|x_{GNSS-RO,i} - x_{RS,i}|)}{n} \quad (6)$$

$$MSE = \sqrt{\frac{\sum_{i=1}^n (x_{GNSS-RO,i} - x_{RS,i})^2}{n}} \quad (7)$$


eşitlikleri ile hesaplanmıştır (Zhang vd., 2018). Bu eşitliklerde, $x_{GNSS-RO}$, GNSS-RO atmosferik parametre verileri; x_{RS} , radyosonda atmosferik parametre verileri ve n, ölçü sayısını ifade etmektedir. MAE ve MSE, GNSS-RO verilerinin radyosonda verileri ile ne kadar uyumlu olduğunu değerlendirmek için hesaplanmıştır. MAE ve MSE değerlerinin düşük düzeyde elde edilmesi RO ve radyosonda verileri arasında uyumun iyi olduğunu, her iki yöntemin de doğru ve güvenilir ölçü sağladığını ortaya koymaktadır.

3. Yapılan Çalışmalar

3.1 Çalışma Alanı ve Veri

Çalışma bölgesi olarak Trapani/Birgi, Kayseri, Samsun radyosonda istasyonları seçilmiştir ve bu istasyonların yakınlarında meydana gelen COSMIC-2 RO olayları tespit edilmiştir. 100 km - 1 saat sınırlandırması için Trapani/Birgi RS, 200 km - 2 saat sınırlandırması için Kayseri RS ve 300 km - 3 saat sınırlandırması için Samsun RS seçilmiştir.

Trapani/Birgi RS için 2019 yılının 353'üncü gününe ait wetPf2_C2E2.2019.353.12.42.G08_0001.0001_nc, Kayseri RS için 291'inci gününe ait wetPf2_C2E3.2019.291.13.41.G31_0001.0001_nc, Samsun RS için 281'inci gününe ait wetPf2_C2E3.2019.281.21.36.G10_0001.0001_nc RO dosyaları kullanılmıştır (Şekil 2, Tablo 1).



Şekil 2. Atmosferik profillerin karşılaştırılması için seçilen RS ve COSMIC-2 RO konumları

Tablo 1. Atmosferik profillerin karşılaştırılması için seçilen RS ve COSMIC-2 RO konumları

RS	RS Enlem	RS Boylam	RS Zaman	RO Enlem	RO Boylam	RO Zaman
(16429) Trapani	37.92°	12.50°	12:00-UTC	38.34°	11.90°	12:39:19
(17196) Kayseri	38.65°	35.50°	12:00-UTC	40.49°	35.41°	13:38:00
(17030) Samsun	41.28°	36.33°	00:00-UTC	39.65°	34.02°	21:36:44

Tablo 1'de 2019 yılının 353'üncü gününde 38.34° Kuzey enlemi ve 11.90° Doğu boylamında gözlenen RO olayı, RS noktasından ~70 km uzaklıktadır. 2019 yılının 291'inci gününde 40.49° Kuzey enlemi ve 35.41° Doğu boylamında gözlenen RO olayı, RS noktasından ~200 km uzaklıktadır. 2019 yılının 281'inci gününde 39.65° Kuzey enlemi ve 34.02° Doğu boylamında gözlenen RO olayı, RS noktasından ~265 km uzaklıktadır.


Çalışmada kullanılan COSMIC-2 RO verileri, UCAR COSMIC Program Ofisi tarafından sağlanan wetPrf ıslak profillerdir. Bu veriler için dosyalar netCDF formatında gerçeğe yakın zamanlı olarak işlenmektedir. WetPrf ıslak profilleri; jeopotansiyel yükseklik, sıcaklık, basınç, buhar basıncı, kırılma, özgül nem vb. parametreleri içermektedir. Çalışmada kullanılan radyosonda verileri, Ulusal Okyanus ve Atmosfer Dairesi (National Oceanic and Atmospheric Administration, NOAA) tarafından sağlanan Entegre Küresel Radyosonda Arşivi (Integrated Global Radiosonde Archive, IGRA) atmosferik profilleridir. Radyosonda profilleri ise yükseklik, basınç, sıcaklık, çığ sıcaklık verilerini içermektedir.

3.2 FORMOSAT-7/COSMIC-2 RO ve Radyosonda Atmosferik Profillerinin Karşılaştırılması

Çalışmada kullanılan COSMIC-2 RO profilleri 0-60 km dikey yüksekliğinde ve 50 m dikey örnekleme çözünürlüğündedir. RO profilleri 0-30 km dikey yüksekliğindedir. Radyosonda profillerinin dikey örnekleme çözünürlüğü ise alt seviyelerde yaklaşık 100 m iken üst seviyelerde 500 m'ye kadar değişebilmektedir. GNSS-RO ve radyosonda teknikleri farklı yöntemler olduğu için bu yöntemler sonucunda temin edilen verilerin yükseklikleri de farklıdır. Bu nedenle, COSMIC-2 RO ve radyosonda profillerinin ortak konumlu dikey karşılaştırmasını yapabilmek için veriler üzerinde 500 m aralıklı olacak şekilde spline enterpolasyon yöntemi uygulanmıştır. Ayrıca, atmosferin yere yakın 10-12 km'sinde önemli meteorolojik olaylar meydana gelmektedir. Bu nedenle, 5-10 km aralığında COSMIC-2 RO ve radyosonda profilleri için MAE ve MSE hesaplanmıştır.

3.2.1 Sıcaklık

Sıcaklık, atmosferin nasıl ısınıp nasıl soğuduğunun anlaşılması için önemli bir parametredir. Atmosferin en alt katmanı olan troposferde sıcaklık, genellikle yükseklikle beraber azalmaktadır (Şekil 3).



Şekil 3. Radyosonda ve COSMIC-2 RO sıcaklık profillerinin karşılaştırılması

Şekil 3 incelendiğinde genel olarak atmosfer içerisindeki sıcaklığın 5 km'den 10-12 km ye kadar azaldığı, 15 km'den sonra arttığı gözlenmiştir. Trapani/Birgi RS için radyosonda sıcaklık profillerinin, 5-10 km arasında COSMIC-2 RO sıcaklık profilleri ile uyumlu olduğu gözlenmiştir. COSMIC-2 RO sıcaklıkları, 10-18 km arasında genel olarak radyosonda sıcaklıklarından daha düşüktür. COSMIC-2 RO ve radyosonda sıcaklıkları, 18 km üzerinde birbirleriyle uyumlu değildir. 18 km üzerinde yükseklik arttıkça bazen COSMIC-2 RO sıcaklıkları radyosonda sıcaklıklarından daha düşük bazen de radyosonda sıcaklıkları COSMIC-2 RO sıcaklıklarından daha düşüktür. Kayseri RS için radyosonda sıcaklık profillerinin 7-12 km arasında COSMIC-2 RO sıcaklık profilleri ile uyumlu olduğu gözlenmiştir. Radyosonda ve COSMIC-2 RO sıcaklık farklarının 13-25 km arasında belirginleştiği gözlenmiştir. Samsun RS için 5-12 km arasında sıcaklık farklarının belirgin olduğu ve radyosonda sıcaklıklarının COSMIC-2 RO sıcaklıklarından daha düşük olduğu gözlenmiştir. 15 km üzerinde ise COSMIC-2 RO sıcaklıkları radyosonda sıcaklıklarından daha düşüktür. Ayrıca, 10 km yüksekliğinde sıcaklıkların Trapani/Birgi RS için -55°C ile -50°C arasında, Kayseri RS için -50°C ile -40°C arasında, ve Samsun RS için ise -50°C ile -40°C arasında değiştiği gözlenmiştir. Kayseri ve Samsun RS için benzer sıcaklık aralıklarının olması, her iki bölgenin birbirine yakın enlem ve boylamlarda yer alması ve benzer güneşlenme süreleri, atmosferik radyasyon etkileri yaşamaları gibi çeşitli meteorolojik koşullara sahip olmasından, Trapani/Birgi RS için gözlenen farklılıklar ise coğrafi konumundan kaynaklanabilir. Sıcaklık profilleri için 5-10 km arasında istatistiksel yorumlama yapabilmek için MAE ve MSE hesaplanmıştır (Tablo 2).

Tablo 2. Radyosonda ve COSMIC-2 RO sıcaklık profillerinin 5-10 km arasındaki hataları

İstasyon	Yükseklik	MAE (°C)	MSE (°C)
Trapani/Birgi	5-10 km	0.7162	0.8672
Kayseri	5-10 km	1.1962	1.7323
Samsun	5-10 km	3.3950	3.7313


Tablo 2 incelendiğinde, radyosonda ve COSMIC-2 RO sıcaklık profilleri için hesaplanan hata sonuçlarının, 100 km - 1 saat sınırlandırması için seçilen Trapani/Birgi RS'de, Kayseri ve Samsun RS'den daha düşük olduğu gözlenmiştir.

3.2.2 Su Buharı Basıncı

Su buharı basıncı, belirli bir sıcaklık ve nem oranındaki havada bulunan su buharının, atmosfer üzerinde oluşturduğu basıncıdır. Su buharı basıncı, çığ sıcaklığına bağlı olarak

$$e_s = 0.611 * 10^{\left(\frac{7.5 * T_d}{237.30 + T_d}\right)} \quad (8)$$

eşitliğinden hesaplanabilir. Burada, T_d çığ sıcaklığı, havadaki su buharının yoğuşmaya başlayarak sıvı hale geçtiği sıcaklıktır. Diğer bir ifadeyle, çığ noktası sıcaklığı, havadaki su buharının mevcut kısmi basıncında doygunluğa ulaşım yoğuşmaya başladığı sıcaklıktır. Troposferde su buharı basıncı genel olarak daha yüksek olma eğilimindedir, ancak bu durum bölgesel iklim, mevsim ve diğer faktörlere bağlı olarak değişebilir. Stratosferde ise su buharı basıncı genellikle daha düşük yoğunluğa sahiptir (Şekil 4).



Şekil 4. Radyosonda ve COSMIC-2 RO su buharı basıncı profillerinin karşılaştırılması

Şekil 4 incelendiğinde 5-10 km arasında radyosonda ve COSMIC-2 RO su buharı basıncı profillerinin belirgin bir farklılık gösterdiği, 10 km üzerinde oldukça uyumlu olduğu gözlenmiştir. Dolayısıyla, su buharı basıncı değerleri arasındaki belirgin farkı istatistiksel olarak yorumlamak için MAE ve MSE hesaplanmıştır (Tablo 3).

Tablo 3. Radyosonda ve COSMIC-2 RO su buharı basıncı profillerinin 5-10 km arasındaki hataları

İstasyon	Yükseklik	MAE (hpa)	MSE (hpa)
Trapani/Birgi	5-10 km	0.1076	0.4826
Kayseri	5-10 km	0.1718	0.8028
Samsun	5-10 km	0.2065	0.9998


Tablo 3 incelendiğinde, radyosonda ve COSMIC-2 RO su buharı basıncı profilleri için hesaplanan hata sonuçlarının, 100 km - 1 saat sınırlandırması için seçilen Trapani/Birgi RS'de, Kayseri ve Samsun RS'den daha düşük olduğu gözlenmiştir.

3.2.3 Özgül Nem

Özgül nem; sıcaklık, basınç ve su buharı değişimleriyle birlikte atmosferik koşulları tanımlamak için kullanılan önemli bir parametredir. Bu parametre, birim ağırlıktaki kuru hava içinde bulunan su buharının ağırlığını ifade eder ve kilogram başına düşen gram (g/kg) biriminde ölçülür. Karışım oranı olarak da adlandırılan özgül nem,

$$q = 0.622 \frac{P_v}{P - P_v} \cong 0.622 \frac{e}{p} \quad (9)$$

eşitliğinden hesaplanabilir. Burada, P toplam basınç, P_v ise kısmi su buharı basıncıdır. Su buharı ağırlığının, aynı sıcaklık ve basınçta hava moleküllerinin ağırlığına oranı 0.622 dir. Özgül nemdeki değişiklikler konum ve mevsime bağlı olarak farklılık gösterebilir. Yüksekliğin artmasına bağlı olarak özgül nemde azalır (Şekil 5).



Şekil 5. Radyosonda ve COSMIC-2 RO özgül nem profillerinin karşılaştırılması

Şekil 5 incelendiğinde radyosonda özgül nem profilleri, 10 km üzerinde COSMIC-2 RO profilleri ile oldukça uyumludur. Trapani/Birgi RS için 5-10 km arasında radyosonda ve COSMIC-2 RO özgül nem profilleri, Kayseri ve Samsun RS'e göre daha uyumludur. 5-10 km arasında özgül nem değerleri arasındaki ilişkiyi istatistiksel olarak yorumlamak için MAE ve MSE hesaplanmıştır (Tablo 4).


Tablo 4. Radyosonda ve COSMIC-2 RO özgül nem profillerinin 5-10 km arasındaki hataları

İstasyon	Yükseklik	MAE (g/kg)	MSE (g/kg)
Trapani/Birgi	5-10 km	0.0118	0.1163
Kayseri	5-10 km	0.0825	0.5239
Samsun	5-10 km	0.1751	0.8860

Tablo 4 incelendiğinde, radyosonda ve COSMIC-2 RO özgül nem profilleri için hesaplanan hata sonuçlarının, 100 km - 1 saat sınırlandırması için seçilen Trapani/Birgi RS'de, Kayseri ve Samsun RS'den daha düşük olduğu gözlenmiştir.

3.2.4 Kırınım

Kırınım, elektromanyetik dalgaların atmosferden geçerken hava yoğunluğundaki değişiklikler nedeniyle düz bir çizgiden sapmasıdır. Yükseklik arttıkça hava yoğunluğu azalır. Bu durum, kırılma indisinin de azalmasına sebep olur. Dolayısıyla, kırılma indisi, yüzeye yakın bölgelerde daha yüksektir ve elektromanyetik dalgalar troposferde daha belirgin şekilde kırılmaya maruz kalır (Şekil 6).



Şekil 6. Radyosonda ve COSMIC-2 RO kırınım profillerinin karşılaştırılması

Şekil 6 incelendiğinde radyosonda ile COSMIC-2 RO kırınım profilleri arasında Trapani/Birgi RS için 6 km, Kayseri RS için 6.5 km ve Samsun RS için 7 km üzerinde oldukça iyi bir uyum gözlenmiştir. İstasyonlar arasında radyosonda ve COSMIC-2 RO kırınım profilleri arasındaki fark, en az Trapani/Birgi'de, en fazla ise Samsun'da gözlenmiştir. Tüm istasyonlarda, hem radyosonda hem de COSMIC-2 RO gözlemlerinde, kırınım değerlerinin 5 km civarında 160 ile 180 N-unit arasında değiştiği gözlenmiştir. 5-10 km arasında kırınım değerleri arasındaki ilişkiyi istatistiksel olarak yorumlamak için MAE ve MSE hesaplanmıştır (Tablo 5).

Tablo 5. Radyosonda ve COSMIC-2 RO kırınım profillerinin 5-10 km arasındaki hataları

İstasyon	Yükseklik	MAE (N-unit)	MSE (N-unit)
Trapani/Birgi	5-10 km	0.5833	2.7858
Kayseri	5-10 km	1.0581	5.1377
Samsun	5-10 km	0.9661	5.5690

Tablo 5 incelendiğinde, radyosonda ve COSMIC-2 RO kırınım profilleri için hesaplanan hata sonuçlarının, 100 km - 1 saat sınırlandırması için seçilen Trapani/Birgi RS’de, Kayseri ve Samsun RS’den daha düşük olduğu gözlenmiştir.

4. Sonuç

Hava olaylarının büyük bölümü atmosferin yere yakın 10-12 kilometresinde meydana gelir. Çalışmada kullanılan radyosonda profilleri 0-30 km, COSMIC-2 RO profilleri ise 0-60 km dikey yükseklikte temin edilmiştir. Atmosferik profiller 5 km altında ters Abel dönüşümü işleminin çok yollu sinyal ve izleme problemlerine bağlı olarak etkilenmektedir. Bu nedenle daha hassas analiz yapabilmek için çalışmada 5-25 km arası dikey atmosferde radyosonda ve COSMIC-2 RO profilleri karşılaştırılmıştır.

5-25 km arası dikey atmosfer için karşılaştırılan radyosonda ve COSMIC-2 RO sıcaklık profillerinde 12 km üzerinde, su buharı basıncı profillerinde 10 km üzerinde, özgül nem profillerinde 10 km üzerinde, kırınım profillerinde 7 km üzerinde genellikle iyi bir uyum gözlenmiştir. 5-10 km arasında radyosonda ve COSMIC-2 RO su buharı basınçları arasında genel olarak farkların fazla olmasının sebeplerinden biri radyosonda nem ölçülerinin düşük sıcaklıklardan etkilenmesi olabilir. Radyosondalar, suyun donma noktasının altındaki sıcaklıklarda bulutların arasından uçtuğunda, nem sensörlerinde buzlanma en büyük sorun olarak ortaya çıkabilir. Ayrıca, alt troposferde atmosferik yansıma ve çok yollu etkilerden kaynaklanan GPS problemleri, radyosonda ve COSMIC-2 RO su buharı basıncı profilleri arasındaki farkların meydana gelmesine sebep gösterilebilir. Radyosonda ve COSMIC-2 RO kırınım profilleri arasındaki fark, COSMIC-2 LEO uydu alıcılarındaki sinyal izleme hataları, çok yollu yayılmadan kaynaklı olabilir.

Konumsal ve zamansal olarak birbirine en yakın mesafede ve zamanda bulunan ve dolayısıyla en iyi karşılaşma beklenen Trapani/Birgi RS için Kayseri ve Samsun RS’den daha hassas sonuç elde edilmiştir. Trapani/Birgi RS için elde edilen MAE değerleri sıcaklık, su buharı basıncı, özgül nem ve kırınım içi sırasıyla 0.7162 °C, 0.1076 hPa, 0.0118 g/kg ve 0.5833 N-unit düzeyindedir. MSE değerleri ise sıcaklık, su buharı basıncı, özgül nem ve kırınım içi sırasıyla 0.8672 °C, 0.4826 hPa, 0.1163 g/kg ve 2.7858 N-unit düzeyindedir.

Radyosonda ve COSMIC-2 RO atmosferik profil farklılıklarının temel nedeni gözlem yöntemleridir. RO tekniğinde sıcaklık, basınç gibi parametreler yeryüzüne yakın yörüngede hareket eden COSMIC-2 uydusundan sağlanırken, radyosonda tekniğinde balon ile yükselen cihazdan sağlanmaktadır. Bu durumda; uydu, alıcı veya sensör özellikleri oldukça önemlidir. Radyosonda gözlemlerinde ise veri kalitesi cihazda kullanılan sensör tipine bağlı olarak büyük ölçüde değişmektedir. Günümüzde dünya çapında birçok farklı sensör türü kullanılmaktadır. Bu sensörlerin kendine özgü bilinen ve bilinmeyen hataları da mevcuttur. Ayrıca, farklı konumlardaki sensör tiplerinin zamanla değişmesi verilerde gerçek olmayan eğilimlerin veya sıçramaların gözlenmesine yol açabilir.

Teşekkür

Bu çalışma, TÜBİTAK-ÇAYDAG tarafından desteklenen 123Y150 numaralı, “Türkiye Genelinde ve Ekstrem Hidrolojik Hava Olaylarına Bağlı Afet Riski Taşıyan Karadeniz Bölgesinde GNSS-Radyo Okültasyon (GNSS-RO) Uydu Tekniği Kullanılarak Yağışa Dönüştürülebilir Su Buharı (PWV) Profillerinin Tahmini ve İzlenmesi”, başlıklı proje kapsamında yapılmıştır. Çalışmada kullanılan COSMIC-2 RO ve radyosonda verileri sırasıyla <https://data.cosmic.ucar.edu/> ve <https://ruc.noaa.gov/raobs/> web adreslerinden ücretsiz olarak temin edilmiştir.

Kaynaklar

- Ahmed, I. F., Abd El-Fatah, M. A., Mousa, A. E. K., & El-Fiky, G. (2022). Analysis of the differences between GPS radio occultation and radiosonde atmosphere profiles in Egypt. *The Egyptian Journal of Remote Sensing and Space Science*, 25(2), 491-500. <https://doi.org/10.1016/j.ejrs.2022.02.006>
- Anthes, R. A., Bernhardt, P. A., Chen, Y., Cucurull, L., Dymond, K. F., Ector, D., & Zeng, Z. (2008). The COSMIC/FORMOSAT-3 mission: Early results. *Bulletin of the American Meteorological Society*, 89(3), 313-334. <https://doi.org/10.1175/BAMS-89-3-313>

- Awange, J. (2018). *GNSS environmental sensing*. Springer International Publishers.
- Beyerle, G., Schmidt, T., Michalak, G., Heise, S., Wickert, J., & Reigber, C. (2005). GPS radio occultation with GRACE: Atmospheric profiling utilizing the zero difference technique. *Geophysical Research Letters*, 32(13), Article L13806. <https://doi.org/10.1029/2005GL023109>
- Bormann, N., & Healy, S. B. (2005). New observations in the ECMWF assimilation system: Satellite limb measurements. *ECMWF Newsletter*, 105, 13-17.
- Choi, M. S., Lee, W. K., Cho, S. K., & Park, J. U. (2010). Operation of the Radio Occultation Mission in KOMPSAT-5. *Journal of Astronomy and Space Sciences*, 27(4), 345-352. <https://doi.org/10.5140/JASS.2010.27.4.345>
- Cook, K., Fong, C. J., Wenkel, M. J., Wilczynski, P., Yen, N., & Chang, G. S. (2013, March 2-9). FORMOSAT-7/COSMIC-2 GNSS radio occultation constellation mission for global weather Monitoring [Conference presentation]. 2013 IEEE Aerospace Conference, Big Sky, MT, USA. <https://doi.org/10.1109/AERO.2013.6497317>
- Fong, C. J., Chu, V., Yen, N. L., Ling, J., Liu, J. Y., & Chang, G. S. (2012, March 28-April 3). FORMOSAT-7/COSMIC-2 radio occultation mission: From research to operations [Conference presentation]. International Radio Occultation Working Group (IROWG) 2nd Workshop, Estes Park, CO, USA.
- Fu, E. J., Zhang, K. F., Marion, K. Y., Xu, X. H., Marshall, J., Rea, A., & Kuleshov, Y. (2009). Assessing COSMIC GPS radio occultation derived atmospheric parameters using Australian radiosonde network data. *Procedia Earth and Planetary Science*, 1(1), 1054-1059. <https://doi.org/10.1016/j.proeps.2009.09.162>
- Fu, E. (2011). *An investigation of GNSS radio occultation atmospheric sounding technique for Australian meteorology* [Doctoral thesis, RMIT University]. <https://researchrepository.rmit.edu.au/esploro/>
- Healy, S. B., Jupp, A. M., & Marquardt, C. (2005). Forecast impact experiment with GPS radio occultation measurements. *Geophysical Research Letters*, 32(3), Article L03804. <https://doi.org/10.1029/2004GL020806>
- Jin, S. Ed. (2012). *Global navigation satellite systems: signal, theory and applications*. BoD–Books on Demand.
- Kuo, Y. H., Schreiner, W. S., Wang, J., Rossiter, D. L., & Zhang, Y. (2005). Comparison of GPS radio occultation soundings with radiosondes. *Geophysical Research Letters*, 32(5), Article L05817. <https://doi.org/10.1029/2004GL021443>
- Kursinski, E. R. (1997). *The GPS radio occultation concept: Theoretical performance and initial results* [Doctoral thesis, California Institute of Technology]. <https://resolver.caltech.edu/CaltechTHESIS:01282013-095417825>
- Kwon, H., Kang, J. S., Jo, Y., & Kang, J. H. (2014). Implementation of a GPS-RO data processing system for the KIAPS-LETKF data assimilation system. *Atmospheric Measurement Techniques*, 8(3), 1259–1273. <https://doi.org/10.5194/amt-8-1259-2015>
- Lewis, H. (2008). *Abel integral calculations in ROPP* (GRAS SAF Report 07). Met Office. https://rom-saf.eumetsat.int/general-documents/gsr/gsr_07.pdf
- Li, X., Dick, G., Lu, C., Ge, M., Nilsson, T., Ning, T., & Schuh, H. (2015). Multi-GNSS meteorology: real-time retrieving of atmospheric water vapor from BeiDou, Galileo, GLONASS, and GPS observations. *IEEE Transactions on Geoscience and Remote Sensing*, 53(12), 6385-6393. <https://doi.org/10.1109/TGRS.2015.2438395>
- Li, Y., Yuan, Y., & Wang, X. (2020). Assessments of the retrieval of atmospheric profiles from GNSS Radio occultation data in moist tropospheric conditions using Radiosonde Data. *Remote Sensing*, 12(17), Article 2717. <https://doi.org/10.3390/rs12172717>
- Norman, R., Le Marshall, J., Zhang, K., Wang, C. S., Carter, B. A., Rohm, W., Manning, T., Gordon, S., & Li, Y. (2014). Comparing GPS radio occultation observations with radiosonde measurements in the Australian region. In C. Rizos & P. Willis (Eds.), *Earth on the edge: Science for a sustainable planet* (Vol. 139, pp. 51–57). Springer. https://doi.org/10.1007/978-3-642-37222-3_7
- Potter, T. D., & Colman, B. R. (2003). Handbook of weather, climate, and water: dynamics, climate, physical meteorology, weather systems, and measurements. *John Wiley and Sons*.
- Rossiter, D. (2003). *Comparison between GPS radio occultation and radiosonde sounding data*. OpenSky. <http://dx.doi.org/10.5065/vrwy-w970>
- Schreiner, W. S., Weiss, J. P., Anthes, R. A., Braun, J., Chu, V., Fong, J., & Zeng, Z. (2020). COSMIC-2 radio occultation constellation: First results. *Geophysical Research Letters*, 47(4), Article e2019GL086841. <https://doi.org/10.1029/2019GL086841>
- Shao, X., Ho, S. P., Zhang, B., Zhou, X. S., Kireev, S., Chen, Y., & Cao, C. (2021). Comparison of COSMIC-2 radio occultation retrieval products with Vaisala RS41 and RS92 radiosonde water vapor and upper-air temperature measurements. *Terrestrial, Atmospheric and Oceanic Sciences*, 32(6), 1015-1032.
- Sioris, C., Piekutowski, T., Nilsson, C., Degenstein, D., Murtagh, D., Solheim, B., von Schéele, F., McLinden, C., Rochon, Y. J., Deblonde, G., Aparicio, J. M., & Adamovic, M. (2014, September 29 – October 3). *The atmospheric limb sounding satellite (ALISS)* [Congress presentation]. 65th International Astronautical Congress, Toronto, Canada.
- Stupar, D. I. (2015). *QB50 GNSS radio occultation* [Master thesis, International Space University]. https://isulibrary.isunet.edu/doc_num.php?explnum_id=1128

- Syndergaard, S. (1999). *Retrieval analysis and methodologies in atmospheric limb sounding using the GNSS radio occultation technique* (Scientific Report No. 99-6). Danish Meteorological Institute. <https://www.dmi.dk/fileadmin/Rapporter/SR/sr99-6.pdf>
- Vryonides, P., & Haralambous, H. (2013). Comparison of COSMIC measurements with the IRI-2007 model over the eastern Mediterranean region. *Journal of Advanced Research*, 4(3), 297-301. <https://doi.org/10.1016/j.jare.2012.09.006>
- Wang, B. R., Liu, X. Y., & Wang, J. K. (2013). Assessment of COSMIC radio occultation retrieval product using global radiosonde data. *Atmospheric Measurement Techniques*, 6(4), 1073-1083. <https://doi.org/10.5194/amt-6-1073-2013>
- Wee, T. K. (2018). A variational regularization of Abel transform for GPS radio occultation. *Atmospheric Measurement Techniques*, 11(4), 1947-1969. <https://doi.org/10.5194/amt-11-1947-2018>
- Wickert, J. (2004). *Comparison of vertical refractivity and temperature profiles from CHAMP with radiosonde measurements* (Scientific Report No. 04-9). Danish Meteorological Institute. <https://d-nb.info/974103632/34>
- Wickert, J., Schmidt, T., Michalak, G., Heise, S., Arras, C., Beyerle, G., Falck, C., König, R., Pingel, D., & Rothacher, M. (2009). GPS radio occultation with CHAMP, GRACE-A, SAC-C, TerraSAR-X, and FORMOSAT-3/COSMIC: Brief review of results from GFZ. In A. Steiner, B. Pirscher, U. Foelsche, & G. Kirchengast (Eds.), *New horizons in occultation research: Studies in atmosphere and climate* (pp. 3-15). Springer.
- Yadav, G., Kalak, S., Deep, A., & Purohit, K. D. (2020). Radiosonde: A tool to monitor atmospheric profiles. *Applied Innovative Research*, 2, 103-106.
- Yue, X., Schreiner, W. S., Pedatella, N., Anthes, R. A., Mannucci, A. J., Straus, P. R., & Liu, J. Y. (2014). Space weather observations by GNSS radio occultation: From FORMOSAT-3/COSMIC to FORMOSAT-7/COSMIC-2. *Space Weather*, 12(11), 616-621. <https://doi.org/10.1002/2014SW001133>
- Zhang, K., Biadegigne, B., Wu, F., Kuleshov, Y., Rea, A., Hodet, G., & Fu, E. (2007). A comparison of atmospheric temperature and moisture profiles derived from GPS radio occultation and radiosonde in Australia. *IEICE Technical Report*, 107(2), 7-12.
- Zhang, K., Fu, E., Silcock, D., Wang, Y., & Kuleshov, Y. (2011). An investigation of atmospheric temperature profiles in the Australian region using collocated GPS radio occultation and radiosonde data. *Atmospheric Measurement Techniques*, 4(10), 2087-2092. <https://doi.org/10.5194/amt-4-2087-2011>
- Zhang, Q., Ye, J., Zhang, S., & Han, F. (2018). Precipitable water vapor retrieval and analysis by multiple data sources: Ground-based GNSS, radio occultation, radiosonde, microwave satellite, and NWP reanalysis data. *Journal of Sensors*, 2018(1), Article 3428303. <https://doi.org/10.1155/2018/3428303>

Kentsel Yeşil Alanların Yeterliliği ve Erişilebilirliğinin Değerlendirilmesi: Tarsus (Mersin) Örneği

Evaluation of the Adequacy and Accessibility of Urban Green Areas: The Case of Tarsus (Mersin)

Aşır Yüksel Kaya^{1*} 

¹Fırat Üniversitesi, İnsani ve Toplum Bilimleri Fakültesi, Coğrafya Bölümü, 23000, Elazığ/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Aşır Yüksel Kaya
aykaya@firat.edu.tr

doi: 10.48123/rsgis.1512435

Yayın süreci

Geliş tarihi: 08.07.2024
Kabul tarihi: 11.09.2024
Basım tarihi: 26.09.2024

Özet

Son dönemlerde iklim değişikliği ve afetlerin yaşanma sıklığının artmasına bağlı olarak kentsel alanlarda yeşil alanların kullanımı, yeterliliği ve erişilebilirliği akademik ve politik söylemde sıkça vurgulanmaktadır. Kentlerin değişen iklim koşullarına adaptasyonu ve sürdürülebilir kentleşme için yeşil alanların yeterliliği ve bu alanlara erişilebilirlik önemlidir. Bu makalede Tarsus'ta bulunan 45 mahallenin yeşil alanların yeterliliği ve erişilebilirliği analiz edilmiştir. Yeşil alanların erişilebilirlik analizinde Tampon Bölge (buffer) Analiz ve Hizmet Alanı (Service area) analizi kullanılmıştır. Tarsus'ta tampon bölge analizinde her bir yeşil alanın yarıçapı 200 m, 400 m ve 600 m olarak hesaplanmıştır. Hizmet Alanı Analizinde ise konut alanlarından yeşil alanlara yürüme süresi 5, 10 ve 15 dakika olarak hesaplanmıştır. Tarsus'ta kişi başına düşen yeşil alan miktarı 4.55 m²'dir. Bu oran bu oran Türkiye yeşil alan yönetmeliklerinde belirtilen 10 m² oldukça altındadır. Kentsel alanda 0-5 dakika süresinde ulaşılabilen toplam alan 26.891.780 m², 5 ile 10 dakika arasında ulaşılabilen alan 70.192.749 m² ve 10 ila 15 dakika yürüme mesafesinde olan alan ise 121.515.881 m²'dir. Sonuç olarak Tarsus'ta kent merkezinde bulunan yeşil alanların erişilebilir konumda olduğu ancak kent çeperinde bulunan yeşil alanlara erişilebilirliğin sınırlı olduğu tespit edilmiştir. Bu kapsamda Tarsus'ta mevcut yeşil alanlar nitelik ve nicelik açısından yetersizdir. Bu alanların kent içinde eşit ve erişilebilir olarak dağılmadığı belirlenmiştir.

Anahtar kelimeler: CBS, Mekânsal analiz, Erişilebilirlik, Yeşil alan

Abstract

Recently, the importance of green spaces in urban areas has become a prominent topic in academic and political discourse due to the increasing frequency of climate change and disasters. The availability of green spaces is crucial for cities to adapt to changing climate conditions and promote sustainable urbanization. In this study, the sufficiency and accessibility of green spaces in 45 neighborhoods of Tarsus were analyzed. To assess the accessibility of green spaces, buffer and service area analyses were employed. In the buffer analysis for Tarsus, the radii of each green space were calculated at 200 m, 400 m, and 600 m. In the service area analysis, the walking time from residential areas to green spaces was determined to be 5, 10, and 15 minutes. The amount of green space per capita in Tarsus was found to be 4.55 m², which falls significantly below the 10 m² standard specified in Turkey's green space regulations. The total area accessible within a 0-5 minute walk in the urban area was 26,891,780 m², the area accessible within 5 to 10 minutes was 70,192,749 m², and the area within a 10 to 15 minute walking distance was 121,515,881 m². The results indicated that while green spaces in the city center of Tarsus are accessible, accessibility to green spaces in the urban fringe is limited. Consequently, the existing green spaces in Tarsus are deemed insufficient in terms of both quality and quantity, and their distribution

Keywords: GIS, Spatial analysis, Accessibility, Green space

1. Giriş

Dünyada artan kentleşme hızı ve kentsel yayılma nedeniyle doğal ve yarı doğal peyzaj alanları daralmakta ve her geçen gün kentsel yapı alanına dönüşmektedir (Zhang vd., 2024). Aslında kentsel yerleşmelerin artan nüfusu, mekân üzerinde büyük bir baskı oluşturmaktadır ve bu durum kentsel yeşil alanların ve yaşam kalitesinin kademeli olarak azalmasına yol açmaktadır (Adıgüzel vd., 2022; Liu vd., 2016). Böylelikle kentsel alanlarda çevresel bozulmalar halk sağlığını olumsuz etkilemektedir. Bunun nedeni artan kentleşme hızı ile birlikte kentsel ekosistemin ayrılmaz bir parçası olan yeşil alanların bu durumdan olumsuz etkilenmesidir (Doğanay, 1986). Ancak sürdürülebilir kentsel arazi kullanımı kapsamında ülkeler ve şehir yöneticileri, kentsel yeşil alanların genişletilmesi ve farklı işlevlere sahip yeşil alan kullanımını artırmaya yönelik plân ve projelere daha fazla önem vermeye yönelmişlerdir (Bertram & Rehman, 2015). Bu kapsamda mevcut şehirlerde kişi başına düşen yeşil alan miktarını artırmaya yönelik girişimler sürmektedir. Kentsel arazi kullanımı arasında yeşil alanlar, kentsel peyzajların iyileştirilen ve kentsel sürdürülebilirliği artıran temel unsurlar olarak kabul edilmekte ve kentsel plânlamanın vazgeçilmez bir unsuru olarak görülmektedir (Keloğlu & Karabacak, 2020).

Kentsel yeşil alanlar, sağladıkları olumlu etkiler sebebiyle yaşam kalitesini artırmada önemli bir yere sahiptir (Chen & Chang, 2015). Parklar, bahçeler, ağaçlar, nehir kenarları ve hatta özel bahçeler gibi yeşil alanlar; fiziksel aktiviteyi, sosyal etkinlikleri, zihinsel rahatlamayı, stres ve sıcaklıktan kurtulmayı kolaylaştırarak zihinsel ve fiziksel faydalar sağlar (Kwon vd., 2021; Liu vd., 2016). Bu bağlamda kentsel yeşil alanlar, sadece fiziksel bir mekân olmanın yanında kentsel yaşam kalitesini etkileyen kültürel bir yapıya sahip alanlardır.

Kentsel yaşam kalitesinin artması ile yeşil alan varlığı arasında kesin olarak kanıtlanmasa bile pozitif bir ilişki olduğu bilinmektedir (Adıgüzel & Doğan, 2020; Kwon vd., 2021). Kentsel yeşil alanlar, kentli bireylere konforlu ve keyifli bir ortam sunarak onların doğayla bağlantı kurmalarına ve açık hava etkinlikleri yapmalarına olanak tanır (Li vd., 2020). Bu olanakların fazlalığı sürdürülebilir kentsel yaşam kalitesi ve kentleşmenin önemli bir bileşenidir.

Kentsel yaşam kalitesi, birbirinden farklı pek çok boyutu içinde barındırması, zaman, mekân ve kişiye göre farklılık göstermesi sebebiyle tanımlanması ve ölçülmesi güç olan bir kavramdır (Görün & Kara, 2010). Ancak kent plânlama ve kentsel arazi kullanımında yeşil alan miktarının artırılması olumlu bir etkiye sahiptir. Kentsel yeşil alana erişimin yüksek olduğu kentlerde; bireysel ve toplumsal aktivitelerin fazlalığı, karşılıklı etkileşimin yüksek olması yaşam kalitesini olumlu etkileyen bir unsur olarak değerlendirilmektedir.

Kentsel yeşil alanların önemli bir özelliği, kentlerde iklim uyumuna katkıda bulunan kentsel sıcaklık düzenlemesi yapmak (Alkan vd., 2017), su akışı düzenlemesi ve yüzey akışının azaltılması gibi birçok düzenleyici ekosistem hizmeti sağlamaktır (Graça vd., 2022). Dünya genelinde değişen iklim koşulları ve yaşanan afetler akademik ve politik söylemde sürdürülebilir ve dirençlilik bağlamında yeşil alanların önemini vurgulamaktadır (Çetin vd., 2023). Kentsel yeşil alanlar, bina yoğunluğuna bağlı olarak meydana gelen kentsel ısı adası oluşumunu değiştirmesi açısından önemlidir. Bir kentte yeşil alan miktarı ne kadar fazla ise kent iklimi daha yaşanabilir bir ortam sağlamaktadır. Ayrıca kentsel yeşil alanlar, karbon tutumu yoluyla iklim değişikliğinin etkilerinin azaltılmasına katkıda bulunur (Nero vd., 2017). Ancak bu etkiler kentsel yeşil alanın işlevsel kullanımı ile yakından ilişkilidir. Kentsel yeşil alanları oluşturan unsurlar (ağaçlar, parklar ve ormanlar), diğer kentsel alanlara (cadde sokaklar ve binalar) göre daha yüksek düzeyde termal konfor sağlar (Aram vd., 2019).

Kent içinde bulunan yeşil alanların, kent ekolojisine olan etkilerinin yanında bir diğer özelliği de kent morfolojisine olan etkileridir. Kropf (2005)'a göre kent morfolojisinin genel yapısı, (a) bina elemanlarını, (b) yol altyapısını ve (c) arazi kullanım bileşenlerini içeren, birbirine bağlı farklı ölçeklerdeki özelliklerin hiyerarşisidir. Bu ağda yeşil alanların kentsel yapıyla doğrudan ve dinamik bir ilişkisi vardır (Margaritis & Kang, 2016). Kent morfolojisinde yeşil alanlar, kentsel gelişim döngüsü içinde çeper kuşak alanlarında ortaya çıkan bir arazi kullanım türüdür (Whitehand, 1988). Bu alanlar sadece yeşil alan olmayıp yoğun yapılaşmış alanların aksine, insanların ferahlayabileceği, çeşitli alternatif kullanımlarla değerlendirilebilecek ve korunabilecek nefes alma alanlarıdır (Hazar & Kubat, 2015). Kentsel yeşil alanlar, kentlerde ekolojik koridorlar oluşturması sebebiyle önemlidir. Dolayısıyla bu alanların ekolojik, ekonomik, sosyal, kültürel, sağlık, refah gibi pek çok konuda yaptığı olumlu katkılar ile kentsel sürdürülebilirliğin ve plânlamanın vazgeçilmez unsurları arasındadır (Keloğlu & Karabacak, 2020). Bu nedenle kentsel yeşil alanların özelliklerinin ve boyutlarının arazi kullanım üzerindeki etkisine ilişkin araştırmalar, son dönemlerde yaygınlaşmıştır. Özellikle gelişmiş ülkelerde yeşil alan kullanımı ve plânlamasının kentsel morfoloji ile ilişkisinin ortaya konmasında yapılan araştırmaların sayısında ciddi artışlar meydana gelmiştir.

Günümüzde kent morfolojisinin önemli bir unsuru olan yeşil alanların, değerlendirilmesi ve ölçülmesinde iki ana yöntem bulunmaktadır. Bu yöntemlerden ilki mevcut yeşil alanların kullanımını değerlendiren öznel araştırmalardır. Bu araştırmalar, daha çok nitel araştırma yöntemidir ve kişisel deneyimlere dayanır (Liu vd., 2016). İkinci ana yöntem ise uydu görüntüleri ve Coğrafi Bilgi Sistemleri (CBS) kullanılarak yapılan sayısal araştırmalardır. Özellikle bu yöntemi nitel araştırmalardan ayıran özellik veri kaynaklarının kullanılabilirliğidir. Genel olarak CBS ve uzaktan algılama çalışmalarında kullanılan veri setleri (a) uydu görüntüleri, kamusal veri setleri (arazi kullanım planları, imar plânı vb.) ve özel amaçlar için tasarlanmış veri tabanlarıdır (oyun alanları, ağaç örtüsü, banklar, sulak alanlar vb.) (Liu vd., 2016; Zhang vd., 2021).

Ancak bu yöntemde veri setlerinin güvenilirliği son derece önemlidir. Kentsel yeşil alanlar kamuya ait alanlar olması sebebiyle özel kullanım alanlarından (stadyumlar, golf sahaları, kapalı konut siteleri vb.) farklıdır. Özellikle uzaktan algılama veri setlerinde araştırmacıların analizlerde yeşil alanların kullanım türüne göre analiz gerçekleştirmesi gerekmektedir. Bir diğer önemli unsurda gelişmekte olan ülkelerde hızlı kentleşme ve kent plânlarında yaşanan değişmelerin veri setlerinde sürekli güncellenme ihtiyacı duymasındır. Fakat son dönemlerde CBS ile mevcut yeşil alanların kullanımı ve bu alanlara erişilebilirliğin belirlenmesi yönelik araştırmalar sayısı artmıştır (Cracu vd., 2024; Liang vd., 2024; Shan vd., 2024; Stanford vd., 2024; Tian vd., 2024; Yang vd., 2024).

Kentsel yeşil alanlara erişilebilirlik, genellikle kentli bireylerin yaşam alanı olan konutlarından bu alanlara erişebilme kabiliyeti olarak tanımlanmaktadır (Kronenberg vd., 2020). Kentsel yeşil alanlara erişilebilirliğin ölçülmesine yönelik belirli bir standart yoktur. Bu standartlar ülkeden ülkeye ve kentten kente değişmektedir. Ancak erişilebilirlik literatürü incelendiğinde, konut alanı ile yeşil alan mesafeleri ve çeşitli kentsel yeşil alan türlerinin minimum boyutları için halihazırda standartlaştırılmış parametreler bulunmaktadır (Tablo 1), (Figueiredo vd., 2016).

Tablo 1. Yeşil alan erişilebilirlik süresi (Figueiredo vd., 2016)

Erişilebilirlik mesafesi ve Süresi	Kaynak
400 m - 5 dakika	(van Herzele & Wiedemann, 2003; Wright Wendel vd., 2012; Boone vd., 2009)
400 m	(Wright Wendel vd., 2012)
300-400 m	(Coles & Bussey, 2000; Giles-Corti vd., 2005; Grahn & Stigsdotter, 2003; Nielsen & Hansen, 2007)
900-1000 m - 15 dakika	(Stanners & Bourdeau, 1995)
<300 m	(Harrison vd., 1995; Wray vd., 2005)

Mevcut literatürde kentsel yeşil alanlara erişilebilirlik “mekânsal maliyet yaklaşımı (The travel cost approach), konteyner yaklaşımı (The container approach) ve mekânsal etkileşim modelleme yaklaşımı (Spatial interaction modeling approach)” gibi yöntemler kullanılarak ölçülmektedir (Zhang vd., 2011). Tüm bu yöntemler öklid mesafesini birincil parametre olarak kullanmıştır (Zhang vd., 2021). Ancak bu mesafe kentlerin plânlı yahut plânsız olmasına göre değişmektedir. Plânlı kentlerde komşuluk birimleri dikkate alınarak yeşil alanlar dağılışı gösterirken, plânsız gelişmekte olan kentlerde dağınık ve düzensizdir (Çetin, 2015). Bu durum yeşil alanların kent içinde dağılımını etkilemekle birlikte kullanım durumunu da etkilemektedir. Özellikle Türkiye gibi hızlı kentleşen ülkelerde daha da belirgindir.

Türkiye’de yeşil alanların plânlanmasına yönelik ilk çalışmalar 16.07.1956 yılında yürürlüğe giren İmar Kanun’u ile gündeme gelmiştir. İlgili kanunun 31 maddesinde “imar ve yol istikamet plânlarında meydan, yol, park, yeşil saha ve otopark gibi kamu hizmetine ayrılmış yerlere rastlayan hazineye ve şahsi işletmelere ait araziler ve arsalar belediyenin teklifi ve icra Vekilleri kararıyla belediyeye bedelsiz terk edilir” şeklindedir. 20.07.1972 yılında 1605 sayılı yasa ile ilgili kanunda yapılan düzenleme sonucunda plânlamaya esas alınan nüfus başına yeşil alan miktarı en az 7 m² iken 02.09.1999 tarihinde çıkarılan bir yönetmelikle, aktif yeşil alan miktarı 10 m²’ye çıkarılmıştır (Gül vd., 2020). 02.11.2011 yılında Bayındırlık ve İskân Bakanlığı Plan yapımına ait esaslara dair yönetmelikte yapılan değişiklikte kişi başına düşen yeşil alan miktarı 10 m² / kişi olarak korunmuştur. Bu oran yeşil alanın türüne ve komşuluk ünitesi düzeyine göre değişmektedir. Özdede vd. (2021) göre bu niceliksel yaklaşım yeterli değildir. Yeşil alan standartlarının saptanmasında, kentin fiziki çevre özelliklerinin yanında (iklim, topografya, kentin konumu vb.), sosyo-kültürel faktörler, ekonomik faktörler ve kullanım yoğunluğu da önemli rol oynamaktadır (Özdede vd., 2021). Bu kapsamda önemli olan yeşil alanların kentlerdeki varlığı değil, kentsel arazi kullanımı ve kent formuna uygun sistemli bir şekilde plânlanması gereklidir (Eminağaoğlu & Yavuz, 2010). Türkiye’de yeşil alan yeterliliği üzerine yapılan çalışmalar incelendiğinde mevcut yeşil alanların 10 m²/kişi standartların altında olduğu belirlenmiştir. Bu kapsamda son dönemlerde yeşil alanların yeterliliği üzerine yapılan çalışmalarda kişi başına düşen yeşil alan miktarı Bingöl’de 2.47 m² (Caf & Koç, 2024), Diyarbakır’da 2,42 m² (Kayan & Biçen, 2023), Aydın’da 2,36 m² (Uzun & Tonyaloğlu, 2024), Niğde’de 5.3 m² (Gümüş vd., 2024), Kahramanmaraş’ta 1,24 m² (Duygun vd., 2016), Çankırı’da 4 m² (Koçan & İbiş, 2020) ve Burdur’da 4.01 4 m² (Yenice, 2012) olarak hesaplanmıştır.

Tarsus yerleşme tarihi oldukça eski bir kent olmasına rağmen 20. yüzyılın ilk çeyreğinden sonra imar plânları oluşturulmuş ve modern kentin ihtiyaçlarını karşılayacak kamusal alanlar inşa edilmeye başlanmıştır (Tüter & Ökesli, 2015). Ancak Tarsus’un Adana ve Mersin gibi Türkiye’nin büyük kentlerinin çeperinde yer alması kentleşme sürecini hızlandırmıştır. Bu durum beraberinde hızlı kentleşme ve buna bağlı olarak kamusal alanların artan nüfusun ihtiyaç ve taleplerini karşılayacak nitelikten uzak olmasına neden olmuştur.

Araştırma kapsamında Tarsus'ta yer alan yeşil alanların kentiçi dağılımları dikkate alınarak, kentsel doku ve sürdürülebilir kentleşme üzerine etkileri analiz edilmektedir. Bu doğrultuda, Akdeniz bölgesinin Çukurova bölümünde yer alan ve nüfusu sürekli artış gösteren Tarsus'ta mevcut yeşil alanların dağılımı ve bu alanlara erişebilirliğin değerlendirilmesi sürdürülebilir kentleşme politikaları oluşturması açısından önemlidir. Bu bağlamda yeşil alanların mekânsal dağılımı ve arzının yetersiz olduğu bir amaçlanmaktadır. Araştırma kapsamında Tarsus'ta bulunan yeşil alan yeterliliği m²/kişi olarak hesaplanmıştır. Yeşil alan yeterliliği üzerine yapılan çalışmalarda da benzer hesaplama yöntemi kullanılmıştır. Ancak bu durum kentiçinde bulunan bütün yeşil alanların homojen bir dağılım gösterdiği prensibine dayanmaktadır (Eminağaoğlu & Yavuz, 2010). Oysa Tarsus'ta yeşil alanların dağılımı belirli bir plânlamanın sonucunda değil, kentleşme sürecinde ortaya çıkan plânsız alanlardır. Belirli bir plânlamanın sonucunda oluşturulmayan bu alanların kent içindeki dağılımlarının yanı sıra büyüklüğü, kullanım durumu ve erişebilirlik düzeyleri de birbirinden farklıdır. Mersin ve Adana gibi Türkiye'nin iki önemli kentinin çeperinde yer alan Tarsus'ta kentsel gelişime bağlı olarak arazi kullanımı sürekli bir değişim potansiyeline sahiptir. Bu kapsamda tüm dünyada artan yeşil alan kullanımı ve yaşanabilir kentsel mekânlar oluşturma gerekliliği var sayımından yola çıkarak Tarsus araştırma alanı olarak belirlenmiştir. Böylece Tarsus özelinde yapılacak plânlamalarda yeşil alanların mekânsal dağılımı, yeterliliği ve erişebilirliği dikkate alınarak plânlarnın hazırlanmasında katkı sağlaması beklenmektedir.

2. Metodoloji

2.1. Çalışma Alanının Yeri ve Sınırları

Çukurova ve İç Anadolu arasındaki geçişin sağlandığı Gülek Boğazı'nın Akdeniz'e açıldığı alanın batı kesiminde yer alan Tarsus, geçmişten günümüze stratejik ve ekonomik açılarından önemli bir yerleşim alanı olmuştur (Gülersoy vd., 2014). Günümüzde idarî olarak Mersin ilinin doğusunda yer alan bir ilçedir. Tarsus'un doğusunda Adana, kuzeyinde Pozantı ve Çamlıyayla, güneyinde Akdeniz ve batısında Mersin kenti bulunmaktadır (Şekil 1). İdari ve nüfus sayım istatistiklerinde Tarsus sınırları içerisinde 180 mahalle bulunmaktadır. Ancak bu mahallelerden kırsal karakterli olan 135 mahalle araştırma kapsamı dışında bırakılmıştır. Tarsus 45 mahalleden oluşmaktadır ve toplam yerleşim alanı yaklaşık 43 km² dir.



Şekil 1. Çalışma alanı lokasyon haritası

Tarsus, yerleşme tarihi oldukça eski bir kenttir. Tarsus tarih boyunca Hitit, Asur, Mısır, Pers, Yunan, Roma, Bizans, Abbasi, Emeviler, Anadolu Selçukluları ve Osmanlı Devlet'i hâkimiyetinde kalmış bir bölgede yer almaktadır (Tüter & Ökesli, 2015). Mersin ilinin 4 merkez ilçe olmak üzere 13 ilçesi bulunmaktadır.

Bu ilçelerden Akdeniz, Mezitli, Yenişehir ve Toroslar merkez ilçelerdir. Anamur, Aydınçık, Bozyazı, Çamlıyayla, Erdemli, Gülnar, Mut, Silifke ve Tarsus ise idarî olarak Mersin iline bağlı diğer ilçelerdir. Günümüzde Mersin ilinin nüfus miktarı bakımından en büyük ilçesi ise Tarsus'tur (Tablo 2). Mersin ili 8 yıllık periyotta nüfus artış hızı % 4.93 iken, Tarsus'ta % 4.91'dir. 8 yıllık periyotta nüfusun artış oranına bakıldığında nüfus artış oranı en yüksek ilçeler merkez ilçeler ve Erdemli, Gülnar ve Silifke'dir. 2015 yılından 2023 yılına kadar geçen 8 yıllık sürede Tarsus nüfusu ise % 8.41 oranında artış göstermiştir.

Tablo 2. Mersin ili nüfus değişimi

	2015			2023			Artış Hızı (%)	Artış oranı (%)
	Erkek	Kadın	Toplam	Erkek	Kadın	Toplam		
Akdeniz*	137.830	134.536	272.366	133.206	127.673	260.879	4.79	-4.22
Anamur	32.509	317.54	64.263	33.769	33.171	66.940	4.87	4.17
Aydınçık	5.676	5.463	11.139	5.977	5.685	11.662	4.87	4.70
Bozyazı	13.309	13.192	26.501	13.583	13.402	26.985	4.85	1.83
Çamlıyayla	4.300	4.124	84.24	4.549	4.143	8.692	4.86	3.18
Erdemli	67.107	67.007	134.114	76.919	77.048	153.967	4.97	14.80
Gülnar	12.713	12.739	25.452	20.685	13.301	33.986	5.12	33.53
Mezitli*	84.481	87.356	171.837	108.030	115.394	223.424	5.09	30.02
Mut	31.078	31.120	62.198	31.908	31.608	63.516	4.85	2.12
Silifke	58.492	57.949	116.441	70.083	66.964	137.047	4.99	17.70
Tarsus	162.488	163.575	326.063	177.208	176.261	353.469	4.91	8.41
Toroslar*	143.572	142.399	285.971	160.805	15.9572	320.377	4.94	12.03
Yenişehir*	116.434	124.018	240.452	132.804	144.641	277.445	4.97	15.38
Mersin İli	869.989	875.232	1.745.221	969.526	968.863	1.938.389	4.93	11.07

Kaynak: Adrese Dayalı Nüfus Kayıt Sistemi (ADNKS), 2015 ve 2023 Nüfus Sayım verileri. * Mersin merkez ilçeler

2.2. Veri Toplama ve Analiz

Araştırmanın ana materyalini, Tarsus yerleşim alanı sınırları içerisinde bulunan kamusal yeşil alanlar oluşturmaktadır. Araştırma kapsamında yeşil alan olarak parklar, bahçeler, çocuk oyun alanları, rekreasyon alanları kullanılmıştır. Bu alanlar genel olarak yeşil alanlar olarak değerlendirilmiştir. Araştırma kapsamında yeşil alanların dağılımı Mersin Büyükşehir Belediyesi'nden alınan sayısal veriler (2023) ve Urban Atlas'ta yer alan 2018 yılı Kentsel Atlas Arazi Örtüsü/Arazi Kullanımı (<https://land.copernicus.eu/en/products/urban-atlas>) verileridir. Bu sayısal veriler mevcut yeşil alanlar ve mahalle sınırlarının sayısal verileridir. Bunun dışında mevcut yeşil alanların yeterliliğini belirlemek için Adrese Dayalı Nüfus Kayıt Sisteminde yer alan 2023 mahalle nüfusları kullanılarak kişi başına düşen yeşil alan miktarı belirlenmiştir (Tablo 3).

Tablo 3. Araştırma kapsamında kullanılan veri setleri

Veri Seti	Kaynak	
Yeşil Alanlar (parklar, bahçeler, çocuk oyun alanları, rekreasyon alanları)	Tarsus Belediyesi Kent Rehberi Google Earth Sokak Görünümü Urban Atlas	https://ebldy.tarsus.bel.tr/keos/?WorkspaceName=rehber https://land.copernicus.eu/en/products/urban-atlas
Kara Yolu	ArcGIS StreetMap Premium	https://www.esriuk.com/en-gb/arcgis/products/arcgis-streetmap-premium/overview
Mahalle Nüfusu	TUİK ADNKS (2023)	https://biruni.tuik.gov.tr/medas/?kn=95&locale=tr
Mahalle Sınırları	Tarsus Belediyesi Kent Rehberi	https://ebldy.tarsus.bel.tr/keos/?WorkspaceName=rehber
Tematik Aitlik Haritalar	Esri Basemap	https://www.arcgis.com/home/group.html?id=702026e41f6641fb85da88efe79dc166#overview

Modern planlanmanın ortaya çıkışından bugüne, kentsel yerleşmelerde açık ve yeşil alanların yeterliliği ve erişilebilirliğini ölçmeye yönelik çok sayıda nicel ölçüm standartları önerilmiştir (Stähle, 2010, Şenik & Uzun, 2021). Tarsus'ta yeşil alanların yeterliliğinin tespitinde ArcGIS Pro 3.3.0 yazılımı kullanılarak "Tampon Bölge (buffer zone)" analizi ile yeşil alanların etki alanları belirlenmiştir. Tampon bölge analizi, nokta (point), çizgi (line) ve çokgenlerin (poligon) etrafında belirli bir genişlikte bir etki alanının oluşturulması prensibine dayanır (Tango & Topçu, 2021, Vural, 2024).

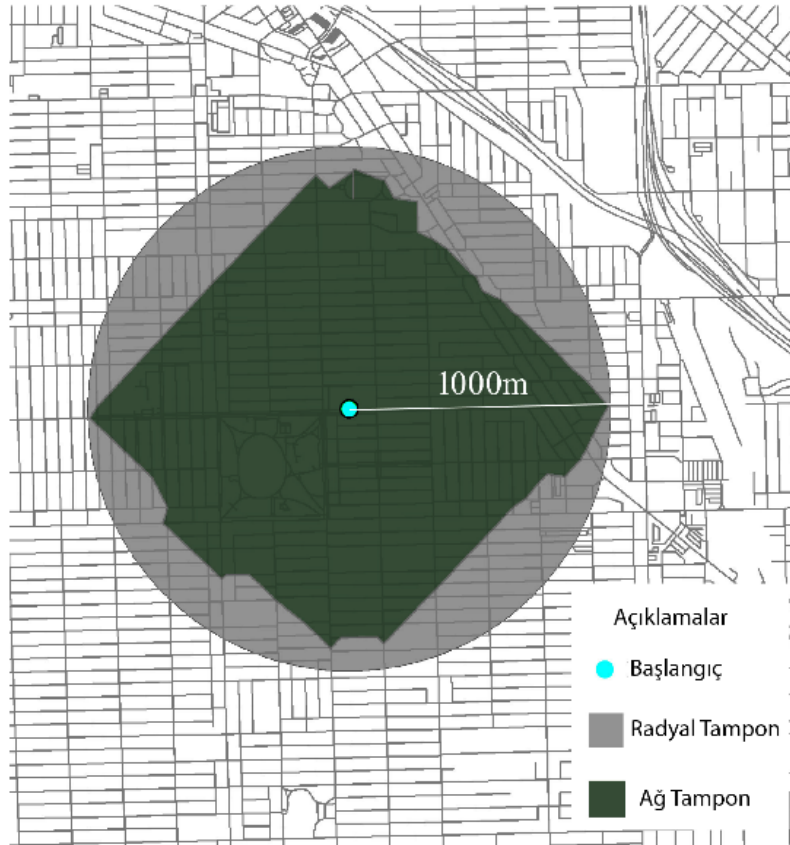
Yakınlık analiz olarak da adlandırılan tampon bölge analizi, özellikle konuma dayalı hesaplamalarda erişim alanı belirlenmesinde kullanılır (Taşkaya & Ulutaş, 2021). Tampon bölge analizi genellikle Radyal Tampon ve Ağ Tampon Analizi olarak uygulanır (Şekil 2). Radyal Tampon Analizi belirli bir alanın etrafında kuş uçuşu mesafeyi tahmin eder. Bu durumda araştırmacı bir radyal mesafe belirlediğinde, CBS yazılımı bu değere eşit yarıçapa sahip dairesel tampon çizer. Daire genellikle belirli bir nokta, çizgi veya çokken olarak belirlenen özelliği (Parklar, hastaneler, binalar, mahalleler vb.) merkez alır. Radyal Tampon Bölge hesaplaması şu formüllere göre yapılır:

$$A = \pi * d^2 \quad (1)$$

Burada, A tampon alanını ve d tampon mesafesini temsil eder (Gümüş vd., 2024) Buna karşılık ağ tamponları ise ulaşım yollarını dikkate alır ve bu ağlara göre bir tahmin eder. CBS yazılımı, araştırmacı mesafeyi belirledikten sonra, yol ağı CBS verilerine dayalı olarak mevcut tüm yürüyüş veya sürüş rotaları boyunca ağ tamponlarını belirler (Browning & Lee, 2017). Ağ Tampon Bölge hesaplaması şu formüllere göre yapılır:

$$A = (d * 2) * L \quad (2)$$

Burada, A tampon alanını, d tampon mesafesini ve L çizginin uzunluğunu temsil eder (Gümüş vd., 2024).

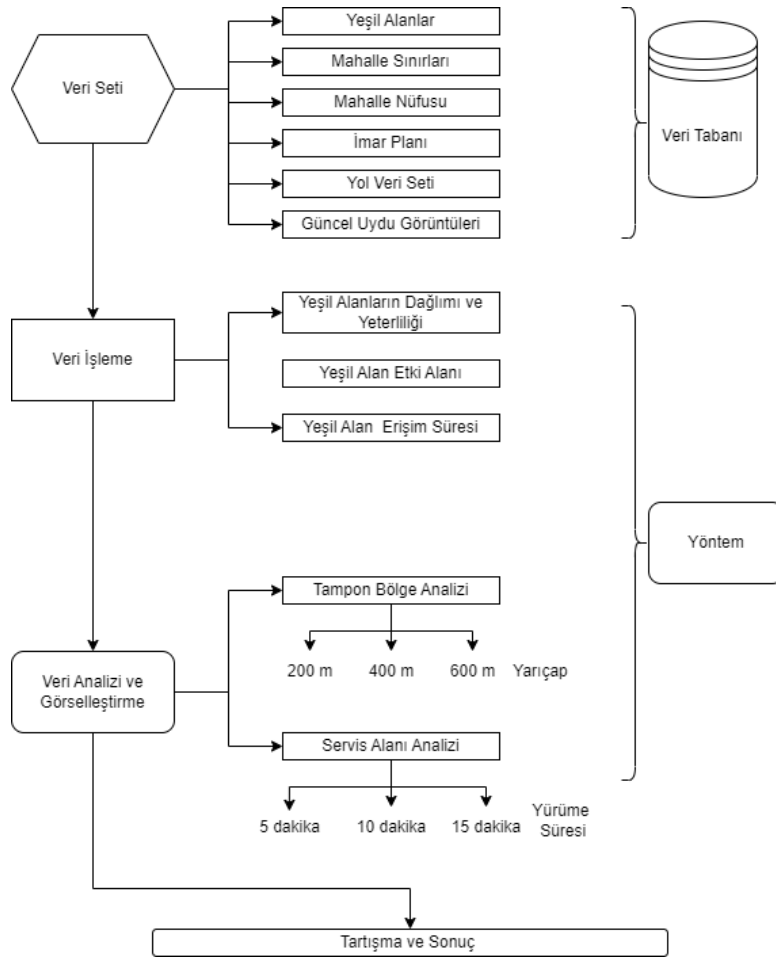


Şekil 2. Radyal ve ağ tampon bölge analiz türleri (Browning & Lee, 2017).

Tarsus kentinde radyal tampon bölge analiz hesaplaması kullanılmıştır. Yeşil alanların etki alanları; "Mekânsal Planlar Yapım Yönetmeliği Dördüncü Bölümde yer alan Mekânsal Planların Yapımına Dair Esaslar hususunda İmar planlarında Yürüme mesafeleri eğitim, sağlık ile yeşil alanların hizmet etki alanındaki nüfusun erişme mesafesi topoğrafya, yapılaşma, yoğunluk, mevcut doku, doğal ve yapay eşikler dikkate alınarak planlanır. Madde 12(2)'ye göre "imar planlarında; çocuk bahçesi, oyun alanı, açık semt spor alanı, aile sağlık merkezi, kreş, anaokulu ve ilkokul fonksiyonları takriben 500 metre mesafe dikkate alınarak yaya olarak ulaşılması gereken hizmet etki alanında planlanabilir" şeklinde ifade edilmiştir (Mekânsal Planlar Yapım Yönetmeliği, 2014). Ancak Tarsus'ta mevcut yeşil alanların oluşturulmasında bu plan kararlarına uyulmamasından dolayı tampon bölge analizinde her bir yeşil alanın yarıçapı 200 m, 400 m ve 600 m olarak hesaplanmıştır.

Yeşil alanlara erişim (yürüme) mesafesini Avrupa Çevre Ajansı (European Environment Agency) yaklaşık (maksimum) 1000 m (15 dakikalık yürüme mesafesi), English Nature ise (maksimum) 300 m olarak belirlemiştir (Şenik & Uzun, 2021). Tarsus'ta yeşil alanların erişilebilirliğinin değerlendirilebilmesi için ise yeşil alanlar hedef alan olarak belirlenmiş ve bu hedefe erişimde yürüme mesafesi (5, 10 ve 15 dakika) dikkate alınmıştır. Tarsus'ta yeşil alanların erişilebilirlik derecesi, ArcGIS Pro 3.3.0 yazılımında (ESRI, 2024) network analizlerden biri olan Hizmet Alanı Analizi (service Area) ile belirlenmiştir.

Ağ (Network) analizleri yollar, demiryolları, nehirler, tesisler ve kamu hizmetleri gibi doğrusal ağlarla ilgili bir dizi erişilebilirlik hesaplamasına olanak sağlar (Comber vd., 2008). CBS yazılımlarında sıklıkla kullanılan Ağ (Network) analiz eklentisi, bir şehir genelinde en iyi rotayı bulma, en yakın acil durum aracını veya tesisini bulma, bir konumun etrafındaki bir hizmet alanını belirleme, bir araç filosuyla bir dizi siparişi karşılama veya açılacak veya kapatılacak en iyi tesisleri seçme gibi yaygın ağ sorunlarını çözmeye olanak tanır (ESRI, 2024). Hizmet Alanı Analizi (Service Area) ulaşım ağına dayalı olarak mesafelerin hesaplanmasına olanak sağlar (Stoia vd., 2022). Araştırma kapsamında hizmet alanı analizinde kullanılan veri setinde ikametgâh alanlarından servis alanı olarak belirlenen yeşil alanlara yürüme mesafesinde erişilme süresi hesaplanmıştır. Hizmet alanı analizindeki ilk aşama, yeşil alanlar ve yol veri tabanının işlenmesi olmuştur. Bir ağ analizi gerçekleştirebilmek için ağ veri setine ihtiyaç vardır. Bu çalışmada açık kaynak kodlu veri tabanları istenilen düzeyde sonuç vermemesinden dolayı ArcGIS StreetMap Premium veri tabanı kullanılmıştır. ArcGIS StreetMap Premium, ArcGIS Pro yazılımında kullanılmak üzere zenginleştirilmiş sokak verileri sağlar ve yüksek kaliteli ve çok ölçekli kartografik harita gösterimi; doğru coğrafi kodlama (toplu, ters ve etkileşimli arama); ve optimize edilmiş rota, sürüş talimatları ve ağ analizi sunar (ESRI, 2024).



Şekil 3. Çalışmanın iş akış şeması

3. Bulgular

3.1. Yeşil Alanların Kentiçi Dağılımı ve Yeterliliği

Kentsel yeşil alanların mekânsal dağılımı, etki sahasındaki nüfusun yoğunluğuna, kentsel arazi kullanımına, kentsel işlevlerin dağılımına, kentin mekânsal özelliklerine göre kentten kente ve ülkeden ülkeye değişmektedir (Tablo 4) (Keloğlu & Karabacak, 2020; Özdede vd., 2021; Öztürk, 2013). Türkiye’de yeşil alanların plânlanması yönetmeliklerle belirlenmiştir. 1985 yılı imar plânı yönetmeliğinde kişi başına düşen yeşil alan miktarı 7 m² iken, 1999 yılında 10 m² olarak belirlenmiştir (Özdede vd., 2021). Ancak bu oranlar yeşil alanların işlevsel kullanımından ziyade toplam yeşil alanın kişi başına düşen miktarını yansıtmaktadır.


Tablo 4. Kişi başına düşen yeşil alan miktarının ülkelere göre dağılımı (Keloğlu & Karabacak, 2020; Özdede vd., 2021; Öztürk, 2013)

	Yeşil Kuşak	Kent Parkı	Mahalle ve Semt Parkı	Çocuk Oyun Alanları	Spor Alanları	Toplam
İsveç	48.1	23.8	-	5.6	10	87.5
ABD	60	13-20	3.9	-	-	77-84
İngiltere	8	40	20	-	10	78
İtalya	18	11.6	5.5	3.2	7.5	45.8
Hollanda	30	9	-	-	6.5	45
Polonya	17.5	5.3	15	-	7.5	45.3
Fransa	10	10	4.2	3.5	8	35.7
Türkiye	-	3.5	2	1.5	3	10

Bayındırlık ve İskân Bakanlığı tarafından belirlenen kriterlere göre, kişi başına 10 m² olan yeşil alanlardan kent parklarının oranı çıkarıldığında, kişi başına yeşil alan 6,5 m²’ye düşmektedir (Keloğlu ve Karabacak, 2020). Araştırma kapsamında kişi başına düşen yeşil alan miktarı hesaplamasında mevcut yeşil alanların kullanım durumları dikkate alınarak sınıflandırılmıştır. Tablo 4’te yer alan sınıflamaya göre Tarsus’ta kentsel yeşil kuşak ve kent parkı niteliğine sahip yeşil alan bulunmamaktadır. Bu sebepten dolayı kişi başına düşen yeşil alan miktarı hesaplamasında 6.5 m² kriteri esas alınmıştır.

Türkiye İstatistik Kurumu (TÜİK) Adrese Dayalı Nüfus Kayıt Sitemine (ADNKS) göre 2023 yılında Tarsus ilçe sınırlarında 353.469 kişi yaşamaktadır. Bu nüfusun 177.208’ni erkekler, 176.261 ise kadınlar oluşturmaktadır. Ancak araştırmaya konu olan Tarsus kentsel alanda bulunan 45 mahallenin toplam nüfusu 271.730’dur. 45 mahallenin toplam alanı 41.143.028 m² iken toplam yeşil alan miktarı ise 1.236.540 m²’dir ve kişi başına düşen yeşil alan miktarı 4.55 m²’dir.

Tarsus’ta 2023 yılı toplam nüfusun mahallelere göre dağılışı ve yoğunluğuna bakıldığında en fazla nüfusu bulunan mahalleler kentin kuzey ve kuzeybatısında bulunan Kırklarsırtı (18.562), Altaylılar (17.224), Şehitler Tepesi (13.395), Gazipaşa (12.637), Anıt (12.017) ve Akşemsettin (11.512) mahalleleridir. Nüfusun en az olduğu mahalleler ise kent merkezinde bulunan Şehitkerim (897), Kızılmurat (694) ve Caminur (469) mahalleleridir. Nüfusun en yoğunluğun olduğu mahalleler ise Duatepe (18.597), Anıt (18.141) ve Yeşilyurt (16.629) mahalleleridir. Buna karşılık kentin güney doğusunda yer alan mahalleler düşük yoğunluğa sahip alanlardır (Şekil 4).



Şekil 4. Tarsus'ta nüfusun mahallelere göre dağılımı ve yoğunluğu

Araştırma sahasında yeşil alanların dağılımına bakıldığında (Şekil 5), mahalleler ve nüfusun dikkate alınmadığı görülmektedir. Bu durum Tarsus'ta yeşil alanların mahallelere göre dengeli dağılmadığını gösterir. Tarsus'ta bulunan mahallelerden sadece 5 mahallenin standartlarının üzerinde yeşil alana sahip olduğu tespit edilmiştir. Bu mahalleler sırasıyla Caminur (98.0 m²/kişi), Çağlayan (57.8 m²/kişi), 82 Evler (39.4 m²/kişi) ve Fevzi Çakmak (7.0 m²/kişi) mahalleleridir (Tablo 5, Şekil 4, Şekil 5).

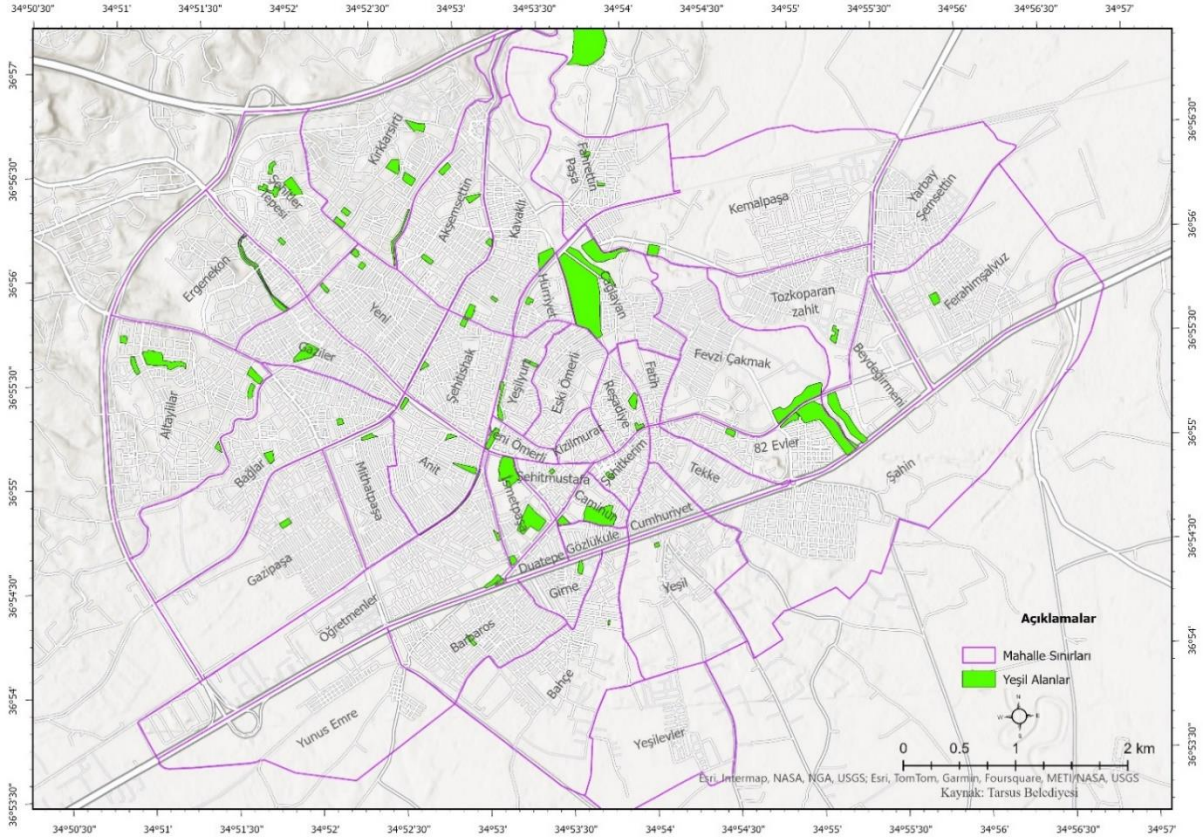
Tablo 5. Mahallelere göre yeşil alan miktarı ve yeterliliği

Mahalle	Toplam Nüfus	Yeşil Alan Sayısı	Büyükölç (m ²)	Kişi Başına Düşen Yeşil Alan Miktarı (m ² /kişi)	10 m ² Standartı	6.5 m ² Standartı
82 Evler	2206	3	86.813	39,4	+	+
Akşemsettin	11843	4	179.44	1,5	-	-
Altaylılar	17224	6	579.41	3,4	-	-
Anıt	12017	4	233.82	1,9	-	-
Bağlar	11439	2	8.880	0,8	-	-
Bahçe	5284	1	6.96	0,1	-	-
Barbaros	10914	1	3.531	0,3	-	-
Beydeğirmeni	900	1	37.492	41,7	+	+
Caminur	469	2	45.957	98,0	+	+
Çağlayan	3766	3	217.658	57,8	+	+
Ergenekon	11563	4	189.44	1,6	-	-
Fahrettin Paşa	5738	3	11.042	1,9	-	-
Fevzi Çakmak	6234	1	43.693	7,0	+	+
Gaziler	6869	1	18.389	2,7	-	-
Gazipaşa	12637	1	4.993	0,4	-	-
Girne	3804	1	4.538	1,2	-	-

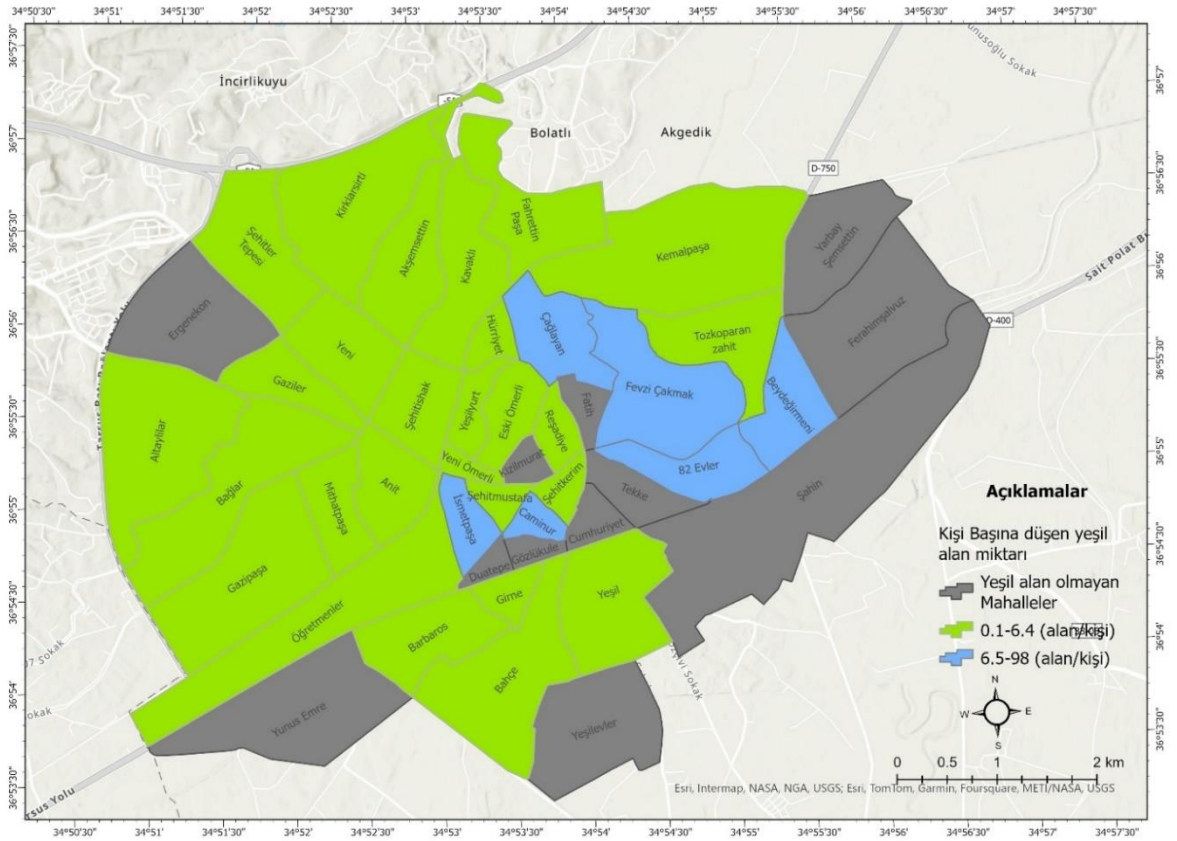
Tablo 5'in devamı

Mahalle	Toplam Nüfus	Yeşil Alan Sayısı	Büyükük (m ²)	Kişi Başına Düşen Yeşil Alan Miktarı (m ² /kişi)	10 m ² Standartı	6.5 m ² Standartı
Hürriyet	2164	1	2.977	1,4	-	-
İsmetpaşa	1217	3	71.510	58,8	+	+
Kavaklı	10544	3	24.216	2,3	-	-
Kemalpaşa	2212	1	8.988	4,1	-	-
Kırklarsırtı	18562	6	44.535	2,4	-	-
Mithatpaşa	7842	1	3.837	0,5	-	-
Öğretmenler	10624	3	10.536	1,0	-	-
Reşadiye	2234	2	10.576	4,7	-	-
Şehitishak	10436	2	5.848	0,6	-	-
Şehitkerim	897	1	2.688	3,0	-	-
Şehitler Tepesi	13395	4	29.531	2,2	-	-
Şehitmustafa	2474	1	1.406	0,6	-	-
Tozkoparan Zahit	7626	1	5.970	0,8	-	-
Yeni	11198	3	9.085	0,8	-	-
Yeni Ömerli	1821	1	9.116	5,0	-	-
Yeşil	2466	1	1.482	0,6	-	-
Yeşilyurt	5044	2	12.044	2,4	-	-

Yeşil alanların mahallelere göre dağılışına bakıldığında, miktar olarak en fazla yeşil alana sahip mahalleler Altaylar (6) ve Kırklarsırtı (6) mahalleleridir (Şekil 5). Bu mahalleler aynı zamanda kentin 2011 yılından sonra gelişen (Gülersoy vd., 2014) ve günümüzde en fazla nüfusa sahip mahalleleridir (Şekil 4). Bu mahallelerde yeşil alan sayısal olarak fazla olsa da toplam kent nüfusunun ~ %13.2'nin iki mahallede yaşamasından dolayı kişi başına düşen yeşil alan miktarı oldukça düşüktür. Buna karşılık kentin güneybatısı, güneyi ve güneydoğusunda bulunan Cumhuriyet, Duatepe, Eski Ömerli, Fatih, Ferahimşalvuz, Gözlükule, Kızılmurat, Şahin, Tekke, Yarbay Şemsettin, Yeşilevler ve Yunus Emre mahallelerinde toplam nüfusun %14'ünü barındırmasına rağmen herhangi bir yeşil alan bulunmamaktadır (Şekil 5). Bu durum yeşil alanlara erişebilirlik ve kullanım düzeyini doğrudan etkilemektedir.




Şekil 5. Tarsus'ta yeşil alanların mekansal dağılışı



Şekil 6. Mahallelere göre yeşil alanların yeterliği ($m^2/nüfus$)

3.2. Yeşil Alanların Erişilebilirliği

Araştırma sahasında bulunan yeşil alanlara erişilebilirliğin ve yeşil alanların etki yarıçapını belirlemede tampon bölge analizi ve hizmet alanı analizlerinden yararlanılmıştır. Bu analizlerden tampon bölge analizi coğrafya çalışmalarında sıklıkla kullanılan bir yöntemdir (Ghodeif vd., 2013; Mallick vd., 2022). Benzer şekilde hizmet alanı analizi de yeşil alanlara erişilebilirlikte en çok tercih edilen yöntemdir (Albalawneh & Mohamed, 2024; Kimpel vd., 2007; Oh & Jeong, 2007; O'Neill vd., 1992). Araştırma sahasında bulunan yeşil alanların etki alanlarının belirlenmesinde 200 m, 400 m ve 600 m yürüme mesafeleri belirlenerek çoklu tampon bölge analizi gerçekleştirilmiştir. Analizlerde kullanılan mesafeler imar plânlarında yürüme mesafesi olarak belirlenen 500 m kriterini kapsayacak şekilde belirlenmiştir. Parkların mevcut büyüklükleri ve kentçi dağılımında plânlama kriterlerinin dikkate alınmamasından dolayı 200 m, 400 m ve 600 m mesafelerine göre analiz yapılmıştır. Elbette bu analizde kentsel form bileşenleri ve topoğrafyanın erişilebilirlik üzerindeki etkisi yok sayılmıştır. Bu analiz modelleme prensibi belirli bir alanın çevresine olan uzaklığını belirleme prensibine dayanmasıdır (Hehai, 1997). Ancak erişilebilirlik tek başına bir parametreye bağlı bir unsur değildir. Burada mekansal özelliklerin yanı sıra bireysel özelliklerde erişilebilirlikte önemli değişkendir. Bu bağlamda kent merkezinde bulunan yeşil alanların erişilebilir konumda olduğu ancak kent çeperlerinde bulunan alanların yeşil alanların erişilebilirliğinin sınırlı olduğu görülmektedir. Özellikle kentin kuzeydoğusu, kuzeyi ve kuzeybatısında bulunan yeşil alanlar 200 m, 400 m ve 600 m yürüme mesafesinde olduğu görülmektedir (Şekil 7). Ancak kentin güneyinde ve doğusunda bulunan kent çeperinde erişilebilirliğin düşük olduğu görülmektedir. Elbette bu durumda etkili olan ana faktör bu mahallelerde mevcut yeşil alanların yetersiz olmasından kaynaklanmaktadır. Özellikle Öğretmenler, Yunusemre, Yeşilevler, Şahin ve Yarbay Şemsettin Mahalleleri yeşil alanlara erişilebilirlik, yeşil alanların fiziksel yeterliliği ve kişi başına düşen yeşil alan miktarı oldukça düşük alanlardır. Bu durumun ana nedeni olarak Tarsus'un diğer Anadolu kentlerine benzer kentleşme süreçlerinden geçmesi ve plânsız kentleşme süreçlerinin bir sonucu olarak değerlendirilebilir.



Şekil 7. Yeşil alanlar tampon bölge analizi (200 m, 400 m, 600 m)

Türkiye’de yeşil alanların yeterliliği üzerine yapılan çalışmalarda kişi başına düşen yeşil alan miktarının mevzuatta belirlenen 10 m²/kişi altında olduğunu ortaya koymuştur (Tablo 6). Özdede vd. (2021) yaptıkları çalışmada, yönetmelikte geçerli olan 10 m²/kişi standardını bile sağlayamayan kentlerin sağlıklı kentsel çevrelerin oluşturulması için oldukça eksik kaldığını ileri sürmüşlerdir. Bu çalışma ile incelenen Tarsus kenti yeşil alanlara ait bulgular; Türkiye’nin diğer kentlerinde olduğu gibi niceliksel standartların oldukça altında olduğunu göstermektedir.

Tablo 6. Son dönemlerde yeşil alanların yeterliliği üzerine yapılan bazı çalışmalarda kişi başına düşen yeşil alan miktarı

Kent	m ² /kişi	Kaynak
Adana (Çukurova ilçesi)	7,47	Adıgüzel ve Doğan (2020)
Antalya	4,2	Manavoğlu ve Ortaçesme (2015)
Aydın	2,36	Uzun ve Tonyaloğlu (2024)
Bingöl	1,55	Vural (2020)
Bingöl	2,47	Caf ve Koç (2024)
Burdur	4,01	Yenice (2012)
Çankırı	4	Koçan ve İbiş (2020)
Diyarbakır	2,42	Kayan ve Biçen (2023)
Isparta	3	Gül ve Küçük (2001)
Kahramanmaraş	1,24	Doygun vd., (2016)
Kastamonu	1,04	Öztürk ve Özdemir (2013)
Kayseri	5,83	Ülger ve Önder (2006).
Niğde	5.3	Gümüş vd., (2024)
Uşak	8,5	Türker ve Gül (2022)

Yeşil alanlar için kişi başı düşen miktarın yanında bir diğer önemli konu da hizmet etkisi bakımından uygun erişim mesafesinde olmalarıdır (Özgeriş, 2023). Erişilebilirlik mekâna ve kişinin yürüme mesafesine bağlı olarak ölçülmektedir (Miller, 2007; Liu vd., 2021). Son dönemlerde yapılan çalışmalarda, yeşil alanlara erişilebilirlikte mesafe temelli erişilebilirlik modelleri kullanılmıştır (Çetin, 2015; Stessens vd., 2017; Fan vd., 2017). Türkiye’de yapılan çalışmaların büyük bir kısmında “Mekânsal Plânlamalar Yönetmeliği’nde” belirlenen 500 m erişim mesafesi kullanılmaktadır. Ancak yer tabanlı bu erişilebilirlik mesafesinde kıstas belirlenirken kentin sosyal, fiziksel ve ekonomik değişkenleri yok sayılmıştır. Araştırma kapsamında yapılan tampon bölge analizinde 200 m, 400 m ve 600 m yarıçapında erişilebilen alanlar analiz edilmiştir. Yapılan araştırmada kent merkezinde bulunan yeşil alanların erişilebilir konumda olduğu ancak kent çeperlerinde bulunan yeşil alanların erişilebilirliğinin sınırlı olduğu tespit edilmiştir. Oysa DSÖ gibi kuruluşlar kent içinde yeşil alanların homojen ve erişilebilir mesafelerde olması gerektiğini önermektedir (World Health Organization, 2016). DSÖ genel bir kural olarak, kentli bireyler evlerinden 300 metre doğrusal mesafe (yaklaşık 5 dakikalık yürüyüş) içinde en az 0,5-1 hektarlık kamusal yeşil alanlara erişebilmeli önerisinde bulunmaktadır. Ancak Türkiye’de yapılan çalışmalarda yeşil alan değerlendirilmesinde kişi başına düşen yeşil alan miktarına odaklanılmıştır. Bu sebeple yaşanabilir, sağlıklı ve kaliteli kentsel mekânların yaratılabilmesi için kentsel planlama ve tasarım çalışmalarında yeşil alanların mahalle, semt ve kent ölçeğinde ve fiziki standartlara göre mekânsal, konumsal ve işlevsel kademelenme içerisinde ele alınması gerekmektedir (Türker & Gül, 2022). Aksi durumlarda kent içinde yeşil alanlar nicelik olarak yeterli, nitelik olarak ise yetersiz olacaktır (Özgeriş, 2023). Bu bağlamda hem politik söylemde hem de uygulamada artan sürdürülebilir dirençli ve yaşanabilir kentler inşa etmenin öncelikli yolu, kentsel yeşil alan miktarının artırılması, kent içindeki mekânsal dağılımları, erişilebilirlik düzeyleri ve fonksiyonel kullanımı ile mümkündür.

Araştırma kapsamında yapılan analizlerde, sağlıklı bir yetişkin için yürüme süresi 5, 10 ve 15 dakika olarak hesaplanmıştır. Mevzuatlarda belirlenen 500 m mesafesinde yürüme hızı ve süresi hesaplamalara dahil edilmemiştir. Oysa her kentin kuruluş yeri ve arazi kullanım tipi birbirinden farklıdır. Bu kapsamda Türkiye’de yapılan hizmet alanı olarak belirlenen yeşil alanlara erişim mesafeleri birbirinden farklıdır. Gümüş vd., (2024) Niğde kentinde yeşil alanların yürüme mesafesinde erişilebilirliğin parkların niteliğine göre değiştiğini tespit etmiştir. Araştırma kapsamında yapılan analizlerde kent merkezinden çeperle doğru gidildiğinde yürüme mesafesinde erişilebilir yeşil alanların yetersiz olduğu tespit edilmiştir.

Sonuç olarak araştırma sahasında nüfusun dağılışı ile yeşil alanların dağılışı benzerlik göstermektedir. Nüfusu en kalabalık mahalleler, aynı zamanda yeşil alan varlığının en yüksek olduğu alanlardır. Bu durumun ana nedeni bu alanların 2010 yılından sonra gelişim göstermesi ve görecelide olsa bir plânlama sürecinin sonucunda ortaya çıkmalarından kaynaklanmaktadır. Ancak bu dönemden önce var olan mevcut mahallelerde arazi kullanımı ve kentsel doku içinde yeşil alan yapımı için uygun alanlar olmamasıdır.

Araştırma kapsamında yeşil alanlara erişilebilirliğin tespitinde CBS teknolojilerinden yararlanılmıştır. Bu kapsamda Tarsus'ta yeşil alanların erişilebilirliğinin analizinde yeşil alanların etki alanları ve bu alanlara yaşam alanlarından yürüme mesafesinde erişilebilirlik düzeyleri hesaplanmıştır. Kent merkezi ve kentin kuzeyinde bulunan mahallerin erişilebilirlik düzeyi yüksek iken kentin güneyinde ve doğusunda bulunan mahallelerin erişilebilirlik düzeyi düşüktür. Yapılan çalışma sonucunda Tarsus'ta mevcut yeşil alanlar nitelik ve nicelik açısından yetersizdir. Bu alanların kent içinde eşit olarak dağılmadığı belirlenmiştir. Gelecekte oluşturulacak kent plânlarında, yeşil alanların mevcut kullanım özelliklerinin yanı sıra sürdürülebilir ve dirençli kent yaklaşımları dikkate alınarak oluşturulması gereklidir. Bu bağlamda kent içinde bulunan yeşil alanların kullanım durumları tespit edilerek gelecek plânlamalarda yeşil alanların niteliksel özellikleri öne çıkarılarak plânlar hazırlanmalıdır. Araştırma bulgularından ve mevcut literatürden yola çıkılarak yapılan analizlerde, yeşil alan plânlamasında şu hususlara dikkat edilmesi önerilmektedir:

- Kentsel yeşil alanlar, komşuluk birimleri dikkate alınarak plânlanmalıdır. Bu kapsamda nüfus yoğunluğu ve yaş gruplarının ihtiyaçları dikkate alınmalıdır. Böylece çocuklar için daha çok oyun alanları ve yetişkinler için dinlenebilecekleri alanlar oluşturulabilir.
- Yeşil alanların yeterlilik tespitinde m²/ kişi hesaplamalarından ziyade kentsel doku içindeki nitelikler dikkate alınarak plânlanabilir.
- Yeşil alanlara erişilebilirlikte yürüme ve bisiklet yolları planlanmalı ve genel ulaşım ağına entegre edilmelidir.
- Yeşil alanların plânlanmasında bireylerin ihtiyaç ve talepleri dikkate alınmalı
- Kentsel yeşil alan plânlanmasında mevcut kentlerin morfolojik özellikleri dikkate alınarak bütüncül bir sistem içinde plânlanmalıdır.
- Yeşil alanlar afet ve acil durumlarda nitelik ve niceliksel olarak halkın temel ihtiyaç ve taleplerine uygun plânlanmalıdır.
- Yeşil alanlar değişen iklim koşullarına uygun plânlanmalıdır.

Kaynaklar

- Adıgüzel, F., & Doğan, M. (2020). Analysis of sufficiency and accessibility of active green areas in Cukurova. *Kastamonu University Journal of Engineering and Sciences*, 6(2), 95–106.
- Adıgüzel, F., Sert, E. B., & Çetin, M. (2022). Kentsel alanda kullanılan zemin malzemelerinden kaynaklanan yüzey sıcaklığı artışının önlenmesinde ağaçların etkisinin belirlenmesi. *Mustafa Kemal Üniversitesi Tarım Bilimleri Dergisi*, 27(1), 18–26. <https://doi.org/10.37908/mkutbd.1024883>
- Albalawneh, D.'a. A., & Mohamed, M. A. (2024). A new federated genetic algorithm-based optimization technique for multi-criteria vehicle route planning using ArcGIS network analyst. *International Journal of Pervasive Computing and Communications*, 20(2), 206–227.
- Alkan, A., Adıgüzel, F., & Kaya, E. (2017). Batman Kentinde Kentsel Isınmanın Azaltılmasında Yeşil Alanların Önemi. *Coğrafya Dergisi*, 34, 62–76.
- Aram, F., García, E. H., Solgi, E., & Mansournia, S. (2019). Urban green space cooling effect in cities. *Heliyon*, 5(4), Article e01339. <https://doi.org/10.1016/j.heliyon.2019.e01339>
- Bertram, C., & Rehdanz, K. (2015). The role of urban green space for human well-being. *Ecological Economics*, 120, 139–152. <https://doi.org/10.1016/j.ecolecon.2015.10.013>
- Boone, C. G., Buckley, G. L., Grove, J. M., & Sister, C. (2009). Parks and People: An Environmental Justice Inquiry in Baltimore, Maryland. *Annals of the Association of American Geographers*, 99(4), 767–787.
- Browning, M., & Lee, K. (2017). Within what distance does “greenness” best predict physical health? A systematic review of articles with GIS buffer analyses across the lifespan. *International Journal of Environmental Research and Public Health*, 14(7), Article 675. <https://doi.org/10.3390/ijerph14070675>
- Caf, A., & Koç, C. (2024). Bingöl kentinde açık ve yeşil alan yeterliliğinin araştırılması. *ISPEC Tarım Bilimleri Dergisi*, 8(1), 183-196.
- Çağlar Uzun, A., & Ersoy Tonyaloğlu, E. (2024). Aydın İli, Efeler İlçesinin Mevcut ve Uygulama İmar Planındaki Kentsel Açık Yeşil Alan Yeterliliğinin Değerlendirilmesi. *Adnan Menderes Üniversitesi Ziraat Fakültesi Dergisi*, 21(1), 53-59. <https://doi.org/10.25308/aduziraat.1429597>
- Cardinali, M., Beenackers, M. A., van Timmeren, A., & Pottgiesser, U. (2024). The relation between proximity to and characteristics of green spaces to physical activity and health: A multi-dimensional sensitivity analysis in four European cities. *Environmental Research*, 241, Article 117605. <https://doi.org/10.1016/j.envres.2023.117605>
- Çetin, M. (2015). Using GIS analysis to assess urban green space in terms of accessibility: case study in Kutahya. *International Journal of Sustainable Development & World Ecology*, 22(5), 420–424.

- Çetin, M., Kaya, A. Y., Elmastas, N., Adiguzel, F., Siyavus, A. E., & Kocan, N. (2023). Assessment of emergency gathering points and temporary shelter areas for disaster resilience in Elazığ, Turkey. *Natural Hazards*, 120(2), 1925–1949. <https://doi.org/10.1007/s11069-023-06271-9>
- Chen, J., & Chang, Z. (2015). Rethinking urban green space accessibility: Evaluating and optimizing public transportation system through social network analysis in megacities. *Landscape and Urban Planning*, 143, 150-159. <https://doi.org/10.1016/j.landurbplan.2015.07.007>
- Coles, R.W., & Bussey, S.C. (2000). Urban forest landscapes in the UK — progressing the social agenda. *Landscape and Urban Planning*, 52(2), 181–188. [https://doi.org/10.1016/S0169-2046\(00\)00132-8](https://doi.org/10.1016/S0169-2046(00)00132-8)
- Comber, A., Brunson, C., & Green, E. (2008). Using a GIS-based network analysis to determine urban greenspace accessibility for different ethnic and religious groups. *Landscape and Urban Planning*, 86(1), 103-114. <https://doi.org/10.1016/j.landurbplan.2008.01.002>
- Cracu, G.-M., Schwab, A., Prefac, Z., Popescu, M., & Sîrodoev, I. (2024). A GIS-based assessment of pedestrian accessibility to urban parks in the city of Constanța, Romania. *Applied Geography*, 165, Article 103229. <https://doi.org/10.1016/j.apgeog.2024.103229>
- Doğanay, H. (1986). Erzurum’da yeşil alan varlığı. *Edebiyat ve Beşeri Bilimler Dergisi*, 15, 43-63.
- Doygun, H., Atmaca, M., & Zengin, M. (2016). Kahramanmaraş’ta kentleşme ve yeşil alan varlığındaki zamansal değişimlerin incelenmesi. *KSÜ Doğa Bilimleri Dergisi*, 18(4), 55-61.
- Eminağaoğlu, Z., & Yavuz, A. (2010, 20-22 Mayıs). *Kentsel yeşil alanların planlanması ve tasarımını etkileyen faktörler: Artvin ili örneği* [Bildiri Sunumu]. III. Ulusal Karadeniz Ormancılık Kongresi, Artvin, Türkiye.
- ESRI. (2024). *Types of network analysis layers*. 7 Ağustos 2024’de <https://pro.arcgis.com/en/pro-app/latest/help/analysis/networks/what-is-network-analyst-.htm> adresinden alındı.
- Fan, P., Xu, L., Yue, W., & Chen, J. (2017). Accessibility of public urban green space in an urban periphery: The case of Shanghai. *Landscape and Urban Planning*, 165, 177-192. <https://doi.org/10.1016/j.landurbplan.2016.11.007>
- Figueiredo, R., Gonçalves, A. B., & Ramos, I. L. (2016). Service areas of local urban green spaces: an explorative approach in Arroios, Lisbon. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4, 111–116. <https://doi.org/10.5194/isprs-annals-IV-4-W1-111-2016>
- Ghodeif, K. O., Arnous, M. O., & Geriesh, M. H. (2013). Define a protected buffer zone for Ismailia Canal, Egypt using Geographic Information Systems. *Arabian Journal of Geosciences*, 6(1), 43–53. <https://doi.org/10.1007/s12517-011-0326-3>
- Giles-Corti, B., Broomhall, M. H., Knuiaman, M., Collins, C., Douglas, K., Ng, K., Lange, A., & Donovan, R. J. (2005). Increasing walking: How important is distance to, attractiveness, and size of public open space? *American Journal of Preventive Medicine*, 28(2), 169–176. <https://doi.org/10.1016/j.amepre.2004.10.018>
- Görün, M., & Kara, M. (2010). Kentsel dönüşüm ve sosyal girişimcilik bağlamında Türkiye’de kentsel yaşam kalitesinin artırılması. *Yönetim Bilimleri Dergisi*, 8(2), 137–164.
- Graça, M., Cruz, S., Monteiro, A., & Neset, T.-S. (2022). Designing urban green spaces for climate adaptation: A critical review of research outputs. *Urban Climate*, 42, Article 101126. <https://doi.org/10.1016/j.uclim.2022.101126>
- Grahn, P., & Stigsdotter, U. A. (2003). Landscape planning and stress. *Urban Forestry & Urban Greening*, 2(1), 1–18. <https://doi.org/10.1078/1618-8667-00019>
- Gül, A., & Küçük, V. (2001). Kentsel açık-yeşil alanlar ve Isparta kenti örneğinde irdelenmesi. *Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi*, 2, 27-48.
- Gül, A., Dinç, G., Akın, T., & Koçak, A. İ. (2020). Kentsel açık ve yeşil alanların mevcut yasal durumu ve uygulamadaki sorunlar. *İdealkent*, 11, 1281-1312.
- Gülersoy, A. E., Çelik, M. A., & Sönmez, M. E. (2014). Tarsus şehrinin alansal gelişimine (1985-2011) ekolojik bakış. *Electronic Turkish Studies*, 9(2), 741-759. <http://dx.doi.org/10.7827/TurkishStudies.6217>
- Gümüş, M. G., Çiftçi, H. Ç., & Gümüş, K. (2024). Buffer ve network analiz teknikleri kullanılarak kentsel aktif yeşil alanlar için mekânsal yeterlilik ve erişilebilirlik analizi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 26(77), 281-290. <https://doi.org/10.21205/deufmd.2024267712>
- Harrison, C., Burgess, J., Millward, A., & Dawe, G. (1995). *Accessible natural greenspace in towns and cities: A review of appropriate size and distance criteria* (Report Number 526). English Nature Research Report. <https://publications.naturalengland.org.uk/file/82004>
- Hazar, D., & Kubat, A. S. (2015). Fringe belts in the process of urban planning and design: Comparative analyses of Istanbul and Barcelona. *A/Z ITU Journal of the Faculty of Architecture*, 12(1), 53–65.
- Hehai, W. (1997). Problem of buffer zone construction in GIS. *Geomatics and Information Science of Wuhan University*, 22(4), 358–365.
- Herzele, A., & Wiedemann, T. (2003). A monitoring tool for the provision of accessible and attractive urban green spaces. *Landscape and Urban Planning*, 63(2), 109–126. [https://doi.org/10.1016/S0169-2046\(02\)00192-5](https://doi.org/10.1016/S0169-2046(02)00192-5)

- Kayan, H. D., & Biçen, A. (2023). Diyarbakır kent merkezinin aktif açık-yeşil alanlarının yeterliliğine yönelik bir değerlendirme. *GRID-Mimarlık Planlama ve Tasarım Dergisi*, 6(2), 411-441.
- Keloğlu, E., & Karabacak, K. (2020). Ankara İli Keçiören İlçesi'nde açık yeşil alanlarının değerlendirilmesi. *Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi*, 60(2), 776-802.
- Kimpel, T. J., Dueker, K. J., & El-Geneidy, A. M. (2007). Using GIS to measure the effect of overlapping service areas on passenger boardings at bus stops. *URISA Journal*, 19(1), 5-11.
- Koçan, N., & İbiş, Ş. (2020). Çankırı ili kentsel açık yeşil alan varlığının belirlenmesi ve geliştirilmesi üzerine bir araştırma. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 10(2), 154-163.
- Kronenberg, J., Haase, A., Łaszkiwicz, E., Antal, A., Baravikova, A., Biernacka, M., Dushkova, D., Filčak, R., Haase, D., Ignatieva, M., Khmara, Y., Niță, M. R., & Onose, D. A. (2020). Environmental justice in the context of urban green space availability, accessibility, and attractiveness in postsocialist cities. *Cities*, 106, Article 102862. <https://doi.org/10.1016/j.cities.2020.102862>
- Kropf, K. (2005). The handling characteristics of urban form. *Urban Design*, 93(93), 17-18.
- Kwon, O.-H., Hong, I., Yang, J., Wohn, D. Y., Jung, W.-S., & Cha, M. (2021). Urban green space and happiness in developed countries. *EPJ Data Science*, 10(1), Article 28. <https://doi.org/10.1140/epjds/s13688-021-00278-7>
- Li, J., Zhang, Z., Jing, F., Gao, J., Ma, J., Shao, G., & Noel, S. (2020). An evaluation of urban green space in Shanghai, China, using eye tracking. *Urban Forestry & Urban Greening*, 56, Article 126903. <https://doi.org/10.1016/j.ufug.2020.126903>
- Liang, H., Yan, Q., & Yan, Y. (2024). A novel spatiotemporal framework for accessing green space accessibility change in adequacy and equity: Evidence from a rapidly urbanizing Chinese City in 2012-2021. *Cities*, 151, Article 105112. <https://doi.org/10.1016/j.cities.2024.105112>
- Liu, D., Kwan, M. P., & Kan, Z. (2021). Analysis of urban green space accessibility and distribution inequity in the City of Chicago. *Urban Forestry & Urban Greening*, 59, Article 127029. <https://doi.org/10.1016/j.ufug.2021.127029>
- Liu, Y., Meng, Q., Zhang, J., Zhang, L., Jancso, T., & Vatsava, R. (2016). An effective Building Neighborhood Green Index model for measuring urban green space. *International Journal of Digital Earth*, 9(4), 387-409.
- Mallick, J., Ibnatiq, A. A., Kahla, N. B., Alqadhi, S., Singh, V. P., Hoa, P. V., Hang, H. T., van Hong, N., & Le, H. A. (2022). Gis-Based Decision Support System for Safe and Sustainable Building Construction Site in a Mountainous Region. *Sustainability*, 14(2), Article 888. <https://doi.org/10.3390/su14020888>
- Manavoğlu, E., & Ortaçşme, V. (2015). Antalya kenti yeşil alanlarının çok ölçütlü analizi ve planlama stratejilerinin geliştirilmesi. *Mediterranean Agricultural Sciences*, 28(1), 11-19.
- Margaritis, E., & Kang, J. (2016). Relationship between urban green spaces and other features of urban morphology with traffic noise distribution. *Urban Forestry & Urban Greening*, 15, 174-185.
- Mekânsal Planlar Yapım Yönetmeliği (2014, 14 Haziran). *Resmi Gazete* (Sayı: 29030). Erişim adresi: <https://www.resmigazete.gov.tr/eskiler/2014/06/20140614-2.htm>
- Miller, H. (2007). Place-based versus people-based geographic information science. *Geography Compass*, 1(3), 503-535. <https://doi.org/10.1111/j.1749-8198.2007.00025.x>
- Nero, B. F., Callo-Concha, D., Anning, A., & Denich, M. (2017). Urban Green Spaces Enhance Climate Change Mitigation in Cities of the Global South: The Case of Kumasi, Ghana. *Procedia Engineering*, 198, 69-83. <https://doi.org/10.1016/j.proeng.2017.07.074>
- Nielsen, T. S., & Hansen, K. B. (2007). Do green areas affect health? Results from a Danish survey on the use of green areas and health indicators. *Health & Place*, 13(4), 839-850. <https://doi.org/10.1016/j.healthplace.2007.02.001>
- Oh, K., & Jeong, S. (2007). Assessing the spatial distribution of urban parks using GIS. *Landscape and Urban Planning*, 82(1-2), 25-32. <https://doi.org/10.1016/j.landurbplan.2007.01.014>
- O'Neill, W. A., Ramsey, R. D., & Chou, J. (1992). Analysis of transit service areas using geographic information systems. *Transportation Research Record*, 1364, 131-138.
- Özdede, S., Aygün, A., & Hazar Kalonya, D. (2021). Pandemi sonrası dönemde kişi başına düşen kentsel yeşil alan ihtiyacını yeniden düşünmek. *İdealkent*, 12, 362-388. <https://doi.org/10.31198/idealkent.843386>
- Özdemir, Z., & Özkaynak, M. (2023). Kentsel Yeşil Alanları Sürdürülebilir Kentleşme Üzerinden Okumak: Amasya Kenti Örneği. *Çevre, Şehir ve İklim Dergisi*, 2(3), 270-292.
- Özgeriş, M. (2023). Aktif yeşil alanların niceliksel ve niteliksel analizi: Erzurum Adnan Menderes Mahallesi Örneği. *JENAS Journal of Environmental and Natural Studies*, 5(1), 68-84. <https://doi.org/10.53472/jenas.1250924>
- Öztürk, S. (2013). Kentsel açık ve yeşil alanların yaşam kalitesine etkisi "Kastamonu Örneği". *Kastamonu University Journal of Forestry Faculty*, 13(1), 109-116.
- Şenik, B., & Uzun, O. (2021). Açık yeşil alan sistemi planlanma ve tasarım süreçlerinde millet bahçelerinin rolü. *Planlama*, 31(3), 378-392.

- Shan, L., Fan, Z., & He, S. (2024). Towards a better understanding of capitalization of urban greening: Examining the interactive relationship between public and club green space accessibility. *Urban Forestry & Urban Greening*, 96, Article 128359. <https://doi.org/10.1016/j.ufug.2024.128359>
- Stähle, A. (2010). More green space in a denser city: Critical relations between user experience and urban form. *Urban Design International*, 15, 47-67. <https://doi.org/10.1057/udi.2009.27>
- Stanford, H. R., Hurley, J., Garrard, G. E., & Kirk, H. (2024). Finding the forgotten spaces: Using a social-ecological framework to map informal green space in Melbourne, Australia. *Land Use Policy*, 141, Article 107114. <https://doi.org/10.1016/j.landusepol.2024.107114>
- Stanners, D. A., & Bourdeau, P. (1995). *Europe's Environment: The Dobriř Assessment*. Office for Official Publications of the European Communities.
- Stessens, P., Khan, A. Z., Huysmans, M., & Canters, F. (2017). Analysing urban green space accessibility and quality: A GIS-based model as spatial decision support for urban ecosystem services in Brussels. *Ecosystem services*, 28, 328-340.
- Stoia, N. L., Niță, M. R., Popa, A. M., & Iojă, I. C. (2022). The green walk—An analysis for evaluating the accessibility of urban green spaces. *Urban Forestry & Urban Greening*, 75, Article 127685. <https://doi.org/10.1016/j.ufug.2022.127685>
- Tango, U., & Topçu, M. (2021). Kentsel donatı alanlarının erişilebilirlik analizi: Mardin Kızıltepe örneği. *Türkiye Coğrafi Bilgi Sistemleri Dergisi*, 3(2), 104–115.
- Taşkaya, S., & Ulutaş, N. (2021). CBS ile yatırıma en uygun restoran alanlarının belirlenmesi, Tunceli örneği. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 4(2), 134-141.
- Tian, D., Wang, J., Xia, C., Zhang, J., Zhou, J., Tian, Z., Zhao, J., Li, B., & Zhou, C. (2024). The relationship between green space accessibility by multiple travel modes and housing prices: A case study of Beijing. *Cities*, 145, Article 104694. <https://doi.org/10.1016/j.cities.2023.104694>
- Türker, H. B., & Gül, A. (2022). Kentsel açık ve yeşil alanlarının niceliksel analizi ve irdelenmesi: Uşak kent merkezi örneği. *Kent Akademisi*, 15(4), 2088-2109. <https://doi.org/10.35674/kent.999451>
- Tüter, R., Ökesli, D.S. (2015). Geleneksel Kent Merkezi Çeperinde Dönüşüm-Tarsus Örneği. In T. Ünlü (Ed.), *Türkiye Kentsel Morfoloji Sempozyumu* (ss. 247–263). Türkiye Kentsel Morfoloji Ağı.
- Ülger, F.N., & Önder, S. (2006). Kayseri kenti açık-yeşil alanlarının nitelik ve nicelik açısından irdelenmesi. *Selçuk Tarım ve Gıda Bilimleri Dergisi*, 20(38), 108-118.
- Uzun, A., & Tonyaloğlu, E. (2024). Aydın İli, Efeler İlçesinin Mevcut ve Uygulama İmar Planındaki Kentsel Açık Yeşil Alan Yeterliliğinin Değerlendirilmesi. *Adnan Menderes Üniversitesi Ziraat Fakültesi Dergisi*, 21(1), 53-59. <https://doi.org/10.25308/aduziraat.1429597>
- Vural, E. (2024). Şanlıurfa Merkez İlçelerinde İtfaiye İstasyonlarının Coğrafi Bilgi Sistemleri ile Erişilebilirlik Analizi. *Kent Akademisi*, 17(3), 852-866. <https://doi.org/10.35674/kent.1437424>
- Vural, H. (2020). Bingöl halkının yeşil alan kullanımı ve kent parkları yeterliliklerinin değerlendirilmesi. *Bartın Orman Fakültesi Dergisi*, 22(1), 79-90. <https://doi.org/10.24011/barofd.671442>
- Whitehand, J. W. R. (1988). Urban fringe belts: development of an idea. *Planning Perspectives*, 3(1), 47–58. <https://doi.org/10.1080/02665438808725651>
- World Health Organization. (2012). *Health Indicators of Sustainable Cities in the Context of the Rio+20 UN Conference on Sustainable Development*. https://cdn.who.int/media/docs/default-source/environment-climate-change-and-health/sustainable-development-indicator-cities.pdf?sfvrsn=c005156b_2
- World Health Organization. (2016). *Urban green spaces and health*. <https://iris.who.int/handle/10665/345751>
- Wright Wendel, H. E., Zarger, R. K., & Mihelcic, J. R. (2012). Accessibility and usability: Green space preferences, perceptions, and barriers in a rapidly urbanizing city in Latin America. *Landscape and Urban Planning*, 107(3), 272–282. <https://doi.org/10.1016/j.landurbplan.2012.06.003>
- Yang, Z., Fang, H., Wei, G., Mo, J., Gao, X., & Zhang, S. (2024). An assessment of urban park accessibility using multi-source data in Hefei, China: A social equity perspective. *Land Degradation & Development*, 35(11), 3627-3641.
- Yenice, M. S. (2012). Kentsel yeşil alanlar için mekansal yeterlilik ve erişilebilirlik analizi; Burdur örneği, Türkiye. *Turkish Journal of Forestry*, 13(1), 41-47. <https://doi.org/10.18182/tjf.74804>
- Zhang, J., Yue, W., Fan, P., & Gao, J. (2021). Measuring the accessibility of public green spaces in urban areas using web map services. *Applied Geography*, 126, Article 102381. <https://doi.org/10.1016/j.apgeog.2020.102381>
- Zhang, Q., Du, Z., Li, L., Zhao, Z., Liang, J., & Li, H. (2024). Urbanized and climatic influences on vegetation changes of urban green space under the increase of atmospheric NOX: A case study in Tianjin. *Ecological Indicators*, 165, Article 112222. <https://doi.org/10.1016/j.ecolind.2024.112222>
- Zhang, X., Lu, H., & Holt, J. B. (2011). Modeling spatial accessibility to parks: A national study. *International Journal of Health Geographics*, 10(1), Article 31. <https://doi.org/10.1186/1476-072X-10-31>

Kentsel Heyelanlara Bir Örnek: Alkaya Heyelanı (Tekirdağ)

An Example to the Urban Landslides: Alkaya Landslide (Tekirdağ)

Emre Özşahin^{1*}, Mikayil Öztürk²

¹Tekirdağ Namık Kemal Üniversitesi, Fen Edebiyat Fakültesi, Coğrafya Bölümü, 59030, Tekirdağ/Türkiye.

²Tekirdağ Namık Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Toprak Bilimi ve Bitki Besleme Bölümü, 59030, Tekirdağ /Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Emre Özşahin
eozsahin@nku.edu.tr

doi: 10.48123/rsgis.1530698

Yayın süreci

Geliş tarihi: 09.08.2024
Kabul tarihi: 04.09.2024
Basım tarihi: 26.09.2024

Özet

Bu çalışmada Tekirdağ kentinde 16.12.2023 tarihinde meydana gelmiş Alkaya heyelanının oluşum özelliklerinin ve mekanizmasının yerbilimsel perspektiften ele alınması amaçlanmıştır. Böylece Tekirdağ kentinde gelecekte meydana gelme olasılığı yüksek diğer kentsel heyelanların potansiyel lokasyon özelliklerinin tahminlerine yönelik çıkarımlarda bulunulması hedeflenmiştir. Çalışma verileri, arazi çalışmaları ve İnsansız Hava Aracı (İHA) tabanlı Uzaktan Algılama (UA) tekniklerinden yararlanılarak üretilmiştir. Bunun için Phantom 4 marka otonom bir İHA sistemi kullanılarak kentsel heyelanın dijital hava fotoğrafları çekilmiştir. Elde edilen veriler bilgisayarda Pix4D yazılımıyla işlenmiş ve sahanın Sayısal Yükseklik Modeli (SYM) ve orto-foto görüntüleri üretilmiştir. Bu görüntüler uzman görüşüne bağlı doğrudan haritalama yöntemi kullanılarak amaç doğrultusunda analiz edilmiştir. Bunun yanında bir taraftan da heyelan oluşumunda etkili rol oynayan faktörlere ait diğer veriler toplanmıştır. Çalışmanın tematik haritaları, Coğrafi Bilgi Sistemleri (CBS) yazılımlarından biri olan ArcGIS Pro (Version 3.0.1) paket programı kullanılarak hazırlanmıştır. Çalışma sonucunda Tekirdağ kentindeki Alkaya heyelanının hazırlayıcı (litoloji, eğim ve yerçekilleri) koşullar ve tetikleyici (yağış ve insan etkinlikleri) faktörlerin denetimi altında meydana geldiği anlaşılmıştır. Bu çalışmanın sonuçları, Tekirdağ kenti özelinde hazırlanacak heyelan risk değerlendirme çalışmalarına önemli katkılar sağlayabilir.

Anahtar kelimeler: Kentsel heyelan, İHA, UA, CBS, Tekirdağ

Abstract

In this study, it is aimed to investigate the formation features and mechanism of the Alkaya landslide that occurred on 16.12.2023 in Tekirdağ city from a geoscientific perspective. Thus, it is aimed to make inferences for the prediction of the potential location characteristics of other urban landslides that are likely to occur in Tekirdağ city in the future. The study data were generated by utilizing field studies and Unmanned Aerial Vehicle (UAV) based Remote Sensing (RS) techniques. For this purpose, digital aerial photographs of the urban landslide were taken using an autonomous Phantom 4 UAV system. The data obtained were processed on the computer with Pix4D software and Digital Elevation Model (DEM) and ortho-photo images of the site were produced. These images were analyzed for the purpose by using direct mapping method based on expert opinion. In addition, other data on the factors that play an effective role in landslide formation were collected. The thematic maps of the study were prepared using ArcGIS Pro (Version 3.0.1) package Systems (GIS) software. As a result of the study, it was understood that the Alkaya landslide in Tekirdağ city occurred under the control of predisposing (lithology, slope and landforms) conditions and triggering (precipitation and human activities) factors. The results of this study can provide important contributions to landslide risk assessment studies to be prepared for Tekirdağ city.

Keywords: Urban landslide, UAV, RS, GIS, Tekirdağ

1. Giriş

Hızlı nüfus artışının bir sonucu olarak kentsel alanlarda zamansal süreçte mekânsal koşullar yetersiz kalmıştır. Bu durum çevresine doğru kontrolsüz bir şekilde büyüyen kentlerde altyapı sorunlarına yol açmasının yanında kentsel gelişim sürecinin temel bileşenlerinden birisi olarak kabul edilen jeomorfolojik özelliklerle ilişkili bazı problemlerin de ortaya çıkmasına sebep olmuştur (Uludağ & Özşahin, 2023). Böylece kentler, jeomorfolojik kökenli doğal afetlerin daha yaygın bir şekilde yaşandığı, düzensiz ve sağlıksız mekânlara dönüşmüştür (Özşahin, 2015a).

Kentsel alanlarda doğal güzellikleri ve manzarası nedeniyle insanlar tarafından daha fazla tercih edilen alanların başında yamaçlar gelmektedir (Olshansky, 1996). Hatta yakın zamanda kentsel alanlardaki yamaçlarda kentsel genişlemenin daha fazla artacağı tahmin edilmektedir (Schuster & Highland, 2007). Ancak kentsel alanlardaki yamaçlarda görülen bu yerleşme baskısı, heyelan başta olmak üzere çeşitli türden kütle hareketlerinin daha fazla oluşma tehlikesinin de artmasına sebep olmaktadır. Nitekim kentsel alanlardaki heyelanların tüm kütle hareketleri arasında en tehdit edici jeomorfolojik tehlikelerden biri olduğu belirtilmiştir (Petley, 2009). Bundan dolayı kentsel alanlarda görülen heyelanlar ayrı bir fenomen olarak görülmüş ve kentsel heyelan (urban landslide) şeklinde tanımlanmıştır (Alexander, 1989).

Kentsel heyelanlar, özellikle konut ve/veya diğer kentsel büyüme alanlarında çoğu zaman doğal olarak meydana gelen süreçler (şiddetli yağışlar gibi) ve antropojenik faaliyetler tarafından tetiklenen çevresel ve sosyo-ekonomik kayıplara neden olan jeomorfolojik tehlikelerden birisidir (Özşahin, 2014a; 2015a). Ancak şaşırtıcı bir şekilde özellikle Türkiye'deki diğer ortamlarda meydana gelen heyelanlarla karşılaştırıldığında kentsel heyelanların araştırılmasına yönelik çok daha az çalışma yapılmıştır (Akıncı vd., 2010; 2015; Alptekin & Yakar, 2020; Çakıcı vd., 2012; Görüm & Nefeslioğlu, 2015; Nefeslioğlu vd., 2010;). Bu durum literatürde önemli bir boşluk oluşturmaktadır.

Son yıllarda, İnsansız Hava Araçları (İHA) tabanlı Uzaktan Algılama (UA) ve Coğrafi Bilgi Sistemleri (CBS) teknikleri kullanılarak kentsel heyelanların incelenmesine yönelik bilimsel çalışmaların sayısı artmıştır (Eker vd., 2018). Zira bu tür çalışmalar, yüksek mekânsal ve zamansal çözünürlük, yüksek verimlilik ve düşük maliyet gibi heyelan topografyası modellemesine katkıda bulunan avantajlara sahiptir (Yu vd., 2017). Dolayısıyla düşük maliyetli ve yüksek doğrulukta verimli ve hassas veri toplamak için yaygın bir şekilde kullanılan İHA tabanlı UA ve CBS teknikleri, kentsel heyelan araştırmalarının da ayrılmaz bir parçası haline gelmiştir (Karantanellis vd., 2020; Turner vd., 2015).

Türkiye'de kentsel heyelanların görüldüğü yerlerden birisi de Tekirdağ kentidir (Özşahin, 2015b). Tekirdağ kentsel alanında doğal faktörlerin heyelana elverişli olduğu yerlerde antropojenik faaliyetler sonucunda meydana gelen fosil ve aktif heyelanlar görülmektedir (Kayran, 2006). Hatta buna dikkat çekmek için bazı bilimsel çalışmalar gerçekleştirilmiştir (Aral & Avcıyener, 2011; Özşahin, 2014a; 2015b). Ancak bu bilimsel çalışmaların sonuçları yeterince dikkate alınmamıştır. Zira 16.12.2023 tarihinde Tekirdağ kentsel alanındaki Alkaya mevkinde yeni bir kentsel heyelan meydana gelmiştir.

Bu çalışmada Tekirdağ kentinde 16.12.2023 tarihinde meydana gelmiş Alkaya heyelanının oluşum özelliklerinin ve mekanizmasının yerbilimsel perspektiften ele alınması amaçlanmıştır. Böylece Tekirdağ kentinde gelecekte meydana gelme olasılığı yüksek diğer kentsel heyelanların potansiyel yayılış alanlarının tahminine yönelik çıkarımlarda bulunulması hedeflenmiştir. Çalışma kentsel heyelanların incelenmesine yönelik küçük ölçekli bir perspektif model sunması bakımından önemlidir.

2. Materyal ve Yöntem

2.1. İnceleme Alanı

İnceleme alanı, Marmara Denizi'ne kıyısı olan koy şeklinde gelişmiş bir kıyının etrafında hilal biçiminde uzanan Tekirdağ kentidir (Şekil 1). İdari yönden Süleymanpaşa ilçesinin merkezini oluşturan Tekirdağ kenti 18 farklı kentsel mahalleden oluşmaktadır (Şekil 1). Kentsel heyelan, inceleme alanının Cumhuriyet Mahallesi'nin Süleymanpaşa Alkaya Paşa sahilinin kıyı gerisindeki yamaç arazide meydana gelmiştir (Şekil 1).

İnceleme alanında, Paleojen'den günümüze kadar çeşitli yaş ve türde jeolojik birimler bulunmaktadır. Ancak en geniş alanda heyelana karşı yüksek duyarlı bir özellik gösteren Orta-Üst Oligosen'e ait litolojik birimler yayılış göstermektedir. Danişmen Formasyonu olarak adlandırılan bu birimler, kıyı kesimlerde kıltaşı, kara yönüne doğru ilerledikçe sırasıyla kumtaşı ve silttaşı geçişinin görüldüğü litolojilerle karakterize edilmektedir (Kayran, 2006). İnceleme alanındaki kentsel heyelan ilgili jeolojik birimin yayılış alanında kalmaktadır. Bunun dışındaki diğer jeolojik birimler ise yaşlıdan gence doğru sırasıyla; Orta-Üst Miyosen'e ait killi-ince çakıllı kum ara seviyeli siltli kil (Ergene Formasyonu), Üst Miyosen-Pliyosen'e ait çakıl ve kil ara seviyeli siltli kil (Trakya Formasyonu), Kuvaterner'e ait alüvyon, Holosen'e ait kıyı çökelleri ve güncel dolgu yüzeyleridir (Kayran, 2006). Aktif tektonik etkinin yüksek olduğu inceleme alanı, Kuzey Anadolu Fay Zonu (KAFZ)'nin hemen kuzeyinde konumlanmaktadır. Marmara Denizi içerisinden geçen bu zon, inceleme alanına 10-20 km uzaklıktadır.



Şekil 1. İnceleme alanının lokasyon haritası (ArcGIS Pro kullanılarak erişilebilen altlık haritalar ESRI tarafından sağlanmıştır)

İnceleme alanı Pliosen yaşlı aşınım yüzeyi şeklinde gelişmiş bir platoya karşılık gelmektedir. Flüvyal süreçlerin ve kıyı dinamiklerinin etkisiyle şekillenen bu plato, eğimi %10'un üzerinde olan yamaçlarla karakterize edilmektedir. İnceleme alanındaki kentsel heyelan da bu tür bir yamaçta meydana gelmiştir. Ayrıca inceleme alanı ve yakın çevresinde vadi, falez, denizel taraça, alüvyal vadi tabanı ve delta gibi farklı elemanter yerşekilleri de gözlenmektedir (Özşahin, 2014a).

Tekirdağ Meteoroloji İstasyonu tarafından tutulan uzun süreli (Ölçüm periyodu: 1940 - 2023) rasat kayıtlarına göre inceleme alanında yıllık ortalama sıcaklık 14,1 °C ve yıllık toplam yağış ise 580,0 mm'dir (Meteoroloji Genel Müdürlüğü, 2024a). Buna göre Akdeniz ikliminin etki alanında yer almasına rağmen yaz kuraklığının Akdeniz iklimindeki kadar hissedilmediği inceleme alanında, Yarı Nemli Marmara (Geçiş) iklim koşulları hakimdir (Özşahin, 2015b).

İnceleme alanında farklı toprak özellikleri görülmektedir. Buna bağlı olarak katenasal ilişki içinde farklı toprak tipleri oluşmuştur. İnceleme alanında Toprak Taksonomisi sınıflandırmasına (U.S. Department of Agriculture, 1975) göre Entisol, Alfisol, İnceptisol ve Mollisol olmak üzere 4 toprak ordosu teşhis edilmiştir (Özşahin, 2015c). Ancak inceleme alanındaki kentsel heyelanın gerçekleştiği sahada İnceptisol ordosuna ait toprak türü bulunmaktadır. Gelişiminin başlangıç aşamasında olan bu toprak türü daha çok killi ana materyal üzerinde oluştuğu için heyelana duyarlı bir karakter göstermektedir (Özşahin, 2014b).


İnceleme alanı yoğun insan etkisine maruz kalan bir yerleşim alanına karşılık gelmektedir. Bu bakımdan çeşitli türden yerleşme faaliyetlerinin izlendiği bu sahada tarım, orman ve mera gibi arazi kullanım türleri de bulunmaktadır (ESRI, 2023). İnceleme alanındaki kentsel heyelan, kentsel yerleşim alanı içerisindeki rekreasyon faaliyetlerine yönelik düzenlenmiş bir sahada meydana gelmiştir.

Daha önce Tekirdağ kentinde, kentsel gelişime bağlı olarak (Özşahin, 2015d) jeomorfolojik bakımdan uygun alanlarda antropojenik faaliyetlerin tetiklenmesiyle heyelan oluşumlarının varlığı gözlemlenmiştir (Özşahin, 2014a).

Hatta meydana gelebilecek olası kentsel heyelanların oluşturacağı zararların azaltılmasına yönelik planlama çalışmalarında rehber olması için kentsel alanın heyelan duyarlılık haritası bile üretilmiştir (Özşahin, 2015b). Ancak karar vericiler tarafından Tekirdağ kentsel alanında meydana gelebilecek potansiyel heyelanların önlenmesine yönelik günümüze kadar hala kayda değer bir çalışma yapılmamıştır. Bu durum Alkaya heyelanının oluşumunu da hızlandırmıştır.

2.2. Yöntem

Bu çalışmanın verileri, arazi çalışmaları ve İHA tabanlı UA tekniklerinden yararlanılarak üretilmiştir (Şekil 2). Bunun için ilk aşamada sahaya intikal edilmiş ve inceleme alanının Phantom 4 marka (Araç numarası: TR-IHA0H5909136) otonom bir İHA sistemi kullanılarak dijital hava fotoğrafları çekilmiştir. Görüntülerin çekimi 10 m yükseklikten sırasıyla %80 enine ve %75 boyuna bindirme oranları kullanılarak gerçekleştirilmiştir. Aynı arazi çalışmaları sırasında yerden ve havadan fotoğraf çekimleri yapılmış, 8 adet Yer Kontrol Noktası (YKN) alınmış ve heyelanın bazı yerlerinden derinlik ölçümleri gerçekleştirilmiştir. İHA ile elde edilen görüntüler bilgisayarda Pix4D yazılımıyla işlenmiş ve sahanın 0,814 cm/piksel çözünürlüğünde sayısal yükseklik modeli (SYM) ve orto-foto görüntüleri üretilmiştir. Bu görüntüler ve ilgili yazılım kullanılarak heyelanın yüzey alanı ve hacmi de hesaplanmıştır. Ayrıca inceleme alanındaki kentsel heyelanı oluşturan malzemenin mühendislik özelliklerine ait veriler ise literatürden derlenmiştir (Aral & Avcıyener, 2011; Çağlı Mühendislik, 2011).



Şekil 2. Çalışma yönteminin iş akış şeması

Kentsel heyelanın hazırlayıcı (litoloji, eğim ve yerşekli) koşulları ve tetikleyici (yağış ve insan etkinlikleri) faktörleri farklı kaynaklardan elde edilen verilerle açıklanmıştır. Litolojik özellikler, Kayran (2006) tarafından hazırlanan Tekirdağ Belediyesi Kent ve Mücavir Alanının Revizyon İmar Planı Yerleşime Uygunluk Amaçlı Etüt Raporunun ekinde sunulan 1/12.000 ölçekli jeoloji haritasından tedarik edilmiştir. Eğim özellikleri, İHA tabanlı uzaktan algılamayla üretilmiş SYM görüntüsünün CBS yazımında işlenmesiyle yüzde (%) olarak belirlenmiştir. Yerşekli özellikleri, SYM ve orto-foto görüntülerinin uzman görüşüne bağlı doğrudan haritalama yöntemi kullanılarak amaç doğrultusunda analiz edilmesiyle tespit edilmiştir (Görüm ve Nefeslioğlu, 2015). Yağış, Meteoroloji Genel Müdürlüğü bünyesinde hizmet eden Tekirdağ Meteoroloji İstasyonuna ait hem uzun süreli (Ölçüm Periyodu:1940-2023) aylık ortalama yağış (Meteoroloji Genel Müdürlüğü, 2024a) hem de 2023 yılının aralık ayına ait günlük yağış verileri kullanılarak açıklanmıştır (Meteoroloji Genel Müdürlüğü, 2024b).

İnsan etkinlikleri arazi çalışmalarıyla elde edilen verilerle saptanmıştır. Çalışmanın tematik haritaları, CBS yazılımlarından biri olan ArcGIS Pro (Version 3.0.1) paket programı kullanılarak hazırlanmıştır.


3. Bulgular

İnceleme alanındaki kentsel heyelan 16.12.2023 tarihinde meydana gelmiştir. Sadece maddi hasara yol açan bu doğal afet, çok sığ (yüzeysel) ve dairesel (dönel) kayma şeklinde gelişmiştir (Şekil 3). Aral ve Avcıyener (2011) Tekirdağ kentindeki heyelanların kayma yüzeyi derinliğinin oldukça sığ olduğu ve eğimin arttığı yerlerde ikincil kaymalar geliştiği için "eğim yukarı doğru gerileyen birleşik heyelan sistemi" olarak tanımlayabileceğini rapor etmişlerdir.




Şekil 3. İnceleme alanındaki Alkaya heyelanının orto-foto görüntüsü

Kentsel heyelanın uzunluğu 26,73 m, taç kısmındaki en geniş yeri 26,52 m, ana ayna uzunluğu ise 42,34 m'dir. Taç kısmında çökmenin maksimum değeri 4 m olup, çöken kısım güneydoğuya doğru ötelenmiştir. Heyelan esnasında ve sonrasında meydana gelmiş enine ve boyuna gerilme çatlakları ise heyelanın kuzey ve güney yönünde genişleme eğiliminde olduğunu göstermektedir (Şekil 4; 5, 6). Yükselti değeri heyelanın taç kısmında 20 m iken, topuk kısmında 11 m'dir. Yüzey alanı 1109,44 m² olan heyelanın hacmi ise 284,95 m³ olarak hesaplanmıştır. Kentsel heyelanın yüzey alanı SYM verisinin işlenmesiyle, hacmi ise yüzey alanının ortalama derinlikle çarpılmasıyla elde edilmiştir.



Şekil 4. İnceleme alanındaki heyelanın jeomorfolojik özellikleri ve kentsel arazi kullanım haritası



Şekil 5. Alkaya heyelanının şematik enine kesiti



Şekil 6. Alkaya heyelanının havadan görünümü


İnceleme alanındaki kentsel heyelan, hazırlayıcı (litoloji, eğim ve yerçekli) koşullar ve tetikleyici (yağış ve insan etkinlikleri) faktörlerin denetiminde meydana gelmiştir. Bu bakımdan kentsel heyelan litoloji ve eğim özelliklerinin uygun olduğu Alkaya sahilindeki yamaç arazide, şiddetli yağış ve yamacın amaç dışı kullanılmasına bağlı yanlış arazi kullanımının etkisiyle gerçekleşmiştir. Görüm ve Nefeslioğlu (2015) inceleme alanının bulunduğu bölgedeki kentsel heyelanların en büyük hazırlayıcı ve tetikleyici faktörünün ani yağışlar olduğunu belirterek, yoğun nüfus artışı ve yanlış arazi kullanımları sonucu zarar görübilirlik oranının giderek yükseldiğini vurgulamışlardır (Görüm & Nefeslioğlu, 2015).

İnceleme alanındaki kentsel heyelanı hazırlayıcı öncelikli faktör litolojik özelliklerdir. Alkaya heyelanının Orta-Üst Oligosen'e ait silttaşı, kumtaşı ve kiltaşından meydana gelen Danişmen Formasyonunun bileşiminde yer alan kiltaş litolojisinde gelişmiş olması da bu durumu desteklemektedir (Şekil 4). Sahadaki heyelanlı zeminlerden alınan numunelerin sıvılık sınırının (LL) %24,5-64,9, plastiklik sınırının (PL) %20,7-31,9 ve plastisite indisinin (PI) %5,8-38,2 arasında olduğu tespit edilmiştir. Bu bakımdan inceleme alanındaki litolojik birimin "yüksek plastisiteli siltli kil (CH)" ile "düşük plastisiteli kil (CL)" zemin sınıfında olduğu anlaşılmıştır. Ayrıca numunelerin gerek LL gerekse PL değerleri bakımından sırasıyla, genellikle "orta-yüksek" ve nadiren de "çok yüksek" olduğu saptanmıştır (Aral & Avcıyener, 2011). Diğer yandan mineralojik bakımdan sahadaki killerin şişme potansiyeli "yüksek" olan "montmorillonit" türünde olduğu belirlenmiştir (Çağıl Mühendislik, 2011). Bütün bu zeminlerin mühendislik özellikleri inceleme alanındaki litolojinin heyelana çok yatkın olduğunu açıkça göstermektedir.

İnceleme alanındaki kentsel heyelanı hazırlayıcı diğer faktörler ise eğim ve yerçekli özellikleridir (Şekil 4; 7). Zira eğimin fazla olduğu yamaçlarda yerçekimi artacağı için heyelan oluşma potansiyelinin yüksek olduğu bilinmektedir (Özşahin, 2015e). Gerçekten de inceleme alanındaki kentsel heyelan eğimin %15'i aştığı bir yamaçta gelişmiştir (Şekil 6). Özşahin (2015b) Tekirdağ kentinde eğim değerlerinin %15'in üzerinde olan yamaç arazilerde heyelanların daha fazla oluştuğunu bildirmiştir (Özşahin, 2015b).

İnceleme alanındaki kentsel heyelanı tetikleyen öncelikli faktör yağıştır (Schwab vd., 2005). Yıllık ortalama yağış miktarının 580,0 mm olduğu inceleme alanında kentsel heyelanın meydana geldiği aralık ayı, aynı zamanda en yağışlı aydır. Zira inceleme alanındaki yıllık toplam yağış miktarının %13,8'i aralık ayında düşmektedir (Tablo 1; Şekil 7). Ancak inceleme alanında 2023 yılının aralık ayında ortalamadan üzerinde bir yağış (85,9 mm) gerçekleşmiştir (Tablo 2; Şekil 7). Meteoroloji Genel Müdürlüğü'nün Yağış Şiddeti sınıflandırmasına (Meteoroloji Genel Müdürlüğü, 2024c) göre "Şiddetli Yağış (76 - 100 mm)" mertebesinde meydana gelen bu hadise, inceleme alanındaki heyelan oluşumunu tetikleyen bir etkiye sebep olmuştur. Lee vd. (2020) son yıllarda anormal hava olaylarının daha sık meydana gelmesiyle birlikte yerel şiddetli yağışların sıklığı arttığı için kentsel alanlardaki heyelan tehlikesinin de arttığını kaydetmişlerdir (Lee vd., 2020).

Dolayısıyla inceleme alanındaki şiddetli yağış neticesinde kentsel heyelanın olduğu zemin, kısmen ya da tamamen suya doymun bir karakter kazanarak akıcı hale gelmiştir (Özşahin, 2015b). Lee vd. (2020) şiddetli yağışlardan sonra zeminin doymunluğa ulaşmaya başlamasıyla beraber gözenek basıncı artarken kayma dayanımı azaldığı için heyelan olasılığının da arttığını ifade etmişlerdir (Lee vd., 2020). Böylece inceleme alanında 16.12.2024 tarihinde aylık ortalamasının yaklaşık yarısına karşılık gelen oranda (%47.6) düşen şiddetli yağış, kentsel heyelanın oluşumunu tetikleyici bir rol oynamıştır.



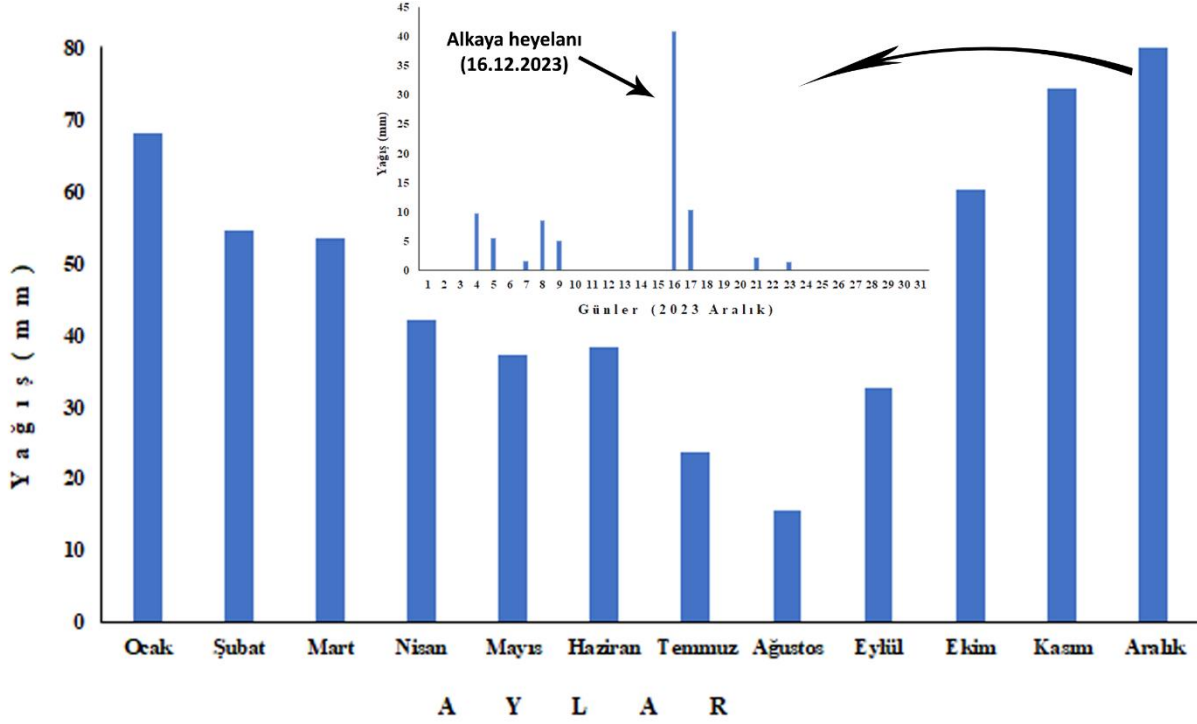
Şekil 7. İnceleme alanının eğim haritası

Tablo 1. İnceleme alanının aylık ortalama yağış değerleri (Meteoroloji Genel Müdürlüğü, 2024a)

Aylar	1	2	3	4	5	6	7	8	9	10	11	12	Yıllık
Yağış (mm)	68,0	54,5	53,4	42,1	37,2	38,3	23,8	15,5	32,7	60,2	74,3	80,0	580,0
%	11,7	9,4	9,2	7,3	6,4	6,6	4,1	2,7	5,6	10,4	12,84	13,8	100,0

Tablo 2. İnceleme alanının aralık ayı günlük ortalama yağış değerleri (Meteoroloji Genel Müdürlüğü, 2024b)

Gün	1	2	3	4	5	6	7	8	9	10	11
Yağış	0	0	0	9,80	5,55	0	1,70	8,60	5,05	0	0
%	0	0	0	11,4	6,5	0	2,0	10,0	5,9	0	0
Gün	12	13	14	15	16	17	18	19	20	21	22
Yağış	0	0	0	0	40,85	10,45	0	0	0	2,25	0
%	0	0	0	0	47,6	12,2	0	0	0	2,6	0
Gün	23	24	25	26	27	28	29	30	31	Aylık Toplam	
Yağış	1,5	0	0	0	0	0	0,1	0	0	85,9	
%	1,7	0	0	0	0	0	0,1	0	0	100,0	



Şekil 8. İnceleme alanının uzun süreli aylık ve 2023 yılı aralık ayı günlük ortalama yağış değerleri

İnceleme alanındaki kentsel heyelanı tetikleyen diğer bir faktör, amaç dışı kullanılmasına bağlı bir şekilde ortaya çıkan yanlış arazi kullanımıdır. Zira daha önce tespit edilmiş başka bir heyelanın yaşandığı (Kayran, 2006) ve heyelan duyarlılığının çok yüksek olduğu (Özşahin, 2015e) inceleme alanı, yoğun insan müdahalesine ve yanlış mühendislik uygulamalarına maruz kalmıştır. Kentsel heyelanın gerçekleştiği yamaç, hemen üst kesiminden karayolunun geçtiği bir yer olmasının yanında, birkaç yıl önceye kadar kullanılmayan ancak yakın zamanda rekreasyon faaliyetleri açısından teraslama usulüyle düzenlenmiştir (Şekil 8). Böylece yamaç arazi gerek üst gerekse bazı yamaç kesimlerinden geçirimsiz yüzeylerle kuşatılmıştır. Yağışlarla gelen suların yüzeyel akışını engellemek için kara yönünde zorunlu olarak yönlendirilmesine yol açan bu durum, suyun şev diplerinden sızmasına etki etmektedir. Böylece sızan sular, alttaki anakayanın su içeriğini arttırmasına karşın sürtünmeyi azaltarak heyelanın hazırlayıcı nedeni olmuştur (Şekil 9).

Dolayısıyla Alkaya heyelanı, hazırlayıcı diğer doğal faktörlerin yanında, yamacın amaç dışı kullanılmasından dolayı meydana gelmiş olmalıdır. Ancak Alkaya heyelanının meydana geldiği tarihten beri (16.12.2023-20.08.2024) sekiz aydan fazla zaman geçmesine rağmen heyelanlı yamaçta hala gerekli önlemler alınmamıştır. Sadece heyelanlı saha güvenlik şeridiyle kapatılmış ve sahanın mevcut kullanımında olan yürüyüş yoluna bakan kısmına “DİKKAT HEYELAN BÖLGESİDİR.” afişi asılmıştır. Bu durum yağışlı dönemin başlamasıyla birlikte sahadaki mevcut heyelanın yeniden aktif hale gelmesine sebep olabilir.



Şekil 9. Alkaya heyelanının meydana geldiği yamaç arazide yanlış arazi kullanımı görülmektedir.



Şekil 10. Alkaya heyelanının meydana geldiği yamaç arazide yağışlarla gelen suyun şev diplerinden sızması, alttaki anakayanın su içeriğinin artmasına ve sürtünmenin azalarak heyelanın oluşmasına sebebiyet vermiştir (Gence, 2023)



Şekil 11. Alkaya heyelanının meydana geldiği tarihten beri heyelanlı yamaçta gerekli önlemler alınmamıştır (Fotoğraf 20.08.2024 tarihinde çekilmiştir).

4. Tartışma

Hızlı nüfus artışıyla birlikte kentsel alanlar çevresine doğru kontrolsüz bir şekilde yayılmaya başlamıştır. İlk aşamada eğitim koşullarının uygun olduğu jeomorfolojik birimler üzerinde başlayan bu kontrolsüz yayılma, zamanla doğal güzellikleri ve manzarası nedeniyle yamaç arazilere doğru kaymıştır (Olshansky, 1996). Yamaçların gayri resmi kentleşmesi olarak tanımlanan bu süreç, kentsel heyelan tehlikesinin görülme sıklığının ve şiddetinin artmasına neden olmuştur (Smyth & Royle, 2000). Tekirdağ, Türkiye’de yaygın bir şekilde fosil ve aktif heyelanların görüldüğü kentlerden birisidir (Kayran, 2006). Kabaca kuzey-güney doğrultusunda akan kısa boylu akarsu vadileriyle parçalanmış denize doğru eğimli bir plato yüzeyi üzerinde bulunan kentsel alandaki yamaç araziler, heyelan duyarlılığı bakımından yüksek maruziyete ve hassasiyete sahiptir (Özşahin, 2015b). Bu sebeple 16.12.2023 tarihinde Tekirdağ kentsel alanındaki Alkaya mevkiinde altyapının zarar görmesine ve ekonomik kayba neden olan sığ karakterde bir kentsel heyelan meydana gelmiştir. Bu çalışma Alkaya kentsel heyelanının hazırlayıcı diğer doğal faktörlerin yanında, asıl yamacın amaç dışı kullanılmasından dolayı oluştuğunu ortaya çıkarmıştır. Schwab vd. (2005) kentsel alanlardaki yamaçlar üzerinde gerçekleştirilen insan faaliyetinin çok daha uzun süre dayanabilecek şevleri istikrarsızlaştırarak kentsel heyelanların meydana gelmesini tetikleyebileceğini vurgulamışlardır (Schwab vd., 2005). Thomson ve Tiedemann (1982) kentsel heyelanları tetikleyen insan faaliyetlerinin önceden planlama yapılarak en aza indirilebileceği gibi yönetim organları tarafından önleyici tedbirler alınarak azaltılabileceğini de açıklamışlardır (Thomson & Tiedemann, 1982).

Genel olarak doğal veya antropojenik faktörler tarafından tetiklenen kentsel heyelanların zamansal ve mekânsal olarak tahmin edilmesinin oldukça güç olduğu bilinmektedir (Görüm & Nefeslioğlu, 2015). Ancak yaşanmış kentsel heyelanların bilimsel bir bakış açısıyla analiz edilmesi, planlama açısından heyelanların oluşturacağı zararların azaltılmasına yardımcı olduğu gibi gelecekte benzer olayların oluşum sahalarının tahmin edilebilmesine de ışık tutmaktadır (Özşahin, 2014b; 2015b). Alexander (1989) kentsel heyelan felaketleri durdurulamıyorsa bile en azından oluşum özelliklerinin ve mekanizmalarının belirlenmesi gerektiğini vurgulamıştır (Alexander, 1989). Bu bakımdan kentsel heyelan tehlikesine karşı hem heyelan hem de mekânsal planlama uzmanları tarafından dört yaklaşımın uygulanması önerilmiştir.

Bunlar; (1) heyelana eğilimli alanlarda kentsel gelişimin sınırlandırılması; (2) kazı, arazi tesviyesi ve inşaat işleriyle ilgili teknik kuralların uygulanması ve güçlendirilmesi; (3) gelecekteki olası hasarı sınırlandırarak teknikler kullanılarak mevcut yapıların korunması; (4) izleme ve uyarı sistemlerinin geliştirilmesi ve kurulumudur. Bu dört yaklaşımın uygulandığı yerlerde genellikle kentsel heyelan risklerinin azaltılmasına yönelik oldukça başarılı sonuçlar elde edilmiştir (Schuster & Highland, 2007). Dolayısıyla bu çalışma hem güncel hem de gelecek durumun anlaşılmasına katkı sağlaması bakımından önem taşır.

Kentsel yerleşimler için büyük bir problem olarak görülen heyelan tehlikesinin çözümü, ancak disiplinler arası bir yaklaşımla mümkündür. Bu konudaki sorunları yerinde çözmedeki başarısızlık, genellikle bireysel uzmanlık veya metodoloji eksikliğinden değil, farklı alanlardaki uzmanlar arasındaki iletişim eksikliğinden kaynaklanmaktadır (Alexander, 1989). Dolayısıyla gelecekteki kentsel heyelan araştırmalarının multidisipliner bir yaklaşımla gerçekleştirilmesi oldukça önemlidir. Başta Alkaya heyelanı olmak üzere Tekirdağ kentindeki ve Türkiye'nin diğer kentsel alanlarındaki potansiyel heyelan alanlarının belirlenmesi ve gerekli önlemlerin alınması için jeologlar ve jeomorfologlar başta olmak üzere çeşitli branşlarda uzmanlaşmış yerbilimcilerden faydalanılmalıdır. Ayrıca heyelan tehlikesi duyarlılığının yüksek olduğu kentlerde karar verici pozisyonda olanların yerel saha koşullarını ve altyapıyı iyileştirmek için ortak bir çaba göstermesi gerekir. Böylece heyelan tehlikesinin önemli ölçüde az olduğu daha güvenli ve sürdürülebilir bir kentsel çevrenin kurulması sağlanarak kalmaz, aynı zamanda insanların yaşadığı çevrenin kalitesi de artar (Smyth & Royle, 2000).

Son yıllarda kentsel heyelan çalışmalarında CBS ve İHA tabanlı UA teknikleri yaygın olarak kullanılmaktadır (Karantanellis vd., 2020). CBS tekniklerinden heyelanlar ve heyelanla ilişkili değişkenler arasındaki karmaşık ilişkileri etkili bir şekilde analiz etmek, İHA tabanlı UA tekniklerinden ise daha hassas veri toplamak için yararlanılmaktadır (Lee vd., 2020). Bu tekniklerin dışında zamansal ve mekânsal kentsel heyelan dinamiklerini izlemek için jeofizik yöntemlerden de faydalanılmaktadır. Ancak yakın zamanda CBS ve İHA tabanlı UA tekniklerinin jeofizik sonuçlarının güvenilirliğini artırmak için kullanılan tamamlayıcı bir yöntem olarak daha fazla tercih edildiği bildirilmiştir (Hussain vd., 2022). Bu çalışmada Alkaya kentsel heyelanı CBS ve İHA tabanlı UA teknikleri kullanılarak incelenmiştir. CBS teknikleri kentsel heyelanın tematik haritalarının hazırlanmasında, İHA tabanlı UA teknikleri ise daha yüksek çözünürlüğe sahip verilerin üretilmesi ve daha hassas ölçümlerin gerçekleştirilmesinde kullanılmıştır. Bundan sonraki çalışmalarda kentsel heyelanların incelenmesinde benzer teknikler kullanılabilir gibi jeofizik yöntemlerden de faydalanılabilir. Ayrıca yerel ölçekte, jeofizik teknikleri İHA tabanlı fotogrametri ile birleştirmek, esneklik, verimlilik, alet yerleştirme kolaylığı ve veri işleme hızı gibi çeşitli avantajlar nedeniyle maliyet etkinliği açısından etkin bir çözüm olarak sunulabilir (Hussain vd., 2022).

5. Sonuç

Bu çalışmanın sonuçları Tekirdağ kentinde 16.12.2023 tarihinde meydana gelen Alkaya kentsel heyelanının bazı hazırlayıcı koşullar ve tetikleyici faktörlerin etkisiyle oluştuğunu göstermiştir. Hazırlayıcı faktörler bakımından şişme potansiyeli "yüksek" olan "montmorillonit" türünde killerden oluşan litolojinin yayılım gösterdiği ve eğimin %15'i aştığı bir yamaçta gelişen kentsel heyelan, ortalamanın üzerinde şiddetli yağış ve yamaçın amaç dışı kullanılmasıyla tetiklenmiştir. Dolayısıyla çalışma sonuçları, Tekirdağ kentindeki benzer özelliklerinin görüldüğü alanların belirlenmesinde kullanılabilir. Ayrıca bu sonuçlar Tekirdağ kenti özelinde hazırlanacak heyelan risk değerlendirme çalışmalarına da önemli katkılar sağlayabilir.

Güncel olarak inceleme alanında oluştuğu zamandan beri herhangi bir rehabilitasyon işlemi yapılmadan duran Alkaya kentsel heyelanının yağışlı dönem gelmeden bir an önce ivedilikle tesviye edilmesi gerekmektedir. Bu bakımdan kayan kütlenin tekrar harekete geçmesinin önlenmesi amacıyla ortamdaki uzaklaştırılması oldukça önemlidir. Diğer yandan hem aynı sahada hem de kentsel alandaki diğer yamaçlarda benzer problemin yaşanmaması için yamaç arazilere yapılacak müdahalelerde çok dikkat edilmesi elzemdir. Tekirdağ kentinde özellikle yamaç arazilerin planlanması sırasında yanlış arazi kullanımının engellenmesi için amaç dışı kullanımlara müsaade edilmemelidir. Bununla birlikte şiddetli yağışlar sonucunda geçirimsiz yüzeylere bağlı olarak ortaya çıkan fazla suların şev diplerinden sızmasının önlenmesi için yamaç şevlerinin doğru bir şekilde drene edilmesi gerekmektedir. Ayrıca bu çalışmada olduğu gibi kentsel heyelanların incelenmesinde CBS ve İHA tabanlı UA tekniklerin kullanılması, verimli ve hassas veri toplama ile bu verilerin zamansal açısından etkili ve yüksek doğrulukta analizi bakımından büyük bir avantaj sağlamaktadır.

Kaynaklar

Akıncı, H., Dogan, S., Kılıçoğlu, C., & Keçeci, S.B. (2010). Samsun İl Merkezinin Heyelan Duyarlılık Haritasının Üretilmesi. *Harita Teknolojileri Elektronik Dergisi*, 2(3), 13-27. <https://dergipark.org.tr/en/download/article-file/84939>

- Akinci, H., Yavuz Özalp, A., & Temuçin Kılıçer, S. (2015). Coğrafi Bilgi Sistemleri ve AHP Yöntemi Kullanılarak Planlı Alanlarda Heyelan Duyarlılığının Değerlendirilmesi: Artvin Örneği. *Doğal Afetler ve Çevre Dergisi*, 1(1-2), 40-53. <https://doi.org/10.21324/dacd.20952>
- Alexander, D. (1989). Urban landslides. *Progress in Physical Geography: Earth and Environment*, 13(2), 157-189. <https://doi.org/10.1177/030913338901300201>
- Alptekin, A., & Yakar, M. (2020). Heyelan bölgesinin İHA kullanarak modellenmesi. *Türkiye İnsansız Hava Araçları Dergisi*, 2(1), 17-21. <https://dergipark.org.tr/en/download/article-file/1099110>
- Aral, İ. F., & Avcıyener, S. (2011, 1-2 Aralık). *Hürriyet Mahallesi (Tekirdağ) yöresi heyelanlarının mühendislik özellikleri* [Bildiri Sunumu]. 4. Geoteknik Sempozyumu, Adana, Türkiye.
- Çağıl Mühendislik. (2011). *Tekirdağ ili Hürriyet mahallesi 212 ada ve 2247 ada alanları içerisinde gelişen heyelanların Mühendislik jeolojisi araştırması*. İstanbul.
- Çakıcı, H., Tüdeş, Ş., & Bulut, F. (2012). Kentsel Kullanım Alanında Gelişen Heyelanlar ve Jeoteknik Analizi: Kırkdğirmenler (Erzurum) Örneği. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 27(4), 739-751.
- Eker, R., Aydın, A. & Hübl, J. (2018). Unmanned aerial vehicle (UAV)-based monitoring of a landslide: Gallenzerkogel landslide (Ybbs-Lower Austria) case study. *Environmental Monitoring and Assessment*, 190, Article 28. <https://doi.org/10.1007/s10661-017-6402-8>
- ESRI. (2023). *Sentinel-2 10m Land Use/Land Cover Timeseries Downloader (2017-2023)*. 9 Temmuz 2024'te <https://livingatlas.arcgis.com/landcoverexplorer/> adresinden alındı.
- Gence, E. (2023, Aralık 16). *Alkaya sahil yürüyüş yolunun üst kısmında yoğun yağış sonrasında heyelan meydana geldi*. 9 Temmuz 2022'te <https://www.facebook.com/100008684106014/posts/pfbid02Qf4Rf8XL2wsrJ5g2fQh9MrQiBoV8V917CrEftZdUMRkXv1vbij4q4eFXd9mbxfkcl/?mibextid=Nif5oz> adresinden alındı.
- Görüm, T., & Nefeslioğlu, H. (2015). Çok zamanlı heyelan aktivitesinin belirlenmesinde jeomorfolojik bir yaklaşım. *Türk Coğrafya Dergisi*, 65, 47-58. <https://doi.org/10.17211/tcd.19041>
- Hussain, Y., Schlögel, R., Innocenti, A., Hamza, O., Iannucci, R., Martino, S., & Havenith, H.B. (2022). Review on the Geophysical and UAV-Based Methods Applied to Landslides. *Remote Sensing*, 14, Article 4564. <https://doi.org/10.3390/rs14184564>
- Karantanellis, E., Marinou, V., Vassilakis, E., & Christaras, B. (2020). Object-Based Analysis Using Unmanned Aerial Vehicles (UAVs) for Site-Specific Landslide Assessment. *Remote Sensing*, 12, Article 1711. <https://doi.org/10.3390/rs12111711>
- Kayran, H. (2006). *Tekirdağ Belediyesi Kent ve Mücavir Alanının Revizyon İmar Planı Yerleşime Uygunluk Amaçlı Etüt Raporu*. Çağıl Mühendislik Müşavirlik Sanayi ve Ticaret Limited Şirketi, Tekirdağ Belediyesi.
- Lee, S., Baek, W.K., Jung, H.S., & Lee, S. (2020). Susceptibility Mapping on Urban Landslides Using Deep Learning Approaches in Mt. Umyeon. *Applied Sciences*, 10, Article 8189. <https://doi.org/10.3390/app10228189>
- Meteoroloji Genel Müdürlüğü. (2024a). *Tekirdağ Meteoroloji İstasyonunun uzun yıllık (Ölçüm Periyodu:1940-2023) aylık ortalama yağış verileri*. 9 Temmuz 2022'de <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=TEKIRDAG> adresinden alındı.
- Meteoroloji Genel Müdürlüğü. (2024b). *Tekirdağ Meteoroloji İstasyonunun 2023 yılının aralık ayına ait günlük yağış verileri* [Data set]. Tekirdağ Meteoroloji İstasyon Müdürlüğü, Tekirdağ.
- Meteoroloji Genel Müdürlüğü. (2024c). *Meteorolojik Hadiselerin Şiddetlerine Ait Sınıflandırma - Yağış Şiddeti*. 9 Temmuz 2022'de <https://www.mgm.gov.tr/site/yardim1.aspx?m=HadSid> adresinden alındı.
- Nefeslioğlu, H.A., Sezer, E., Gokceoğlu, C., Bozkır, A. S., & Duman, T.Y. (2010). Assessment of Landslide Susceptibility by Decision Trees in the Metropolitan Area of Istanbul, Turkey. *Mathematical Problems in Engineering*, 2010, Article 901095. <https://doi.org/10.1155/2010/901095>
- Olshansky, R.B. (1996). *Planning for Hillside Development* (Report Number 466). American Planning Association, Planning Advisory Service.
- Özşahin, E. (2014a). CBS Kullanılarak Şehir ve Jeomorfoloji Arasındaki İlişkinin İncelenmesi: Tekirdağ Şehri Örneği. *İğdır Üniversitesi Sosyal Bilimler Dergisi*, 6, 93-122. <https://dergipark.org.tr/tr/download/article-file/2154112>
- Özşahin, E. (2014b). Tekirdağ İlinde Coğrafi Bilgi Sistemleri ve Analitik Hiyerarşi Süreci Kullanarak Heyelan Duyarlılık Analizi. *Humanitas - Uluslararası Sosyal Bilimler Dergisi*, 2(3), 167-186. <https://doi.org/10.20304/husbd.84015>
- Özşahin, E. (2015a). Kent Planlaması ve Jeomorfoloji. In M. Karakuyu, A. Keçeli & Ş. Çelikoğlu (Eds.), *Kent Çalışmaları II* (10. Bölüm, 215-231), Pegem Akademi.
- Özşahin, E. (2015b). Coğrafi Bilgi Sistemleri (CBS) ve Analitik Hiyerarşi Süreci (AHS) Kullanılarak Tekirdağ Şehrinin Heyelan Duyarlılık Analizi. *Avrasya Bilimler Akademisi Sosyal Bilimler Dergisi*, 6, 50-71. <https://doi.org/10.17740/eas.soc.2015-V6-4>
- Özşahin, E. (2015c). Şehir ve Toprak Arasındaki İlişkinin Coğrafi Yaklaşımla İncelenmesi: Tekirdağ Şehri Örneği. *Turkish Studies-International Periodical For the Languages, Literature and History of Turkish or Turkic*, 10/3, 733-758. <http://dx.doi.org/10.7827/TurkishStudies.7982>

- Özşahin, E. (2015d). Tekirdağ'da kentsel gelişim ve jeomorfolojik birimler arasındaki ilişkinin zamansal değişimi. *Turkish Studies - International Periodical for the Languages, Literature and History of Turkish or Turkic*, 10(1), 579-602. <https://doi.org/10.7827/TurkishStudies.7811>
- Özşahin, E. (2015e). Coğrafi Bilgi Sistemleri Yardımıyla Heyelan Duyarlılık Analizi: Ganos Dağı Örneği (Tekirdağ). *Harita Teknolojileri Elektronik Dergisi*, 7(1), 47-63.
- Petley, D. N. (2009). On the impact of urban landslides. *Geological Society, London, Engineering Geology Special Publications*, 22, 83-99. <https://doi.org/10.1144/EGSP22.6>
- Schuster, R. L., & Highland, L. M. (2007). The Third Hans Cloos Lecture. Urban landslides: socioeconomic impacts and overview of mitigative strategies. *Bulletin of Engineering Geology and the Environment*, 66, 1-27. <https://doi.org/10.1007/s10064-006-0080-z>
- Schwab, J., FAICP, Gori, P., & Jeer, S. (2005). *Landslide hazards and planning*. APA Planning Advisory Service. <https://w1.planning.org/publications/report/9026862/>
- Smyth, C. G., & Royle, S. A. (2000). Urban landslide hazards: incidence and causative factors in Niterói, Rio de Janeiro State, Brazil. *Applied Geography*, 20(2), 95-118. [https://doi.org/10.1016/S0143-6228\(00\)00004-7](https://doi.org/10.1016/S0143-6228(00)00004-7)
- Thomson, S., & Tiedemann, C.E. (1982). A Review of Factors Affecting Landslides in Urban Areas. *Environmental & Engineering Geoscience*, 19(1), 55-65. <https://doi.org/10.2113/gsegeosci.xix.1.55>
- Turner, D., Lucieer, A., & de Jong, S. M. (2015). Time series analysis of landslide dynamics using an unmanned aerial vehicle (UAV). *Remote Sensing*, 7(2), 1736-1757. <https://doi.org/10.3390/rs70201736>
- Uludağ, M., & Özşahin, E. (2023). Şehirsel Yayılmanın Jeomorfolojik Birimlerle İlişkinin Zamansal ve Mekansal Analizi: Edirne Örneği. *Jeomorfolojik Araştırmalar Dergisi*, 10, 49-66. <https://doi.org/10.46453/jader.1205061>
- U.S. Department of Agriculture. (1975). *Soil Taxonomy: A Basic System of Soil Classification for Making and Interpreting Soil Surveys* (Agriculture Handbook 436). U.S. Department of Agriculture, Natural Resources Conservation Service.
- Yu, M., Huang, Y., Zhou, J., & Mao, Y. (2017). Modeling of landslide topography based on micro-unmanned aerial vehicle photography and structure-from-motion. *Environmental Earth Sciences*, 76, Article 520. <https://doi.org/10.1007/s12665-017-6860-x>

2015-2023 Yılları Arasında Kadıköy Barajı Su Yüzey Alanının OTSU Yöntemiyle Sentinel-2 Multispektral Görüntülerinden Operasyonel Olarak Belirlenmesi

Operational Estimation of Kadıköy Dam Surface Water Extent from Sentinel-2 Multispectral Imagery Using OTSU Method between 2015 and 2023

Suphi Öztürk¹, Ali Levent Yağcı^{1*}

¹Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kocaeli, Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Ali Levent Yağcı
alyagci@gtu.edu.tr

doi: 10.48123/rsgis.1508139

Yayın süreci

Geliş tarihi: 01.07.2024
Kabul tarihi: 26.09.2024
Basım tarihi: 26.09.2024

Özet

Bu çalışmada, Kadıköy Barajı'nın 2015-2023 yılları arasındaki su yüzey alanı değişimleri, Sentinel-2 uydu görüntüleri kullanılarak otomatik bir şekilde belirlenmesi amaçlanmıştır. Çalışma kapsamında, yaygın olarak kullanılan Normalleştirilmiş Fark Su İndeksi (NDWI) ve Modifiye Edilmiş Normalleştirilmiş Fark Su İndeksi (MNDWI) kullanılmıştır. NDWI ve MNDWI sonuçlarındaki mekânsal çözünürlük farkını ortadan kaldırmak için 20m çözünürlüğündeki kısa dalga kızılötesi bandı (SWIR-1), evrişimli sinir ağları yöntemiyle 10m çözünürlüğe yükseltilmiştir. Su alanlarını diğer alanlardan ayırmak için MNDWI ile hem sabit (MNDWI_0) hem de OTSU (MNDWI_OTSU) dinamik eşikleme yöntemleri kullanılmıştır. Daha sonra, elde edilen sonuçlar, Kadıköy Barajını NDWI OTSU dinamik eşikleme yöntemi ile operasyonel olarak takip eden Global Water Watch (GWW) gözlemleri ve Level-2 Sentinel-2 sınıflandırma katmanındaki (SCL) su olarak etiketlenen piksellerden hesaplanan baraj alanı ile bulutluluk oranının %1'in altında olduğu günlerde karşılaştırılmıştır. Sonuçlara göre, en düşük bağıl hata MNDWI_OTSU ile MNDWI_0 yöntemleri arasında görülmesine rağmen, MNDWI_OTSU ile GWW yöntemleri arasında en düşük ortalama bağıl hata görülmüştür. Bunun nedeni, GWW gözlemlerinde bazı günlerde fiziksel olarak mümkün olmayan ani değişimler ortalama bağıl hatayı yükseltmiştir.

Anahtar kelimeler: MNDWI, OTSU, Su yüzey alanı, Su kaynakları yönetimi

Abstract

The objective of this study is to automatically estimate the surface water extent of Kadıköy Dam between 2015 and 2023 using Sentinel-2 satellite imagery. In this regard, widely used indices such as the Normalized Difference Water Index (NDWI) and the Modified Normalized Difference Water Index (MNDWI) were employed. The shortwave infrared band (SWIR-1) in 20m spatial resolution was upscaled to 10m resolution using a convolutional neural network method to eliminate the resolution discrepancy in NDWI and MNDWI results. A fixed (MNDWI_0) and OTSU dynamic thresholding (MNDWI_OTSU) scheme applied to MNDWI results to delineate water surface from land surfaces. The results obtained from MNDWI_0 and MNDWI_OTSU methods were compared to the observations downloaded from Global Water Watch (GWW) website and the counting of the water pixels in the scene classification layer (SCL) during the days when cloud cover is below 1%. The OTSU thresholding scheme applied to NDWI maps to derive the water extent estimates on the GWW website. The results indicated that even though the lowest average relative error was observed between MNDWI_0 and MNDWI_OTSU methods, the lowest median relative error was observed between GWW and MNDWI_OTSU water extent results because several physically impossible sudden changes or outliers seen in GWW water extent time series inflated the average relative error of GWW results.

Keywords: MNDWI, OTSU, Surface water extent, Freshwater management

1. Giriş

Günümüzde tatlı su kaynakları, tarımsal faaliyetlerin sürdürülebilirliği için gerekli olduğundan bu kaynakların yönetimi büyük bir öneme sahiptir. Su kaynaklarının etkin bir şekilde yönetilmesi, ekosistemlerin ve toplumların su ihtiyaçlarını karşılamayı hedeflerken aynı zamanda tarım alanlarının sulanması için gereken suyun teminini sağlamaktadır (Aggarwal vd., 2009; OECD, 2010). Dünya genelinde tarımın büyük bir su tüketicisi olduğu göz önünde bulundurulduğunda, suyun verimli ve adil bir şekilde yönetilmesi, tarımsal üretim ve gıda güvenliği açısından hayati öneme sahiptir. Aynı zamanda, su kaynaklarının izlenmesi, hidrolojik kuraklığın takibine olanak sağlamaktadır. Dolayısıyla, su kaynaklarının sürdürülebilirliği ve etkin bir şekilde yönetilmesi için bu kaynakların operasyonel olarak izlenmesi gereklidir (Katusiime & Schütt, 2020; Senay vd., 2015).

Bu bağlamda, yüksek mekânsal ve zamansal çözünürlükteki kutupsal yörüngeli uydulardan elde edilen uzaktan algılanmış görüntüler, su kaynaklarının operasyonel olarak izlenmesinde önemli bir araç haline gelmiştir (Huang vd., 2023; Liu vd., 2022). Su kaynaklarının izlenmesi, yoğunlukla Sentinel-2 ve Landsat uydu misyonlarından elde edilen görüntülerden hesaplanan su yüzey alanı hesaplamaları ile yapılmaktadır (Albarqouni vd., 2022; Atiz vd., 2023; Bai vd., 2011; Firatli vd., 2022; Tottrup vd., 2022; Yılmaz, 2023). Örneğin, Çanakkale'deki Atikhisar Baraj Gölü'nün yüzey alanı Landsat 8 uydu görüntülerinden hesaplanan Normalleştirilmiş Fark Su İndeksi (NDWI) ile belirlenmiş ve 1984-2018 yılları arasındaki yüzey alanının yıllık değişimi ile meteorolojik kuraklık arasında ilişkisi araştırılmıştır (Özelkan, 2019). Bir diğer çalışmada, 1988-2021 arasında Yunnan Platosundaki dokuz gölün yüzey su alanlarının mekânsal ve zamansal analizi, Google Earth Engine (GEE) platformu üzerinde Landsat uydu görüntüleri ve NDWI, Modifiye Edilmiş Normalize Fark Su İndeksi (MNDWI), Otomatik Su Çıkarma İndeksi (AWEI), Normalleştirilmiş Su İndeksi (NWI) ve Su İndeksi (WI) indeksleri kullanarak yapılmıştır (Lu & Sun, 2023). Çukurova, Köyceğiz, Burdur, Hazar ve Çıldır göllerini baz alarak yapılan bir çalışmada, Sentinel-2 uydu görüntüleri kullanılarak farklı su yüzey belirleme indekslerinin performans analizi yapılmıştır (Yılmaz, 2023). Benzer şekilde Bafa Gölü'nün 1984-2022 yılları arasındaki uzun vadeli değişimlerinin Landsat 5 ve 8 uydu görüntüleri ve GEE platformu kullanılarak yıllık su alanları NDWI, MNDWI ve AWEI indeksleriyle hesaplanmıştır (Atiz vd., 2023). Landsat 5 ve 8 uydu görüntüleri kullanılan bir diğer çalışmada, Türkiye'nin Göller Bölgesi'nde bulunan Burdur, Eğirdir ve Beyşehir göllerinin 2000 – 2021 yılları arası su yüzey alanı ve göl yüzey suyu sıcaklığı (LSWT) analizlerini içeren bir diğer çalışmada, NDWI kullanılarak su alanları çıkarılmıştır (Albarqouni vd., 2022). Küçük ve orta ölçekli barajlar ile göllere yönelik yapılan çalışmada, yapay su rezervlerinin 35 yıllık yüzey su alanlarına dair zaman serileri oluşturulmuştur. Türkiye'deki doğal göllerin genel özellikleri ve zaman içindeki yüzey su alanlarındaki değişimler ele alınmıştır. Her iki çalışmada, Landsat ve Sentinel-2 uydu görüntüleri ile NDWI kullanılmıştır (Donchyts vd., 2022; Firatli vd., 2022). Kuzeybatı Çin'de yapılan bir çalışmada, 2000 ile 2020 yılları arasındaki dönemi kapsayacak şekilde Xinjiang'daki göllerin su depolama değişikliklerini incelenmiştir. Global Surface Water Monthly Historical dataset (JRC GSW) ve Hydroweb'den elde edilen uydu verileri kullanılarak göl alanı, su seviyesi ve su depolama değişiklikleri analiz edilmiştir (Huang vd., 2023). Aral Denizi Havzası'ndaki yüzey su alanındaki değişiklikler JRC GSW veri seti ve GEE bulut platformu kullanılarak incelenmiştir. 1992 ile 2020 arasındaki, göl ve barajların su alanlarının değişimleri belirlenmiştir (Huang vd., 2023). Üç milyon Landsat uydu görüntüsü kullanarak son 32 yılda küresel yüzey suyu değişikliklerini incelendiği bir başka çalışmada, 1984-2015 arasında, kalıcı su yüzeyleri ve yeni su yüzeyleri raporlanmıştır (Pekel vd., 2016). 2010-2020 yılları arasını kapsayan bir başka çalışmada, Sentinel-1, Sentinel-2 ve Landsat 8 uyduları kullanılarak 14 farklı uydulara dayalı yaklaşımlar karşılaştırmalı olarak incelenmiştir (Tottrup vd., 2022). Son olarak, 2001-2019 yılları arasındaki Landsat 5, 7 ve 8 uydu görüntüleri ile GEE platformu kullanılarak yüzey su alanı dinamiklerini incelenmiştir (Zhou vd., 2021).

Su yüzey alanları, sayısal yükseklik modelleri veya batimetri haritaları ile birleştirildiğinde barajlardaki su miktarı ve su yüksekliği takip edilebilmektedir (Khattab vd., 2017; Yue & Liu, 2019). Örneğin, 2015-2017 yılları arası Sentinel-2A uydu misyonundan elde edilen uydu görüntülerinden hesaplanmış NDWI ile dijital yükseklik modeli verileri karşılaştırılarak barajdaki su miktarının tahminleri yapılmıştır (Karaman & Özelkan, 2022). Benzer bir şekilde, Avustralya ve ABD'nin çeşitli göllerinin yüzey su alanları, Landsat 5 uydu görüntüleri kullanılarak denetimli sınıflandırma yöntemi ile belirlenmiştir. Su yüksekliğini belirlemek için dijital arazi modeli verileri kullanılmış ve su hacmi hesaplanmıştır (Fuentes vd., 2019). 2016 yılında gerçekleştirilen başka bir çalışmada, göllerin dağılımı, hacmi ve kalma süresi gibi önemli özelliklerini anlamak için bir jeostatistik model geliştirilmiştir. Araştırmada, göllerin yüzey alanı ve diğer hidrografik bilgilerini içeren HydroLAKES veri seti kullanılmıştır. Batimetrik ve derinlik verileri, 12150 doğal gölden elde edilmiş ve yüksek çözünürlüklü küresel hidrolojik modelden alınan debi tahminleri ile işlenmiştir (Messenger vd., 2016).

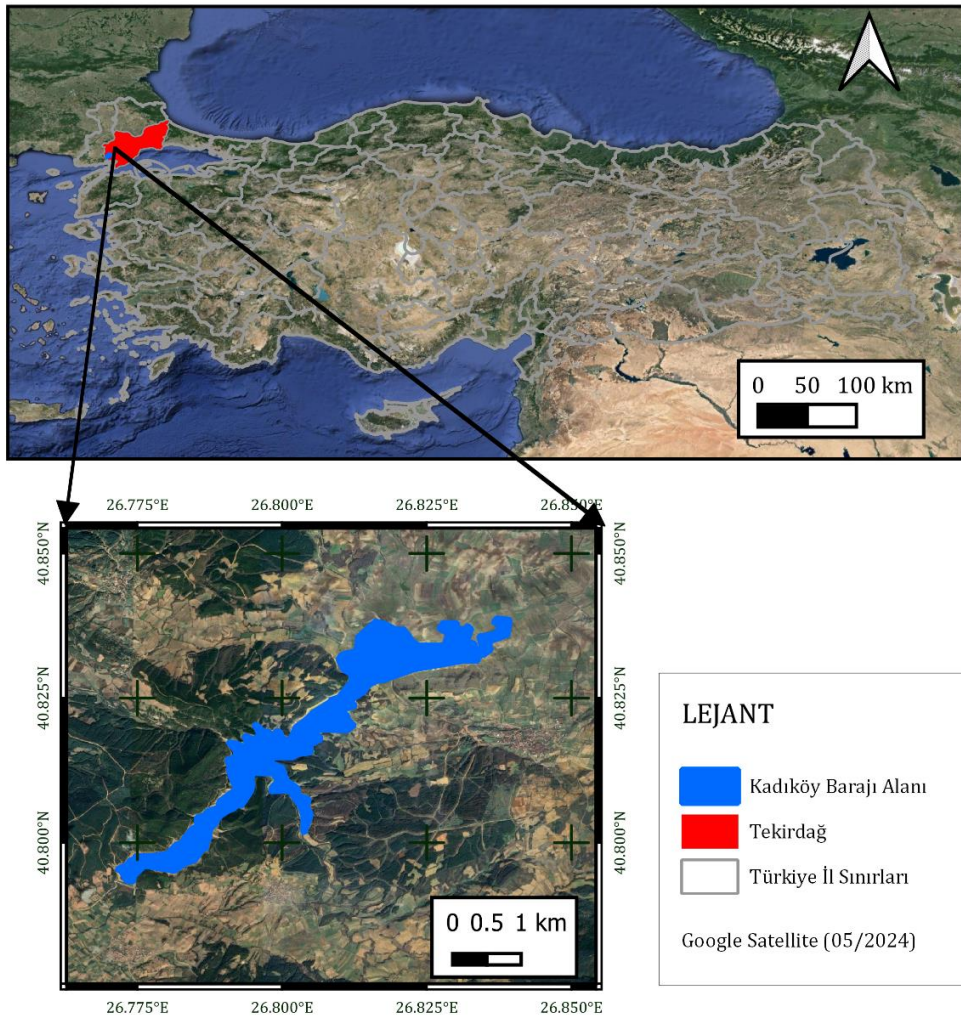
Bu çalışmada, yukarıda anlatılan çalışmalardan farklı olarak baraj yüzey alanının kullanıcıdan bir eşik değeri almadan operasyonel olarak hesaplanması amaçlanmıştır. Bu kapsamda geliştirilen metodoloji Tekirdağ'ın Malkara ilçesinde yer alan Kadıköy Barajında 2015-2023 yılları arasında Level-2 Sentinel-2 uydu görüntüleri test edilmiştir. İlk olarak, 20 m çözünürlüğündeki kısa dalga kızılötesi bandı (SWIR-1), evrişimli sinir ağları yöntemi ile 10m çözünürlüğe yükseltilmiştir. Daha sonra, yeşil ve kısa dalga kızılötesi bantları kullanılarak MNDWI hesaplanmış ve OTSU eşikleme yöntemi ile su pikselleri belirlenmiştir. Son olarak, baraj alanı dışında kalan su pikselleri ve hatalı olarak etiketlenen su pikselleri, su yüzey haritalarından arındırılarak su yüzey alanları hesaplanmıştır.

Tüm işlem adımlarının otomasyonu Python programlama diliyle sağlanmıştır. Ayrıca, geliştirilen yöntem ile elde edilen sonuçlar, Global Water Watch (GWW) gözlemleri, MNDWI sabit eşik değeri yöntemi ve Level-2 Sentinel-2 sınıflandırma katmanındaki su olarak etiketlenen piksellerden hesaplanan baraj alanı ile karşılaştırılmıştır.

2. Materyal ve Yöntem

2.1 Çalışma Alanı

Bu çalışma kapsamında, Türkiye'nin Tekirdağ ilinin Malkara sınırları içinde bulunan Kadıköy Barajı'nın (Şekil 1) su yüzey alanı değişimleri incelenmiştir. Baraj, Derbent Deresi üzerine 1967-1973 yılları arasında inşa edilmiş bir yapay barajdır. Barajın sulak alanı 223,21 hektar büyüklüğündedir. Sulama, taşkın kontrolü, içme-kullanma ve sanayi suyu temini gibi çeşitli amaçlarla kullanılmaktadır (Doğa Koruma ve Milli Parklar Genel Müdürlüğü, 2023). Barajın yer aldığı bölgede kışları ılıman ve nemli, yaz aylarında ise sıcak ve kurak iklim hakimdir ve Köppen – Geiger iklim sınıflandırmasına göre Csa iklim tipine sahiptir. Bu iklim tipinde kışlar ılık geçerken yazlar ise oldukça sıcak bir seyir izlemektedir (Öztürk vd., 2017).



Şekil 1. Kadıköy Barajı'nın konumu. Barajın alanı Hydrolakes veri tabanından alınmıştır

2.2 Materyal

2.2.1 Sentinel-2 uydu görüntüleri

Sentinel-2, Avrupa Uzay Ajansı (ESA) tarafından geliştirilen bir uydu misyonudur. Bu misyonun amacı, Dünya'nın yüzeyini geniş bir spektral aralıkta 10m-60m çözünürlükte gözlemlemektir. Sentinel-2 uydu görüntüleri elektromanyetik spektrumun kırmızı, yeşil, mavi ve yakın-kızılötesi gibi bölgelerinde gözlem toplamaktadır.

Bu spektral bantlar, tarım, ormancılık, su yönetimi ve çevre izleme gibi birçok uygulama için geniş bir kullanım sunmaktadır (Drusch vd., 2012; Filipponi, 2019; Segarra vd., 2020; Vasilakos vd., 2020).

Tablo 1. Çalışma kapsamında toplanan Sentinel-2 uydu görüntülerinin yıllara ve aylara göre sayısı

Ay / Yıl	2015	2016	2017	2018	2019	2020	2021	2022	2023
Ocak		3	5	13	13	12	12	12	12
Şubat		4	6	10	11	11	11	11	11
Mart		3	6	12	12	13	13	13	13
Nisan		4	6	12	12	12	12	12	12
Mayıs		5	6	13	12	11	12	12	12
Haziran		6	7	12	12	12	12	12	12
Temmuz	2	6	12	12	12	13	13	13	13
Ağustos	6	6	13	13	13	12	12	11	11
Eylül	4	6	12	11	11	12	12	12	12
Ekim	3	6	12	12	12	12	12	12	12
Kasım	3	5	12	12	12	12	12	12	12
Aralık	3	6	11	12	12	13	12	13	13

Çalışma kapsamında Sentinel-2 misyonu kapsamında 2015-2023 tarihleri arasında toplanmış 1054 tane Level 2 Sentinel-2A ve -2B uydusu görüntüleri kullanılmıştır (Tablo 1). Kadıköy barajı konum olarak iki farklı Sentinel-2 yörüngesinin (R007 ve R050) kesişme alanında bulunmaktadır. Çalışma alanı üzerinde iki farklı yörüngeden görüntü toplandığı için, görüntü sayısı aylık 11-13 arasında değişmiştir (Tablo 1). NDWI ve MNDWI gibi su indeksleri hesaplarında kullanılan spektral bantların özellikleri Tablo 2’de verilmiştir. Yeşil ve Yakın kızılötesi (NIR) bantları NDWI hesabında kullanılırken, Yeşil ve kısa dalga kızılötesi bantları MNDWI hesabında kullanılmaktadır.

Tablo 2. Çalışmada kullanılan Sentinel-2 bantlarının özellikleri

Bant No	Bant Adı	Dalga boyu (nm)	Mekânsal çözünürlük (m)
B3	GREEN	543-578	10
B8	NIR	785-899	10
B11	SWIR-1	1565-1655	20

2.2.2 Sentinel-2 Sınıflandırma Katmanı (SCL)

Her Level-2 Sentinel-2 uydu görüntüsü bir sınıflandırma katmanı (SCL; Scene Classification Layer) ile gelmektedir. Bu katman, arazi kullanımı/örtüsünü sınıflandırmak için oluşturulmuştur. SCL katmanı, veri yok değeri (No data value) dışında, doymuş ya da hasarlı, gölgeler, bulut gölgeleri, bitki örtüsü, bitki örtüsü olmayan alanlar, su, sınıflandırılmamış alanlar, orta olasılıklı bulutlar, yüksek olasılıklı bulutlar, ince sirus bulutları ve kar olmak üzere 11 farklı sınıf içermektedir (Tablo 3) (Main-Knorn vd., 2017).

Bu çalışmada SCL bandı iki amaç için kullanılmıştır. İlk olarak bulutlu günlerin tespiti için kullanılmıştır. Bu günlerde uydu, bulutlardan dolayı yeryüzü üzerinde veri toplayamayacağı için baraj su yüzey alanının uydu görüntüleri ile tespit edilmesi mümkün değildir. Ondandır, eğer baraj yüzeyi üzerinin %1’den fazla bulutlu olduğu günlerde baraj yüzeyi alanı hesabı yapılmamaktadır. İkinci olarak, bu katmanın içerisinde su yüzeyleri sınıflandırıldığı için baraj yüzey alanı bu katmandan bulunabilmektedir. Ondandır, çalışma kapsamında SCL bandındaki su pikselleri sayılarak baraj alan hesabı yapılmıştır ve çalışma kapsamında elde edilen diğer baraj su yüzey alanları ile karşılaştırılmıştır.

2.2.3 Global Water Watch (GWW) verileri

Global Water Watch (GWW) platformu, dünya genelindeki en az 10 hektarlık yüzeye sahip göl ve barajların dağılımı, yüzey alanı değişimleri ve su ikamet süresi gibi kritik coğrafi ve ekolojik süreçlerin ana bileşenlerini anlamak için geliştirilen bir veri tabanıdır. Bu veri tabanında Kadıköy Barajının su yüzey alanı, 80978 kimlik numarası ile periyodik olarak hesaplanmaktadır (Deltares, 2024). GWW platformunda çalışan algoritma, ilk aşamada bulutsuz level-1 Landsat ve Sentinel-2 uydu verilerine Canny Edge filtresi uygulayarak baraj sınırları belirlemektedir. İkinci aşamada, eşitlik (1) kullanılarak NDWI görüntülerini oluşturmaktadır.

Son aşamada ise su ile su olmayan alanları ayırt edecek eşik değer her NDVI görüntüsü için Otsu yöntemi bulunmaktadır (Otsu, 1979). Daha sonra baraj su yüzey alanı hesaplanmaktadır ve zaman serileri oluşturulmaktadır (Donchyts vd., 2022).

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR} \quad (1)$$

Yukarıdaki formülde, "GREEN" terimi yeşil bandı, "NIR" terimi ise yakın kızılötesi bandını ifade etmektedir. NDWI ile hesaplanan görüntünün piksel değerleri -1 ile +1 arasında değişmektedir. Kabaca, su içeren pikseller 0'dan büyük değer alırken, su olmayan piksellerin negatif değer almaktadır (McFeeters, 1996).

Tablo 3. SCL bandının piksel etiketleri ve karşılıkları

Piksel No	Sınıf
0	Veri yok
1	Doymuş ya da hasarlı
2	Gölgeler
3	Bulut gölgeleri
4	Bitki örtüsü
5	Bitki örtüsü olmayan
6	Su
7	Sınıflandırılmamış
8	Orta bulut olasılığı
9	Yüksek bulut olasılığı
10	İnce sirus bulutu
11	Kar


2.2.4 HydroLAKES veri tabanı

HydroLAKES en az 10 hektarlık yüzeye sahip göl alanlarının sınır verileri içeren global bir veri tabanıdır. Bu veri tabanında her göl için sınır uzunluğu, ortalama derinlik, su hacmi, suyun kalma süresi ve öznelik bilgileri mevcuttur (HydroSHEDS, 2024). Bu veri tabanından Kadıköy Barajının sınır vektör verisi indirilmiştir ve bu sınır verisine 500 m tampon uygulanmıştır.

2.3 Yöntem

Çalışmada ilk olarak Sentinel-2 uydu misyonunun Level 2A görüntüleri, Sentinel uydu programı API web hizmeti kullanılarak indirilmiştir ve tüm görüntüler iş akışına koyulmuştur (Copernicus Data Space Ecosystem, 2024). Bu görüntülerdeki Bant 3, Bant 8, Bant 11 ve SCL bandı, tamponlanmış Kadıköy Baraj alanının sınırlarına göre kesilmiştir. Daha sonra, SCL bandında bulut olarak işaretlenmiş pikseller sayılarak baraj üzerindeki bulutluluk oranı hesaplanmıştır. Eğer bulutluluk oranının %1'den fazla çıktığı durumda ilgili gün bulutlu sayılarak baraj yüzey alanı algoritmasının iş akışı bir sonraki aşamaya geçmeden sonlandırılmaktadır. Eğer bulutluluk oranı %1'den az ise bir sonraki aşamaya geçerek 20 m çözünürlüğündeki SWIR-1 bandı evrişimli sinir ağı yöntemiyle 10 m çözünürlüğe yükseltilmektedir. Ardından Yeşil (GREEN) ve SWIR-1 bantlar ile eşitlik (2) kullanılarak MNDWI hesaplanmaktadır. MNDWI görüntülerinden OTSU yöntemiyle su ile su olmayan piksellerini ayıran eşik değer bulunmuştur. Bu eşik değer kullanılarak baraj su yüzey alanı haritaları elde edilmiştir. Ancak, bu baraj su yüzey haritalarındaki hatalı etiketlen su pikselleri "bağlantılı bileşen etiketleme algoritması" ile ayıklanmaktadır (Fiorio & Gustedt, 1996; Walt vd., 2014; Wu vd., 2005). En son oluşan baraj su yüzey haritasından baraj su yüzey alanı hesap edilerek zaman serileri oluşturulmaktadır.

Çalışmanın iş akışı Şekil 2'de sunulmuştur ve bu iş akışının baştan sonra otomasyonu, Rasterio, NumPy, GeoPandas ve scikit-image gibi çeşitli ücretsiz ve açık kaynaklı kütüphaneler kullanılarak Python programlama dilinde yazılan program ile gerçekleştirilmektedir. Sentinel-2 SWIR-1 bandının çözünürlük artırma kısmı ise Lanaras tarafından (2024) geliştirilen Python kodu ile sağlanmıştır.



Şekil 2. Çalışmanın iş akışı

2.3.1 Modifiye edilmiş normalize fark su indeksi (MNDWI)

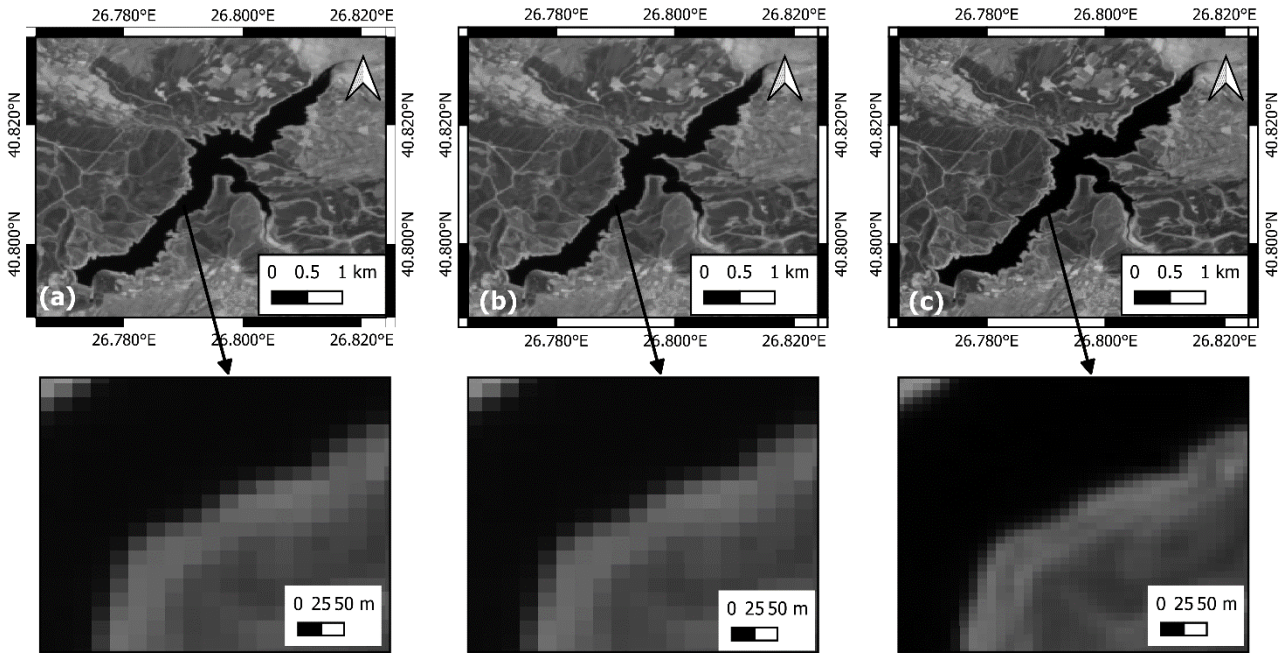
McFeeters (1996) tarafından geliştirilen NDWI indeksi, uydu görüntülerinde su yüzey alanlarını bulmak amacıyla geliştirilmiştir. Ancak, yapılaşma olan bölgelerde bu indeksin performansının düşük olduğu için Xu (2006) tarafından alternatif bir indeks olan MNDWI geliştirilmiştir (Li vd., 2013; Xu, 2006). Formül (2)'de verilen MNDWI, uydu görüntülerindeki su yüzey alanlarının belirlenmesinde yaygın olarak kullanılmaktadır (Davranche vd., 2010; Duan & Bastiaanssen, 2013; Feyisa vd., 2014; Hui vd., 2008; Pan vd., 2020).

$$MNDWI = \frac{GREEN - SWIR1}{GREEN + SWIR1} \quad (2)$$

Formüldeki "GREEN" terimi yeşil bandı, "SWIR" terimi ise kısa dalga kızılötesi bandını ifade etmektedir. Pozitif ve negatif MNDWI değerleri sırasıyla su ve su olmayan sınıfları göstermektedir (Xu, 2006).

2.3.2 SWIR-1 bandının mekânsal çözünürlüğünün iyileştirilmesi

MNDWI hesabında GREEN ve SWIR-1 bantları kullanılmaktadır. Ancak, Sentinel-2 görüntülerindeki yeşil bantı 10 m'lik mekânsal çözünürlüğünde olmasına rağmen, kısa dalga kızılötesi bantın mekânsal çözünürlüğü 20 m'dir. Bundan dolayı NDWI'dan 10 m çözünürlüğünde baraj su yüzey alanı haritaları oluşturulabilmesine rağmen MNDWI'dan 20 m çözünürlüğünde haritalar oluşturulmaktadır. MNDWI'dan da 10 m çözünürlüğünde baraj su yüzeyi haritaları oluşturulabilmesi için SWIR bantının çözünürlüğü iyileştirilmelidir. Bu amaçla, Lanaras vd. (2018) tarafından evrişimli sinir ağları (CNN; Convolutional Neural Network) derin öğrenme yöntemi kullanılarak geliştirilen DSen2 adlı algoritma ile SWIR-1 bantı 10 m mekânsal çözünürlüğe indirilmiştir. CNN, karmaşık veri yapılarını analiz ederek öğrenebilmektedir ve böylece kısa dalga kızılötesi bantlarının düşük çözünürlüklerini yüksek çözünürlüğe çevirebilmektedir. CNN tabanlı DSen2 dünyanın farklı iklim bölgelerinde bulunan farklı arazi örtüsü sınıflarına göre eğitildiği için dünyanın her yerinde tüm arazi örtüsü sınıfları ile hızlı ve verimli çalışabilen bir genel çözünürlük yükseltme algoritmasıdır. DSen2 metodunda 20 m'lik ve 60 m'lik Sentinel-2 bantlarını 10 m'ye yükselten iki tane CNN algoritması eğitilmiştir. DSen2 yöntemi literatürde bulunan diğer çözünürlük artırma yöntemlerine göre %50 ve üzeri daha düşük karesel ortalama hata vermiştir (Lanaras vd., 2018). DSen2 yönteminin Python programlama dilinde geliştirilen çözünürlük iyileştirme iş akışının kodu github'da sunulmaktadır (Lanaras, 2024) ve bu kod iş akışına dahil edilerek SWIR bantının çözünürlüğü artırılmıştır. SWIR-1 bantının DSen2 ve en yakın komşu yöntemi 10 m'ye çözünürlüğü yükseltilmiş örnekleri Şekil 3'te gösterilmiştir.




Şekil 3. a) 20 m çözünürlüklü orijinal SWIR-1 bantı, b) en yakın komşu ile yeniden 10 m'ye örneklenen SWIR-1 bantı ve c) DSen2 yöntemi ile 10 m'ye yükseltilen SWIR-1 bantı üzerinde Kadıköy Barajının genel görünümü. Alt görüntülerde baraj sınırına yaklaştırılmış bir kesit verilmiştir

2.3.3 OTSU eşikleme yöntemi

McFeeters (1996) ve Xu (2006) tarafından yapılan çalışmalara göre, NDWI ve MNDWI görüntülerinde yüzey su alanlarının belirlenmesinde 0 sabit eşik değeri kullanılmaktadır ve bu eşikten büyük değerler su olarak değerlendirilmektedir (McFeeters, 1996; Xu, 2006). Ancak, bu eşik değerinin sabit kalmadığı ve görüntülerin toplanma zamanına ve spektral değişimlere bağlı olarak değiştiği görülmüştür (Du vd., 2016; Li vd., 2013).

Bu nedenle, su yüzey alanlarının bulunması dinamik olarak eşik değerlerinin hesaplanması gerektiği ortaya konmuştur (Bai vd., 2011; Donchyts vd., 2022; Ji vd., 2009). Bu çalışmada, yukarıdaki çalışmalara paralel olarak OTSU algoritması ile optimal eşik değerler dinamik olarak bulunmuştur. OTSU yöntemi, sınıf içi varyansı minimum, sınıflar arası varyansı ise maksimum yapan eşik değerini belirlemektedir. Bu sayede, pikseller arasındaki ayrımı en üst düzeye çıkarıp, iki farklı sınıfa yerleştirmektedir (Otsu, 1979).

16.11.2023 tarihinde toplanan Sentinel-2 görüntüsünden hesaplanan MNDWI histogramı Şekil 4'te verilmiştir. Bu histograma göre, MNDWI değerleri iki tepeli dağılım göstermektedir. Bu histogramın sol tarafındaki tepe ve etrafında su olmayan pikseller ve sağ tarafındaki tepe ve etrafında su olan pikseller toplanmıştır. Mor eğri iki sınıf arasındaki varyans eğrisini ifade etmektedir. OTSU metodu bu iki sınıf arasındaki varyansın en yüksek değere ulaştığındaki MNDWI değerini seçmektedir. Bu tarihte su piksellerini su olmayan piksellerden ayıran eşik değeri -1241 olarak bulunmuştur.



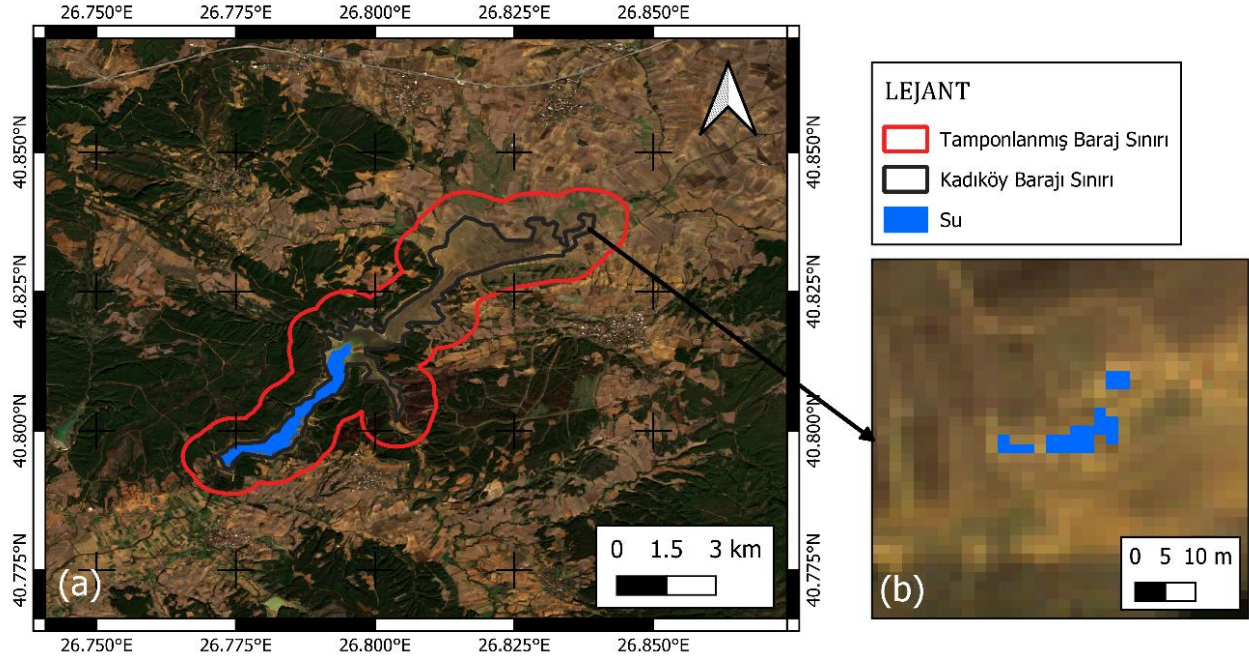
Şekil 4. 16.07.2015 tarihindeki Sentinel-2 görüntülerinden oluşan MNDWI histogramı. Mor eğri iki sınıf arasındaki varyans eğrisini ifade etmektedir

3. Bulgular

Elde edilen bulgular dört başlıkta sunulmuştur. İlk olarak oluşturulan yüzey su haritalarından hatalı su piksellerinin ayrıştırılması gösterilecektir. Daha sonra çalışma kapsamında iki farklı eşik değeri yöntemi kullanılarak elde edilen su yüzey alanları, GWW platformu ve SCL bandından elde edilen su yüzey alanları ile karşılaştırılacaktır. Üçüncü olarak, OTSU yöntemi ile bulunan MNDWI eşik değerlerinin frekans dağılımı incelenecektir. Son olarak ta 4 farklı yöntem ile elde edilen Kadıköy Barajı su yüzey alanları arasındaki bağıl hata hesapları gösterilecektir.

3.1 Su Yüzey Haritalarının Hatalı Piksellerden Arındırılması

Çalışma kapsamında üretilen baraj su yüzeyi haritaları görsel olarak incelendiğinde 500m tamponlanmış baraj sınırları ile kesilen bölgede baraj ile ilgili olmayan ve su olarak etiketlenmiş pikseller sıklıkla görülmüştür (Şekil 5). Bu haritadan baraj su yüzey alanı su olarak etiketlenen pikseller sayılarak elde edildiği için baraj yüzey alanı hatalı hesaplanmaktadır. Genel olarak bakıldığında, hatalı etiketlenen su pikselleri baraj alanına göre çok küçük bir alan kapsamaktadır. Bağlantılı bileşen etiketleme algoritması otomatik olarak su yüzey alanı haritasındaki birbiri ile bağlantılı en büyük objeyi, diğer bir deyişle baraj su yüzey alanını, bulduktan sonra diğer küçük objeleri, diğer bir deyişle baraj ile ilgili olmayan küçük su bölgelerini, "su değil" diyerek işaretlemektedir. Bundan dolayı, baraj su yüzeyi alanı, OTSU ile elde edilen su yüzey haritasına bağlantılı bileşen etiketleme algoritması uygulandıktan sonra hesaplanmaktadır ve baraj ile ilgili olmayan ancak su olarak etiketlenen pikseller baraj su yüzey alanı hesabına katılmamaktadır.



Şekil 5. 16.11.2023 tarihinde OTSU eşikleme yöntemiyle elde edilen su yüzey haritası: a) hatalı etiketlenen su pikselleri, b) barajın sınır verisi Hydrolakes veri tabanından alınmıştır


3.2 Su Yüzey Alanı Sonuçlarının Karşılaştırılması

2015-2023 yılları arasında GWW platformundaki Kadıköy Barajı'nın su yüzey alanları ile çalışma kapsamında geliştirilen MNDWI_OTSU modeliyle üretilen su yüzey alanları karşılaştırılmıştır (Şekil 6). Sonuçlara göre iki farklı yöntemden üretilen su yüzey alanları arasında doğrusal ($m=0.991$) ve çok güçlü bir ilişki görülmektedir ($R^2=0.993$). Baraj alanı düşük, orta ve yüksek seviyede olduğunda her iki yöntem birbirine çok yakın sonuçlar vermektedir. Ancak, baraj alanı 2-3 km² arasında olduğunda GWW barajın yüzey alanın daha fazla hesapladığı görülmektedir.


GWW (Şekil 7) ve MNDWI_OTSU (Şekil 8) baraj su yüzey alanı değişimleri zamansal olarak incelenmiştir. Her iki yüzey alanı zaman serilerinde benzer mevsimsel dalgalanmalar görülmektedir. Örneğin, 2015-2023 yılları arasında barajın su yüzey alanı her yılın Mayıs ayında en yüksek değere ulaşmıştır. Aynı şekilde, baraj yüzey alanı en düşük değere her yılın Aralık ayında ulaşmıştır.

GWW ve MNDWI_OTSU baraj su yüzey alanı zaman serileri görsel olarak benzer değişimler gösterse de GWW sonuçlarında (Şekil 7) bazı ani değişimler gözlemlenmektedir. Örneğin, 2016 yılının Ocak ayında baraj yüzey alanı beş gün içinde 1.5 km²'den 3.5 km² fırladığı görülmekte ve daha sonraki beş günde içinde tekrar 1.5 km² seviyesine gerilediği gözlemlenmiştir. Aynı şekilde, 2023 Mayıs ayında baraj su yüzey alanının çok kısa bir sürede 1.5 km²'den 4.5 km² arttığı gözlemlenmekte ve daha sonra tekrar 1.5 km² seviyesine düştüğü görülmektedir. Böyle ani artış ve düşüşler, 2015-2023 yılı arasındaki GWW sonuçlarında 10'dan fazla görülmektedir. Baraj su yüzey alanında böyle %100'den fazla ani değişimlerin fiziksel olarak görülmesi mümkün olmadığı için GWW platformunda kullanılan algoritmada bazı sıkıntılar olduğu görülmektedir.

GWW sonuçlarına kıyasla, MNDWI_OTSU (Şekil 8) yöntemi ile üretilen baraj su yüzey alanı zaman serilerinde ani değişimler görülmemiştir. Her iki yöntemde baraj su yüzey alanlarında benzer mevsimsel eğilimleri görülmesine karşın, MNDWI_OTSU yönteminde baraj su yüzey alanı zamansal olarak beklendiği gibi yavaş değişim göstermektedir. GWW sonuçlarında görülen ani değişimlerin yaşandığı tarihlerde MNDWI_OTSU yöntemi baraj su yüzey alanı hesabı yapılmadığı görülmüştür. MNDWI_OTSU yönteminde %1'den fazla bulutlu günlerde hesap yapılmadığı düşünüldüğünde, GWW yönteminde, bulutlar ile su yüzeyinin birbirine karıştırıldığı düşünülmektedir. Örneğin, baraj yüzey alanı ani artış gösterdiği günlerde, GWW bulutlu pikselleri su pikseli olarak etiketlemekte ve suni olarak baraj yüzey alanını arttırmaktadır.




Şekil 6. GWW ile MNDWI_OTSU su yüzey alanları arasındaki saçılım grafiği




Şekil 7. 2015-2023 yılları arasındaki Global Water Watch (GWW) tarafından hesaplanan Kadıköy Barajı su yüzey alanı değişimleri

SCL katmanında su olarak etiketlenen piksellerden hesaplanan (SCL_SU) Kadıköy Barajı su yüzey alanları (Şekil 9), MNDWI_OTSU yöntemi (Şekil 8) ile hesaplanan alanlar ile karşılaştırılmıştır. Sonuçlara göre SCL_SU ve MNDWI_OTSU yöntemiyle üretilen su yüzey alanları arasında güçlü bir ilişki (Şekil 10) görülmesine rağmen ($R^2=0.8355$), GWW ile MNDWI_OTSU arasında görülen ilişki kadar çok güçlü değildir. Bazı günlerde SCL_SU ile hesaplanan baraj su yüzey alanları, MNDWI_OTSU ile hesaplanan baraj su yüzey alanlarına göre çok daha düşüktür. Genel olarak SCL_SU sonuçlarında negatif bir bias ($m=0.836$) görülmektedir (Şekil 10).

MNDWI_OTSU (Şekil 8) ve SCL_SU (Şekil 9) yoluyla elde edilen baraj su yüzey alanları zamansal olarak incelenmiştir. Eğer ani değişimlerin yaşandığı tarihler dikkate alınmadığında, her iki yüzey alanı zaman serilerinde benzer mevsimsel dalgalanmalar görünmektedir. Genel olarak baraj su yüzey alanı 2015-2023 tarihleri arasında en yüksek değere her yılın Mayıs ayında en düşük değere ise Aralık ayında ulaştığı görülmektedir. Ancak, SCL_SU bandıyla elde edilen baraj su yüzey alanlarındaki ani değişimler barajın mevsimsel değişim analizini olumsuz etkilemektedir.




Şekil 8. 2015-2023 yılları arasında MNDWI_OTSU yöntemi kullanılarak hesaplanan Kadıköy Barajı su yüzey alanı değişimleri




Şekil 9. 2015-2023 yılları arasında SCL bandındaki su pikselleri sayılarak (SCL_SU) elde edilmiş Kadıköy Barajı su yüzey alanı değişimleri

SCL_SU ve MNDWI_OTSU baraj su yüzey alanı zaman serileri görsel olarak incelendiğinde benzer görülsa de SCL_SU sonuçlarında (Şekil 9) sıklıkla ani değişimler gözlemlenmektedir. Örneğin, SCL_SU bandı 2017 yılının Ağustos ve Eylül aylarında barajda hiç su kalmadığını göstermektedir. Ancak baraj alanı 0 km² düştükten sonra kısa sürede (5 gün) tekrardan 1.75 km² çıktığını göstermektedir. Aynı şekilde, 2018 yılının haziran ayında baraj alanı kısa sürede 5.75 km²'den 3 km² düştükten sonra 5.5 km²'ye çıktığı görülmektedir. İlaveten, 2019 yılının mayıs ayında baraj su yüzey alanı 10 gün içinde yaklaşık 5.5 km²'den 3km² düştükten sonra tekrardan 5.5 km²'ye çıktığı gözlenmiştir. GWW yöntemine göre SCL_SU sonuçlarında ani değişimler daha çok ve daha yüksek olduğu görülmüştür. Baraj su yüzey alanında böyle %100'den fazla ani değişimlerin fiziksel olarak görülmesi mümkün olmadığı için SCL_SU bandındaki su piksellerini işaretleyen algoritma sıklıkla hatalı sonuçlar ürettiği görülmektedir.

Su yüzey alanları, her görüntüden OTSU yöntemi ile dinamik eşik değeri bulanarak ayırt edilmesine karşın, 0 sabit eşik değeri kullanılarak da bulunmaktadır (Feyisa vd., 2014; Xu, 2006; Yağmur vd., 2020). Çalışma kapsamında üretilen MNDWI sonuçlarında 0'dan büyük pikseller su olarak etiketlenerek (MNDWI_0), 2015-2023 yılları arasında Kadıköy Barajı su yüzey alanı hesabı yapılmıştır. Sonuçlara göre (Şekil 11), GWW yönteminde olduğu gibi iki farklı yöntemden üretilen su yüzey alanları arasında doğrusal ($m=0.995$) ve çok güçlü bir ilişki görülmektedir ($R^2=0.9965$). Diğer iki yöntemde göre (GWW ve SCL_SU), en yüksek ilişki MNDWI_0 ve MNDWI_OTSU yöntemlerinde görülmüştür.



Şekil 10. SCL bandındaki su pikselleri sayılarak (SCL_SU) elde edilmiş zaman serisi ile MNDWI_OTSU zaman serisinin saçılım grafiği




Şekil 11. MNDWI_0 ve MNDWI_OTSU zaman serilerinin saçılım grafiği

MNDWI_OTSU (Şekil 8) ve MNDWI_0 (Şekil 12) yöntemleri ile elde edilen baraj su yüzey alanları zamansal olarak incelenmiştir. Her iki yüzey alanı zaman serilerinde benzer mevsimsel dalgalanmalar görülmektedir. Örneğin, 2015-2023 yılları arasında barajın su yüzey alanı her yılın Mayıs ayında en yüksek değere ulaşmıştır. Aynı şekilde, baraj yüzey alanı en düşük değere her yılın Aralık ayında ulaşmıştır. Diğer iki yöntemin (GWW ve SCL_SU) sonuçlarında görülen aykırı değerler MNDWI_0 yöntemi sonuçlarında görülmediği için baraj su yüzey alanındaki mevsimsel değişimler kolaylıkla ayırt edilmektedir.

MNDWI_0 yöntemi ile elde edilen baraj su yüzey alanı sonuçları (Şekil 12) incelediğinde, GWW ve SCL_SU sonuçlarına göre çok daha az aykırı değerler görülmüştür. Örneğin, 13.04.2018 tarihinde (Şekil 12’de ok ile gösterilen tarih) baraj su yüzey alanı %10’luk bir düşüş gösterdikten sonra tekrardan 10 gün önceki değere geri gelmiştir. 10 gün içerisinde baraj su yüzey alanında bu kadar büyük bir değişim mümkün olmadığı için bu tarihteki sonuçlar güvenilir olmadığı düşünülmektedir.


Özetle, 2015-2023 yılları arasındaki Kadıköy Barajı su yüzey değişimleri (Şekil 7, Şekil 8, Şekil 9 ve Şekil 12) ani değişim veya aykırı değer görülme sayısına göre değerlendirildiğinde, MNDWI_OTSU yöntemi en güvenilir sonuçlar ürettiği bulunmuştur. İkinci olarak MNDWI_0 yöntemi, üçüncü olarak GWW ve en kötü SCL_SU sonuçları olduğu görülmüştür.



Şekil 12. 2015-2023 yılları arasında MNDWI ve 0 sabit eşik değeri kullanılarak (MNDWI_0) elde edilen Kadıköy Barajı su yüzey alanı

3.3 Eşik değerlerinin incelenmesi

2015-2023 yılları arasında MNDWI_OTSU yöntemi su piksellerini bulmak için her görüntüde dinamik olarak eşik değeri hesaplamaktadır. Hesaplanan bu eşik değerlerinin frekans grafiği Şekil 13’de verilmiştir. Eşik değerlerin en çok -250 ile 0 aralığında olduğu görülmektedir. İkinci olarak -500 ile -250 ve üçüncü olarak 0 ile 250 aralığında olduğu gözlemlenmiştir. Özetle, MNDWI görüntülerinde su piksellerini diğer arazi sınıfı piksellerinden ayırmak için kullanılan eşik değerinin her zaman MNDWI_0 sabit eşik değerinde kullanılan 0 veya 0'a yakın değerler almadığını göstermektedir.



Şekil 13. MNDWI_OTSU eşik değerlerine göre piksel değerlerinin dağılımı

3.4 Bağlı hata hesapları

2015-2023 yılları arasındaki Kadıköy Barajı su yüzey alanı değişimleri, 4 farklı yöntem kullanılarak hesaplanmıştır (Şekil 7, Şekil 8, Şekil 9 ve Şekil 12). Bu sonuçlar arasında fiziksel olarak mümkün olmayan ani değişimler veya aykırı değerler MNDWI_OTSU yöntemi sonuçlarında en az görülmüştür (Şekil 8). Ondan dolayı, MNDWI_OTSU yöntemi sonuçları ile diğer 3 yöntemden (GWW, SCL_SU, MNDWI_0) elde edilen sonuçlar arasında bağlı hata değerleri aşağıdaki formülle (3) hesaplanmıştır.

$$\text{Bağlı hata} = \left| \frac{e - o}{o} \right| \times 100 \quad (3)$$

e ve o sırasıyla GWW, SCL_SU, MNDWI_0 yöntemlerinden biri ile hesaplanmış Kadıköy Barajı su yüzey alanını ve MNDWI_OTSU yöntemi ile hesaplanmış Kadıköy Barajı su yüzey alanını ifade etmektedir. GWW, SCL_SU, MNDWI_0 yöntemlerinin MNDWI_OTSU yöntemine göre 2015-2023 yılları arası ortalama ve 2015-2023 yılları arasında görülen ortalama, minimum ve maksimum bağlı hata miktarları 'te sunulmuştur.

Tablo 4. 2015-2023 yılları arasında GWW, SCL_SU, MNDWI_0 yöntemlerinin MNDWI_OTSU yöntemine göre ortalama, ortalama, minimum ve maksimum bağlı hata (%) miktarları

Yöntem	Ortalama (%)	Ortanca (%)	Minimum (%)	Maksimum (%)
MNDWI_0	3.103	2.746	0.017	9.890
SCL_SU	12.862	6.157	0.020	100.000
GWW	3.721	2.132	0.016	39.774

Su yüzey alanı değişimleri görsel sonuçlarında olduğu gibi, MNDWI_OTSU yöntemi ile MNDWI_0 yöntemi arasında en düşük ortalama bağlı hata (%3.103) görülmüştür. İkinci en düşük ortalama hata, MNDWI_OTSU ile GWW (%3.721) ve en yüksek bağlı hata MNDWI_OTSU ile SCL_SU (%12.862) sonuçlarında görülmüştür. Her üç yöntemin MNDWI_OTSU yöntemine göre minimum hataları birbirine benzer olmasına rağmen, maksimum hatalarında büyük farklar vardır. Bazı günlerde baraj su alanı hesaplarında MNDWI_OTSU ile SCL_SU arasında %100'e varan farklar görülmektedir. MNDWI_OTSU ile MNDWI_0 arasındaki en yüksek fark %9.89 olmasına karşın, MNDWI_OTSU ve GWW arasındaki en yüksek fark %39.774 olarak görülmüştür.

Ortalama bağlı hata değerleri sonuçlarından farklı olarak, en düşük ortanca bağlı hata değeri MNDWI_OTSU ile GWW arasında görülmüştür. Daha sonra, ikinci olarak en düşük ortanca değeri MNDWI_OTSU ve MNDWI_0 arasında görülmüştür. En kötü ortanca bağlı hata değeri, ortalama bağlı hata değeri sonuçlarında olduğu gibi MNDWI_OTSU ve SCL_SU sonuçları arasında görülmüştür. Ortanca bağlı hata değerleri, MNDWI_OTSU ile GWW sonuçlarının daha yakın olduğunu göstermektedir. Ancak, GWW sonuçlarındaki bazı aykırı değerler ortalama bağlı hatayı yükselttiği için MNDWI_OTSU ile MNDWI_0 arasındaki ortalama bağlı hata daha düşük gelmiştir. GWW sonuçlarında 2016 ve 2023 yıllarında (Şekil 7'de) görülen aykırı değerler hata hesaplarından çıkarıldığında hem MNDWI_OTSU ile GWW yöntemleri arasında görülen hem ortalama hem de ortanca bağlı hata miktarları düşmektedir.

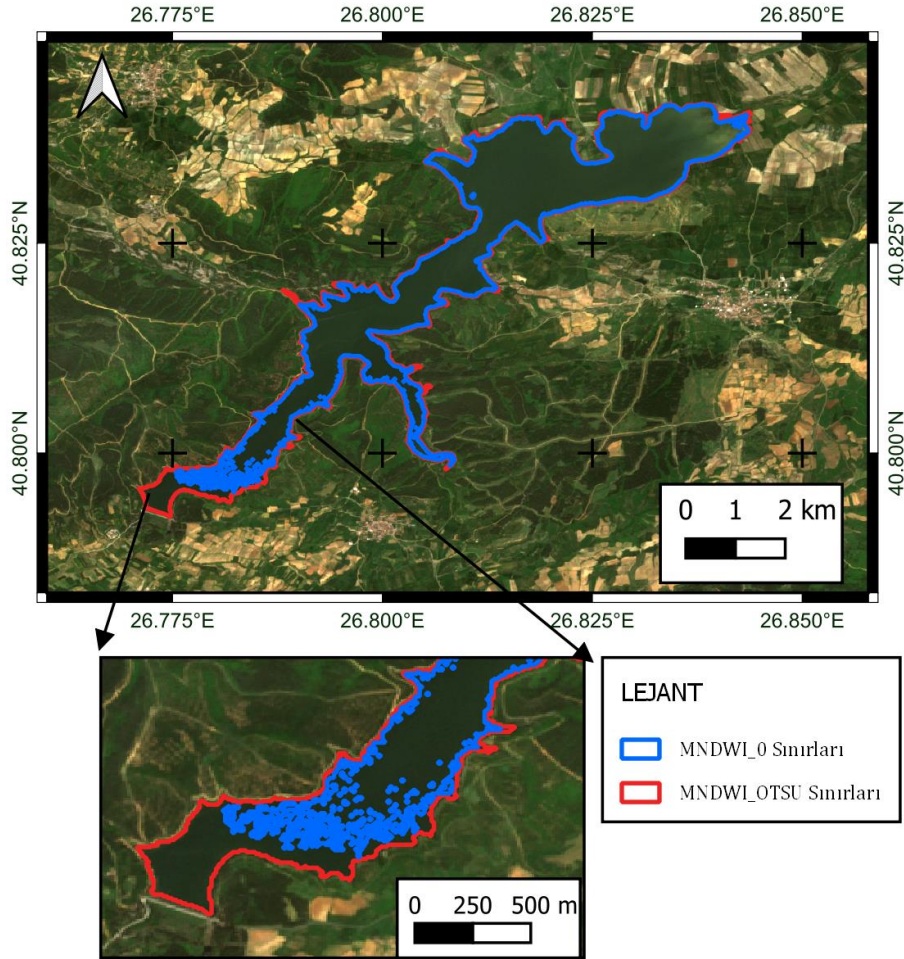
4. Tartışma

Elektromanyetik spektrumun optik bölgesinde toplanan görüntülerde en önemli sorun bulutlardır. Sensör bulutlardan yeryüzünü göremediği için bulutlar altında kalan bölgenin hangi arazi örtüsü ve kullanımı sınıfa dahil olduğunu belirlemez. Yarı bulutlu günlerde, bulutlar ve bulut gölgesi benzer spektral değerlere sahip olduğu için yanlışlıkla su olarak sınıflandırılmaktadır. Örneğin, bulutluluk dikkate alınmadan ve bulutlar maskelenmeden MNDWI_OTSU ve MNDWI_0 yöntemi ile Kadıköy Baraj su yüzey alanı değişimleri hesaplandığında, GWW yönteminde (Şekil 7) 2023 yılında görülen ani değişimler ve aykırı değerler sıklıkla görülmüştür. Ondan dolayı, SCL bandında belirtilen bulut ve bulut gölgesi pikselleri baraj su yüzey alanının %1'den fazla olduğunda hesaplama yapılmamıştır.

Doğrudan bulut filtrelemesi yapmayıp farklı yöntemlerden yararlanan çalışmalarda mevcuttur. Örneğin, GWW, Level-1 Sentinel-2 ve Landsat uydu misyonları kullandığı için parlak görüntülerin filtrelenmesi yöntemi diye adlandırdığı bir yöntem ile bulutları analizden çıkarmaya çalışmaktadır. Bu yöntemde, bulut maskesi açıkça uygulanmamış, bunun yerine global bulut sıklığı veri seti kullanılarak bölgenin üzerindeki en parlak görüntüler filtrelenmiştir. Bu süreçte, her görüntü için atmosferin üstündeki yansıma değeri (TOA) hesaplanmış ve bu değer kullanılarak parlak görüntüler filtrelenmiştir (Donchyts vd., 2022). Bu şekilde, bulutlarla tamamen kaplı görüntüler çalışma dışı bırakılmıştır.

JRC GSW veri tabanında ise uzman sistemi olarak bilinen bir algoritma kullanılarak coğrafi ve zamansal bilgi kullanarak bulut gölgeleri ve diğer optik engelleri tespit etmektedir. Bu yöntemde suyun yansımaya değerlerinin zaman içinde nasıl değiştiğini analiz edilerek bulut ve gölge etkisini minimize etmektedir (Pekel vd., 2016).

Çok yaygın kullanılan basit çözünürlük yükseltme algoritmaları en yakın komşu, çift lineer ve çift kübik yöntemlerdir ancak çalışma kapsamında SWIR-1 bandının çözünürlük iyileştirilmesi CNN tabanlı DSen2 yöntemi ile yapılmıştır. En yakın komşu ile çözünürlük artırıldığında histogram şekli değişmediği için baraj yüzey alanlarında herhangi bir değişim olmamaktadır (Şekil 3). Çift lineer ve çift kübik yöntemleri ile çözünürlük artırıldığında görüntüler bulanıklaşmaktadır ve Sentinel-2 görüntülerinin çözünürlükleri iyileştirildiğinde kullanılan yöntemler arasında en yüksek karesel ortalama değeri çift kübik yöntemi vermiştir (Lanaras vd., 2018).



Şekil 14. 13.04.2018 tarihli (Şekil 12’de ok ile gösterilen tarih) Sentinel-2 görüntülerinden MNDWI_0 ve MNDWI_OTSU yöntemleriyle üretilen Kadıköy Barajı su yüzey alanlarının sınırları

Her ne kadar MNDWI_OTSU ve MNDWI_0 yöntemi arasında ortalama bağıl hata daha düşük olmasına rağmen ortanca bağıl hata değerleri dikkate alındığında MNDWI_OTSU ve GWW yöntemi birbirine daha yakın sonuçlar vermiştir. Buna sebep olarak OTSU yönteminde bulunan eşik değerlerin her zaman 0 ve 0’ yakın değerler almayıp bazı günler negatif bazı günler pozitif değerler aldığı gösterilebilir (Şekil 13). Ek olarak, GWW’de baraj su yüzey alanları NDWI_OTSU yöntemi ile hesaplanmaktadır. Eğer GWW su yüzeyi zaman serisinde görülen aykırı değerler çıkarıldığında ortalama bağıl hata da düşmektedir.

Eşik değeri seçiminin Kadıköy Barajı su yüzey haritası etkisi incelenmiştir. Örnek olarak, MNDWI_OTSU ve MNDWI_0 yöntemleriyle elde edilen 13.04.2018 tarihli (Şekil 12’de okla gösterilen aykırı değer) yüzey su alanı haritası karşılaştırılmıştır (Şekil 14). Bu tarihte MNDWI_OTSU yöntemi -1032’yi eşik değeri olarak hesaplamıştır. MNDWI_0 yönteminde ise 0 eşik değeridir. Bundan dolayı, MNDWI_0 yöntemi su alanını 5.30 km² belirlerken, MNDWI_OTSU yöntemi su alanını 5.80 km² olarak hesaplamıştır. Bu durumda barajın sınır bölgelerinde güneybatı bölümündeki büyük bir alan, su olarak değerlendirilmemiştir. Sabit eşik değeri yöntemi bazı günlerde baraj alanını daha büyük bazı günlerde ise daha düşük bulmaktadır.

GWW yönteminde görülen aykırı değerler GWW yönteminde kullanılan bulut algoritmasının her zaman düzgün çalışmadığını göstermektedir. Ondandır, Level-1 Landsat veya Sentinel-2 görüntülerinden hesaplanacak baraj su yüzey alanlarında, farklı bulut algoritmaları kullanılması uygun olacaktır. Örneğin, Qiu vd. (2019) tarafından geliştirilen Fmask algoritması da bulut ve bulut gölgelerinin tespiti yaygın kullanılmaktadır. Fmask, Level-1 Landsat 4-9 ve Sentinel-2 görüntülerinden bulut ve bulut gölgelerinin otomatik olarak tespit edebilmektedir. Bu algoritma, yardımcı veri entegrasyonu, yeni bulut olasılıkları ve spektral-bağlamsal özellikler gibi yenilikçi iyileştirmeler içermektedir. Fmask, özellikle Sentinel-2 görüntülerinde daha yüksek doğruluk sağladığı belirtilmiştir (Qiu vd., 2019). SCL katmanı Level-2 Sentinel-2 görüntüleriyle gelmektedir. Yakın zamanlı sonuç gerektiren uygulamalarda, Sentinel-2 görüntülerinin Level-2 düzeyine çıkarılması beklemek yerine Level-1 Sentinel-2 görüntüleri ve Fmask ile bulut maskesi oluşturularak baraj su yüzey alanları daha hızlı hesaplanabilir.

5. Sonuçlar

Bu çalışmada, Kadıköy Barajı'nın 2015-2023 yılları arasındaki su yüzey alanı değişimleri, Sentinel-2 misyonu kapsamında toplanmış uydu görüntüleri kullanılarak tam otomatik bir şekilde belirlenmiştir. CNN yöntemi ile SWIR-1 bandının çözünürlüğünün artırılması sayesinde MNDWI görüntüleri 10m mekânsal çözünürlükte elde edilmiştir. MNDWI_OTSU yöntemi, diğer yöntemlere göre su yüzey alanlarını belirlemede daha tutarlı ve güvenilir sonuçlar verdiği görülmektedir. Ayrıca, SCL bandı kullanılarak %1'den fazla bulutluluk oranına sahip günlerde baraj yüzeyi alanı hesabı yapılmadığı için sonuçların güvenilirliği önemli ölçüde artmıştır. Bu yöntemde, su sınıfının diğer yeryüzü sınıflarında ayrıştırmak için kullanılan eşik değerlerinin her zaman sabit olmadığı görülmüştür. GWW ve MNDWI_0 yöntemleri ile MNDWI_OTSU yöntemi sonuçları arasında güçlü bir doğrusal ilişki bulunmuştur. En kötü sonuçlar SCL_SU sonuçlarında görülmüştür.

Baraj su yüzey alanı zaman serileri incelendiğinde Kadıköy Barajı 2018 ve 2019 yıllarında su yüzey alanının 6 km²'ye kadar çıktığı görülmektedir ve barajın tam dolu olduğu gözlemlenmiştir. 2020 yılında yaşanan kuraklıktan sonra baraj su yüzey alanı 2021 yılında 1km² kadar düşmüştür. 2020-2023 yılları arasında baraj su yüzey alanı 3 km² üzerine hiç çıkmamıştır. 2023 yılı sonu itibarıyla, 2020 yılındaki kuraklıktan sonra tekrar tam kapasite dolmadığı görülmektedir.

Bu çalışma, uzaktan algılama teknolojisinin su yüzey alanı izleme ve su kaynaklarının yönetiminde etkin ve operasyonel bir şekilde kullanılabileceğini göstermektedir. Ayrıca, su yüzey alanı değişimlerinden geliştirilecek indeksler ile hidrolojik kuraklık izlenmesi gibi uygulamalara zemin oluşturabileceği düşünülmektedir. Ancak, yöntemin farklı bölgelerde bulunan baraj ve göller üzerinde test edilmesi planlanmaktadır.

Teşekkür

Bu çalışma TÜBİTAK 2525 kodlu Almanya Eğitim ve Araştırma Bakanlığı (BMBF) ile İkili İşbirliği Programı (Proje No: 120R065) kapsamında desteklenmiştir.

Kaynaklar

- Aggarwal, R., Kaushal, M., Kaur, S., & Farmaha, B. (2009). Water resource management for sustainable agriculture in Punjab, India. *Water Science and Technology*, 60(11), 2905-2911. <https://doi.org/10.2166/wst.2009.348>
- Albarqouni, M. M. Y., Yagmur, N., Bektas Balcik, F., & Sekertekin, A. (2022). Assessment of Spatio-Temporal Changes in Water Surface Extents and Lake Surface Temperatures Using Google Earth Engine for Lakes Region, Türkiye. *ISPRS International Journal of Geo-Information*, 11(7), Article 407. <https://doi.org/10.3390/ijgi11070407>
- Atiz, Ö. F., Alkan, T., & Durduran, S. S. (2023). Google Earth Engine Based Spatio-Temporal Changes of Bafa Lake from 1984 to 2022. *International Journal of Environment and Geoinformatics*, 10(3), 116-123.
- Bai, J., Chen, X., Li, J., Yang, L., & Fang, H. (2011). Changes in the area of inland lakes in arid regions of central Asia during the past 30 years. *Environmental Monitoring and Assessment*, 178(1), 247-256. <https://doi.org/10.1007/s10661-010-1686-y>
- Copernicus Data Space Ecosystem. (2024). *OpenSearch Catalog web service*. 16 Mayıs 2024'de <https://documentation.dataspace.copernicus.eu/APIs/OpenSearch.html> adresinden alındı.
- Davranche, A., Lefebvre, G., & Poulin, B. (2010). Wetland monitoring using classification trees and SPOT-5 seasonal time series. *Remote Sensing of Environment*, 114(3), 552-562. <https://doi.org/10.1016/j.rse.2009.10.009>
- Deltares (2024). *Global Water Watch*. 08 Mayıs 2024'de <https://www.globalwaterwatch.earth/reservoir/80987> adresinden alındı.
- Doğa Koruma ve Milli Parklar Genel Müdürlüğü. (2023). *Ulusal Sulak Alan Envanteri Yönetim Bilgi Sistemi*. 08 Mayıs 2024'de <https://saybis.tarimorman.gov.tr/> adresinden alındı.

- Donchyts, G., Winsemius, H., Baart, F., Dahm, R., Schellekens, J., Gorelick, N., ... & Schmeier, S. (2022). High-resolution surface water dynamics in Earth's small and medium-sized reservoirs. *Scientific Reports*, 12(1), Article 13776. <https://doi.org/10.1038/s41598-022-17074-6>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., ... & Bargellini, 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>
- Du, Y., Zhang, Y., Ling, F., Wang, Q., Li, W., & Li, X. (2016). Water Bodies' Mapping from Sentinel-2 Imagery with Modified Normalized Difference Water Index at 10-m Spatial Resolution Produced by Sharpening the SWIR Band. *Remote Sensing*, 8(4), Article 354. <https://doi.org/10.3390/rs8040354>
- Duan, Z., & Bastiaanssen, W. G. M. (2013). Estimating water volume variations in lakes and reservoirs from four operational satellite altimetry databases and satellite imagery data. *Remote Sensing of Environment*, 134, 403-416.
- Feyisa, G. L., Meilby, H., Fensholt, R., & Proud, S. R. (2014). Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment*, 140, 23-35. <https://doi.org/10.1016/j.rse.2013.08.029>
- Filipponi, F. (2019). Exploitation of Sentinel-2 Time Series to Map Burned Areas at the National Level: A Case Study on the 2017 Italy Wildfires. *Remote Sensing*, 11(6), Article 622. <https://doi.org/10.3390/rs11060622>
- Fiorio, C., & Gustedt, J. (1996). Two linear time Union-Find strategies for image processing. *Theoretical Computer Science*, 154(2), 165-181. [https://doi.org/10.1016/0304-3975\(94\)00262-2](https://doi.org/10.1016/0304-3975(94)00262-2)
- Firatli, E., Dervisoglu, A., Yagmur, N., Musaoglu, N., & Tanik, A. (2022). Spatio-temporal assessment of natural lakes in Turkey. *Earth Science Informatics*, 15(2), 951-964. <https://doi.org/10.1007/s12145-022-00778-8>
- Fuentes, I., Padarian, J., van Ogtrop, F., & Vervoort, R. W. (2019). Comparison of Surface Water Volume Estimation Methodologies That Couple Surface Reflectance Data and Digital Terrain Models. *Water*, 11(4), Article 780. <https://doi.org/10.3390/w11040780>
- Huang, S., Chen, X., Ma, X., Fang, H., Liu, T., Kurban, A., ... Van de Voorde, T. (2023). Monitoring Surface Water Area Changes in the Aral Sea Basin Using the Google Earth Engine Cloud Platform. *Water*, 15(9), Article 1729. <https://doi.org/10.3390/w15091729>
- Huang, Z., Xu, J., & Zheng, L. (2023). Long-Term Change of Lake Water Storage and Its Response to Climate Change for Typical Lakes in Arid Xinjiang, China. *Water*, 15(8), Article 1444. <https://doi.org/10.3390/w15081444>
- Hui, F., Xu, B., Huang, H., Yu, Q., & Gong, P. (2008). Modelling spatial-temporal change of Poyang Lake using multitemporal Landsat imagery. *International Journal of Remote Sensing*, 29(20), 5767-5784.
- HydroSHEDS (2024). *HydroLAKES*. 31 Ekim 2023'de <https://www.hydrosheds.org/products/hydrolakes> adresinden alındı.
- Ji, L., Zhang, L., & Wylie, B. (2009). Analysis of Dynamic Thresholds for the Normalized Difference Water Index. *Photogrammetric Engineering & Remote Sensing*, 75(11), 1307-1317. <https://doi.org/10.14358/PERS.75.11.1307>
- Karaman, M., & Özelkan, E. (2022). Comparative assessment of remote sensing-based water dynamic in a dam lake using a combination of Sentinel-2 data and digital elevation model. *Environmental Monitoring and Assessment*, 194(2), Article 92. <https://doi.org/10.1007/s10661-021-09703-w>
- Katusiime, J., & Schütt, B. (2020). Integrated Water Resources Management Approaches to Improve Water Resources Governance. *Water*, 12(12), Article 3424. <https://doi.org/10.3390/w12123424>
- Khattab, M. F. O., Abo, R. K., Al-Muqdadı, S. W., & Merkel, B. J. (2017). Generate Reservoir Depths Mapping by Using Digital Elevation Model: A Case Study of Mosul Dam Lake, Northern Iraq. *Advances in Remote Sensing*, 6(3), 161-174. <https://doi.org/10.4236/ars.2017.63012>
- Lanaras, C., Bioucas-Dias, J., Galliani, S., Baltsavias, E., & Schindler, K. (2018). Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 305-319. <https://doi.org/10.1016/j.isprsjprs.2018.09.018>
- Lanaras, C. (2024). *Super-Resolution of Sentinel-2 Images: Learning a Globally Applicable Deep Neural Network*. Jupyter Notebook. <https://github.com/lanha/DSen2>
- Li, W., Du, Z., Ling, F., Zhou, D., Wang, H., Gui, Y., ... Zhang, X. (2013). A Comparison of Land Surface Water Mapping Using the Normalized Difference Water Index from TM, ETM+ and ALI. *Remote Sensing*, 5(11), 5530-5549. <https://doi.org/10.3390/rs5115530>
- Liu, C., Hu, R., Wang, Y., Lin, H., Zeng, H., Wu, D., ... Shao, C. (2022). Monitoring water level and volume changes of lakes and reservoirs in the Yellow River Basin using ICESat-2 laser altimetry and Google Earth Engine. *Journal of Hydro-environment Research*, 44, 53-64. <https://doi.org/10.1016/j.jher.2022.07.005>
- Lu, L., & Sun, H. (2023). Dynamic monitoring of surface water areas of nine plateau lakes in Yunnan Province using long time-series Landsat imagery based on the Google Earth Engine platform. *Geocarto International*, 38(1), Article 2253196. <https://doi.org/10.1080/10106049.2023.2253196>

- Main-Knorn, M., Pflug, B., Louis, J., Debaecker, V., Müller-Wilm, U., & Gascon, F. (2017). Sen2Cor for Sentinel-2. *Image and Signal Processing for Remote Sensing XXIII*, 10427, 37-48. SPIE. <https://doi.org/10.1117/12.2278218>
- 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>
- Messenger, M. L., Lehner, B., Grill, G., Nedeva, I., & Schmitt, O. (2016). Estimating the volume and age of water stored in global lakes using a geo-statistical approach. *Nature Communications*, 7(1), Article 13603. <https://doi.org/10.1038/ncomms13603>
- OECD. (2010). *Sustainable Management of Water Resources in Agriculture*. OECD. <https://doi.org/10.1787/9789264083578-en>
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66. <https://doi.org/10.1109/TSMC.1979.4310076>
- Özelkan, E. (2019). Uzaktan Algılama ile Belirlenen Baraj Gölü Alanının Zamansal Değişiminin Meteorolojik Kuraklık ile Değerlendirilmesi: Atıkhisar Barajı (Çanakale) Örneği. *Türk Tarım ve Doğa Bilimleri Dergisi*, 6(4), 904-916.
- Öztürk, M. Z., Çetiñkaya, G., & Aydın, S. (2017). Köppen-Geiger İklim Sınıflandırmasına Göre Türkiye'nin İklim Tipleri. *Journal of Geography*, 35, 17-27. <https://doi.org/10.26650/JGEOG295515>
- 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), Article 1611. <https://doi.org/10.3390/rs12101611>
- Pekel, J.-F., Cottam, A., Gorelick, N., & Belward, A. S. (2016). High-resolution mapping of global surface water and its long-term changes. *Nature*, 540(7633), 418-422. <https://doi.org/10.1038/nature20584>
- Qi, S., Zhu, Z., & He, B. (2019). Fmask 4.0: Improved cloud and cloud shadow detection in Landsats 4-8 and Sentinel-2 imagery. *Remote Sensing of Environment*, 231, Article 111205. <https://doi.org/10.1016/j.rse.2019.05.024>
- Segarra, J., Buchailot, M. L., Araus, J. L., & Kefauver, S. C. (2020). Remote Sensing for Precision Agriculture: Sentinel-2 Improved Features and Applications. *Agronomy*, 10(5), Article 641. <https://doi.org/10.3390/agronomy10050641>
- Senay, G. B., Velpuri, N. M., Bohms, S., Budde, M., Young, C., Rowland, J., & Verdin, J. P. (2015). Chapter 9 - Drought Monitoring and Assessment: Remote Sensing and Modeling Approaches for the Famine Early Warning Systems Network. In J. F. Shroder, P. Paron, & G. D. Baldassarre (Eds.), *Hydro-Meteorological Hazards, Risks and Disasters* (pp. 233-262). Boston: Elsevier. <https://doi.org/10.1016/B978-0-12-394846-5.00009-6>
- Tottrup, C., Druce, D., Meyer, R. P., Christensen, M., Riffler, M., Dulleck, B., ... Paganini, M. (2022). Surface Water Dynamics from Space: A Round Robin Intercomparison of Using Optical and SAR High-Resolution Satellite Observations for Regional Surface Water Detection. *Remote Sensing*, 14(10), Article 2410. <https://doi.org/10.3390/rs14102410>
- Vasilakos, C., Kavrouidakis, D., & Georganta, A. (2020). Machine Learning Classification Ensemble of Multitemporal Sentinel-2 Images: The Case of a Mixed Mediterranean Ecosystem. *Remote Sensing*, 12(12), Article 2005. <https://doi.org/10.3390/rs12122005>
- Walt, S. van der, Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., ... Yu, T. (2014). scikit-image: Image processing in Python. *PeerJ*, 2, Article e453. <https://doi.org/10.7717/peerj.453>
- Wu, K., Otoo, E., & Shoshani, A. (2005). *Optimizing connected component labeling algorithms*. <https://escholarship.org/uc/item/7jg5d1zn>
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033.
- Yağmur, N., Tanık, A., Tuzcu, A., Musaoğlu, N., Erten, E., & Bilgilioglu, B. (2020). Opportunities provided by remote sensing data for watershed management: Example of Konya Closed Basin. *International Journal of Engineering and Geosciences*, 5(3), 120-129. <https://doi.org/10.26833/ijeg.638669>
- Yilmaz, O. S. (2023). Uzaktan algılama teknikleri ile su yüzeylerinin tespit edilmesinde kullanılan su çıkarma indekslerinin performans analizi. *Türk Uzaktan Algılama ve CBS Dergisi*, 4(2), 242-261. <https://doi.org/10.48123/rsgis.1256092>
- Yue, H., & Liu, Y. (2019). Variations in the lake area, water level, and water volume of Hongjiannao Lake during 1986–2018 based on Landsat and ASTER GDEM data. *Environmental Monitoring and Assessment*, 191(10), Article 606. <https://doi.org/10.1007/s10661-019-7715-6>
- Zhou, H., Liu, S., Hu, S., & Mo, X. (2021). Retrieving dynamics of the surface water extent in the upper reach of Yellow River. *Science of The Total Environment*, 800, Article 149348. <https://doi.org/10.1016/j.scitotenv.2021.149348>