







Turkish Journal of REMOTE SENSING

Türkiye Uzaktan Algılama Dergisi



Vol/Cilt:4
Issue/Sayı:2
December/Aralık, 2022

e-ISSN: 2687-4997



Türkiye Uzaktan Algılama Dergisi

Dergi Hakkında

Türkiye Uzaktan Algılama Dergisi (TUZAL) bilim ve teknolojiadaki gelişmelere paralel olarak Uzaktan Algılama alanındaki yeniliklerle ilgili yapılan çalışmaları yayınlayan ve Uluslararası İndeks ve Veri tabanlarında taranan bir dergidir.

Amaç & Kapsam

TUZAL Dergisi,

- ✚ Uzaktan Algılama alanında ulusal ve uluslararası gelişmeleri Harita, jeoloji, Çevre, Elektrik ve Elektronik, Bilgisayar vb. mühendislik alanı ile ilgilenen bilim insanlarının bilgisine sunmak,
- ✚ Konu ile doğrudan veya dolaylı etkinliklerde bulunan bilim insanları, araştırmacılar, mühendisler ve diğer uygulayıcılar arasındaki bilgi ve deneyim paylaşımını güçlendirecek ve hızlandıracak, kolay erişilebilen, geniş katılımlı bir tartışma ortamı sağlamak ve bunları yayma olanağı yaratmak,
- ✚ Türkiye'nin teknolojik ve ekonomik kalkınmasında rol oynayabilecek Uzaktan Algılama teknolojilerine ilişkin sorunların daha etkin bir şekilde çözüme kavuşturulması açısından büyük önem taşıyan kurumlar arası işbirliğinin başlatılmasına ve geliştirilmesine katkıda bulunmak,
- ✚ Türkçe'nin Uzaktan Algılama alanında bilim dili olarak geliştirilmesini ve yabancı sözcüklerden arındırılmasını özendirmek amaçlarına sahiptir.

Dergisinin kapsamı;

Temel Uzaktan Algılama Uygulamaları,

RADAR/SAR/LIDAR,

Hiperspektral uzaktan algılama,

Görüntü sınıflandırma ve analiz yöntemleri,

Radyometrik düzeltme için atmosferik modellemenin geliştirilmesi,

Uygu verilerinden elde edilmiş parametrelerin modellenmesi

Küresel modelleme, izleme ve sürdürülebilir kalkınma için küresel veri tabanı ve değişim göstergelerinin belirlenmesi,

Laboratuvar ve yerinde test yöntemleri kullanarak veri ve bilginin kontrolü,

Uzaktan algılama ve CBS yöntemlerinin entegrasyonu,

CBS Uygulamaları,

İnsansız Hava Araçları (İHA) ve Yersel Lazer Tarama ile gözlem uygulamaları,

Havasal ve Uzaysal Uzaktan Algılama

Afet ve risk etkilerinin azaltılması için bilgi desteği: erken uyarı sistemleri, etki değerlendirmesi, izleme, esneklik ve risk azaltma çalışmaları,

Çevre kirliliği: değerlendirme ve etki çalışmaları,

Jeoloji, Jeomorfoloji ve Pedolojide Yeryüzü Bilimi Uygulamaların ile uzaktan algılanmış girdilerin entegrasyonu,

Sürdürülebilir tarımsal üretim ve tarımın korunması için tarım ürünlerinin büyümesinin çok boyutlu izlenmesi,

İklim değişikliği çalışmaları,

Arazi kullanımı/örtüsünün küresel ve bölgesel dinamikleri, biyo-çeşitlilik, bozulma,

Çölleşme ve kuraklık çalışmaları,

Topraklar, bitki örtüsü ve iç, kıyı ve okyanus sularında karbon akıları,

Su kalitesi çalışmaları vb.

Yayınlanma Sıklığı

Yılda 2 sayı(Haziran-Aralık)

ISSN

2687-4997

WEB

<https://dergipark.org.tr/tr/pub/tuzal>

İletişim

osmanorhan44@gmail.com / osmanorhan@mersin.edu.tr / tuzaldergisi@gmail.com



Turkish Journal of Remote Sensing

About Journal

Turkish Journal of Remote Sensing publishes studies related to innovation in the field of Remote Sensing parallel to the developments in science and technology and indexed in the International Index and database.

Aim & Scope

The Journal,

- ✚ To present to the knowledge of National and international developments in the field of Remote Sensing to scientists related with Geomatics, Geology, Environment, Electric and Electronic, Computer etc. engineering fields.
- ✚ To provide an easily accessible, broadly attended discussion environment that will strengthen and accelerate the sharing of knowledge and experience between scientists, researchers, engineers and other practitioners who engage in direct or indirect activities with the subject, and create an opportunity to disseminate them,
- ✚ Turkey's technological and economic development in the problems related to remote sensing technology that can more effectively play a role of great importance in terms of inter-agency cooperation to be initiated and resolved to contribute to the development,
- ✚ It has the aim of encouraging the development of Turkish as a scientific language in the field of Remote Sensing and to be free from foreign words.

Scope of The Journal;

- ✓ Basic remote sensing applications,
- ✓ RADAR/SAR/LIDAR,
- ✓ Hyperspectral remote sensing,
- ✓ Image classification and analysis methods,
- ✓ Development of atmospheric modelling for radiometric correction,
- ✓ Determine global database and alteration indicator for global modelling, monitoring and sustainable development,
- ✓ Data and information control using laboratory and in-situ tests,
- ✓ Integration of remote sensing and GIS methods,
- ✓ CBS Uygulamaları,
- ✓ İnsansız Hava Araçları (İHA) ve Yersel Lazer Tarama ile gözlem uygulamaları,
- ✓ Havasal ve Uzaysal Uzaktan Algılama
- ✓ Information utility for reducing disaster and risk effects: Early warning systems, impact evaluation, monitoring, flexibly and risk reducing studies,
- ✓ Environment pollution: Evaluation and effect studies,
- ✓ Integration of Earth science applications in Geology, Geomorphology and Pedology with remote sensing data
- ✓ Multidimensional monitoring of growth of agricultural goods for sustainable agricultural production and protection of agriculture
- ✓ Climate change studies,
- ✓ Land use/ Dynamics of global and regional land, biodiversity, deterioration,
- ✓ Carbon amount in Earth, plant cover and in shore, ocean waters,
- ✓ Water quality studies etc.

Publication frequency

Biannual (June-December)

ISSN

2687-4997

WEB

<https://dergipark.org.tr/tr/pub/tuzal>

Contact

osmanorhan44@gmail.com / osmanorhan@mersin.edu.tr / tuzaldergisi@gmail.com



Turkish Journal of Remote Sensing

EDİTÖR / EDITOR

Assoc. Prof. Dr. Osman ORHAN

Mersin University, Institute of Science / Remote Sensing and Geographic Information Systems
Mersin

EDİTÖR YARDIMCILARI / ASSOCIATE EDITORS

Assist. Prof. Dr. Resul ÇÖMERT

Eskişehir Technical University, Earth and Space Sciences Institute
Eskişehir

Assist. Prof. Dr. Ahmet Tarık TORUN

Ankara Hacı Bayram Veli University, Academy of Land Registry and Cadastre
Ankara

EDİTÖR KURULU / EDITORIAL BOARD

- Prof. Dr. Dursun Zafer ŞEKER, İstanbul Technical University, TR
- Prof. Dr. Nebiye MUSAOĞLU, İstanbul Technical University, TR
- Prof. Dr. Taşkın KAVZOĞLU, Gebze Technical University, TR
- Prof. Dr. Semih EKERCİN, Aksaray University, TR
- Prof. Dr. Ömer MUTLUOĞLU, Konya Technical University, TR
- Prof. Dr. Ferruh YILMAZTÜRK, Aksaray University, TR
- Assoc. Prof. Dr. Khalil VALIZADEH KAMRAN, University of Tabriz, Iran
- Assoc. Prof. Dr. Uğur AVDAN, Eskişehir Technical University, TR
- Assoc. Prof. Dr. Saygın ABDİKAN, Bülent Ecevit University, TR
- Assoc. Prof. Dr. Süleyman Sefa BİLGİLİOĞLU, Aksaray University, TR
- Assoc. Prof. Dr. Enes YİĞİT, Karamanoğlu Mehmet Bey University, TR
- Assoc. Prof. Dr. Murat UYSAL, Afyon Kocatepe University, TR
- Assoc. Prof. Dr. Ali İhsan ŞEKERTEKİN, Çukurova University, TR
- Assoc. Prof. Dr. Senem TEKİN, Adıyaman University, TR
- Assoc. Prof. Dr. Akif DURDU, Konya Technical University, TR
- Assoc. Prof. Dr. Mustafa YALÇIN, Afyon Kocatepe University, TR
- Assoc. Prof. Dr. Mehmet Ali DERELİ, Giresun University, TR
- Assist. Prof. Dr. Lütfiye KARASAKA, Konya Technical University, TR
- Assist. Prof. Dr. Nizar POLAT, Harran University, TR
- Assist. Prof. Dr. Mustafa ÜSTÜNER, Artvin Çoruh University, TR
- Dr. Emre HAVAZLI, NASA, USA
- Dr. Fabiana CALO, Irea Cnr, Italy
- Dr. Kaan KALKAN, TÜBİTAK, TR
- Dr. Müge Ünal ÇİLEK, Çukurova University, TR

DANIŞMA KURULU / ADVISORY BOARD

- Prof. Dr. Murat YAKAR, Mersin University, TR
- Prof. Dr. Ferruh YILDIZ, Konya Technical University, TR
- Prof. Dr. Hacı Murat YILMAZ, Aksaray University, TR
- Prof. Dr. Caner ÖZDEMİR, Mersin University, TR
- Prof. Dr. İbrahim YILMAZ, Afyon Kocatepe University, TR

TUZAL Dergisi Dil Editörleri / TUZAL Journal Language Editors

Assist. Prof. Dr. Pınar KARAKUŞ

Osmaniye Korkut Ata University, Geomatics Engineering /Osmaniye, TR

Res. Ast. Merve Kolikpınar

Ardahan University, Department of Turkish Language and Literature / Ardahan, TR

Mizanpaj - Technical Staff

Assist. Prof. Dr. Hasan Bilgehan MAKİNECİ

Konya Technical University, Geomatics Engineering /Konya, TR

Mohammad Maleki

Kharazmi University / Tehran, Iran

İçindekiler


Contents

Araştırma Makaleleri;

Research Articles;

S. No

-
- 43- *Landsat Verileri ve Makine Öğrenme Algoritmaları ile Su Yüzeyi Değişiminin Belirlenmesi Ve Tahmini; Marmara Gölü Örneği*
(*Determination and Estimation of Water Surface Change With Landsat Data and Machine Learning Algorithms; A Case Study in Lake Marmara*)
Can CEZAYIRLIOĞLU, Ramazan ÇELİK, Dilek KÜÇÜK MATCI
- 53- *Detection of Equivalent Water Thickness Changes with GRACE/GRACE-FO Satellites on The Caspian Sea Between 2002-2021*
(*GRACE/GRACE-FO Uyduları ile Hazar Denizi 2002-2021 Yılları Arasındaki Eşdeğer Su Kalınlığı Değişimlerinin Tespiti*)
Miray Nil MAKİNECİ , Serkan DOĞANALP
- 62- *İstanbul İli Merkez İlçelerindeki NO₂ ve CO Emisyonlarının Uzaktan Algılama ve Yersel İstasyon Verileri Kullanılarak İncelenmesi*
(*Investigation of NO₂ and CO Emissions in Istanbul Province Central Districts using Remote Sensing and Terrestrial Station Data*)
Hasan Bilgehan MAKİNECİ
- 75- *Kuraklığa NDVI ve Makine Öğrenmesi ile Bakış: Konya Kapalı Havzası*
(*A View to Drought with NDVI and Machine Learning: Konya Closed Basin*)
Hilmi Emre GÖKTAŞ, Zerrin DAĞLI
- 87- *GIS-Based Assessment of Land Surface Temperature Changes Over Khorramabad City (Lorestan, Iran)*
(*Khorramabad Şehrindeki (Luristan-İran) Arazi Yüzey Sıcaklığı Değişimlerinin CBS Tabanlı Değerlendirilmesi*)
Mohammad Hassan KHAMESI-MAYBODI



Landsat Verileri ve Makine Öğrenme Algoritmaları ile Su Yüzeyi Değişiminin Belirlenmesi Ve Tahmini; Marmara Gölü Örneği

Can Cezayirlioğlu¹, Ramazan Çelik¹, Dilek Küçük Matcı^{*1}

¹Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, Uydu ve Uzay Bilimleri Anabilim Dalı, Eskişehir, Türkiye

Anahtar Kelimeler:

Uzaktan Algılama
Marmara Gölü
Çevre
Su Yüzey Alanı Değişimi

ÖZ

Su kaynakları yaşamın devamlılığında önemli bir rol oynamaktadır. Bu nedenle su kaynaklarının haritalanması ve değişikliklerin izlenmesi gerekmektedir. Su kaynaklarının izlenmesi, kontrolü ve koruma çalışmalarında uzaktan algılama teknolojileri önemli veriler sağlamaktadır. Bu veriler, su kütleleri ile ilgili çalışmalarda planlayıcılar için önemlidir. Bu çalışmada Manisa'ya 70 km uzaklıkta bulunan Gölarmara ilçesinde yer alan Marmara Gölü su yüzeyinin değişim analizi gerçekleştirilmiştir. Ek olarak Marmara Gölünün gelecekteki alansal değişimine ait tahminleme çalışması gerçekleştirilmiştir. Bu doğrultuda yüzey alanları, çalışma alanına ait 2002-2021 yıllarına ait Landsat 7 görüntülerinin kontrolsüz sınıflandırma yöntemi ile analizi sonucunda elde edilmiştir. Bunun yanında alana ait yağış, sıcaklık ve arazi yüzey sıcaklığı (LST) verileri Google Earth Engine yardımıyla elde edilmiştir. Elde edilen veriler kullanılarak en doğru tahminlemeyi yapabilmek amacıyla Radyal Tabanlı Fonksiyon (RBF Regressor), Doğrusal Regresyon (Lineer Regresyon), Toplamsal Regresyon (Additive Regression) ve Çok Katmanlı Perceptron Sınıflandırıcı (MultiLayer Perceptron Classifier) yöntemleri kullanılmıştır. 2002-2012 yılları arasındaki veriler kullanılarak 2013 ve 2021 yılları arasındaki değişim belirlenmiştir. Sonuçlar incelendiğinde en iyi tahminin R²= 0.91 ile Çok Katmanlı Perceptron CS ile elde edildiği gözlemlenmiştir. Bu yöntem ile 2022 ve 2026 yılları için gerçekleştirilen tahmin çalışması sonucunda gölün çok daha fazla küçüleceği ve 1.56 km²' ye ulaşacağı öngörülmüştür.

Determination and Estimation of Water Surface Change With Landsat Data and Machine Learning Algorithms; A Case Study in Lake Marmara

Keywords:

Remote Sensing
Marmara Lake
Environment
Changes in Water Surface
Area

ABSTRACT

Water resources play an important role in the continuity of life. Therefore, it is necessary to map water resources and monitor changes. Remote sensing technologies provide important data in the monitoring, control and protection studies of water resources. These data are important for planners in studies related to water bodies. In this study, the change of the water surface of Marmara Lake, located in Gölarmara district, 70 km from Manisa, was determined. In addition, an estimation study of the future spatial change of Marmara Lake was carried out. In this direction, the surface areas were obtained as a result of the analysis of the Landsat 7 images of the study area for the years 2002-2021 with the unsupervised classification method. In addition, precipitation, temperature and LST data of the area were obtained with the help of Google Earth Engine. RBF Regressor, Linear Regression, Additive Regression and MultiLayer Perceptron CS methods were used to make the most accurate estimation using the data obtained. Using the data between 2002 and 2012, the change between 2013 and 2021 was determined. When the results were examined, it was observed that the best estimation was obtained with MultiLayer Perceptron CS with R²= 0.91. As a result of the estimation study carried out for the years 2022 and 2026 with this method, it is predicted that the lake will shrink much more and reach 1.56 km².

*Sorumlu Yazar

(cancezayirlioglu8@gmail.com) ORCID ID 0000-0002-9096-0210
(celikr1994@gmail.com) ORCID ID 0000-0002-7273-149X
(dkmatci@anadolu.edu.tr) ORCID ID 0000-0002-4078-8782

Kaynak Göster(APA);

Cezayirlioğlu, C., Çelik, R., Küçük Matcı, D. (2022). Landsat Verileri ve Makine Öğrenme Algoritmaları ile Su Yüzeyi Değişiminin Belirlenmesi ve Tahmini; Marmara Gölü Örneği. *Türkiye Uzaktan Algılama Dergisi*, 4 (2) , 43-52.

1. GİRİŞ

Su kütleleri, yeryüzünde canlılığı sağlayan en önemli unsurlardan biridir. Su alanlarının insan yaşamının devamlılığının sağlanması ve gelişiminde önemli bir etkisi olmuştur (Ridd & Liu, 1998). Su kütlelerinin iklimle birlikte değişen dinamikleri, mevsim veya yıllar arası değişim özellikleri hakkında çok az şey bilinmektedir. Nehirler, göller, sulak alanlar, seller ve taşkınların izlenmesi, değişim mekanizmasını anlamak ve yüzey suyu kaynaklarının yönetimini planlayabilmek için büyük önem taşımaktadır (Papa vd., 2008). Uzaktan algılama bu çalışmalara sağlıklı, güncel ve ekonomik veri sağlamak adına önemli bir araçtır.

Literatürde doğal felaketlerin yarattığı etkilerin, su kütlelerinin izlenmesi, değişimlerin tespit edilmesi ve arazi kullanım değişimlerinin haritalanması amacıyla yapılan çalışmalarda uzaktan algılama teknolojisi kullanılmaktadır (Rokni vd., 2014; Sun vd., 2012; Torun vd., 2017). Uzaktan algılanmış verilerle su kütlelerini belirlemek için kullanılan yöntemlerinden biri su indeksi kullanımıdır. Bu yöntem, su ve diğer yüzey sınıflarının sinyallerini bant oranı yöntemiyle ayırarak yüzey suyu kütlelerini tanımlamak için basit ve etkili bir yöntemdir. McFeeters (2013), multispektral bantlardan yeşil ve yakın kızılötesi (NIR) bantlarına dayalı olarak normalleştirilmiş fark su indeksini (NDWI) tasarlamıştır (McFeeters, 2013). MNDWI su alanlarını belirlerken arka plandaki yerleşim alanlarını bastırması için önerilmiştir (Xu, 2006). Ayrıca multispektral görüntülerdeki diğer bantlar kullanılarak AWEI (Automated Water Extraction Index), ABWI (All-Bands Water Index) ve MBWI (Multi-Band Water Index) gibi farklı su indeksleri önerilmiştir (Feyisa vd., 2014; Wang vd., 2018; Xiong vd., 2018).

Su kütlesi haritalama amacıyla kullanılan diğer yöntemler kontrollü ve kontrolsüz sınıflandırma yaklaşımlarıdır. Örneğin, Chen ve ark. rastgele bir orman (RF) sınıflandırıcısı aracılığıyla bir su ve kentsel arazi kullanım haritası hazırlamıştır (Chen vd., 2018). Başka bir çalışmada ise su türlerini belirlemek için makine öğrenmesi algoritmaları kullanılmıştır (Huang vd., 2019). Xie vd. (2016), Landsat görüntülerinden su alanını çıkarmak için su indekslerini ve Otsu yöntemini kullanmıştır (Xie vd., 2016). Başka bir çalışmada, Landsat ve Sentinel-1 görüntüleri ve Otsu yöntemi kullanılarak Ebinur Gölü'nün su yüzey alanındaki aylık değişimler belirlenmiştir (Wang vd., 2019). Çeşitli uydu görüntüleri, spektral indeksler ve eşikler kullanılarak yapılan bir çalışmada Aral Gölü'nün 1960-2018 yılları arasındaki mekânsal ve hacimsel değişimleri belirlenmiştir (Yang vd., 2020).

Su kütlelerinin kontrol edilebilmesi ve yönetilebilmesi için gelecekteki değişimlerinin planlanması gerekmektedir. Uzaktan algılanmış veriler kullanılarak farklı alanların değişimlerinin tahmin edilebilmesi için yapay sinir ağları (Maithani,

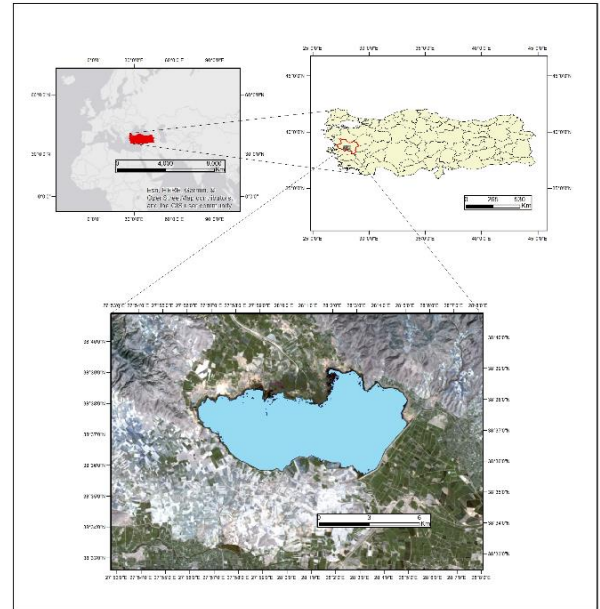
2009; Pijanowski vd., 2005), makine öğrenimi, karar ağaçları (Bununu, 2017; Huang vd., 2010) ve doğrusal veya lojistik regresyonlar (Hu & Lo, 2007; Seto & Kaufmann, 2003) gibi yöntemler kullanılmıştır. Pek çok farklı alanın değişimlerinin tahminleme çalışması yapıyor olmasına rağmen su kütlelerinin değişiminin tahminlenmesi çok az çalışılmıştır.

Bu çalışmada, Landsat 7 uydu görüntüleri kullanılarak 2002-2021 yıllarındaki Marmara Gölü'nün su yüzeyi değişimleri belirlenmiştir. Elde edilen veriler kullanılarak göl alanının gelecekteki değişimini tahminleme amacıyla dört farklı yöntem kullanılmış ve sonuçlar karşılaştırılmıştır. En iyi sonucu veren yöntem belirlenmiş ve gelecekteki alansal değişimi tahmin edilmiştir.

2. KULLANILAN VERİLER VE YÖNTEM

2.1. Çalışma Alanı

Marmara Gölü, Manisa'nın ilçesi Gölarmara'nın güneyinde yer alır (Şekil 1). Marmara Gölü, Gediz Nehri'nin alüvyon vadisine ait alüvyonlarla kaplı bir göldür; kuzeybatıda Gölarmara ilçesi ile güneydoğuda Salihli ilçeleri arasında paylaşılmakta olup, balıkçılık ve sulama faaliyetleri için önemli bir lokasyondur (Tarkan vd., 2017). Marmara Gölü'nün yer aldığı Gediz Nehri Havzası, bazı alanlarda Akdeniz iklimi ile karakterize edilen ağırlıklı olarak karasal bir iklime sahiptir (Yıldız vd., 2007).




Şekil 1. Çalışma alanı

2.2. Kullanılan Veriler

Çalışmada Marmara Gölü'nün su yüzeyi alanındaki değişimlerinin izlenmesi amacıyla Landsat-7 uydusuna ait görüntüler kullanılmıştır. 1970' li yıllardan itibaren veri üreten Landsat

sistemi, değişim belirlenmesi çalışmalarında önemli bir veri kaynağıdır (Gülci vd., 2019). Çalışmada kullanılan görüntülerin alanı kapsayan bulutsuz görüntüler olmasına dikkat edilmiştir (Tablo 1). Çalışmada kullanılan uydu görüntüleri Şekil 2’ de verilmiştir.



Şekil 2. Landsat 7 Görüntüleri a) 2002 b) 2005 c) 2010 d) 2015 e) 2020 f)2021

Marmara Gölünün gelecek yıllardakini gelişimini tahmin etmek amacıyla uydu görüntülerinin yanı sıra yağış, hava sıcaklığı ve LST kullanılmıştır (Tablo 1). Çalışmada kullanılan yağış verileri CHIRPS Daily: Climate Hazards Group InfraRed Precipitation With Station Data (Version 2.0 Final) veri setinden elde edilmiştir. 1981’ den günümüze kadar olan verileri içerir. CHIRPS, trend analizi ve mevsimsel kuraklık izleme çalışmalarında kullanılmak üzere yağış zaman serileri oluşturmaktadır (Funk vd., 2015).

Tablo 1. Çalışmada kullanılan veriler


Veri	Kaynak	Tarih
Uydu Görüntüleri	Landsat 7	14/02/2002
		03/10/2005
		04/09/2010
		22/03/2015
		19/03/2020
		05/09/2021
Yağış	CHIRPS Daily	Tüm çalışma yılları için "01 Şubat-31 Mayıs" tarihleri arasındaki yağışların ortalaması
Hava Sıcaklığı	NCEP/NCAR Reanalysis Data, Surface Temperature	Tüm çalışma yılları için "01 Şubat-31 Mayıs" tarihleri arasındaki sıcaklık verilerinin ortalaması
LST	MOD11A1.006 Terra Land Surface Temperature and Emissivity Daily Global	Tüm çalışma yılları için "01 Şubat-31 Mayıs" tarihleri arasındaki LST verilerinin ortalaması

Çalışmada kullanılan bir diğer veri olan hava sıcaklığı verileri NCEP/NCAR Reanalysis Data, Surface Temperature verisetinden elde edilmiştir. Bu veriler 1948'den günümüze kadar olan verileri ile son analiz/tahmin sistemi kullanıyor. Veriler 6 saatlik zamansal çözünürlüğe (00:00, 06:00, 12:00 ve 18:00 UTC) ve 2.5 derece uzamsal çözünürlüğe sahiptir (Kalnay vd., 1996).

Marmara gölünün alansal değişimini tahminlemek amacıyla kullanılan bir diğer veri seti LST verileridir. Bu doğrultuda MOD11A1.006 Terra Land Surface Temperature and Emissivity Daily Global 1 km verileri kullanılmıştır. Bu veri hem gündüz hem de gece yüzey sıcaklık bantları ve kalite göstergesi katmanları sunmaktadır. 1200 x 1200 kilometrelik bir ızgarada günlük LST ve emisyon değerleri sağlamaktadır (Wan, 2007).

2.3. Uygulanan Yöntem

Marmara Gölünün 2002-2021 yılları arasındaki alansal değişiminin belirlenmesi ve geleceğe yönelik tahmin yapılması için uygulanan yöntem Şekil 3’ de verilmiştir.



Şekil 3. Çalışmada uygulanan yöntem

Buna göre ilk olarak çalışma alanının 2002-2021 yıllarına ait Landsat 7 görüntüleri Google Earth Engine yardımıyla elde edilmiştir. Bu görüntüler kullanılarak Normalleştirilmiş Fark Su İndeksi (NDWI), Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), Normalize Edilmiş Yerleşim Alanı İndeksi (NDBI) ve WIBI (Enhanced index for water body delineation) indeksleri hesaplanmıştır. NDVI' yı hesaplamak için Formül 1 kullanılmıştır (Tucker vd., 1985). Sonuçlar -1 ile +1 arasında değişir. Bu indeks, uydu görüntülerinden bitki örtüsü hakkında detaylı bilgi elde etmek için birçok çalışmada kullanılmıştır (DeFries & Townshend, 1994; Demir, 2020; Guha vd., 2018)

$$NDVI=(NIR-KIRMIZI)/(NIR+KIRMIZI) \quad (1)$$

NDWI indeksi, uydu görüntülerinden su bileşenlerini tanımlamak için McFeeters (1996) ve Gao (1996) tarafından geliştirilmiştir (Gao, 1996; McFeeters, 1996). McFeeters (1996) tarafından geliştirilen NDWI su indeksi ile su bileşenleri, yakın kızılötesi (NIR) ve görünür yeşil (Yeşil) ışık kullanılarak toprak ve yer üstü bitkileri ortadan kaldırılarak belirlenir (Formül 2). NDWI ayrıca su yüzeyinin bulanıklığını belirlemek için de kullanılır.

$$NDWI=(NIR-YEŞİL)/(YEŞİL+NIR) \quad (2)$$

NDBI indeksi, yakın kızılötesi (NIR) bölgeye kıyasla kısa dalga kızılötesi (SWIR) bölgesinde tipik olarak daha yüksek bir yansımının olduğu kentsel alanları vurgular (Formül 3)(Zha vd., 2003).

$$NDBI=(NIR-SWIR)/(NIR+SWIR) \quad (3)$$

İsmail ve arkadaşları (2021) tarafından geliştirilen WIBI indeksi, NDBI ve NDWI indekslerinin farkının alınması ile hesaplanır (Formül 4) (İsmail vd., 2021).

$$WIBI=NDWI- NDBI \quad (4)$$

Sonraki adımda elde edilen indekslerin eklendiği görüntüler K-Ortalamalar yöntemiyle sınıflandırılmıştır. Bu çalışmada tercih edilen sınıflandırma algoritması literatürde sıklıkla kullanılan K-Ortalamalar algoritmasıdır (Celik, 2009; Kanungo vd., 2002; Koonsanit vd., 2012; Usman, 2013). Bu yöntemin genel ilkesi, bir n nesne kümesini k kümeye bölmektir. Buna göre süreç içinde oluşturulan kümeler, maksimum küme içi benzerliklere ve minimum kümeler arası benzerliklere sahip olmalıdır (Kanungo vd., 2002). Çalışmada kullanılan görüntüler su alan ve su olmayan alanlar şeklinde iki sınıfa ayrılmıştır. Elde edilen sonuç haritalarından göle ait alanlar hesaplanmıştır. Hesaplanan alanlar kullanılarak değişim belirlenmiştir.

LST, yağış ve hava sıcaklığı verileri Google Earth Engine yardımıyla elde edildikten sonra tahminleme işlemi gerçekleştirilmiştir. Bu amaçla literatürde tahminleme amacıyla sıklıkla kullanılan yöntemlerden olan Radyal Tabanlı Fonksiyon (RBF Regressor) , Lineer Regresyon, Bayesian Additive Regresyon Ağaçları (BART) ve Çok Katmanlı Perceptron Sınıflandırıcı yöntemleri kullanılmıştır.

2.3.1. Çalışmada Kullanılan Tahminleme Yöntemleri

Çalışmada tahminleme amacıyla kullanılan yöntemlerden biri olan RBF yönteminin yapısı üç katmandan oluşur. Bu yapı eğitim sürecini kolaylaştırır. Bu yöntemin avantajlarından biri, yüksek gürültülü verilere uygulanabilmeleridir (Tatar vd., 2013). RBF yaklaşımı, zaman serisi tahmini, sınıflandırma ve sistem kontrolü dahil olmak üzere birçok alanda kullanılmıştır (Gopi vd., 2020; Rojas vd., 2002; Yu vd., 2011).

Lineer Regresyon belirli bir X değeri için Y'nin sayısal değerini tahmin etmek amacıyla kullanılan (genellikle doğrusal bir ilişki) bir yöntemdir. Eğer bu regresyon çizgisinin eğimi ve y-kesişi biliniyorsa, X için bir değer eklenebilir ve Y için ortalama değer tahmin edilebilir (Sreehari & Srivastava, 2018).


BART, regresyon ağaçlarını kullanarak parametrik olmayan fonksiyon tahminine Bayes yaklaşımıdır. BART, olasılığı hesaplamak için kullanılan Bayes teoremini kullanır. Öncelik ve olasılığa dayalı olarak, çıktı/tahminler üretilir. Bilinmeyen regresyon fonksiyonunun nokta ve aralık tahminlerinin yanı sıra potansiyel tahmin edicilerin marjinal etkileri de dahil olmak üzere, bu yaklaşım kullanılarak tam sonsal çıkarım yapılabilir (Logan vd., 2019).

Tahminleme amacıyla çalışmada kullanılan son yöntem Çok Katmanlı Perceptron Sınıflandırıcı yöntemidir. Bu yöntem verileri sınıflandırmak için geri yayılım kullanan bir sınıflandırıcıdır. Bu sınıflandırıcının yapısı elle veya bir algoritma tarafından oluşturulabilir. Yapı, eğitim süresi boyunca izlenebilir ve değiştirilebilir (Fernandez vd., 2013).

En iyi tahminleme sonucunu belirlemek amacıyla 2002-2012 yılları arasındaki veriler kullanılmış ve 2013-2021 yılları arasındaki alanları belirlenmiştir. Daha sonra en iyi sonuç veren yöntem ile 2022-2027 yıllarına ait beş yıllık alansal değişim hesaplanmıştır.

3. BULGULAR VE TARTIŞMA

Bu çalışmada Marmara gölünün 2002 ve 2021 yıllarına göre değişimleri incelenmiştir. Bu doğrultuda kullanılan görüntüler K-Ortalamalar algoritması ile sınıflandırılmıştır. Elde edilen sonuç haritaları Şekil 4' te verilmiştir.



Şekil 4. Sınıflandırma Sonuçları a) 2002 b) 2005 c) 2010 d) 2015 e) 2020 f)2021

Oluşturulan sonuç haritaları üzerinden Marmara Gölü' nün alanı hesaplanmıştır. Hesaplanan sonuçların doğruluğunun test edilmesi amacıyla Genel Doğruluk Oranı (OverAll Accuracy) yöntemi kullanılmıştır. Genel doğruluk, bir elemanın doğru bir şekilde sınıflandırılma olasılığıdır; yani, gerçek pozitifler artı gerçek negatiflerin toplamının test edilen toplam birey sayısına bölümüdür. Bir sonraki aşamada Marmara Gölü' nün gelecekteki beş yıllık alansal değişimini tahmin edebilmek amacıyla LST, yağış ve hava sıcaklığı verileri elde edilmiştir. Elde edilen tüm veriler ve sınıflandırma doğruluk analizi sonuçları Tablo 2' de verilmiştir.

Tablo 2. Elde edilen veriler

Yıl	Alan (km ²)	Genel Doğruluk	LST	Hava Sıcaklığı (C ⁰)	Yağış (mm/gün)
2002	56.01	0.98	22.64	13.5	1.59
2003	62.78	0.95	20.11	10.85	2.32
2004	57.1	0.97	22.06	12.39	1.19
2005	57.27	0.97	22.39	12.63	2.59
2006	57.99	0.94	21.79	13.14	2.14
2007	49.89	0.98	24.14	13.67	1.502
2008	39.62	0.97	24.55	13.5	1.35
2009	58.53	0.91	20.71	12.2	2.84
2010	56.36	0.96	22.42	14.37	2.34
2011	57.09	0.94	20.99	13.68	1.77
2012	65.21	0.98	21.55	13.27	2.33
2013	62.28	0.97	22.37	15.26	2.51
2014	58.94	0.95	24.04	13.68	1.79
2015	58.12	0.94	21.28	13.27	1.95
2016	63.11	0.95	23.32	15.26	1.86
2017	50.98	0.97	23.27	13.67	1.59
2018	44.53	0.93	23.96	15.93	1.95
2019	51.28	0.97	22.93	13.55	1.74
2020	37.26	0.95	22.81	13.66	1.66
2021	23.5	0.97	23.17	12.52	2.05

Tahminleme çalışmasında en doğru sonucu elde etmek amacıyla Radyal Tabanlı Fonksiyon, Doğrusal Regresyon, Toplamsal Regresyon ve Çok Katmanlı Perceptron CS yöntemleri kullanılmıştır. Bu


doğrultuda elde edilen verilerden 2002-2012 yılları arasındaki veriler kullanılarak 2013-2021 yıllarına ait alanlar tahminlenmiştir. Elde edilen sonuçlar Tablo 3’ de verilmiştir.

Tablo 3. Tahminleme sonuçları

Yıl	Gerçek Göl Alanı (km ²)	Çok Katmanlı Perceptron Sınıflandırıcı (km ²)	Doğrusal Regresyon (km ²)	Radyal Tabanlı Fonksiyon (km ²)	Toplamsal Regresyon (km ²)
2013	62.28	65.79	56.56	58.04	64.51
2014	58.94	61.16	56.52	51.74	56.25
2015	58.12	63.42	56.64	51.72	57.38
2016	63.11	63.27	56.67	52.33	57.38
2017	50.98	60.78	56.7	50.45	54.09
2018	44.53	50.36	56.76	50.01	62.38
2019	51.28	45.52	56.82	49.54	64.54
2020	37.26	38.82	56.89	48.85	64.54
2021	23.5	22.97	56.95	48.49	64.97

Hesaplanan alanların doğruluğunu belirleyebilmek amacıyla gerçek alan ve tahminleme sonuçları arasındaki korelasyon hesaplanmıştır. Korelasyon analizi, iki değişken arasındaki doğrusal ilişkinin gücünü ölçmek ve ilişkilerini hesaplamak için kullanılan istatistiksel bir yöntemdir. Yüksek bir

korelasyon, iki değişken arasında güçlü bir ilişkiye işaret ederken, düşük bir korelasyon, değişkenlerin zayıf bir şekilde ilişkili olduğu anlamına gelir. Sonuçlar Şekil 5’ te verilmiştir.



Şekil 5. Tahmin sonuçları ile gerçek göl alanları arasındaki korelasyon

Buna göre en iyi tahminleme sonucu $R^2=0.91$ ile Çok katmanlı PerceptronCS yöntemi hesaplamıştır. Bu yöntemin çalışması için gerekli olan parametrelerden öğrenme oranı: 0.51, momentum 0.501, eğitim süresi 110 ve eşik değeri 855 olarak tanımlanmıştır. Elde sonuçlar incelendiğinde Radyal Tabanlı Fonksiyon, ve Çok Katmanlı Perceptron CS yöntemleri ile elde edilen sonuçların pozitif yönde, Doğrusal Regresyon ve Toplamsal Regresyon yöntemlerinin negatif yönde ilişki olduğu gözlenmektedir.

Son olarak en iyi sonuç veren bu yöntem olan MultiLayer PerceptronCS kullanılarak önümüzdeki beş yıl için alansal tahminleme gerçekleştirilmiştir. Bu aşamada da en iyi sonucun elde edilmesini sağlayan konfigürasyon kullanılmıştır. Elde edilen sonuçlar Tablo 4' te verilmiştir.

Tablo 4. Beş yıllık alansal tahminleme sonucu

Yıl	Alan (km ²)
2022	11.59
2023	7.57
2024	7.57
2025	3.53

Bu çalışmada Marmara Gölü' ndeki alansal değişim analiz edilmiş ve önümüzdeki beş yıl için alansal değişim tahminleme çalışması gerçekleştirilmiştir. Elde edilen sonuçlar incelendiğinde göl alanının 2002-2021 yılları arasında %58 oranında azaldığı belirlenmiştir. Göl yüzey alanının 2026 yılına kadarki değişimi hesaplandığında daha da küçüleceği ve 1.56 km²' te ulaşacağı görülmektedir.

4. SONUÇ VE ÖNERİLER

Su kütleleri, su döngüsünün önemli bir parçasıdır. Dünya üzerindeki tüm canlılar için yaşamsal bir öneme sahiptir. Küresel iklim değişikliği ve insan faaliyetlerinin artan etkisi, buzulların erimesi, yüzeysel su kaynaklarında mekânsal ve zamansal dağılım değişikliklere yol açmaktadır. Bu nedenle su kütleleri üzerindeki değişimler takip edilmeli ve bu değişikliğe neden olan etmenler belirlenmelidir.

Bu çalışmada Marmara Gölünün alansal değişimi incelenmiş ve önümüzdeki yıllardaki değişimi ile ilgili tahminleme çalışması yapılmıştır. Bu doğrultuda 2002-2021 yılları arasındaki alansal değişim Landsat görüntülerinin sınıflandırılması ile elde edilmiştir. Buna ek olarak sıcaklık, yağış ve LST verileride kullanılarak en uygun tahminleme yöntemi belirlenmiştir. Belirlenen yöntem ile % 91 doğrulukla alan verilerinin tahminlenebilmiştir. En yüksek sonucu Çok Katmanlı Perceptron CS yönteminden sonra en iyi sonucu %79 ile Doğrusal Regresyon yöntemi vermiştir. En kötü sonuç ise Toplamsal Regresyon yöntemi ile elde edilmiştir.

Bu çalışma su kütlelerinin planlanması için önemli bir veri sağlamaktadır. Gelecekteki çalışmalarda buharlaşma, su kalınlığı gibi farklı parametreleri de ekleyerek su kütlesi değişimleri incelenecektir.

Araştırmacıların katkı oranı beyan özeti

Araştırmacılar makaleye eşit oranda katkı sağlamışlardır.

Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

Araştırma ve yayın etiği beyanı

Yapılan çalışmada yazarlar, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

KAYNAKÇA

- Bununu, Y. A. (2017). Integration of Markov chain analysis and similarity-weighted instance-based machine learning algorithm (SimWeight) to simulate urban expansion. *International Journal of Urban Sciences*, 21(2), 217-237.
- Celik, T. (2009). Unsupervised change detection in satellite images using principal component analysis and k-means clustering. *IEEE Geoscience and Remote Sensing Letters*, 6(4), 772-776.
- Chen, J., Du, P., Wu, C., Xia, J., & Chanussot, J. (2018). Mapping urban land cover of a large area using multiple sensors multiple features. *Remote Sensing*, 10(6), 872.
- DeFries, R. S., & Townshend, J. (1994). NDVI-derived land cover classifications at a global scale. *International Journal of Remote Sensing*, 15(17), 3567-3586.
- Demir, N. (2020). NDVI Analysis of Australian Bushfires with Cloud Computing. *Türk Uzaktan Algılama ve CBS Dergisi*, 1(2), 78-84.
- Fernandez, F. G., Los Santos, I. S., Martinez, J. L., Izquierdo, S. I., & Redondo, F. L. (2013). Use of artificial neural networks to predict the business success or failure of start-up firms. *Artificial neural networks-architecture and applications*, 245-56.
- 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.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., . . . Hoell, A. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific data*, 2(1), 1-21.
- Gao, B.-C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257-266.
- Gopi, A. P., Jyothi, R., Narayana, V. L., & Sandeep, K. S. (2020). Classification of tweets data based on polarity using improved RBF kernel of SVM. *International Journal of Information Technology*, 1-16.
- Guha, S., Govil, H., Dey, A., & Gill, N. (2018). Analytical study of land surface temperature with NDVI and NDBI using Landsat 8 OLI and TIRS data in Florence and Naples city, Italy. *European Journal of Remote Sensing*, 51(1), 667-678.
- Gülci, S., Gülci, N., & YÜKSEL, K. (2019). Aslantaş Baraj Gölü ve çevresinin su yüzey alanı ve arazi örtüsü değişiminin Landsat uydu görüntüleri kullanılarak izlenmesi. *Journal of the Institute of Science and Technology*, 9(1), 100-110.
- Hu, Z., & Lo, C. (2007). Modeling urban growth in Atlanta using logistic regression. *Computers, Environment and Urban Systems*, 31(6), 667-688.
- Huang, B., Xie, C., & Tay, R. (2010). Support vector machines for urban growth modeling. *Geoinformatica*, 14(1), 83.
- Huang, F., Yu, Y., & Feng, T. (2019). Automatic extraction of urban impervious surfaces based on deep learning and multi-source remote sensing data. *Journal of Visual Communication and Image Representation*, 60, 16-27.
- Ismail, M. A., Waqas, M., Ali, A., Muzzamil, M. M., Abid, U., & Zia, T. (2021). Enhanced index for water body delineation and area calculation using Google Earth Engine: a case study of the Manchar Lake. *Journal of Water and Climate Change*, 13 (2): 557-573.
- Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., . . . Woollen, J. (1996). The NCEP/NCAR 40-year reanalysis project. *Bulletin of the American Meteorological Society*, 77(3), 437-472.
- Kanungo, T., Mount, D. M., Netanyahu, N. S., Piatko, C. D., Silverman, R., & Wu, A. Y. (2002). An efficient k-means clustering algorithm: Analysis and implementation. *IEEE transactions on pattern analysis and machine intelligence*, 24(7), 881-892.
- Koonsanit, K., Jaruskulchai, C., & Eiumnoh, A. (2012). Parameter-free K-means clustering algorithm for satellite imagery application. *Information Science and Applications (ICISA)*, 2012 International Conference on,

- Logan, B. R., Sparapani, R., McCulloch, R. E., & Laud, P. W. (2019). Decision making and uncertainty quantification for individualized treatments using Bayesian Additive Regression Trees. *Statistical Methods in Medical Research*, 28(4), 1079-1093.
- Maithani, S. (2009). A neural network based urban growth model of an Indian city. *Journal of the Indian Society of Remote Sensing*, 37(3), 363-376.
- 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.
- McFeeters, S. K. (2013). Using the Normalized Difference Water Index (NDWI) within a Geographic Information System to Detect Swimming Pools for Mosquito Abatement: A Practical Approach. *Remote Sensing*, 5(7), 3544-3561.
- Papa, F., Prigent, C., & Rossow, W. B. (2008). Monitoring flood and discharge variations in the large Siberian rivers from a multi-satellite technique. *Surveys in Geophysics*, 29(4), 297-317.
- Pijanowski, B. C., Pithadia, S., Shellito, B. A., & Alexandridis, K. (2005). Calibrating a neural network-based urban change model for two metropolitan areas of the Upper Midwest of the United States. *International Journal of Geographical Information Science*, 19(2), 197-215.
- Ridd, M. K., & Liu, J. (1998). A comparison of four algorithms for change detection in an urban environment. *Remote Sensing of Environment*, 63(2), 95-100.
- Rojas, I., Pomares, H., Bernier, J. L., Ortega, J., Pino, B., Pelayo, F. J., & Prieto, A. (2002). Time series analysis using normalized PG-RBF network with regression weights. *Neurocomputing*, 42(1-4), 267-285.
- Rokni, K., Ahmad, A., Selamat, A., & Hazini, S. (2014). Water feature extraction and change detection using multitemporal Landsat imagery. *Remote Sensing*, 6(5), 4173-4189.
- Seto, K. C., & Kaufmann, R. K. (2003). Modeling the drivers of urban land use change in the Pearl River Delta, China: integrating remote sensing with socioeconomic data. *Land Economics*, 79(1), 106-121.
- Sreehari, E., & Srivastava, S. (2018). Prediction of climate variable using multiple linear regression. *2018 4th International Conference on Computing Communication and Automation (ICCCA)*, 1-4.
- Sun, F., Sun, W., Chen, J., & Gong, P. (2012). Comparison and improvement of methods for identifying waterbodies in remotely sensed imagery. *International Journal of Remote Sensing*, 33(21), 6854-6875.
- Tarkan, A. S., Sarı, H. M., İlhan, A., Kurtul, I., & Vilizzi, L. (2017). Risk screening of non-native and translocated freshwater fish species in a Mediterranean-type shallow lake: Lake Marmara (West Anatolia). *Zoology in the Middle East*, 63(1), 48-57.
- Tatar, A., Shokrollahi, A., Mesbah, M., Rashid, S., Arabloo, M., & Bahadori, A. (2013). Implementing radial basis function networks for modeling CO₂-reservoir oil minimum miscibility pressure. *Journal of natural gas science and engineering*, 15, 82-92.
- Torun, A. T., Ekercin, S., & Gezgin, C. (2017). Ysa ile optimize edilmiş yapay arı koloni algoritmasının landsat uydu görüntülerinin sınıflandırılmasında kullanılabilirliğinin araştırılması. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 17(4), 86-93.
- Tucker, C. J., Townshend, J. R. G., & Goff, T. E. (1985). African Land-Cover Classification Using Satellite Data. *Science*, 227(4685), 369-375.
- Usman, B. (2013). Satellite imagery land cover classification using k-means clustering algorithm computer vision for environmental information extraction. *Elixir Computer Science and Engineering*, 63, 18671-18675.
- Wan, Z. (2007). Collection-5 MODIS land surface temperature products users' guide. *ICESSE, University of California*, Santa Barbara.
- Wang, J., Ding, J., Li, G., Liang, J., Yu, D., Aishan, T., Zhang, F., Yang, J., Abulimiti, A., Liu, J. (2019). Dynamic detection of water surface area of Ebinur Lake using multi-source satellite data (Landsat and Sentinel-1A) and its responses to changing environment. *Catena*, 177, 189-201.
- Wang, X., Xie, S., Zhang, X., Chen, C., Guo, H., Du, J., & Duan, Z. (2018). A robust Multi-Band Water Index (MBWI) for automated extraction of surface water from Landsat 8 OLI imagery. *International Journal of Applied Earth Observation and Geoinformation*, 68, 73-91.

- Xie, H., Luo, X., Xu, X., Pan, H., & Tong, X. (2016). Evaluation of Landsat 8 OLI imagery for unsupervised inland water extraction. *International Journal of Remote Sensing*, 37(8), 1826-1844.
- Xiong, L., Deng, R., Li, J., Liu, X., Qin, Y., Liang, Y., & Liu, Y. (2018). Subpixel surface water extraction (SSWE) using Landsat 8 OLI data. *Water*, 10(5), 653.
- 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.
- Yang, X., Wang, N., He, J., Hua, T., & Qie, Y. (2020). Changes in area and water volume of the Aral Sea in the arid Central Asia over the period of 1960–2018 and their causes. *Catena*, 191, 104566.
- Yildiz, Ş., Altındağ, A., & Ergönül, M. B. (2007). Seasonal fluctuations in the zooplankton composition of a eutrophic lake: Lake Marmara (Manisa, Turkey). *Turkish Journal of Zoology*, 31(2), 121-126.
- Yu, H., Xie, T., Paszczyński, S., & Wilamowski, B. M. (2011). Advantages of radial basis function networks for dynamic system design. *IEEE Transactions on Industrial Electronics*, 58(12), 5438-5450.
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583-594.



© Author(s) 2022.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>



Detection of Equivalent Water Thickness Changes with GRACE/GRACE-FO Satellites on The Caspian Sea Between 2002-2021

Miray Nil Makineci*¹, Serkan Doğanalp¹

¹Konya Technical University, Faculty of Engineering and Natural Sciences, Geomatics Engineering Department, Konya, Turkey

Keywords

Caspian Sea
CSR
DDK Filter
EWT
GRACE and GRACE-FO

ABSTRACT

The Caspian Sea is the world's largest inland water body, studied for years. The Caspian Sea, in which water level changes were examined with the data acquired from tide gauges in the past years, is also observing using altimeter satellite data with the improvement of satellite programs. In addition, water mass changes can be investigated with the GRACE and GRACE Follow-On (GRACE-FO) satellites, which can capture mass changes on the earth. Within the scope of the study, the Equivalent Water Thickness (EWT) changes in and around the Caspian Sea were examined using Level-2 Release-06 data obtained from the GRACE/GRACE-FO satellites with a long-term data set covering the years 2002-2021. While making the calculations, a long-term average model was created, and the average value of each year was subtracted from the average model. Center for Space Research (CSR) was preferred as the data center, and the Decorrelation Filtering (DDK) technique was used to eliminate correlation-based errors. Also, the results have been illustrated with a map, and the data obtained has been given in a table. In addition, EWT changes according to years were calculated by selecting a point in the region where EWT changes were observed intensely. When the results are analyzed, negative EWT changes have been detected that have increased rapidly in the last few years. Negative values of EWT changes mean that the water body of that area is decreasing.

GRACE/GRACE-FO Uyduları ile Hazar Denizi 2002-2021 Yılları Arasındaki Eşdeğer Su Kalınlığı Değişimlerinin Tespiti

Anahtar Kelimeler:

Hazar Denizi
CSR
DDK Filtresi
EWT
GRACE ve GRACE-FO

ÖZ

Hazar Denizi yıllardır üzerinde çalışmalar yapılan Dünya'nın en büyük iç su kütesidir. Geçmiş yıllarda mareograf istasyonlarından alınan veriler ile su seviyesi değişimlerinin incelendiği Hazar Denizi, uydu programlarının gelişmesi ile altimetre uydu verileri kullanılarak da gözlemlenmektedir. Ayrıca yeryüvarı üzerindeki kütleli değişimleri yakalayabilen GRACE ve GRACE Follow-On (GRACE-FO) uyduları ile de su kütesi değişimleri araştırılabilmektedir. Çalışma kapsamında Hazar Denizi ve çevresinde gerçekleşen eş değer su kalınlığı (EWT) değişimleri GRACE/GRACE-FO uydularından elde edilen Seviye-2 Sürüm-06 verileri yardımıyla incelenmiş ve 2002-2021 yıllarını kapsayan uzun dönemli veri seti elde edilmiştir. Hesaplamalar yapılırken uzun dönemli ortalama bir model oluşturulmuş ve her bir yılın ortalama değeri oluşturulan ortalama modelden çıkarılmıştır. Veri merkezi olarak CSR (Center for Space Research) tercih edilmiş ve korelasyon bazlı hataların ortadan kaldırılması amaçlı DDK (Decorrelation Filter) filtreleme tekniği kullanılmıştır. Sonuçlar haritalandırılmış olup elde edilen veriler tablo şeklinde verilmiştir. Ayrıca EWT değişimlerinin yoğun şekilde gerçekleştiği gözlemlenen bölge içerisinde bir nokta seçilerek yıllara göre EWT değişimleri hesaplanmıştır. Sonuçlar analiz edildiğinde son birkaç yıldır hızla artmakta olan negatif yönlü EWT değişimleri tespit edilmiştir. EWT değişikliklerinin negatif değerleri, o bölgenin su kütesinin azaldığı anlamına gelir.

1. INTRODUCTION

Examining the factors that cause global warming and climate change and making predictions have started to find priority in interdisciplinary studies, especially in recent years. So, these studies have been supported by many different satellite programs. One of the areas where the effects of global warming and climate change are seen intensely is water mass changes. Mainly, water mass changes in closed seas are susceptible to global warming and climate changes. Disruption of the balance between precipitation and evaporation causes extraordinary water mass changes (Elguindi & Giorgi, 2006).

Thanks to the progress of satellite earth observation missions and the increase in studies with satellite data, changes on earth can be monitored with high accuracy through multiple data sources. Level-2 data of the GRACE and GRACE Follow-On (GRACE-FO) satellites are used to examine the temporal changes in the earth's gravity field (Atlı 2022).

Level-2 solutions obtained from GRACE and GRACE-FO satellites are in terms of harmonic coefficients. A long-term average model is needed to eliminate model errors caused by harmonic coefficients. The model used in the study is a long-term model covering the years 2002-2021 as a result of the combined use of GRACE and GRACE-FO satellites. Some of the errors in the coefficients have been corrected with the average model used. Level-2 solutions with the third Decorrelation Filter (DDK-3) obtained from the Center for Space Research (CSR) data center ensured the elimination of correlation errors. DDK methods are offered to users by the International Center for Global Earth Models (ICGEM). No extra smoothing or decorrelation operations are required for DDK filters published in different radius from one to eight (Atlı, 2022).

This study aims to determine the equivalent water thickness (EWT) changes due to global warming and climate change in the Caspian Sea, which has the world's largest inland water body. For this purpose, previous years' changes were examined using the GRACE/GRACE-FO Level-2 Release-06 DDK-3 filtered data obtained from the CSR data center.

In the studies, which investigated the water level changes of the Caspian Sea for years, conducted with tide gauges, positive increases were observed in the water level between 2002-2006 with both gauges stations and altimeter technique (Lebedev & Kostianoy 2008; Chen et al. 2017a; Chen et al. 2017b). The research detected sudden negative decreases from 2010 to 2015 (Chen et al. 2017a; Chen et al. 2017b).

In the study, GRACE-FO data, which started to work as of 2018, were combined with GRACE data, which started to work in 2002, in order to examine recent changes. As the monthly data published on ICGEM is updated, it is designed to be updated in the

study. The updateability of EWT changes has been presented as a contribution to the literature.

2. MATERIALS AND METHOD

2.1. GRACE/GRACE-FO Satellite System

In order to explore the changes in the earth, information about the temporal changes of the gravity field is obtained with the GRACE twin satellites, which started to work in 2002 with the American-German partnership. Low Earth Orbiter GRACE satellites placed in orbit at an altitude of 500 km provide users with three data sets based on gravity information (Level-1, Level-2, Level-3). Although the mission period of the GRACE twin satellites ended in 2017, GRACE-FO, which was placed into orbit in 2018, GRACE's missions have continued from where they left off. While its mission is to examine the temporal variation of the earth's gravity field (Hofmann and Moritz 2006), GRACE also has investigated the distribution of water and glaciers on the planet, bettering glacial mass losses, sea level changes, mass-based changes, and ocean circulation processes during its more than 15-year mission (Figure 1). In addition, it has played an essential role in determining the growth, shrinkage, and drought levels in groundwater resources (Landerer et al., 2020).




Figure 1. The GRACE/GRACE-FO Satellite System (URL-1)

The data received from the GRACE and GRACE-FO satellites are in the form of harmonic coefficients and are published monthly (Atlı 2022). Two periods cannot be directly compared in studies with harmonic coefficients because monthly solutions are loaded with model-based errors due to harmonic coefficients (Wahr et al. 2006, Liu 2008). A static or long-term average model is used to eliminate model-based errors (Liu 2008).

$$\Delta C_{nm} = \begin{cases} C_{nm}(t) - \bar{C}_{nm} \\ or \\ \bar{C}_{nm,i} - \bar{C}_{nm,j} \end{cases},$$

$$\Delta S_{nm} = \begin{cases} S_{nm}(t) - \bar{S}_{nm} \\ or \\ \bar{S}_{nm,i} - \bar{S}_{nm,j} \end{cases},$$

$$(2 \leq n \leq n_{max}, 0 \leq m \leq n) \quad (1)$$

In Equation (1), C_{nm} and S_{nm} are the n . degrees and m . are ordinary harmonic coefficients. i and j denote annual models. Within the scope of the study,

a long-term annual average model was created, and mappings were made on this model.

2.2. Study Area

The Caspian Sea is the world's largest inland water body and the world's largest saltwater lake. It has both sea and lake features. Its surface area is 371,000 km², and its surface altitude is 28 meters below sea level. The Caspian Sea is not connected to the oceans, and for this reason, the water level is constantly changing (Chen et al. 2017a). Today, its borders are between Iran, Azerbaijan, Russia, Kazakhstan, and Turkmenistan (Figure 2).



Figure 2. Study area

2.3. The Equivalent Water Thickness (EWT) Changes

The water mass changes are concentrated in a layer about several kilometers thick on the Earth's surface. GRACE and GRACE-FO satellites are very sensitive to mass changes occurring on the Earth (Wahr et al. 2006, Liu 2008). EWT change, one of the changes that occur due to hydrological events, can be obtained by GRACE and GRACE-FO satellites. EWT changes from the GRACE and GRACE-FO satellites correlate with all water layers (Figure 3).




Figure 3. Integrated water layers measured by GRACE (Cazenave and Chen 2010)

Surface mass anomalies occur due to changes in the thin water layer (<1 km) on the physical earth. The recognized change can be shown with the harmonic expansion in Equation 2 (Wahr 2007, Liu 2008).

$$\Delta\sigma(\vartheta, \lambda) = a\rho_w \sum_{n=2}^{n_{max}} \sum_{m=0}^n (\Delta\check{C}_{nm}\cos m\lambda + \Delta\check{S}_{nm}\sin m\lambda) P_{nm}(\cos\vartheta) \quad (2)$$

In Equation (2), ΔC_{nm} and ΔS_{nm} give the surface density coefficient changes, while ρ_w expresses the density of water (1000 kg/m³). The water thickness change corresponds to the density change is defined as (Equation 3).

$$\Delta e(\vartheta, \lambda) = \frac{\Delta\sigma(\vartheta, \lambda)}{\rho_w} \quad (3)$$

There is a relationship between the scaled surface density coefficient changes with the major semi-axis of the reference ellipsoid and the coefficient changes given in Equation (1) (Wahr et al 1998, Wahr 2007, Liu 2008).

$$a \begin{Bmatrix} \Delta\check{C}_{nm} \\ \Delta\check{S}_{nm} \end{Bmatrix} = a \frac{\rho_{ave}(2n+1)}{3\rho_w(1+k_n)} \begin{Bmatrix} \Delta C_{nm} \\ \Delta S_{nm} \end{Bmatrix} = K_n \begin{Bmatrix} \Delta C_{nm} \\ \Delta S_{nm} \end{Bmatrix} \quad (4)$$

The ρ_{ave} in Equation (4) shows the average density of the earth (5517 kg/m³), and k_n expresses the n degrees of the Love numbers.

If the coefficient changes given in Equation (4) are used in Equation (2) and then the density change obtained is substituted in Equation (3), linear expression of the EWT changes can be found depending on the GRACE harmonic coefficient changes (Equation 5).

$$\Delta e(\vartheta, \lambda) = \sum_{n=2}^{n_{max}} \sum_{m=0}^n (\Delta C_{nm}\cos m\lambda + \Delta S_{nm}\sin m\lambda) K_n P_{nm}(\cos\vartheta) \quad (5)$$

2.4. The Method

The data used in the numerical application are Level-2 Release-06 data of 60 × 60 degrees covering the GRACE and GRACE-FO satellites of the CSR data center located on the ICGEM page. Data are published monthly in terms of harmonic coefficients. The method used to remove the noise in the high order coefficients of these data is the DDK-3 filtering method. Filtered data with the DDK-3 filtering method can be obtained from ICGEM. In the data consisting of harmonic coefficients, abnormal changes were detected in the C_{20} coefficients, representing the ground's kurtosis (Cheng and Tapley 2004). For this reason, the C_{20} coefficients obtained from the GRACE and GRACE-FO tasks were replaced with the C_{20} coefficients obtained from the Satellite Laser Ranging (SLR). In addition, GRACE and GRACE-FO gravity solutions do not contain short-term atmospheric and ocean mass signals. Therefore, the GAD background models need to be reintroduced to the GRACE monthly solutions (Figure 4) (Atli, 2022).

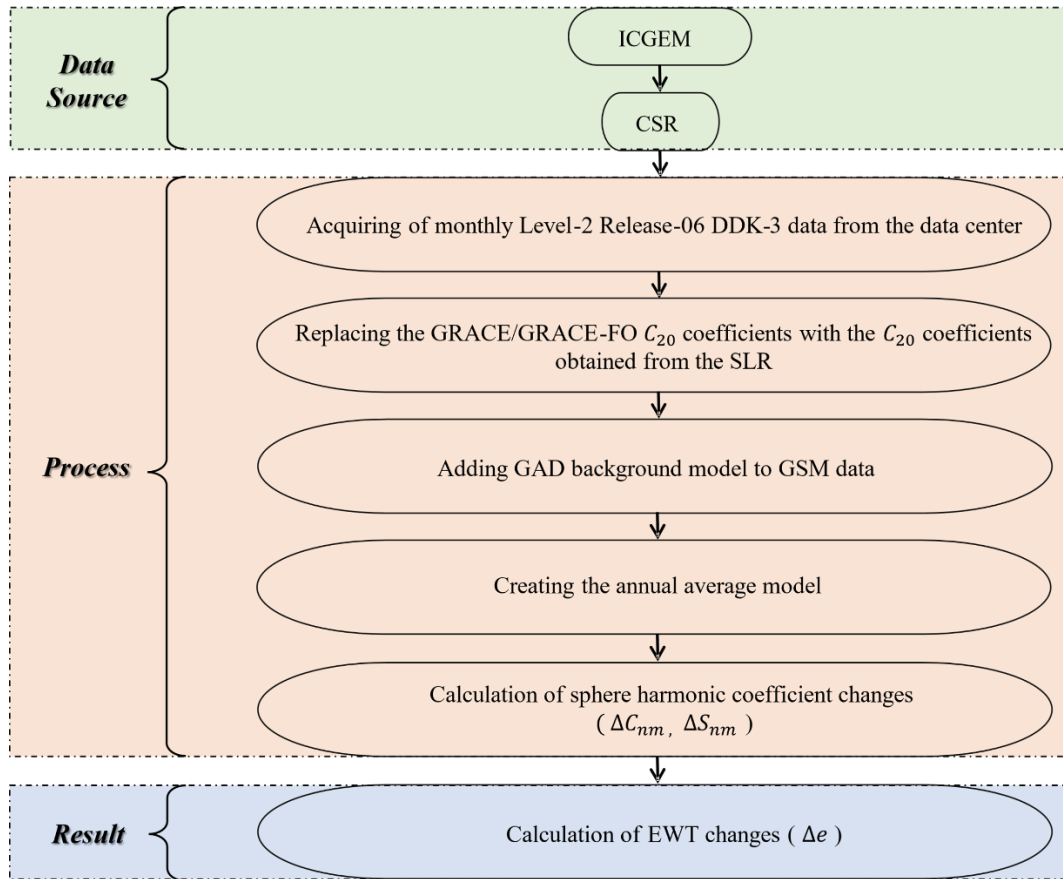


Figure 4. The workflow schema of the study

3. RESULTS AND DISCUSSION

EWT variations in the region within the latitude of $35^{\circ} \leq \theta \leq 50^{\circ}$ and longitude $40^{\circ} \leq \lambda \leq 60^{\circ}$ covering the Caspian Sea were calculated as $0.5^{\circ} \times 0.5^{\circ}$ grids. In the model in which the annual change is examined, the results are obtained by subtracting the average value of the relevant year from the average value of all years (Figure 5). When Figure 5 is examined, it is seen that there are positive values between 2002-2010. However, EWT changes from 2012 are in the form of negative values.

Table 1 shows the minimum, maximum, mean, and standard deviation (std) values of the EWT changes in the area selected as the study area. The std value is a measure of the distribution of a data group, and it is a measure of how close or far our data is from the arithmetic mean which is the expected value. While a high std shows that the values are dispersed throughout a wider range, a low std indicates that the values tend to be close to the mean and the calculated estimate values are quite good (Bland and Altman 1996). In this study, the std values for the EWT changes were calculated based on the harmonic coefficients and the std values of these coefficients obtained from the data centers. However, the std values of the coefficients obtained from the data centers contain some systematic effects. Therefore, the computed std values can be considered as the precision (Atayer 2012).

According to the Table 1, the average values with positive EWT values between 2002 and 2010 have followed a negative trend since 2011 (Figure 6). Similarly, when the std values obtained by years are examined, it is seen that there was a decreasing trend in general between 2002 and 2011, while there was a general increase after 2011 (Figure 7).

Similar results were obtained in the study of Chen et al. It was studied until 2015 and it was observed that the EWT changes measured from 2010 to 2015 were negative values, while the values between 2002 and 2006 were positive (Chen et al. 2017a; Chen et al. 2017b). Similarly, Lebedev et al. obtained solutions with positive values between 2002 and 2006 (Lebedev and Kostianoy 2008).

In order to observe the EWT changes on a point-based basis, a point was selected in the area where the intense change was experienced, and the EWT changes were analyzed. The analysis results between 2002-2021 on the point at $40^{\circ} 54' 36.77''$ latitude and $50^{\circ} 23' 23.12''$ longitude chosen from the region where EWT changes are observed intensely are given in Table 2. According to Table 2, while positive values were checked until 2011, negative values began to be seen in 2012. While the most significant positive value was observed in 2005 (33.59 cm), the most significant negative (-54.20 cm) was observed in 2021. In addition, it was observed that the EWT changes were upward from 2002 to 2005 and downward after 2005 (Figure 8).

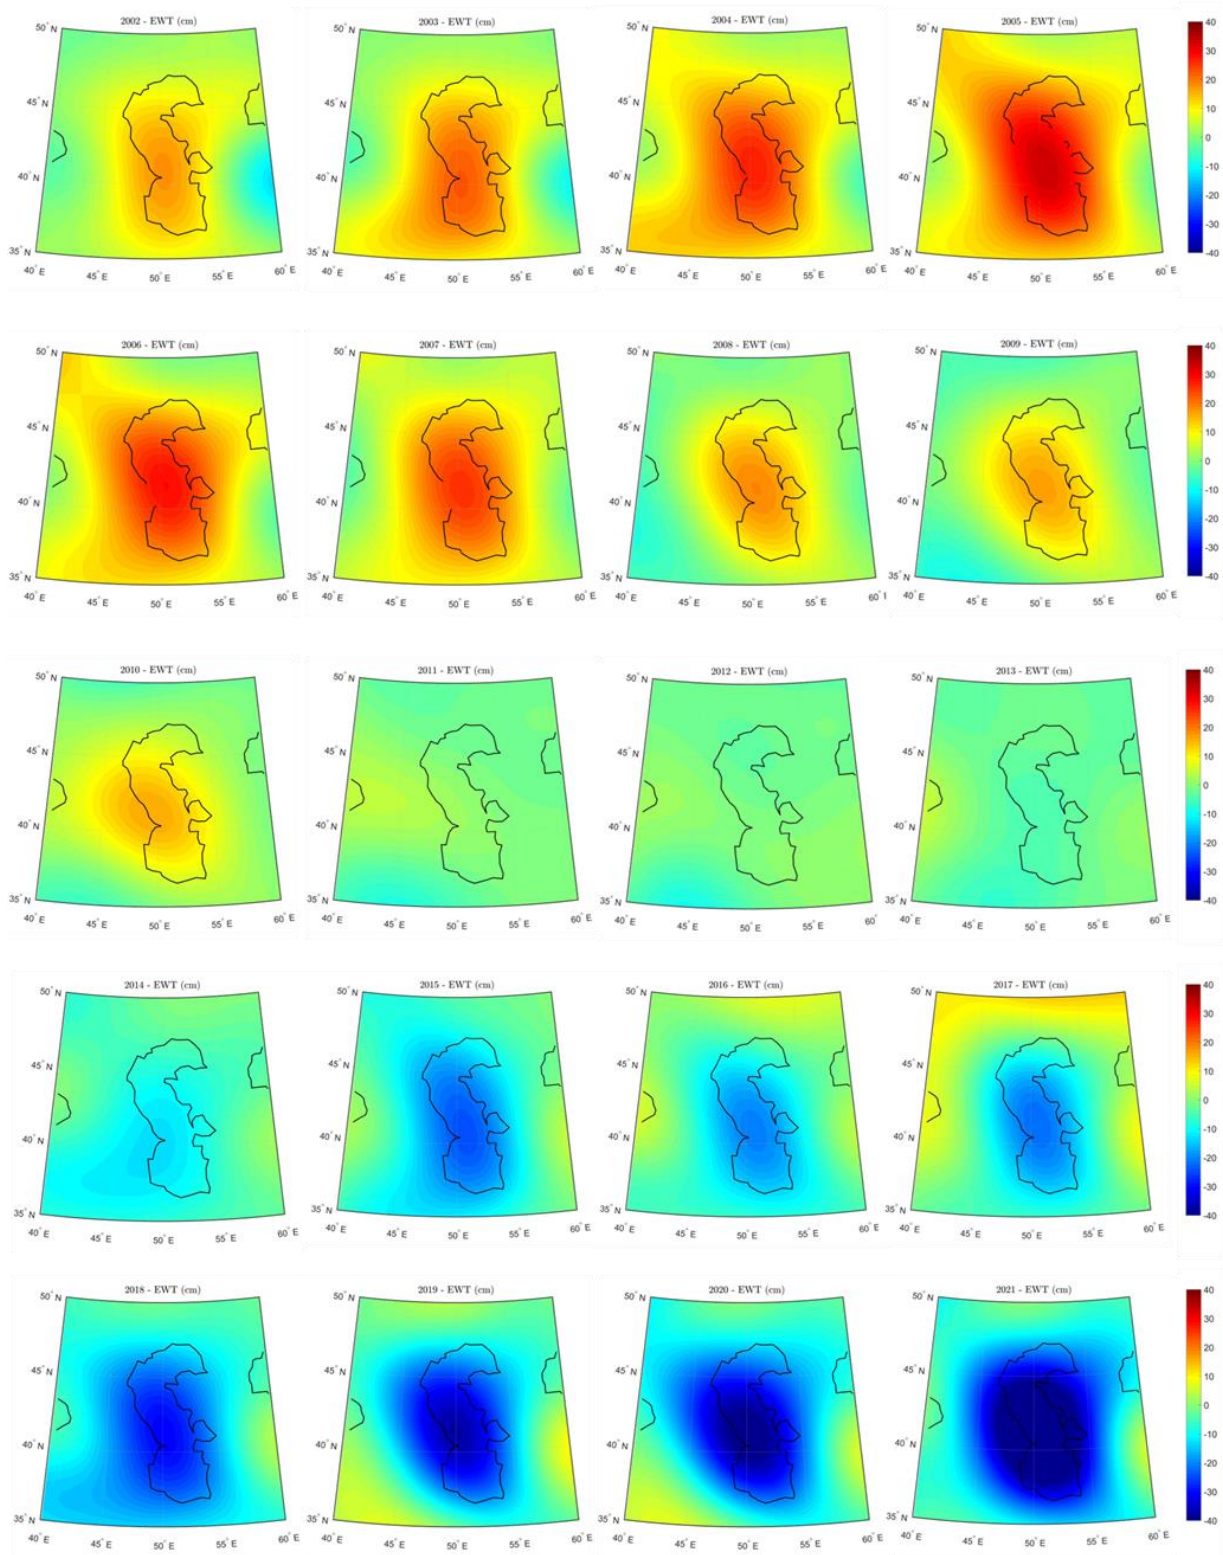


Figure 5. EWT changes in and around the Caspian Sea between 2002-2021

Table 1. EWT changes in the study area between 2002-2021

Year	min (cm)	max (cm)	mean (cm)	std (cm)	Year	min (cm)	max (cm)	mean (cm)	std (cm)
2002	-13.22	17.98	3.79	5.76	2012	-9.19	8.49	-0.85	2.47
2003	-10.19	22.77	5.85	7.06	2013	-6.55	7.60	-0.79	3.26
2004	-5.36	27.23	10.14	6.57	2014	-13.20	1.87	-5.78	3.54
2005	-2.42	33.62	12.17	8.21	2015	-24.55	8.45	-6.76	7.83
2006	-3.53	28.80	10.09	7.51	2016	-20.79	8.09	-3.54	7.21
2007	-8.20	25.71	6.57	8.16	2017	-22.30	13.53	-0.65	9.04
2008	-8.32	18.83	1.66	6.96	2018	-30.74	3.60	-11.75	7.44
2009	-9.05	16.85	1.48	6.05	2019	-37.78	9.80	-8.36	10.84
2010	-5.98	16.14	3.54	4.72	2020	-42.11	7.48	-11.96	11.16
2011	-8.08	4.32	-0.11	2.50	2021	-54.26	6.18	-15.57	13.85

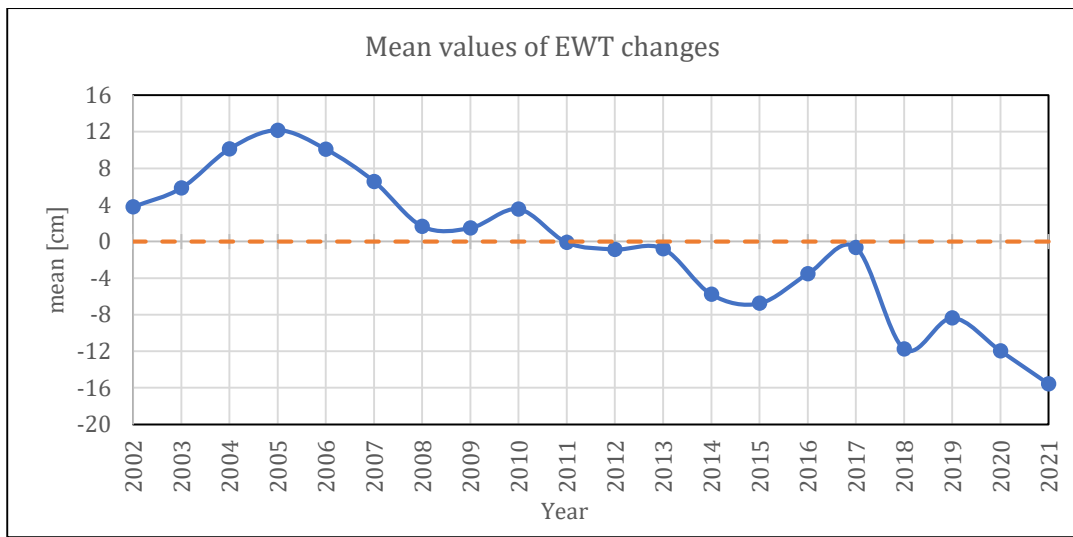


Figure 6. Mean values of EWT changes

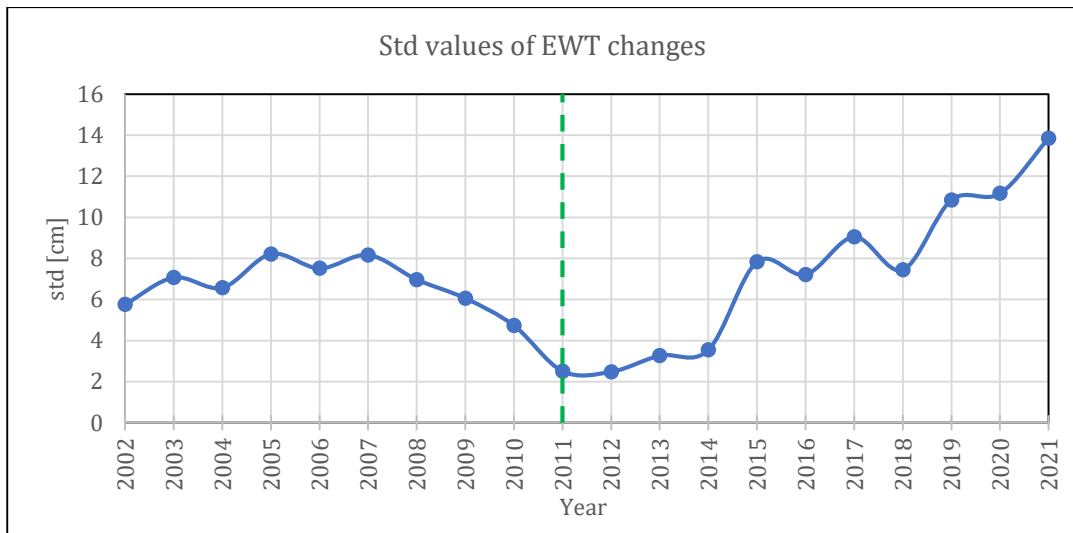


Figure 7. Std values of EWT changes

Table 2. EWT changes at the chosen point between 2002-2021

Year	EWT changes (cm)	Year	EWT changes (cm)
2002	18.00	2012	-0.62
2003	22.55	2013	-4.50
2004	27.25	2014	-12.87
2005	33.59	2015	-24.51
2006	28.51	2016	-20.75
2007	25.65	2017	-22.16
2008	18.72	2018	-30.72
2009	16.75	2019	-37.54
2010	15.84	2020	-42.07
2011	1.60	2021	-54.20




Figure 8. Chosen point EWT change

4. CONCLUSIONS

The aim of the study is to determine the EWT changes due to global warming and climate change in and around the Caspian Sea with GRACE/GRACE-FO satellites Level-2 Release-06 data. In the study, the harmonic coefficients were analyzed, and the changes over the years were presented in the form of visual maps. Since most of the water mass changes in the Caspian Sea, which has the world's largest inland water body, depend on the balance between precipitation and evaporation, water mass changes are highly affected by global warming and climate change. When the average values calculated annually as a result of the study are examined, the negative EWT changes observed since 2011 show the decrease in water bodies in those years. Especially when Figure 5 is examined, intense EWT decreases from 2014 to 2021 can be seen formally. It supports the map created with the values given in Table 1. With the help of the maps created, when the data on the selected point in the area where the change is

most intense in the study area is examined, it is seen that the EWT values, which are rapidly decreasing from 2012 to 2021. The EWT values for the years 2020-2021, when the highest negative change is seen, can be shown as a reflection of the negative effects of global warming and climate change on the Caspian Sea.

Acknowledment

The authors would like to thank ICGEM, NASA, and CSR data centers for all their contributions to the creation of this study.

Author contributions

MN. Makineci (First Author): Created the datasets and figures, Methodology, Discussion.

S. Doğanalp (Second Author): Designed the research, Analyzed the data, Review and editing.

Conflicts of Interest

The authors declare no conflict of interest.

Declaration of research and publication ethics

In the study, the authors declare that there is no violation of research and publication ethics and that the study does not require ethical committee approval.

REFERENCES

- Athi, M. N. (2022). Su Kütle Değişimlerinin Farklı Uydu ve Model Verileri ile Belirlenmesi. *Master's Thesis*, Konya Technical University, Konya, 121p (in Turkish).
- Atayer, E. S. (2012). Yeryuvarı Gravite Alanının Aylık GRACE Çözümleri ile İzlenmesi ve Duyarlılığı Üzerine Bir İnceleme. *Master's Thesis*, Yıldız Technical University, İstanbul, 122p (in Turkish).
- Bland, J. M., & Altman, D. G. (1996). Statistics notes: measurement error. *BMJ*, 312 (7047): 1654. doi:10.1136/bmj.312.7047.1654.
- Cazenave, A., & Chen, J. (2010). Time-variable gravity from space and present-day mass redistribution in the Earth system. *Earth and Planetary Science Letters*, 298(3-4), 263-274.
- Chen, J. L., Pekker, T., Wilson, C. R., Tapley, B. D., Kostianoy, A. G., Cretaux, J. F., & Safarov, E. S. (2017a). Long-term Caspian Sea level change. *Geophysical Research Letters*, 44(13), 6993-7001.
- Chen, J. L., Wilson, C. R., Tapley, B. D., Save, H., & Cretaux, J. F. (2017b). Long-term and seasonal Caspian Sea level change from satellite gravity and altimeter measurements. *Journal of Geophysical Research: Solid Earth*, 122(3), 2274-2290.
- Cheng, M., & Tapley, B. D. (2004). Variations in the Earth's oblateness during the past 28 years. *Journal of Geophysical Research: Solid Earth*, 109(B9).
- Elguindi, N., & Giorgi, F. (2006). Projected changes in the Caspian Sea level for the 21st century based on the latest AOGCM simulations. *Geophysical research letters*, 33(8).
- Hofmann, B., & Moritz, H. (2006). *Physical geodesy (Second Corrected Edition)*. Springer Science & Business Media.
- Landerer, F. W., Flechtner, F. M., Save, H., Webb, F. H., Bandikova, T., Bertiger, W. I., Bettadpur S.V., Byun, S.H.,... & Yuan, D. N. (2020). Extending the global mass change data record: GRACE Follow-On instrument and science data performance. *Geophysical Research Letters*, 47(12), e2020GL088306.
- Lebedev, S. A., & Kostianoy, A. G. (2008). Integrated use of satellite altimetry in the investigation of the meteorological, hydrological, and hydrodynamic regime of the Caspian Sea. *TAO: Terrestrial, Atmospheric and Oceanic Sciences*, 19(1-2), 7.
- Liu, X. (2008). Global gravity field recovery from satellite-to-satellite tracking data with the acceleration approach. *PhD Thesis Netherlands Geodetic Commission, Publication on Geodesy 68, TU Delft, Delft, The Netherlands 226p* (in English).
- Wahr, J., Molenaar, M., & Bryan, F. (1998). Time variability of the Earth's gravity field: Hydrological and oceanic effects and their possible detection using GRACE. *Journal of Geophysical Research: Solid Earth*, 103(B12), 30205-30229.
- Wahr, J., Swenson, S., & Velicogna, I. (2006). Accuracy of GRACE mass estimates. *Geophysical Research Letters*, 33(6).
- Wahr, J. (2007). Time-variable gravity from satellites. *Treatise on geophysics*, 3, 213-237.

URL-1:


<https://gracefo.jpl.nasa.gov/resources/86/grace-fo-3d-model/>

[Access Date: 01.08.2022]



© Author(s) 2022.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>



İstanbul İli Merkez İlçelerindeki NO₂ ve CO Emisyonlarının Uzaktan Algılama ve Yersel İstasyon Verileri Kullanılarak İncelenmesi

Hasan Bilgehan Makineci*¹ 

¹Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Konya, Türkiye

Anahtar Kelimeler

CO
Google Earth Engine
Hava Kirlenmeleri
NO₂
Sentinel-5p

ÖZ

Bu çalışmada canlı yaşamının temel taşı olan havanın içeriğinde bulunan kirlenici gaz konsantrasyonlarının (NO₂ ve CO) zamansal değişimlerinin tespiti gerçekleştirilmiştir. Tutarlı verilerin olduğu toplam on yedi aylık bir dönem (Ocak 2020 – Mayıs 2021) için gerçekleştirilen analizler sonucunda atmosferdeki kirlenici gazlardan ikisinin artış ve azalış trendleri ortaya konulmuştur. Türkiye'nin en kalabalık şehri olan İstanbul'un Anadolu ve Avrupa yakalarından birer yersel istasyona (Üsküdar ve Mecidiyeköy) ait veriler ile yersel araştırmalar gerçekleştirilmiştir. Avrupa Uzay Ajansı tarafından atmosferdeki gazların konsantrasyonunun tespiti ve izlenmesi amacıyla oluşturulan Sentinel-5 Precursor (S5p) algılayıcısı ile uydu bazlı araştırmalar da gerçekleştirilmiştir. Elde edilen sonuçlar hem yersel istasyon bazlı analizlerin hem de S5p uydu verilerine dayalı analizlerin hava kalitesinin zamansal değişimlerini tespit etmede ve izlemede kullanılabilir olduğu belirlenmiştir.

Investigation of NO₂ and CO Emissions in Istanbul Province Central Districts using Remote Sensing and Terrestrial Station Data

Keywords

CO
Google Earth Engine
Air Pollutants
NO₂
Sentinel-5p

ABSTRACT

This study focused on the temporal changes of pollutant gas concentrations (NO₂ and CO) in the air data from different resources, the cornerstone of living life. As a result of the analyzes carried out for a total of seventeen months (January 2020 – May 2021) with consistent data, the increase and decrease trends of two of the polluting gases in the atmosphere were revealed. Geographical studies were carried out with data from one terrestrial station (Üsküdar and Mecidiyeköy) from the Anatolian and European sides of Istanbul, the most populated city in Türkiye. Satellite-based research was also carried out with the Sentinel-5 Precursor (S5p), which the European Space Agency (ESA) created to detect and monitor the concentration of gases in the atmosphere. It has been determined that either terrestrial station-based or S5p satellite data based analyzes can detect and monitor temporal changes in air quality.

1. GİRİŞ

Hava kalitesinin canlı sağlığına doğrudan etkisi inkâr edilemez bir gerçektir. Normal ve kabul edilebilir hava içeriği %78,084 N₂ (azot), %20,946 O₂ (Oksijen), %0,934 Ar (Argon), %0,035 CO₂ (Karbon dioksit), % 0,001'i Ne (Neon), CH₄ (Metan), He (Helyum), H₂ (Hidrojen) ve Kr (Kripton) gazlarından ve yaklaşık %0,25'i su buharından oluşmaktadır. Hava kirleticileri olarak bilinen Karbon monoksit (CO) ve Azot dioksit (NO₂) ise canlı yaşamına verdikleri zararlar dolayısıyla solunan havada olmaması istenen gazlardır (Kalıpcı & Başer, 2019; Nazarenko vd., 2021; Shams vd., 2021). Renksiz, kokusuz olan CO gazı yakıtlarda bulunan karbonun (C) tam olarak yakılmadığı durumlarda ortaya çıkan ve oksijeni (O₂) bağlayarak canlılarda boğulmalara yol açan bir gazdır. İçten yanmalı motorlar, endüstriyel sanayi üretimleri, yoğun odun yakılması ve orman yangınları CO gazının başlıca oluşum kaynakları olarak söylenebilir (Taheri & Razban, 2021). Yüksek sıcaklıklarda oluşan ve suda erimeyen, renksiz, kokusuz bir gaz türü olan NO₂ ise üst solunum yollarında önemli olumsuzluklara yol açabilir. Atmosfere salınan azot oksitler (NO) yükseldikçe oksitlenerek NO₂ haline dönüşür. Bu gaz katı ve sıvı yakıtların yanmasıyla ortaya çıkar. Temel olarak motorlu taşıtlar, termik santral çevreleri, endüstriyel tesisler, ticari ve evsel ısınma amaçlı yakılan yakıtlar NO ve NO₂ oluşumunu hızlandırmaktadır (Shams vd., 2021; Kaplan & Yigit Avdan, 2020).


Sentinel-5 Precursor (S5p) Avrupa Uzay Ajansı (European Space Agency -ESA-) tarafından 2018 yılından itibaren atmosfer ile ilgili veriler sunan bir görev olarak tanımlanmaktadır. TROPospheric Monitoring Instrument (TROPOMI) cihazını taşıyan bir uydu olarak S5p Tropomi görevinin temel amacı hava kalitesi, ozon ve UV radyasyonu ve iklim izleme ve tahmin için kullanılmak üzere yüksek uzaysal-zamansal çözünürlükte atmosferik ölçümler yapmaktır (Sümsüli & Kalkan, 2022). Verilerine Sentinel Data Hub sisteminden erişilebildiği gibi Google Earth Engine (GEE) platformundan da ulaşılabilmektedir (Albarqouni vd., 2022; Ghasempour vd., 2021; Shami vd., 2022; Karaca vd., 2022).

Uzaktan algılama ve meteoroloji verileri gibi verilere daha kolay erişebilmek ve otomatik indekslerde işlemler yapabilmek için son zamanlarda sık kullanılan GEE platformu Dünya'nın yüzeyindeki değişiklikleri tespit etmek, eğilimleri haritalamak ve farklılıkları ölçmek için tercih edilmektedir. S5p verisi 840 km orbital yörüngede bulunan ve atmosferik bilgiler ile havadaki gazları değerlendiren bir uydu olarak CO ve NO₂ gazları için elde edilen verilerin birimleri mol/m² olarak sunulmuştur. Yersel hava kalitesi izleme istasyonlarında ise CO ve NO₂ gazları için elde edilen verilerin birimleri µg/m³ cinsindedir (Kaplan & Yigit Avdan, 2020; Ghasempour vd., 2021).

Bu çalışmanın amacı İstanbul merkezde yer alan Üsküdar ve Şişli ilçelerinde hava birleşiminin içerisindeki CO ve NO₂ gaz oranlarının yersel istasyon verileri ve uydu gözlemleriyle tespit edilmesi ve zamansal analizlerinin yapılmasıdır. Seçilen ilçelerin ortak özelliği İstanbul gibi metropol şehrin insan yoğunluğu yüksek ve ana kullanım bölgeleri olmasıdır. Ocak 2020 ile Mayıs 2021 arasındaki toplam on yedi aylık dönemde aylık ortalamalar cinsinden veriler yorumlanarak analiz edilmiştir. Dönemsel olarak artış ve eksilmeler tablolarında her iki gaz için de sunulmuş ve yersel istasyonlar ile S5p uydu verileri arasında korelasyon ortaya konulmuştur.

2. YÖNTEM

Araştırmada kullanılan S5p uydusu ve uyduya ait 17 aylık CO ve NO₂ gazları verileri GEE online platformundan elde edilmiştir. Yersel istasyon verileri ise Çevre ve Şehircilik Bakanlığı'nın Hava Kalitesi - İstasyon Veri İndirme platformundan elde edilmiştir (URL-1). Çalışmanın iş akışı Şekil 1'de görüldüğü gibidir.



Şekil 1. Çalışmaya ait iş akış şeması

2.1. Sentinel-5 Precursor Uydusu ve Verisi

S5p üzerinde bulunan spektrometre algılayıcısıyla (TROPOMI), Ağustos 2019'dan bu yana yakın kızılötesi bant ile nadir doğrultusunda 3,5×7,5 km² piksel boyutlarında küresel, sürekli konumsal çözünürlükte ve günlük tekrar ziyaret süresinde veri toplamaktadır. TROPOMI, NO₂, O₃, formaldehit, SO₂, CH₄, CO ve aerosoller gibi çok sayıda eser gazı 0.01 arc derece konumsal çözünürlükte haritalama yeteneğine sahiptir (URL-2). Temelde üç farklı veri şekliyle çalışılmaktadır. Bu veriler, gerçek zamanlıya yakın (NRTI) veri, çevrimdışı veri (OFFL) ve tekrar işlemeli (RPRO) veri olarak sınıflandırılmaktadır. NRTI verileri, alımdan

sonra 3 saat içinde elde edilebilirken, OFFL ve RPRO verileri, alımdan sonraki birkaç gün içinde kullanılabilir hale getirilmektedir. Veri indirebilmek için seçilen her bir parametreye ait veriler günlük olarak (mol/m^2 biriminde) belirlenen zaman aralığında toplam olacak şekilde elde edilmektedir.

Çalışma için Ocak 2020 ile Mayıs 2021 arasındaki toplam on yedi aylık periyotta CO ve NO₂ gazlarına ait elde edilen verilen GEE platformundan alınmıştır.

2.2. Yersel İstasyon Verileri

Çevre ve Şehircilik Bakanlığı Sürekli İzleme Merkezi (SİM) Ulusal Hava Kalitesi İzleme Ağı (UHKİA) tarafından sunulan Hava Kalitesi İstasyon Veri İndirme platformu ile şehirlere ve ilçelere ait hava içeriği ve PM10, PM2.5, NO_x, NO₂, O₃, SO₂, CH₄, CO maddelerinin yoğunluğunu günlük veya saatlik olarak toplamda aylık olarak elde edilen bir platformdur (Sümsüli & Kalkan, 2022). Veri indirebilmek için seçilen her bir parametreye ait veriler saatlik olarak ($\mu\text{g}/\text{m}^3$ biriminde) belirlenen zaman aralığında Min. Değer, Min. Tarih, Max. Değer, Max. Tarih, Ort. Değer, Veri Adeti, Olması Gereken Veri, Veri Yüzdesi, Standart Sapma ve Toplam Değer olarak elde edilmektedir.

Çalışma için Ocak 2020 ile Mayıs 2021 arasındaki toplam on yedi aylık periyotta CO ve NO₂ gazlarına ait emisyonları “Hava Kalitesi - İstasyon Veri İndirme” sisteminden elde edilmiştir.

2.3. Google Earth Engine

GEE platformu akademik kullanıcılar için coğrafi veri setlerini analiz edebilen ve raster olarak kullanıcılara sunabilen bir araçtır. Kod editörü ile kullanıcılar GEE aracının içerisinde bulunan çok büyük verileri kendi kullanım amaçları doğrultusundan sınırlandırarak otomatik analizler yapabilir (URL-2).

Bu çalışmada S5p verileri GEE platformunda belirlenen çalışma bölgesini ve istenilen zaman aralığını kapsayacak şekilde GEE kod editöründen üretilerek lokal kullanıcı bilgisayarına aktarılmıştır. Bu şekilde çalışmanın iyi yanı küçük kodlar kullanarak ve bilgisayar gücünü daha az tüketerek hazır üretilmiş verilere ulaşılabilmesidir (Ghasempour vd., 2021; Shami vd., 2022; Karaca vd., 2022).

Ek 1 ve Ek 2 kod editörü aracında GEE platformunda kullanılan örnek kodlar yer almaktadır. Bu kodlara spesifik bölgeler koordinatları ve zaman aralıkları yazılarak NO₂, O₃, formaldehit, SO₂, CH₄, CO ve aerosoller gibi tüm hava kirleticilerinin S5p TROPOMI sensöründe tespit edilen miktarlarına ulaşılabilir. Kod editöründen COPERNICUS_S5P_OFFL_L3_NO2 ve COPERNICUS_S5P_OFFL_L3_CO verileri çalışma için elde edilmiştir.

2.4. Çalışma Alanı

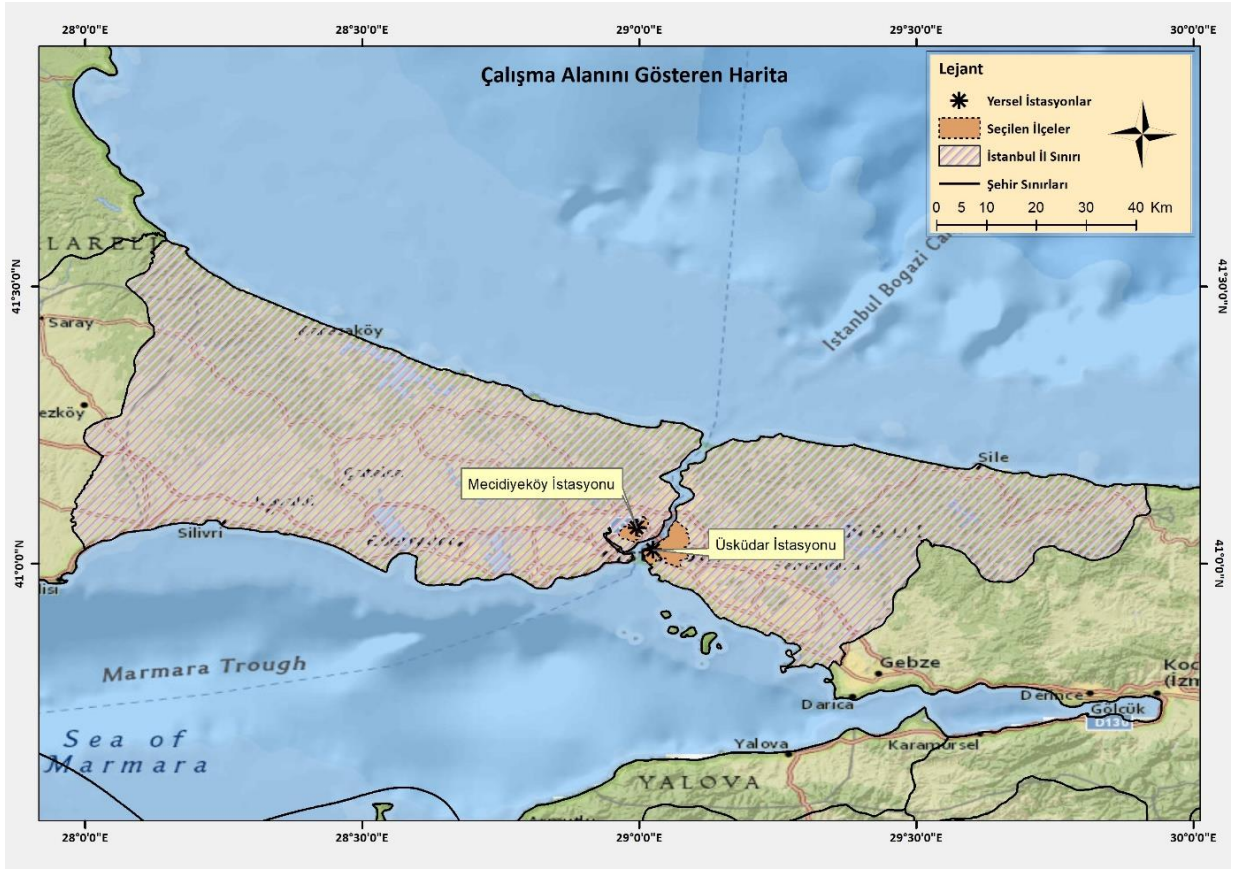
Türkiye'nin en kalabalık ve nüfus yoğunluğu en yüksek ili olan İstanbul Metropol Şehri 2021 yılı Aralık Ay sonu itibarıyla 15.840.900 kişiye ev sahipliği yapmaktadır. Nüfus yoğunluğu olarak ise İstanbul 3.050 kişi/km² ile ülke ortalamasının neredeyse 30 katında yoğunluğa sahiptir (Türkiye'nin nüfus yoğunluğu 110 kişi/km²) (URL-3).

Araştırmaya konu olan Şişli ve Üsküdar ilçeleri 2020 yılında sırasıyla 266.793 ve 520.771 nüfus değerlerine sahipti. Şişli ve Üsküdar ilçeleri 2021 yılında ise sırasıyla 284.294 ve 525.395 nüfus değerlerine ulaşmıştır. Çalışma alanı ve yersel istasyonlara ait konumlar Şekil 2'de sunulmaktadır (URL-3).

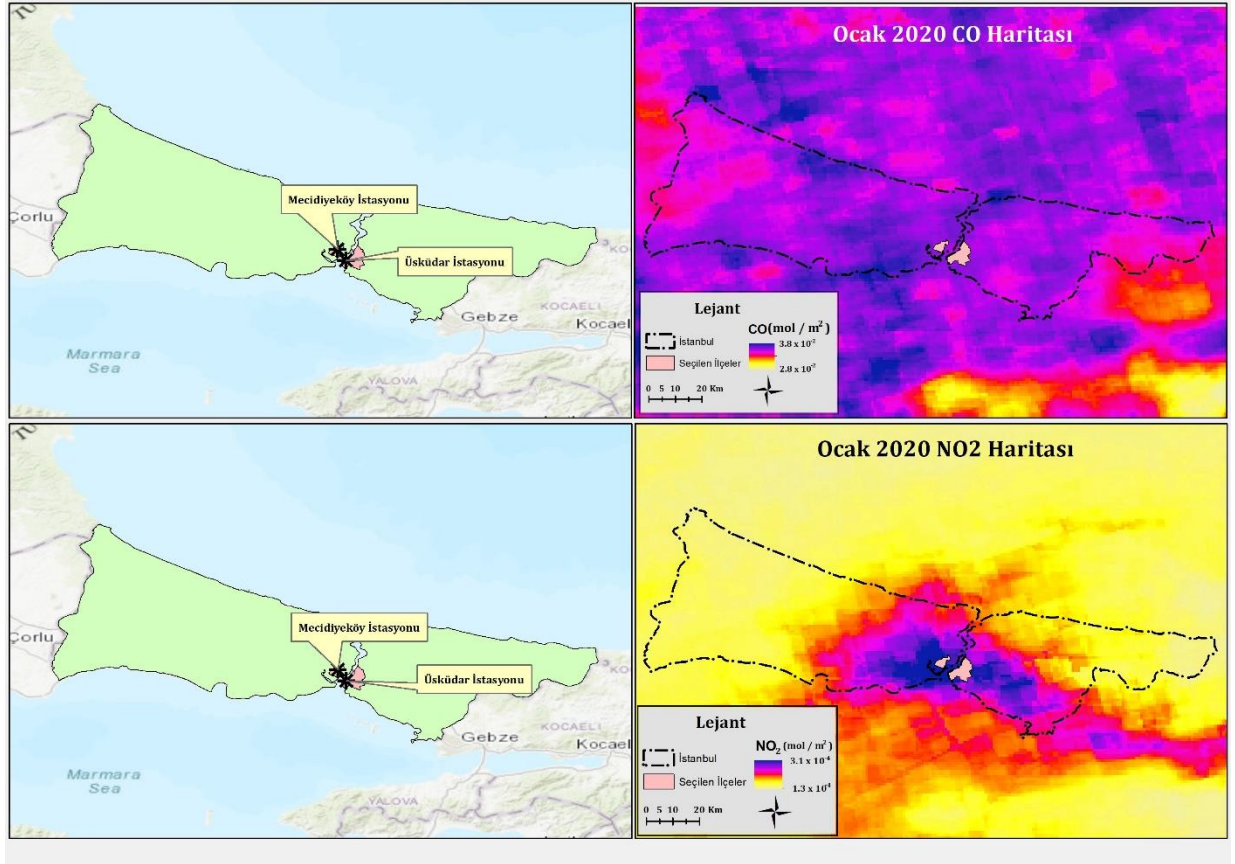
2.5. Verilerin Normalizasyonu

Çalışmada kullanılan CO ve NO₂ gazlarına ait S5p verilerinin birimleri mol/m^2 ve yersel hava kalitesi izleme istasyonlarında ise CO ve NO₂ gazları için elde edilen verilerin birimleri $\mu\text{g}/\text{m}^3$ cinsindedir. Bu iki farklı verilerin birbirine dönüşümü gerçekleştirilemediği için oranlama yapılarak birimsiz hale getirilmiştir. Birimsiz olarak ise çok küçük veya çok büyük değerlerin analizi görsel olarak uygun olmadığı için min-maks normalizasyonu gerçekleştirilmiştir. Eşitlik 1'de belirtildiği üzere Normalize edilmiş değer (X'), tüm örneklem kümesinin en küçük (X_{min}) ve en büyük (X_{maks}) değerleri kullanılarak 0 ile 1 aralığında değişen yeni değerler olarak tanımlanmasını sağlamaktadır (Jain vd., 2018; Kappal, 2019).

$$X' = \frac{X - X_{min}}{X_{maks} - X_{min}} \quad (1)$$



Şekil 2. Yersel istasyonların konumları ve çalışma bölgesi



Şekil 3. Yersel istasyonların konumları ve çalışma bölgesi

3. BULGULAR

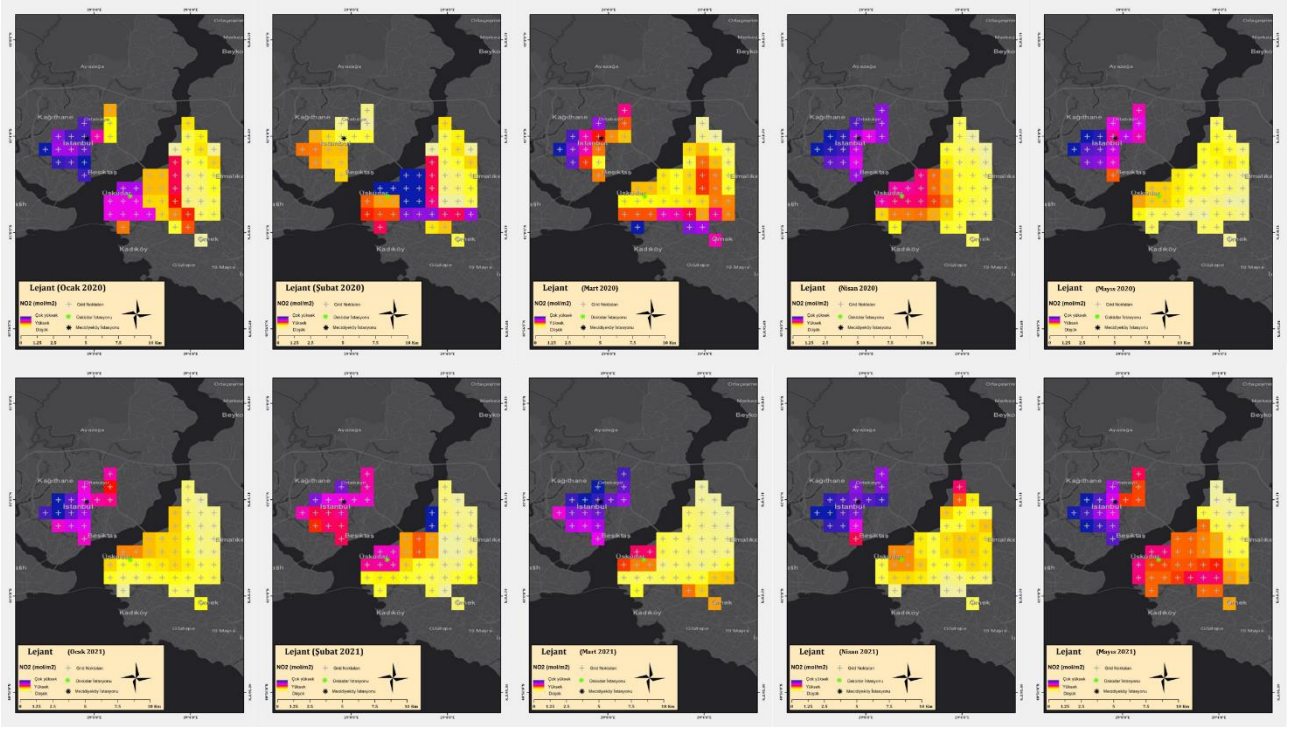
Araştırmada kullanılan iki tür CO ve NO₂ verisi (yersel istasyon ve uydu verileri) yorumlanabilir hale getirilmek için öncelikle verilerin işlenmesi gerekmektedir. Yersel istasyon verileri metrik değerler olarak elde edilmiştir. Fakat uydu verileri GEE platformundan raster olarak alınmaktadır. Ocak 2020 ile Mayıs 2021 arasında her aya ait (on yedi aylık süreç) veriler aynı işlemlere tabii tutularak analiz için hazırlanmıştır. Raster veri setleri öncelikle kullanılan CBS yazılımında çalışma alanı için uygun şekilde kesilmiştir. Kesilmeden önce ham raster verisi Şekil 3'te sunulmuştur.

S5p uydu verilerinde kırpma, gridleme ve üretilen noktalardan (grid ortalarına atılan noktalar) elde edilen bilgiler sayesinde İstanbul İli merkez ilçeleri Üsküdar ve Şişli (Mecidiyeköy) ile ilgili zamansal analiz gerçekleştirilmiştir. Kırpma işlemi sonucunda elde edilen ürünlerde kırpma öncesi piksel derinliği ile kırpma işlemi sonrası piksel derinliği aynıdır. Şekil 4 ve Şekil 5'te sunulduğu üzere CO ve NO₂ gazlarına ait zamansal değişim (şekillerde sadece 2020 ve 2021 yıllarının ilk beş ayları sunulmuştur) uydu verilerinden tespit edilebilmektedir. NO₂ gazı için kış aylarında (ocak ve şubat) düşük olan ortalama konsantrasyon baharla beraber artmakta iken CO gazı için kış aylarında yüksek baharın ilk döneminde azalan Mayıs'tan itibaren ise yeniden artan ortalama konsantrasyon söylenebilir (özellikle Üsküdar için). On yedi aylık ortalama ise CO konsantrasyonu için trendin ilkbahar ve yaz aylarında düşüş, sonbahar ve kış aylarında ise yükseliş yönünde olduğu görülmektedir (Tablo 1). On yedi aylık ortalama NO₂ gazı konsantrasyonu için trendin aralık ve şubat ayları arasında en üst seviyelere çıktığı kalan aylarda da düşüş trendine girdiği söylenebilmektedir (Tablo 2).

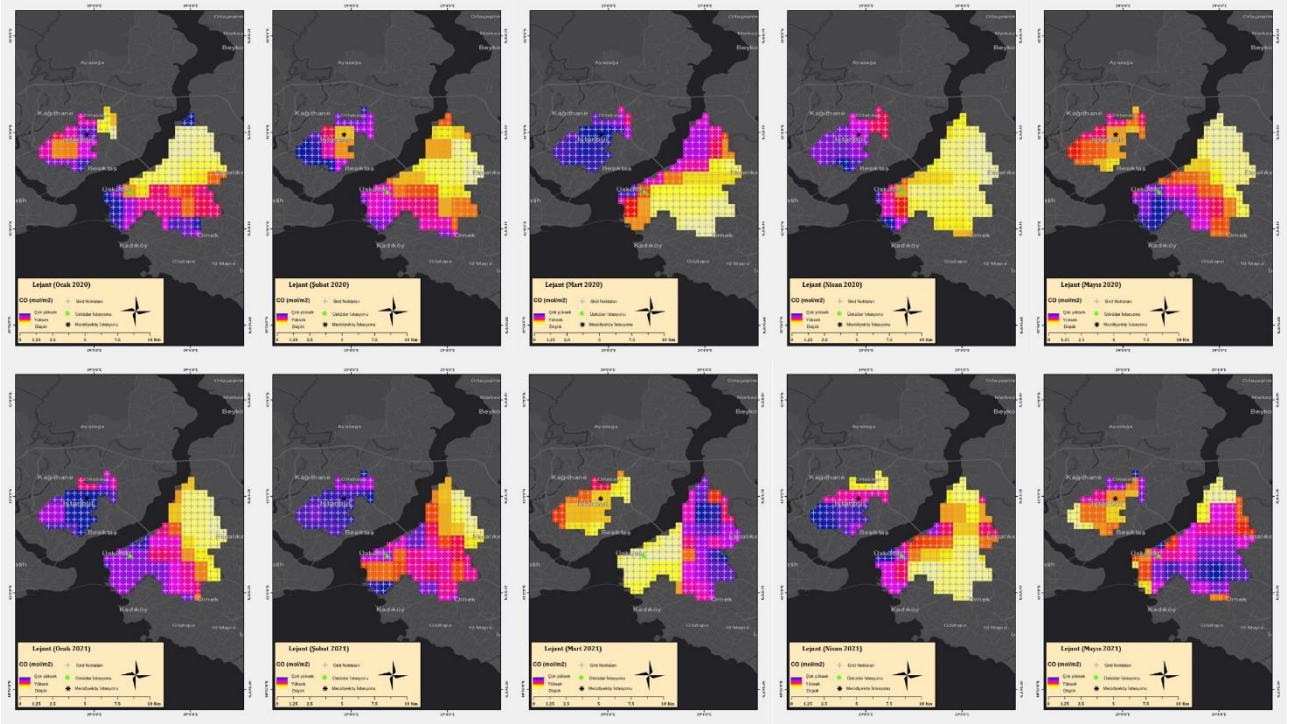
Yersel istasyonlar kısıtlı bir çevreyi temsil edebildikleri için S5p uydu verilerinden elde edilen

konsantrasyon değerlerini istasyon konumlarının civarında bulunan en yakın noktalara indirgeyerek tekrardan analizler yapılmıştır. Bu analizler sonucunda ise Üsküdar istasyonu civarında yer alan noktalardan elde edilen CO gazı konsantrasyonunun Tablo 3'te görüldüğü gibi Ocak-Nisan aylarında yükseldiği ve Mayıs'tan itibaren düşmeye başladığı tespit edilmiştir. CO gazı konsantrasyonunun yersel Mecidiyeköy istasyonunda benzer hareketi yaparak Ocak-Nisan aylarında yükseldiği ve Mayıs'tan itibaren düşmeye başladığı görülmektedir (Tablo 4). Üsküdar istasyonu civarında yer alan noktalardan elde edilen NO₂ gazı konsantrasyonunun Tablo 5'te görüldüğü gibi Ocak-Nisan aylarında düştüğü ve Kasım'dan itibaren yükselmeye başladığı tespit edilmiştir (Şekil 6, Şekil 7, Şekil 8 ve Şekil 9). NO₂ gazı konsantrasyonunun yersel Mecidiyeköy istasyonunda benzer hareketi yaparak Ocak-Nisan aylarında düşüş trendine girdiği ve Kasım'dan itibaren Üsküdar'da olduğu gibi yükseliş trendine başladığı görülmektedir (Tablo 6)(Şekil 10 ve Şekil 11).

Sadece yersel istasyonlar kullanılarak yapılan hava kalitesi analizde CO ve NO₂ gazlarının konsantrasyonu ile ilgili birtakım problem olduğu düşünülmektedir. Özellikle pandemi önlemleri gereği sokağa çıkma yasağı olan aylarda (2020 yılı Ocak-Mayıs arasında) CO gazı için konutsal alanların yoğun olduğu Üsküdar istasyonu ve çevresinde trend sabit olarak devam etmektedir (Tablo 7 ve Tablo 8). İş alanları ve yol ağının yoğun olduğu Mecidiyeköy istasyonu ve çevresinde ise 2020 yılının Ocak-Kasım aylarında trend rutin olarak ilerlemektedir. 2020 yılının Ağustos ayından itibaren Üsküdar istasyonu için ve aynı yılın Aralık ayından itibaren Mecidiyeköy istasyonu için değişimler daha yorumlanabilir hale gelmektedir. NO₂ gazı için ise yersel istasyonların her ikisi için de tüm aylar incelendiğinde herhangi bir trend ortaya konulamamıştır (Tablo 9 ve Tablo 10) (Şekil 12, Şekil 13 ve Şekil 14).



Şekil 4. NO₂ gazı için S5p verileri





Şekil 5. CO gazı için S5p verileri

Tablo 1. CO gazı için S5p verileri

Tarih	CO Ortalama (mol/m ²)	CO Normalize Ortalama
Oca.20	0.03518	0.556
Şub.20	0.03597	0.636
Mar.20	0.03669	0.708
Nis.20	0.03957	1.000
May.20	0.03587	0.626
Haz.20	0.03147	0.180
Tem.20	0.02969	0.000
Ağu.20	0.03018	0.050
Eyl.20	0.03159	0.192
Eki.20	0.03364	0.400
Kas.20	0.03360	0.396
Ara.20	0.03360	0.396
Oca.21	0.03727	0.767
Şub.21	0.03699	0.739
Mar.21	0.03874	0.916
Nis.21	0.03814	0.856
May.21	0.03424	0.460

Tablo 2. NO₂ gazı için S5p verileri

Tarih	NO ₂ Ortalama (mol/m ²)	NO ₂ Normalize Ortalama
Oca.20	0.00023	1.000
Şub.20	0.00016	0.612
Mar.20	0.00012	0.427
Nis.20	0.00006	0.119
May.20	0.00004	0.029
Haz.20	0.00004	0.000
Tem.20	0.00007	0.140
Ağu.20	0.00006	0.118
Eyl.20	0.00008	0.221
Eki.20	0.00011	0.363
Kas.20	0.00018	0.748
Ara.20	0.00023	0.998
Oca.21	0.00013	0.455
Şub.21	0.00022	0.961
Mar.21	0.00014	0.498
Nis.21	0.00011	0.342
May.21	0.00007	0.166

**Şekil 6.** S5p uydu verisinden üretilen CO değerlerinin zamansal değişimini gösteren grafik**Şekil 7.** S5p uydu verisinden üretilen NO₂ değerlerinin zamansal değişimini gösteren grafik**Tablo 3.** CO gazı için S5p verileri (Üsküdar istasyonu bölgesi)

Tarih	CO Ortalama (mol/m ²)	CO Normalize Ortalama
Oca.20	0.03524	0.548
Şub.20	0.03618	0.645
Mar.20	0.03662	0.690
Nis.20	0.03964	1.000
May.20	0.03679	0.707
Haz.20	0.03172	0.186
Tem.20	0.02991	0.000
Ağu.20	0.03024	0.034
Eyl.20	0.031803	0.195
Eki.20	0.03399	0.419
Kas.20	0.03346	0.365
Ara.20	0.03346	0.365
Oca.21	0.03776	0.807
Şub.21	0.03697	0.725
Mar.21	0.03804	0.836
Nis.21	0.03830	0.862
May.21	0.03426	0.447

Tablo 4. CO gazı için S5p verileri (Mecidiyeköy istasyonu bölgesi)



Tarih	CO Ortalama (mol/m ²)	CO Normalize Ortalama
Oca.20	0.03536	0.523
Şub.20	0.03576	0.561
Mar.20	0.03768	0.743
Nis.20	0.04038	1.000
May.20	0.03575	0.560
Haz.20	0.03184	0.189
Tem.20	0.02986	0.000
Ağu.20	0.03030	0.042
Eyl.20	0.03169	0.174
Eki.20	0.03398	0.392
Kas.20	0.03343	0.340
Ara.20	0.03343	0.340
Oca.21	0.03826	0.799
Şub.21	0.03732	0.709
Mar.21	0.03847	0.818
Nis.21	0.03837	0.810
May.21	0.03406	0.400


Tablo 6. NO₂ gazı için S5p verileri (Mecidiyeköy istasyonu bölgesi)

Tarih	NO ₂ Ortalama (mol/m ²)	NO ₂ Normalize Ortalama
Oca.20	0.000219	0.745
Şub.20	0.000152	0.468
Mar.20	0.000132	0.386
Nis.20	0.000069	0.123
May.20	0.000044	0.022
Haz.20	0.000039	0.000
Tem.20	0.000081	0.174
Ağu.20	0.000071	0.131
Eyl.20	0.000090	0.211
Eki.20	0.000111	0.297
Kas.20	0.000155	0.480
Ara.20	0.000256	0.898
Oca.21	0.000151	0.463
Şub.21	0.000280	1.000
Mar.21	0.000209	0.702
Nis.21	0.000124	0.352
May.21	0.000075	0.147

Tablo 5. NO₂ gazı için S5p verileri (Üsküdar istasyonu bölgesi)

Tarih	NO ₂ Ortalama (mol/m ²)	NO ₂ Normalize Ortalama
Oca.20	0.000215	0.807
Şub.20	0.000162	0.558
Mar.20	0.000118	0.353
Nis.20	0.000060	0.078
May.20	0.000050	0.033
Haz.20	0.000043	0.000
Tem.20	0.000061	0.085
Ağu.20	0.000062	0.089
Eyl.20	0.000086	0.200
Eki.20	0.000106	0.296
Kas.20	0.000194	0.709
Ara.20	0.000256	1.000
Oca.21	0.000126	0.388
Şub.21	0.000193	0.705
Mar.21	0.000152	0.513
Nis.21	0.000104	0.287
May.21	0.000072	0.136

**Şekil 8.** S5p uydu verisinden üretilen Üsküdar istasyonu ve civarındaki CO değerlerinin zamansal değişimini gösteren grafik**Şekil 9.** S5p uydu verisinden üretilen Üsküdar istasyonu ve civarındaki NO₂ değerlerinin zamansal değişimini gösteren grafik



Şekil 10. S5p uydu verisinden üretilen Mecidiyeköy istasyonu ve civarındaki NO₂ değerlerinin zamansal değişimini gösteren grafik

Tablo 7. CO gazı için yersel Üsküdar istasyon verileri

Tarih	CO Ortalama (µg/m ³)	CO Normalize Ortalama
Oca.20	965.060	0.008
Şub.20	1035.400	0.018
Mar.20	1204.020	0.043
Nis.20	1038.070	0.019
May.20	1028.040	0.017
Haz.20	1150.600	0.035
Tem.20	1035.020	0.018
Ağu.20	3268.980	0.345
Eyl.20	2718.310	0.265
Eki.20	5102.750	0.614
Kas.20	1215.940	0.045
Ara.20	6139.770	0.765
Oca.21	4162.540	0.476
Şub.21	5240.960	0.634
Mar.21	6780.590	0.859
Nis.21	7742.550	1.000
May.21	909.520	0.000

Tablo 8. CO gazı için yersel Mecidiyeköy istasyon verileri





Tarih	CO Ortalama (µg/m ³)	CO Normalize Ortalama
Oca.20	777.32	0.050
Şub.20	670.2	0.027
Mar.20	853.01	0.066
Nis.20	637.98	0.020
May.20	572.11	0.006
Haz.20	572.05	0.006
Tem.20	572.86	0.006
Ağu.20	544.19	0.000
Eyl.20	837.76	0.062
Eki.20	955.43	0.087
Kas.20	1025.78	0.102
Ara.20	3268.46	0.579
Oca.21	3925.24	0.718
Şub.21	3335.55	0.593
Mar.21	5162.14	0.981
Nis.21	5249.94	1.000
May.21	2653.59	0.448

Tablo 9. NO₂ gazı için yersel Üsküdar istasyon verileri


Tarih	NO ₂ Ortalama (µg/m ³)	NO ₂ Normalize Ortalama
Oca.20	43.11	0.662
Şub.20	43.49	0.675
Mar.20	43.19	0.665
Nis.20	32.81	0.306
May.20	30.37	0.222
Haz.20	40.82	0.583
Tem.20	23.95	0.000
Ağu.20	26.42	0.085
Eyl.20	32.54	0.297
Eki.20	52.9	1.000
Kas.20	37.9	0.482
Ara.20	39.83	0.549
Oca.21	43.14	0.663
Şub.21	25.68	0.060
Mar.21	37.57	0.470
Nis.21	52.2	0.976
May.21	40.05	0.556

Tablo 10. NO₂ gazı için yersel Mecidiyeköy istasyon verileri

Tarih	NO ₂ Ortalama (µg/m ³)	NO ₂ Normalize Ortalama
Oca.20	51.55	0.615
Şub.20	51.78	0.625
Mar.20	36.19	0.000
Nis.20	43.04	0.274
May.20	37.87	0.067
Haz.20	52.09	0.637
Tem.20	46.08	0.396
Ağu.20	48.53	0.494
Eyl.20	54.62	0.738
Eki.20	61.15	1.000
Kas.20	47.42	0.450
Ara.20	41.52	0.214
Oca.21	41.21	0.201
Şub.21	51.21	0.602
Mar.21	53.71	0.702
Nis.21	49.7	0.541
May.21	41.36	0.207

**Şekil 11.** Yersel istasyon verisinden üretilen Üsküdar istasyonu ve civarındaki CO değerlerinin zamansal değişimini gösteren grafik**Şekil 12.** Yersel istasyon verisinden üretilen Mecidiyeköy istasyonu ve civarındaki CO değerlerinin zamansal değişimini gösteren grafik**Şekil 13.** Yersel istasyon verisinden üretilen Üsküdar istasyonu ve civarındaki NO₂ değerlerinin zamansal değişimini gösteren grafik**Şekil 14.** Yersel istasyon verisinden üretilen Mecidiyeköy istasyonu ve civarındaki NO₂ değerlerinin zamansal değişimini gösteren grafik

Şekil 15'te görüldüğü gibi verilerin uyumlu olup olmadığının belirlenmesi için oluşturulan grafiklerde S5p verisinin kendi içinde daha kabul edilebilir sonuçlar ürettiği görülmektedir. Yersel istasyon verilerinde oluşan anlık farklar ise yersel istasyonların S5p verileri ile direkt olarak kıyaslanabilir olmadığını ortaya koymaktadır.



Şekil 15. Yersel istasyon verisinden üretilen Mecidiyeköy istasyonu ve civarındaki NO₂ değerlerinin zamansal değişimini gösteren grafik

4. SONUÇLAR

Bu çalışmada belirlenen amaç İstanbul İli merkez ilçelerinde Üsküdar ve Şişli için havada bulunan CO ve NO₂ gaz konsantrasyonlarını S5p uydu verileri ve yersel hava kalitesi istasyonları kullanarak tespit edebilmektir. Bu amaç doğrultusunda GEE platformundan elde edilen S5p verileri ve Üsküdar-Mecidiyeköy istasyon verileri metrik olarak değerlendirilmiştir. Ortaya konulan bulgular ile insanlar için temel yaşam kaynağı olan temiz hava içindeki kirletici gazların konsantrasyon değerlerinin belirlenebildiği gösterilmiştir. Çalışma Ocak 2020 ile Mayıs 2021 tarihleri arasında gerçekleştirilmiştir. Farklı verilerin analizinde birim olarak birliktelik sağlanabilmesi için kullanılan normalizasyon yönteminin olumlu sonuçlar verdiği belirlenmiştir. Atmosferik ölçümler yapan S5p uydusu havadaki gazların bir bölümünü farklı bir atmosferik seviyede tespit edebiliyorken, yersel hava kalitesi izleme istasyonları havadaki gazların bir bölümünü daha yeryüzüne yakın seviyede tespit edebilmektedir. Bu sebeple ortaya konulan sonuçlar bir alt model oluşturmadan birbirleriyle direkt olarak ilişkilendirilememiştir.

Teşekkür

Bu çalışmada kullanılan S5p verileri için Avrupa Uzay Ajansı (ESA), verilerin elde edilmesi için Google Earth Engine platformu, yersel hava kalitesi verilerinin elde edilmesi için Çevre ve Şehircilik Bakanlığı ve demografik bilgiler için Türkiye İstatistik Kurumu (TUIK) yetkililerine destekleri için teşekkür ederim.

Araştırmacıların katkı oranı beyan özeti

Yazar makaleye %100 oranında katkı sağlamıştır.

Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur.

Araştırma ve yayın etiği beyanı

Yapılan çalışmada yazarlar, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

EKLER

Ek 1:

```
import geometry.
var sentinel5p =
ee.ImageCollection('COPERNICUS/S5P/OFFL/L3_C
O')
.select('CO_column_number_density')
.filterDate('2021-05-01', '2021-05-30')
```

```

.filterBounds(geometry);
var mean = sentinel5p.mean();
var output = mean.toFloat();
var native_resolution =
output.projection().nominalScale();
var band_viz = {
  min: 0,
  max: 0.05,
  palette: ['black', 'blue', 'purple', 'cyan', 'green',
'yellow', 'red']
};
Map.addLayer(sentinel5p.mean(), band_viz, 'S5P
CO');
Map.setCenter(32, 41, 8);
Export.image.toDrive(
{
  image: output,
  folder: 'CO_1',
  description: 'CO_21_05',
  scale: 500,
  region: geometry
}
);

```

Ek 2:

```

var geometry =
  /* color: #98ff00 */
  /* displayProperties: [
    {
      "type": "rectangle"
    }
  ] */
  geometry;
var sentinel5p =
ee.ImageCollection('COPERNICUS/S5P/OFFL/L3_N
O2')
.select('tropospheric_NO2_column_number_density'
)
.filterDate('2021-05-01', '2021-05-30')
.filterBounds(geometry);
var mean = sentinel5p.mean();
var output = mean.toFloat();
var native_resolution =
output.projection().nominalScale();
var band_viz = {
  min: 0,
  max: 0.0002,
  palette: ['black', 'blue', 'purple', 'cyan', 'green',
'yellow', 'red']
};
Map.addLayer(sentinel5p.mean(), band_viz, 'S5P
NO2');
Map.setCenter(33, 41, 8);
Export.image.toDrive(
{
  image: output,
  folder: 'NO2_1',
  description: 'NO2_21_05',
  scale: 1000,
  region: geometry
}
);

```

KAYNAKÇA

- Albarqouni, M.M.Y., Yagmur, N., Bektas Balcik, F., Sekertekin A., (2022). A Assessment of Spatio-Temporal Changes in Water Surface Extents and Lake Surface Temperatures Using Google Earth Engine for Lakes Region, *Türkiye. ISPRS Int. J. Geo-Inf.* 2022, 11, 407. <https://doi.org/10.3390/ijgi11070407>
- Ghasempour, F., Sekertekin, A., & Kutoglu, S. H. (2021). Google Earth Engine based spatio-temporal analysis of air pollutants before and during the first wave COVID-19 outbreak over Turkey via remote sensing. *Journal of Cleaner Production*, 319, 128599.
- Jain, S., Shukla, S., & Wadhvani, R. (2018). Dynamic selection of normalization techniques using data complexity measures. *Expert Systems with Applications*, 106, 252-262.
- Kalıpcı, E. & Başer, V. (2019). Coğrafi Bilgi Sistemi (CBS) ve Hava Kalitesi Verileri Kullanılarak Türkiye'nin Hava Kirliliğinin Değerlendirilmesi. *Karadeniz Fen Bilimleri Dergisi*, 9 (2) , 377-389. <https://doi.org/10.31466/kfbd.645698>
- Kappal, S. (2019). Data normalization using median median absolute deviation MMAD based Z-score for robust predictions vs. min-max normalization. *London Journal of Research in Science: Natural and Formal*.
- Kaplan G. & Yigit Avdan Z. (2019). Space-borne air pollution observation from Sentinel-5p Tropomi: relationship between pollutants, geographical and demographic data. *International Journal of Engineering and Geosciences*. 2020; 5(3): 130-137.
- Karaca, M., Yağmur, N. & Balçık, F. (2022). İstanbul Terkos Gölü zamansal değişiminin Google Earth Engine kullanılarak belirlenmesi . *Geomatik* , 7 (3) , 235-242 . <https://doi.org/10.29128/geomatik.975714>
- Nazarenko, Y., Pal, D., & Ariya, P. A. (2021). Air quality standards for the concentration of particulate matter 2.5, global descriptive analysis. *Bulletin of the World Health Organization*, 99(2), 125-137D. <https://doi.org/10.2471/BLT.19.245704>
- Shami, S., Ranjgar, B., Bian, J., Khoshlahjeh Azar, M., Moghimi, A., Amani, M., & Naboureh, A. (2022). Trends of CO and NO2 Pollutants in Iran during COVID-19 Pandemic Using Timeseries Sentinel-5 Images in Google Earth Engine. *Pollutants*, 2(2), 156-171.

Shams, S.R., Jahani, A., Kalantary, S. et al. (2021). Artificial intelligence accuracy assessment in NO2 concentration forecasting of metropolises air. *Sci Rep* 11, 1805 (2021). <https://doi.org/10.1038/s41598-021-81455-6>

URL-1: <https://sim.csb.gov.tr/>
[Erişim Tarihi: 01.08.2022]

URL-2: <https://code.earthengine.google.com/>
[Erişim Tarihi: 01.08.2022]

Sünsüli M. & Kalkan K. (2022). Sentinel-5p Uydu Görüntüleri İle Azot Dioksit (NO2) Kirliliğinin İzlenmesi. *Türkiye Uzaktan Algılama Dergisi*. 2022; 4(1): 1-6.


URL-3: <https://data.tuik.gov.tr>
[Erişim Tarihi: 01.08.2022]

Taheri, S., & Razban, A. (2021). Learning-based CO2 concentration prediction: Application to indoor air quality control using demand-controlled ventilation. *Building and Environment*, 205, 108164.



© Author(s) 2022.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>



Kuraklığa NDVI ve Makine Öğrenmesi ile Bakış: Konya Kapalı Havzası

Hilmi Emre Göktaş^{*1}, Zerrin Dağlı¹

¹Mersin Yusuf Kalkavan Anadolu Lisesi, Mersin, Türkiye

Anahtar Kelimeler:

NDVI
Regresyon
Makine Öğrenmesi
Konya Kapalı Havzası
Bitki Örtüsü

ÖZ

Kuraklık uzun yıllardır dünyanın çoğu coğrafyasını olduğu gibi Konya Kapalı Havzasını da etkilemektedir. Bu çalışmada Konya Kapalı Havzasındaki kuraklık hakkında makine öğrenmesi ile geleceğe yönelik tahminler yapmak amaçlanmaktadır. Çalışmamızda 2000-2021 yılları arasındaki Landsat 5-8 uydu görüntüleri kullanılmıştır. Uygulama Python programlama dili ile yazılmış komut satırlarıyla gerçekleştirilmiştir, havzaya ve havzadaki il ve ilçelere ait Normalize Edilmiş Fark Bitki Örtüsü İndisi (NDVI) değerleri elde edilmiştir. Meteorolojik veriler ile makine öğrenmesi algoritması olan regresyonla gelecek 5 yıl için (2022-2026 arası) tahmini veriler elde edilmiştir. Daha sonra meteorolojik veriler ile NDVI değerleri birleştirilmiş ve ayrı bir regresyon ile tahmini meteorolojik parametrelere bağlı olarak tahmini NDVI değerleri elde edilmiştir. Çalışmamıza göre havza içerisinde bulunan 66 ilçeden 26'sının NDVI değerlerinin artma eğiliminde olduğu fakat 40 ilçenin de NDVI değerlerinin azalma eğiliminde olduğu tespit edilmiştir. İl bazında da Antalya ve Isparta için 5 yıl içerisinde bitki örtüsü bozulması olacağı, diğer illerde de çok fazla bir değişimin olmayacağı tahmin edilmiştir. Havzadaki kuraklığın önlenmesi için havza içerisinde yapılan ağaçlandırma çalışmalarının artırılması, çiftçilerin tarım konusunda bilinçlendirilmesi, orman yangınları ile mücadele çalışmalarının hızlandırılması, havzadaki bitki örtüsü sağlığı ve kuraklık için önem arz etmektedir.

A View to Drought with NDVI and Machine Learning: Konya Closed Basin

Keywords:

NDVI
Regression
Machine Learning
Konya Closed Basin
Vegetation

ABSTRACT

Drought has been affecting the Konya Closed Basin as well as most places for many years. In this study, it is aimed to make predictions about the drought of Konya Closed Basin for the future with machine learning. In our study, Landsat 5-8 satellite images between the years 2000-2021 were used. The application was carried out in Python programming language, and the Normalized Difference Vegetation Index (NDVI) values of the basin and the provinces and districts in the basin were obtained. Estimated data for the next 5 years (between 2022-2026) were obtained by using meteorological data and regression. Then, meteorological data and NDVI values were combined and estimated NDVI values were obtained based on predicted meteorological parameters with a separate regression. According to our study, it has been determined that the NDVI values of 26 of the 66 districts in the basin tend to increase, but the NDVI values of 40 districts tend to decrease. On a provincial basis, it has been estimated that there will be deterioration of vegetation within 5 years for Antalya and Isparta, and there will not be much change in other provinces. To prevent drought in the basin, increasing afforestation activities in the basin, raising awareness of farmers on agriculture, and accelerating efforts to combat forest fires are important for vegetation health and drought in the basin.

*Sorumlu Yazar

(goktashilmiemre@gmail.com) ORCID ID 0000-0001-6037-036X
(zerrin.dagli33@gmail.com) ORCID 0000-0001-9490-6425

Kaynak Göster(APA);

Göktaş H.E., Dağlı, Z. (2022). Kuraklığa NDVI ve Makine Öğrenmesi ile Bakış: Konya Kapalı Havzası. *Türkiye Uzaktan Algılama Dergisi*, 4(2), 75-86.

1. GİRİŞ

Kuraklık, yağışların kaydedilen normal değerlerin önemli ölçüde altına düşmesi sonucu arazi ve kaynak üretim sistemlerini olumsuz etkileyen ve ciddi hidrolojik dengesizliklere yol açan doğal bir olaydır (URL-1). Tüm dünyada yaşanan iklim değişikliğinden dolayı sera gazlarının atmosferdeki birikimleri hızla artmış, bunun sonucunda dünya ikliminin daha sıcak ve daha değişken olmasına sebep olmuştur (Turan, 2018). Bu sebeple yağış ve sıcaklıklarda meydana gelebilecek ani artış ve azalışlar kuraklığın boyutunu büyütebilme etkisine sahiptir ve böylece kuraklık bir felakete sürüklenebilir (Oğuztürk, 2010). Küresel iklim değişikliğinin olası etkileri ülkemiz açısından ele alındığında; Türkiye'nin risk grubu ülkeler arasında yer aldığı, gelecekte özellikle Akdeniz ve İç Anadolu Bölgelerimizin iklim değişikliğinden daha çok etkileneceği tahmin edilmektedir (Kapluhan, 2013). Bu nedenle Akdeniz ve İç Anadolu Bölgelerinde yapılacak çalışmalar önemlidir.

Çölleşme ve Erozyonla Mücadele Genel Müdürlüğü [ÇEM] tarafından 2017 yılında yayınlanan Türkiye Çölleşme Modeli'ne göre Türkiye arazisinin %45'i çeşitli düzeylerde (orta %25,3, yüksek %13, çok yüksek %5,8 ve aşırı yüksek %0,7) çölleşme süreçlerinden etkilenmektedir ve Konya Kapalı Havzası yüksek-düşük ve yüksek-orta derece çölleşme alanı olarak sınıflandırılmıştır (ÇEM, 2017).

Literatürde Konya Kapalı Havzası veya İç Anadolu Bölgesi üzerine çalışmalar bulunmaktadır. Bu çalışmalarda sıcaklık ve yağış gibi parametreler ile meteorolojik kuraklığın tespit edildiği görülmektedir. Yıldız'ın çalışmasında standart yağış indeksi (SPI) yöntemi ile zamansal kuraklık tespit edilmiş ve 1956-2001 yılları arasında İç Anadolu Bölgesinin %40'ının çeşitli kuraklıklardan etkilendiği görülmüştür (Yıldız, 2014). Sarış ve Gedik ise Konya Kapalı Havzasındaki kuraklığı benzer bir şekilde SPI ile incelemiş ve havzadaki meteorolojik kuraklığın, tarımsal ve hidrolojik kuraklığa doğru ilerlediği gözlemlenmiştir (Sarış ve Gedik, 2021). Akın'ın çalışmasında De Martonne Kuraklık İndisi, Erinç Yağış Etkinliği İndisi, Thornthwaite İklim Sınıflandırması yöntemleriyle Tuz Gölü'ne ait kuraklık tespit edilmiş (Akın, 2019), Türkes ve arkadaşları da Palmer Kuraklık İndisi ile İç Anadolu Bölgesindeki kurak dönemleri ve kuraklık şiddetini gözlemlenmiştir (Türkes, Akgündüz & Demirörs, 2009). Şensoy ve arkadaşları da çalışmamıza benzer bir amaç taşıyan Karaman ve Karapınar'ın iklim değişikliği eğilimlerini araştırmıştır (Şensoy vd., 2017). Orhan ve Ekercin'in çalışmasında uzaktan algılama yöntemleriyle Konya Kapalı Havzasına ait arazi yüzey sıcaklığı, bitki durum indeksi ve sıcaklık-bitki indeksleri ile kuraklık tespit edilmiştir (Orhan ve Ekercin, 2015). Demir ve Kaya ise havza içerisindeki arazi kullanım değişikliklerini regresyon ile tahmin

etmiştir (Kaya ve Demir, 2022). Literatürdeki bu çalışmalardan farklı olarak uzaktan algılama ve makine öğrenmesi ile gelecekte bitki örtüsü durumunu tahmin etmek çalışmamızda amaçlanmıştır.

Kuraklık tespit çalışmalarında sıklıkla bitki örtüsü indeksleri kullanılır. Bitki örtüsü indeksi, uydu görüntüsündeki her bir resim ögesi veya piksel için yeşilliği -bitki örtüsünün göreceli yoğunluğunu ve sağlığını- tanımlayan bir göstergedir (URL-2). Vejetasyon indislerinin analizine dayanarak, toprak bozulmasına maruz kalan bölgeler ayırt edilir (Koroleva vd., 2021) ve bitki örtüsünün tespiti yapılabilir (URL-3).

Literatüre bakıldığında bitki örtüsü ile meteorolojik parametreler arasında sıkı bir ilişki olduğunu görmekteyiz. Çünkü bitki örtüsü değişimi, sıcaklık, yağış gibi bölgedeki hidrotermal değişikliklere bağlıdır (Zhifang vd., 2019). Bunların yanında yüzey koşullarına ve beşerî faktörlere de bağlı olduğunu söyleyebiliriz (Feng vd., 2020). Bölgesel ekolojik çalışmalarda da bitki örtüsü indekslerinin yanında iklim parametrelerini kullanmak önemli katkı sağlar (Zhan vd., 2022). Çalışmamızda bitki örtüsü değerlerinin yanında ayrıca meteorolojik parametreler kullanılmıştır.

Bu çalışmanın amacı, meteorolojik parametrelerin gelecek değerleri tahmini ile havzanın ve havzadaki il ve ilçelerin gelecek yıllardaki bitki örtüsü değerlerini elde ederek gelecekteki bitki örtüsü bozulmaları için öngörude bulunmaktadır.

2. YÖNTEM

Çalışmamızda makine öğrenmesi teknikleri, görüntü işleme, veri bilimi ve uzaktan algılama teknikleri kullanılmıştır. Programlama işlemi için Python programlama dili kullanılmıştır. Çalışmamız çevrimiçi kod yazabilme imkânı veren Kaggle üzerinde, Python 3.7.6 sürümü kullanılarak gerçekleştirilmiştir.

Çalışmada raster görüntü üzerindeki işlemler için Rioxarray, Rasterio ve Earthpy; coğrafi veriler için Shapely ve Geopandas; veri inceleme için Numpy ve Pandas; verilerin görselleştirilmesi için Matplotlib; haritalandırma için Folium ve regresyon modelleri için Sklearn kütüphaneleri kullanılmıştır.

Çalışmada Sklearn kütüphanesinin regresyon algoritmalarından rastgele orman regresyonu (random forest regression) ve gradyan hızlandırıcı regresyon (gradient boosting regression) kullanılmıştır. Bu algoritmalar toplu (ensemble) (URL-4) ve hızlandırıcı (boosting) (URL-5) algoritmalar olduğundan dolayı doğruluk oranının daha yüksek çıkacağı düşüncesiyle seçilmiştir.

2.1. Çalışma Alanı

Konya Kapalı Havzası, Orta Anadolu Bölgesi'nde 36°51'-39°29' kuzey enlemlerinde, 31°36'-34°52' doğu boylamlarında konumlanmaktadır ve yaklaşık 1000 m rakımındadır (Orhan ve Ekercin, 2015).



Şekil 1. Konya Kapalı Havzası'nın Türkiye'deki konumu (T.C. Orman ve Su İşleri Bakanlığı, 2017)

Şekil 1'de Türkiye'deki konumu gösterilmiş Konya Kapalı Havzası, Türkiye'nin toplam yüzölçümünün yaklaşık %7'sine karşılık gelir ve Havza, Türkiye'nin en büyük kapalı havzasıdır (Orhan ve Ekercin, 2015). Yaşanan kuraklıklar ve çölleşme sonucunda Konya Kapalı Havzası içerisindeki bazı göller kuruma tehlikesiyle karşı

karşıya kalmış ve havza içerisindeki obruk sayısı artmıştır. Havzanın en büyük gölü olan Tuz Gölü, iklim değişikliğine bağlı olarak küçülmektedir (URL-6). Karapınar ilçe sınırları içerisinde yer alan Meke Gölü, yağış azlığı gibi nedenlerle büyük oranlarda kurumuştur (URL-7). Ayrıca son yıllarda adını obruklarla duyuran Karapınar'da halk ani toprak göçmelerinden dolayı tedirgin durumdadır (URL-8).

2.2. Verilerin Elde Edilmesi

Çalışmamızda 2000- 2021 yıllarına ait Landsat 5 ve Landsat 8 uydu görüntüleri kullanılmıştır. Havza sınırlarını belirlemek için kullandığımız veri seti Ahmet Kargın tarafından ücretsiz bir şekilde alınmıştır. İl ve ilçe sınırları verisi T.C. Millî Savunma Bakanlığı Harita Genel Müdürlüğü (HGM) internet sitesi üzerinden ücretsiz bir şekilde alınmıştır (URL-9). Kullanılan meteorolojik veriler Mersin Meteoroloji İl Müdürlüğünden alınmıştır. Elde edilen meteorolojik veriler aylık ortalama sıcaklık, aylık maksimum sıcaklık, aylık minimum sıcaklık, aylık ortalama maksimum sıcaklık, aylık ortalama minimum sıcaklık, aylık maksimum yağış ve aylık toplam yağış değerleridir. Kullanılan meteorolojik istasyonlar Tablo 1'de verilmiştir. Çalışmaya ait iş akış şeması Şekil 2'de gösterilmiştir.

Tablo 1. Kullanılan verilerin ölçüm yaptığı istasyonlar (URL-9)

İstasyon Adı	İstasyon No	Bulunduğu İl / İlçe	Koordinatları
Aksaray	17192	Aksaray / Merkez	38°22'13.8"N 33°59'55.3"E
Beyşehir	17242	Konya / Beyşehir	37°40'39.7"N 31°44'46.7"E
Çumra	17900	Konya / Çumra	37°33'56.9"N 32°47'24.0"E
Ereğli	17248	Konya / Ereğli	37°31'31.8"N 34°02'54.6"E
Karaman	17246	Karaman / Merkez	37°11'35.5"N 33°13'12.7"E
Karapınar	17902	Konya / Karapınar	37°42'58.7"N 33°31'33.6"E
Konya Bölge	17245	Konya / Meram	37°52'07.3"N 32°28'16.7"E
Konya Havalimanı	17244	Konya / Selçuklu	37°59'01.3"N 32°34'26.4"E
Kulu	17754	Konya / Kulu	39°04'43.7"N 33°03'56.5"E
Niğde	17250	Niğde / Merkez	37°57'30.6"N 34°40'46.2"E
Seydişehir	17972	Konya / Seydişehir	37°26'58.6"N 31°51'13.7"E

2.3. Görüntü İşleme ve Uzaktan Algılama

İlk olarak uydu görüntüleri birleştirilmiş ve havza sınırlarına göre kesilmiştir. Bulut ve kar oranı düşük görüntüler içerisinde her mevsime eşit dağılım sağlanmamıştır fakat her yıl için sonbahar ve yaz aylarına ait görüntüler olduğu tespit edilmiştir. Bitki örtüsünün yıllara göre kıyaslamasında daha doğru bir sonuç almak için sadece yaz ve sonbahar aylarına ait görüntüler

birleştirilmiştir.

Literatüre bakıldığında NDVI (Normalized Difference Vegetation Index, Türkçe: Normalleştirilmiş Fark Bitki Örtüsü İndisi) bitki örtüsü ve kuraklık tespit çalışmalarında sıklıkla kullanılmaktadır. Bu indis, bitki örtüsü tarafından yansıtılan görünür kırmızı (RED) ve yakın kızılötesi (NIR) ışıktan hesaplanır (URL-10). Denklem 1'de görüldüğü üzere NIR ve RED bantlarındaki piksel değerlerinin farkının toplamına bölümüyle NDVI

elde edilir (URL-10).

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (1)$$


Bir pikselin NDVI değeri -1 ile +1 arasında değer alır, aynı şekilde 0 değerine yaklaştıkça vejetasyonun az olduğu görülür, +1'e yaklaştıkça vejetasyon yoğun olduğu görülür (URL-10). Bitki örtüsünün olduğu yer 0'dan küçük değerler almaz, NDVI değeri 0'dan küçük olan yerlerde bitki örtüsü hakkında bir yorum yapılamaz. Çünkü NDVI değeri -1 ile 0 arasında olan değerler; nehir, göl, deniz gibi sulak alanlara karşılık gelir (Silleos vd., 2006; URL-11). Aynı zamanda NDVI değeri 1'e eşit olamaz, eğer piksel NDVI değeri 1'e eşitse o pikselin RED bandındaki değerinin 0 olduğunu gösterir (URL-12). Bu değerlerin olduğu piksellerde de bulut olma ihtimali vardır (URL-11). Bu yüzden NDVI hesaplaması sırasında 0'dan küçük ve 1'den büyük değerler maskelenmiştir, daha sonrasında NDVI görüntüler kaydedilmiştir.

HGM'nin il ve ilçe sınırları verisi bütün

Türkiye'yi kapsadığı için bu veriler Konya Kapalı Havzasına göre kırılmıştır ve bu illeri çevreleyebilmesi için havza sınırları ile birleştirilmiştir.

Veri setinde bulunan tekli çizgi (linestring) veriler çokgen (polygon) haline getirilmiş, sonrasında da Folium kütüphanesi kullanılarak çokgenlerin (polygonların) haritalandırılması gerçekleştirilerek ilgili çokgenlerin (polygonların) kapsadığı il/ilçeler tespit edilmiştir. Sonrasında elde ettiğimiz il ve ilçelerin çokgenleri (polygonları) havza sınırlarına göre kırılarak Konya Kapalı Havzası il ve ilçeleri elde edilmiştir. Daha sonrasında bu il ve ilçeler, elde edilen NDVI görüntülere göre kırılıp oluşturulan görüntüler kaydedilmiştir.

Havza geneli NDVI görüntülerin ve il ve ilçe sınırlarına göre kırılmış NDVI görüntülerinin ait olduğu yıl, yer (havza geneli ya da il/ilçe adı) ve ortalama NDVI değeri "csv" formatında dosyaya yazdırılmış ve kaydedilmiştir.



Şekil 2. Kullanılan veriler ve işlem şeması

2.4. Meteorolojik Parametrelerin Tahmini

Literatüre bakıldığında NDVI ile meteorolojik parametreler arasında sıkı bir ilişki olduğunu görmekteyiz. Bu yüzden geleceğe yönelik tahmin yapmak maksadıyla NDVI değerlerinin yanında sıcaklık ve yağış gibi değerlere de ihtiyacımız vardır.

Meteorolojik veriler yıllık olarak düzenlendikten sonra geleceğe dair tahmini meteorolojik parametre değerleri regresyon algoritmaları kullanılarak elde edilmiştir.

Yıl bazında düzenlenen verilerimiz ile bir sonraki yılın meteorolojik değerleri tahmin edilmiştir. Tahmin edilen meteorolojik değerler

“yıllık maksimum sıcaklık, yıllık ortalama maksimum sıcaklık, yıllık ortalama sıcaklık, yıllık minimum sıcaklık, yıllık ortalama minimum sıcaklık, yıllık maksimum yağış, yıllık toplam yağış” değerleridir ve bu değerler için regresyon modelleri ayrı ayrı çalıştırılmıştır. Modellerin eğitim test bölütleme oranı %90 / %10’dur. Eğitim test oranı %70/%30 ve %80/%20 olan modellere kıyasla %90 / %10 bölütlemesinin doğruluk değeri daha yüksek sonuçlar verdiği ve verilerin dağılımı incelendiğinde gerçek değerlere daha yakın değerler elde edildiği gözlemlenmiştir.

2021 yılına ait veriler ve daha önceden tahmin edilmiş veriler ile gelecekteki 5 yıla ait değerler (2022-2026 yıllarına ait değerler) tahmin edilmiştir. Determinasyon katsayısı (R^2) ve ortalama mutlak hata (MAE) doğruluk yöntemlerine ait denklemler sırasıyla Denklem 2 ve 3’te yer almaktadır (UADMK, 2022) (URL- 14).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (y_i - x_{ort})^2} \quad (2)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (3)$$

Yapılan eğitim ve test işlemlerinden sonra parametreler için yapılan regresyonların doğruluk oranları Tablo 2’de gösterilmiştir. Bazı parametreler için elde edilen doğruluk oranları çok yüksek olmasa da 2000 yılından önce elimizde verinin olmamasından dolayı çalışmaya bu modeller ile devam edilmiştir. Gelecek yıllara ait tahmin işlemlerinde her bir parametre için doğruluk oranı en yüksek modeller kullanılmıştır. Maksimum sıcaklık, ortalama maksimum sıcaklık, ortalama minimum sıcaklık, ortalama sıcaklık, toplam yağış için gradyan hızlandırıcı (gradient boosting) ve minimum sıcaklık, maksimum yağış parametreleri için rastgele orman (random forest) modelleri kullanılmıştır. Bu modeller 2022, 2023, 2024, 2025, 2026 yılları yani gelecekteki ilk 5 yıl için tahmin üretmiştir. Bir yıla ait çıktılar başka bir model için referans veri olarak kullanılmıştır. Örneğin 2022 yılına ait veriler, 2023 yılına ait değerlerin tahmini için kullanılmıştır.

Tablo 2. Parametrelerin tahmini sırasında doğruluk oranları

Parametre	Rastgele Orman Regresyonu (Random Forest Regressor)		Gradyan Hızlandırıcı Regresyon (Gradient Boosting Regressor)	
	R^2	MAE	R^2	MAE
Maksimum Sıcaklık (°C)	0.4091	1.0277	0.4447	0.9929
Ortalama Maksimum Sıcaklık (°C)	0.6156	0.5551	0.6927	0.5026
Minimum Sıcaklık (°C)	0.3860	1.8489	0.1279	2.2081
Ortalama Minimum Sıcaklık (°C)	0.9802	0.6175	0.9869	0.4948
Ortalama Sıcaklık (°C)	0.6663	0.4791	0.7156	0.4252
Toplam Yağış (mm)	0.8081	55.5504	0.8234	49.6450
Maksimum Yağış (mm)	0.6538	5.3019	0.5962	5.7376

2.5. NDVI Değerlerin Tahmini

Elde edilen NDVI değerleri ile ilçeye en yakın mesafede bulunan istasyonun verileri birleştirilmiştir. İller için de benzer bir işlem uygulanmıştır fakat içerisinde birden fazla meteorolojik istasyon bulunduran illerde, sahip olduğu istasyonların verilerinin ortalamaları ile birleştirilmiştir. Havza geneli için ise bütün istasyonların verilerinin ortalamaları ile birleştirilmiştir.

Ortalama NDVI değeri alınan il ve ilçeler, en yakın istasyonun verileri ile birleştirildikten sonra makine öğrenmesi ile tahmin yapılmıştır. Referans veri olarak il/ilçe, en yakın istasyon ve bu istasyona ait yıllık maksimum sıcaklık, yıllık ortalama maksimum sıcaklık, yıllık ortalama sıcaklık, yıllık minimum sıcaklık, yıllık ortalama minimum sıcaklık, yıllık maksimum yağış, yıllık toplam yağış

kullanılmıştır ve doğrusal (lineer) regresyon, rastgele orman (random forest) ve gradyan hızlandırıcı regresyon (gradient boosting regressor) modelleri havzanın, ilin, ilçenin yıllık ortalama NDVI değerini tahmin etmiştir. Doğruluk değerleri Tablo 3’te gösterilmiştir. Veriler %80 eğitim, %20 test olarak ayrılmıştır. En doğru değer rastgele orman modeli ile yapıldığı için gelecek 5 yılın NDVI değerlerinin tahmininde rastgele orman modeli kullanılmıştır. Meteorolojik parametreler için yaptığımız makine öğrenmesi çalışmasında 2022, 2023, 2024, 2025, 2026 yıllarına ait elde edilmiş meteorolojik parametreler ile ortalama NDVI değerleri tahmin edilmiştir. Bu tahmin her bir il ve ilçe için aynı zamanda havza için 2022, 2023, 2024, 2025, 2026 yani gelecek 5 yıl için yapılmıştır.

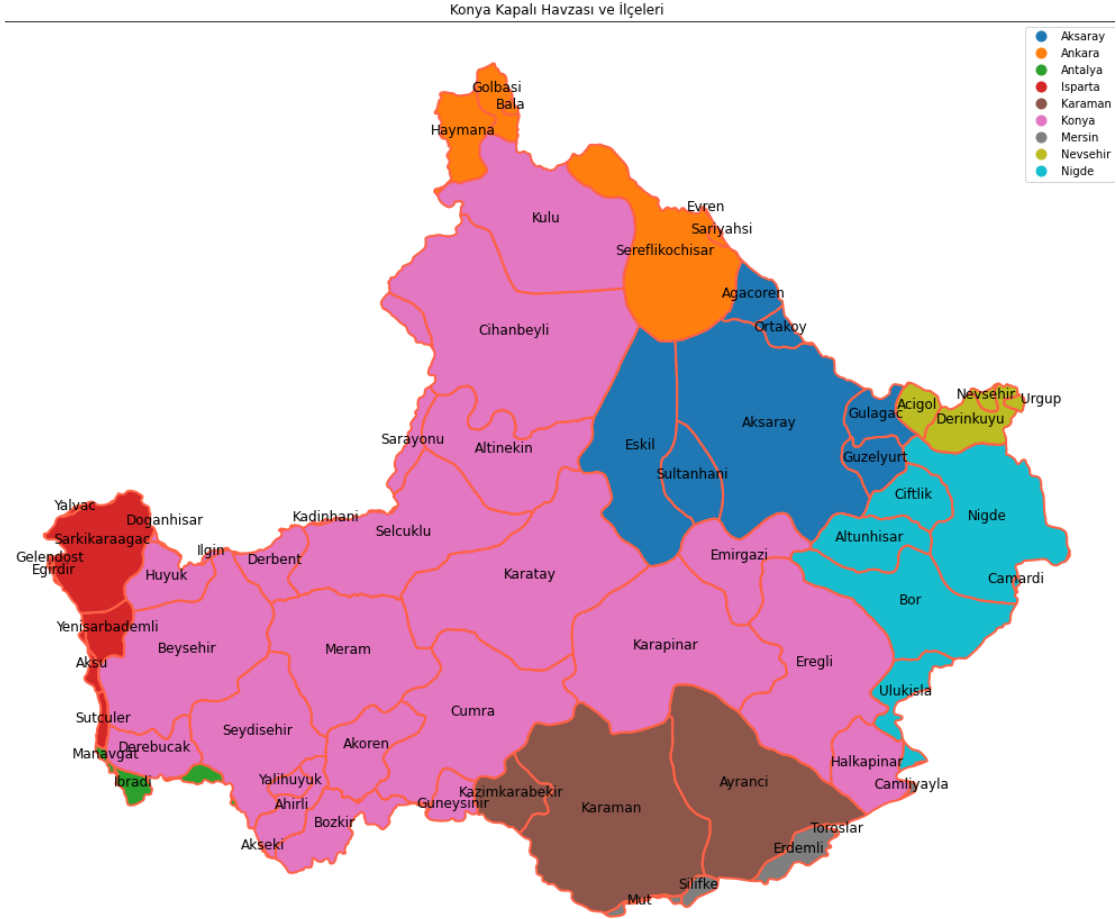
Tablo 3. NDVI değerlerinin tahmininde modellerin doğruluk oranları

	Lineer Regresyon	Rastgele Orman Regresyonu	Gradyan Hızlandırıcı Regresyon
R^2	0.6841	0.8383	0.7482
MAE	0.0161	0.0097	0.0147


3. BULGULAR

Şekil 3'te gösterildiği üzere çalışmamızda Konya Kapalı Havzası ve havza içerisindeki 9 il ve 66

ilçenin sıcaklık ve yağışa bağlı olarak bitki örtüsündeki değişimi gözlemlenmiştir. Şekil 4-5-6'de ilgili grafikler gösterilmiştir.



Şekil 3. Konya Kapalı Havzası il ve ilçeleri haritası




Şekil 4. Konya Kapalı Havzası ilçelerinin a) 2021 yılı ortalama NDVI değerleri haritası, b) 2026 yılı tahmini ortalama NDVI değerleri haritası

Şekil 4a'ya göre:

- Şekil 4a, Konya Kapalı Havzasında bulunan ilçelerin 2021 yılı ortalama NDVI değerlerini göstermektedir.
- Havzanın batı tarafındaki ilçelerde ortalama NDVI değerleri daha yüksek iken doğuya doğru NDVI değerleri düşmektedir ve havzanın doğusundaki ilçelerde ortalama NDVI değerleri daha düşüktür.
- Genel olarak Isparta, Antalya ve Konya'nın batısı içerisindeki ilçeler yüksek NDVI değerlerine sahip iken Karaman, Mersin, Aksaray, Konya'nın doğusu, Niğde, Ankara ve Nevşehir'de bulunan ilçelerin NDVI değerleri daha düşüktür.
- En düşük ortalama NDVI değerine sahip ilçe 0.053927 NDVI değeri ile Mersin'in Çamlıyayla ilçesi iken en yüksek ortalama NDVI değerine sahip ilçe 0.233398 NDVI değeri ile Konya'nın Ilgın ilçesidir. Çamlıyayla ilçesinin havza içerisinde bulunan kısmında yerleşik nüfus bulunmadığından dolayı sonuç dikkat çekicidir.

Şekil 4b'ye göre:

- Şekil 4b, Konya Kapalı Havzasında bulunan ilçelerin 2026 yılı tahmini ortalama NDVI değerlerini göstermektedir. Bu değerler regresyon çalışması ile elde edilmiştir.
- 2021 NDVI değerleri kadar olmasa da havzanın batı tarafında tahmini ortalama NDVI değerleri daha yüksektir. Fakat 2021 yılına göre daha düşüktür. Havzanın doğu tarafına doğru gidildikçe tahmini ortalama NDVI değeri azalmaktadır fakat 2021 NDVI değerlerine göre havzanın doğu tarafındaki ortalama NDVI değerleri daha yüksektir. Havzanın güney tarafına inildikçe tahmini ortalama NDVI değeri düşmektedir.
- Isparta, Antalya ve Konya'nın batısı içerisindeki ilçeler yüksek tahmini NDVI değerlerine sahip iken Karaman, Mersin, Aksaray, Konya'nın doğusu, Niğde, Ankara ve Nevşehir'de bulunan ilçelerin tahmini NDVI değerleri daha düşüktür.
- En düşük tahmini ortalama NDVI değerine sahip ilçe 0.054119 NDVI değeri ile Mersin'in Çamlıyayla ilçesi iken en yüksek tahmini ortalama NDVI değerine sahip ilçe 0.221232 NDVI değeri ile Konya'nın Derbent ilçesidir. Çamlıyayla ilçesinin havza içerisinde bulunan kısmında yerleşik nüfus bulunmadığından dolayı 2021 NDVI değerlerindeki gibi sonuç dikkat çekicidir.



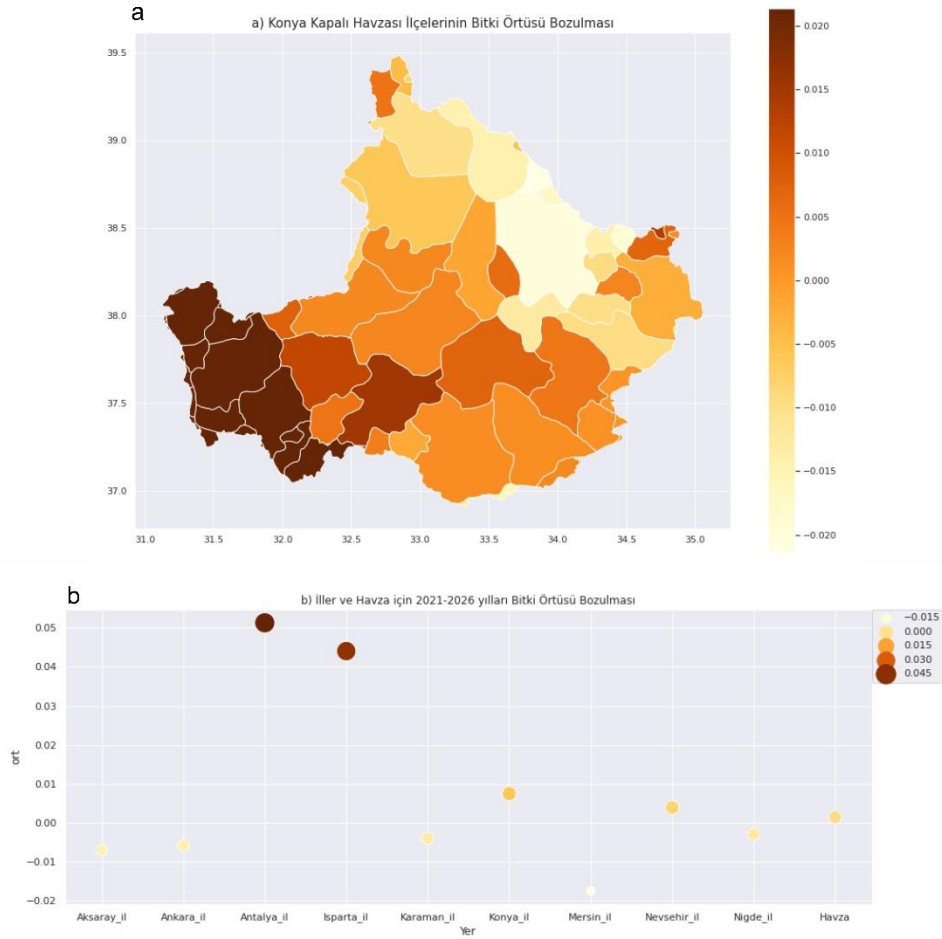
Şekil 5. Konya Kapalı Havzası illerinin a) 2021 yılı ortalama NDVI değerleri grafiği, b) 2026 yılı tahmini ortalama NDVI değerleri grafiği

Şekil 5a'ya göre:

- Şekil 5a, Konya Kapalı Havzasında bulunan illerin 2021 yılı ortalama NDVI değerlerini göstermektedir.
- En yüksek ortalama NDVI değerine sahip il Antalya iken en düşük ortalama NDVI değerine sahip il Mersin'dir.
- En yüksek ortalama NDVI değerini Antalya'dan sonra sırasıyla Isparta, Konya ve Nevşehir izlemektedir.
- En düşük ortalama NDVI değerini Mersin'den sonra sırasıyla Ankara, Aksaray, Niğde ve Karaman izlemektedir.
- Havza ortalama NDVI değeri ise Nevşehir ve Niğde NDVI değerleri arasında kalarak 0.14436 NDVI değerine sahiptir.

Şekil 5b'ye göre:

- Şekil 5b, Konya Kapalı Havzasında bulunan illerin 2026 yılı tahmini ortalama NDVI değerlerini göstermektedir. Bu değerler regresyon çalışması ile elde edilmiştir.
- En yüksek ortalama NDVI değerine sahip il Isparta iken en düşük ortalama NDVI değerine sahip il Ankara olarak tahmin edilmiştir.
- En yüksek ortalama NDVI değerini Isparta'dan sonra sırasıyla Antalya, Nevşehir, Konya, Karaman ve Aksaray olarak tahmin edilmiştir.
- En düşük tahmini ortalama NDVI değerini Ankara'dan sonra sırasıyla Mersin ve Niğde izlemektedir.
- Havza tahmini ortalama NDVI değeri ise Nevşehir ve Konya NDVI değerleri arasında kalarak 0.142922 NDVI değerine sahiptir. 2021 yılına göre bu değer düşmesi beklenmektedir.



Şekil 6. Konya Kapalı Havzası a) ilçelerinin ve b) illerinin bitki örtüsü bozulma grafikleri

Şekil 6a'ya göre:

- Şekil 6a, Konya Kapalı Havzasında bulunan ilçelerin regresyon sonucunda tahmin edilmiş bitki örtüsü bozulmasını göstermektedir. 2021 NDVI değerlerinin 2026 tahmini NDVI değerlerinden çıkarılması ile elde edilmiştir.
- Havzanın batı tarafında bitki örtüsü bozulmasının daha fazla olacağı tahmin edilmiştir. Seydişehir ve Beyşehir Göllerine kıyısı bulunan alanlarda ortalama NDVI değerleri diğer bölgelere kıyasla yüksek derecede azalmaktadır. Aynı zamanda Konya ilinin orta kesimlerinde ve Karaman ilinde ciddi tahribat beklenmektedir.
- Aksaray ilinde daha az bitki örtüsü tahribatı beklenmektedir. Aksaray kadar olmasa da havzanın kuzey kesimlerinde daha az bitki örtüsü bozulması olacağı tahmin edilmektedir. Ayrıca Konya'nın Kulu ve Cihanbeyli ilçeleri ile Ankara'nın Şereflikoçhisar ilçelerinde diğer bölgelere göre kıyasla NDVI değerinin artma eğiliminde olduğu gözlemlenmiştir. Bu ilçelerin ve Aksaray'ın Tuz Gölü kıyısında olması da dikkat çekicidir.
- En düşük tahmini bitki örtüsü bozulması değerine sahip ilçe -0.02141 değeri ile Aksaray'ın Ağaçören ilçesi iken en yüksek tahmini bitki örtüsü bozulması değerine sahip

ilçe 0.074175 NDVI değeri ile Konya'nın Ilgın ilçesidir.

Şekil 6b'ye göre:

- Şekil 6b, Konya Kapalı Havzasında bulunan illerin regresyon sonucunda tahmin edilmiş bitki örtüsü bozulmasını göstermektedir. 2021 NDVI değerlerinin 2026 tahmini NDVI değerlerinden çıkarılması ile elde edilmiştir.
- En fazla bozulma Antalya'da, en az bozulma da Mersin'de gözlemlenmesi beklenilmektedir.
- En fazla tahmini bozulma değerini Antalya'dan sonra Isparta, Konya ve Nevşehir izlemiştir.
- En az tahmini bozulma değerini Mersin'den sonra Aksaray, Ankara, Karaman ve Niğde izlemiştir. Bu illerde bitki örtüsü miktarının artacağı tahmin edilmektedir.
- Havzadaki bozulma değeri 0.001438 değeri olması beklenmektedir.

Tablo 4'e göre NDVI değerinin artma eğiliminde (bitki örtüsü tahribatının olmadığı ve bitki örtüsünün arttığı) 26 ilçe, NDVI değerinin azalma eğiliminde (bitki örtüsü tahribatının olduğu) 40 ilçe belirlenmiştir.

Tablo 4. İl ve ilçelerin NDVI değerlerinin artma ve azalma eğilimleri tablosu

İl ve İlçeler	Artış Eğiliminde Olan Sayısı	Azalış Eğiliminde Olan Sayısı	Toplam
Aksaray İlçeleri	7	1	8
Ankara İlçeleri	5	0	5
Antalya İlçeleri	0	3	3
Isparta İlçeleri	0	7	7
Karaman İlçeleri	1	2	3
Konya İlçeleri	4	21	25
Mersin İlçeleri	4	1	5
Niğde İlçeleri	4	2	6
Nevşehir İlçeleri	1	3	4
Bütün İlçeler	26	40	66
Bütün İller	5	4	9
İller ve İlçeler	31	44	75

4. SONUÇLAR

Çalışmamızda 2026 yılına ait tahmini NDVI değerleri elde edilmiş, 2021 yılı ile karşılaştırılmış ve analizler yapılmıştır. Çalışmamızın sonuçlarına göre havzada NDVI değeri azalma eğiliminde olan ilçelerin sayısı, artma eğiliminde olan ilçelerin sayısından fazla çıkmıştır. Tablo 4'te görüldüğü üzere 66 ilçe üzerinde yapılan çalışmada 26 ilçenin NDVI değerinin artma eğiliminde olduğu fakat 40 ilçenin de NDVI değerinin azalma eğiliminde olduğu tahmini değerlere göre tespit edilmiştir. Bu sonuç, havzada ve ülkemizde iklim değişikliğinden dolayı yaşanan kuraklıkların ilçeleri olumsuz bir şekilde etkileyeceğinin göstergesidir.

Şekil 6a'da görüldüğü üzere Tuz Gölüne kıyısı bulunan ilçelerde bitki örtüsü tahribatı diğer bölgelere göre daha düşüktür ve regresyon modeli sonucunda bitki örtüsünde artış olacağı tahmin edilmektedir. Fakat havzanın batısında daha büyük oranda bitki örtüsü tahribatı olacağı tahmin edilmektedir. Ayrıca Şekil 5b'de görüldüğü üzere 2026 yılındaki NDVI değerleri havzanın güneyinde en düşüktür. Havzanın güneyi ve batısında yapılacak ağaçlandırma çalışmaları ve tarım faaliyetleri önemlidir. Özellikle ilçelerin NDVI değerleri yıllık olarak incelendiğinde bazı yıllarda artışlar meydana gelmiştir ve bu tarihlerde kamu ve özel girişimli çeşitli ağaçlandırma çalışmaları yapıldığı görülmüştür (URL 14, 15, 16, 17, 18). Aynı zamanda bazı yıllarda NDVI değerlerinde düşüşler de görülmüştür, bunlar da havzada çıkan orman yangınları (URL 19, 20, 21) ve havzada yapılan bilinçsiz tarım (Tomar, 2014) gibi sebeplerden dolayı olduğu düşünülmektedir.

İllere bakacak olursak Şekil 6b'de görüldüğü üzere genel olarak bitki örtüsünün bozulmayacağı fakat bitki örtüsünde çok büyük bir gelişme de olmayacağı tahmin edilmiştir. Antalya ve Isparta için bitki örtüsü bozulması olacağı tahmin edilmiştir. Bazı illerde çok az miktarda olsa da bitki örtüsünün artacağı tahmin edilmiştir.

Havza genelinde ise ortalama NDVI değerinin azalma eğiliminde olduğu tahmin edilmektedir. Kaya ve Demir'in Konya Kapalı Havzası üzerine yaptığı çalışmaya göre 2036 yılına kadar sulak ekilebilir tarım alanları dışındaki tüm tarım

arazilerinin azalacağı tahmin edilmekte iken orman arazisi sayısının ve doğal çayır arazisi sayısının azalacağı tahmin edilmektedir (Kaya ve Demir, 2022). Yayınlanan çalışmada plansız kentleşmenin orman arazilerini işgal ettiğinden bahsedilmektedir (Kaya ve Demir, 2022). Havza içerisinde yapılan ağaçlandırma çalışmalarının artırılması, çiftçilerin tarım konusunda bilinçlendirilmesi, orman yangınları ile mücadele çalışmalarının hızlandırılması ve doğru şehir planlama çalışmalarının yapılması havzadaki bitki örtüsü sağlığı ve kuraklık için önem arz etmektedir.

Teşekkür

Bu çalışmaya görüşleriyle katkı sağlayan elektrik-elektronik mühendisi Osman BAHADIR'a ve coğrafya öğretmeni Bilal ER'e teşekkür ederiz. Ayrıca bu çalışma TÜBİTAK 2204-D Lise Öğrencileri İklim Değişikliği Araştırma Projeleri Yarışması kapsamında gerçekleştirilmiş ve çalışma Çevre alanından 2. seçilmiştir. Desteklerinden dolayı TÜBİTAK'a teşekkür ederiz.

Araştırmacıların katkı oranı beyan özeti

Araştırmacılar makaleye eşit oranda katkı sağlamıştır.

Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

Araştırma ve yayım etiği beyanı

Yapılan çalışmada yazarlar, araştırma ve yayım etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

KAYNAKÇA

Akın, B. (2019). Tuz Gölü Havzası'nın Kuraklık Analizi. *Ulusal Çevre Bilimleri Araştırma Dergisi*. 2 (1), 44-56.

Çölleşme ve Erozyonla Mücadele Genel Müdürlüğü. (2017). *Türkiye çölleşme modeli, teknik özet*.

Ankara, Türkiye.

- Feng, J., Dong, B., Qin, T., Liu, S., Zhang, J., & Gong, X. (2020). Temporal and spatial variation characteristics of NDVI and its relationship with environmental factors in Huangshui River Basin from 2000 to 2018. *Pol. J. Environ. Stud.*, 30 (4), 3043-3063.
- Kapluhan, E. (2013). Türkiye’de kuraklık ve kuraklığın tarıma etkisi. *Marmara Coğrafya Dergisi*, 27, 487-510.
- Kaya, H. E., & Demir, V.(2022). Estimation of land use and land cover changes in Konya Closed Basin. 4th *Intercontinental Geoinformation Days (IGD)*, 180-183, Tabriz, Iran.
- Koroleva, P. V., Rukhovich, D. I., Rukhovich, D. D. & Kalinina N. V. (2021). The use of deep machine learning for the automated select of remote sensing data for the determination of areas of arable land degradation processes distribution. *Remote Sensing*, 13(1), 155.
- Oğuztürk, G. (2010). *Kızılırmak Havzası’nda SYİ ile kuraklık analizi ve YSA yöntemi ile kuraklık tahmini. Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale, Türkiye.*
- Orhan, O. (2018). Determining potential sinkhole areas using remote sensing and geographic information systems. *Doktora tezi, Selçuk Üniversitesi, Konya, 182s.*
- Orhan. O. & Ekercin, S. (2015). Konya Kapalı Havzasında uzaktan algılama ve CBS teknolojileri ile iklim değişikliği ve kuraklık analizi. *TUFUAB VIII. Teknik Sempozyumu, Selçuk Üniversitesi, Konya.*
- Sarış, F. & Gedik, F. (2021). Konya Kapalı Havzası’nda meteorolojik kuraklık analizi. *Coğrafya Dergisi Journal of Geography*, (42),295-308.
- Silleos, G., Alexandridis, T., Gitas, I. & Perakis, K. (2006). Vegetation indices: Advances made in biomass estimation and vegetation monitoring in the last 30 years. *Geocarto International*, 21, 21-28.
- URL-1:
[https://web.archive.org/web/20170425114748/http://www.cem.gov.tr/erozyon/Files/faaliyetler/dis_iliskiler/collesme_ile_mucadele_sozlesmesi/UNCCD_BM_Collesme_ile_Mucadele_Sozlesmesi_\(Turke\).pdf](https://web.archive.org/web/20170425114748/http://www.cem.gov.tr/erozyon/Files/faaliyetler/dis_iliskiler/collesme_ile_mucadele_sozlesmesi/UNCCD_BM_Collesme_ile_Mucadele_Sozlesmesi_(Turke).pdf)
[Erişim tarihi: 30.01.2022]
- URL-2:
- Şensoy S., Coşkun, M., Sumer, U.M., Demircan, M., Gürkan, H., Eskioğlu, O., Yazıcı, B., Türkoğlu, N. & Çiçek, İ. (2017). Karaman ve Karapınar’ın iklim değişikliği trendleri. *IV. Türkiye İklim Değişikliği Kongresi, TİKDEK.*
- T.C. Orman ve Su İşleri Bakanlığı. (2017). Konya Kapalı Havzası sektörel su tahsis planını hazırlamasına yönelik teknik destek hizmet alım işi- taslak mevcut durum raporu. Ankara, Türkiye.
- Tomar, A. (2014). Toprak ve su kirliliği ve su havzalarının korunması. *1.İzmir Kent Sempozyumu Bildirileri, TMMOB.*
- Turan, E. S. (2018). Türkiye'nin iklim değişikliğine bağlı kuraklık durumu. *Artvin Çoruh Üniversitesi Doğal Afetler Uygulama ve Araştırma Merkezi Doğal Afetler ve Çevre Dergisi*, 4(1), 63-69.
- Türkeş, M., Akgündüz, A.S. & Demirörs, Z. (2009). Palmer Kuraklık İndisi’ne göre İç Anadolu Bölgesi’nin Konya Bölümü’ndeki kurak dönemler ve kuraklık şiddeti. *Coğrafi Bilimler Dergisi*, 7 (2), 129-144.
- UADMK. (2022). 4. hafta.pdf, Ankara Üniversitesi Açık Ders Malzemeleri. Erişim Adresi: https://acikders.ankara.edu.tr/pluginfile.php/62029/mod_resource/content/0/4.%20hafta.pdf, Erişim tarihi: 15.04.2022
- Yıldız, O. (2014). Spatial temporal analysis of historical droughts in the Central Anatolia, Turkey. *Gazi University Journal of Science GU J Sci*, 27(4),1177-1184.
- Zhan, C., Liang, C., Zhao, L., Jiang, S., Niu, K., Zhang, Y. & Cheng, L. (2022). Vegetation dynamics and its response to climate change in the Yellow River Basin, China. *Environmental Informatics and Remote Sensing, frontiers in Environmental Science*, 10:892747.
- Zhifang, P., Fang, S., Yang, W., Wang, L., Wu, M., Zhang, Q., Han, W. &Khoi, D.N. (2019). The relationship between NDVI and climate factors at different monthly time scales: A case study of grasslands in Inner Mongolia, China (1982–2015). *Sustainability*, 11(24), 7243.
- <https://www.usgs.gov/special-topics/remote-sensing-phenology/science/ndvi-foundation-remote-sensing-phenology#:~:text=NDVI%20is%20especially%20useful%20for,sensitive%20to%20underlying%20soil%20color>
[Erişim tarihi: 13.04.2022]
- URL-3:

<https://www.earthdatascience.org/courses/us-e-data-open-source-python/multispectral-remote-sensing/vegetation-indices-in-python/>
[Erişim tarihi: 13.04.2022]

URL-4:

<https://scikitlearn.org/stable/modules/ensemble.html#ensemble>
[Erişim Tarihi: 12.06.2022]

URL-5:

<https://machinelearningmastery.com/why-use-ensemble-learning/>
[Erişim Tarihi: 12.06.2022]

URL-6:

<https://www.aa.com.tr/tr/cevre/tuz-golu-kuraklik-nedeniyle-kuculuyor/2442995>
[Erişim Tarihi:01.02.2022]

URL-7:

<https://www.aa.com.tr/tr/pg/foto-galeri/dunyanin-nazar-boncugu-kuruyor>
[Erişim Tarihi:01.02.2022]

URL-8:

<https://www.aa.com.tr/tr/pg/foto-galeri/karapinar-halkinin-quot-obrukquot-korkusu/0/11770>
[Erişim Tarihi:01.02.2022]

URL-9:

<https://konya.mgm.gov.tr/istasyonlar.aspx>
[Erişim Tarihi: 02.04.2022]

URL-10:

https://earthobservatory.nasa.gov/features/MeasuringVegetation/measuring_vegetation_2.php
[Erişim Tarihi:05.02.2022]

URL-11:

<https://github.com/sentinel-hub/custom-scripts/tree/master/sentinel-2/ndvi>
[Erişim Tarihi: 13.04.2022]

URL-12:

<https://www.researchgate.net/post/What-is-value-range-for-different-Vegetation-Indices/598d954b404854fcc17db610/citation/download>

[Erişim Tarihi: 02.05.2022]

URL-13:

https://en.wikipedia.org/wiki/Mean_absolute_error
[Erişim Tarihi: 15.04.2022]

URL-14:

<https://www.nigdehaber.com.tr/haber/6774/agaclandirma-calismalari-devam-ediyor.html>
[Erişim Tarihi: 12.05.2022]

URL-15:

<https://www.cekud.org.tr/tr/konya-fidan-dikim-calismalari/>
[Erişim Tarihi: 12.05.2022]

URL-16:

<https://www.cekud.org.tr/tr/meramda-2-bin-fidan-toprakla-bulusturuldu/>
[Erişim Tarihi: 12.05.2022]

URL-17:

<https://www.karamandan.com/haber/7358725/torku-ormanlarindaki-agac-sayisi-21-milyona-ulasti>
[Erişim Tarihi: 12.05.2022]

URL-18:

<http://www.ydavakfi.org.tr/sosyal-sorumluluklar/konya-sarayonu-ilcesi%CC%87-agaclandirma-projesi/>
[Erişim Tarihi: 12.05.2022]

URL-19:

www.fibhaber.com<https://www.fibhaber.com/nevsehir/nevsehir-de-orman-yangini-42-donum-alan-zarar-gordu-h56049.html>
[Erişim Tarihi: 12.05.2022]

URL-20:

https://www.konhaber.com/haber-konya_da_cikan_orman_yangini_kontrol_altina_alindi-1594366.html
[Erişim Tarihi: 12.05.2022]

URL-21:

<https://www.trthaber.com/haber/turkiye/konyada-orman-yangini-505830.html>
[Erişim Tarihi: 12.05.2022]



© Author(s) 2022.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>



Turkish Journal of Remote Sensing

<https://dergipark.org.tr/en/pub/tuzal>

e-ISSN 2687-4997



GIS-Based Assessment of Land Surface Temperature Changes Over Khorramabad City (Lorestan, Iran)

Mohammad Hassan Khamesi-Maybodi*¹ 

¹Yazd University, Technical and Vocational Schools, Yazd, Iran

Keywords

Land surface temperature
Vegetation
Reflective roof
Remote sensing
Landsat

ABSTRACT

Development of remote sensing applications has led to their use in a wide range of environmental studies. One of these aspects is urban studies and especially land surface temperature. In this study, the changes in land surface temperature in the Khorramabad city in Iran were investigated and the causes of land temperature changes were investigated. For this purpose, Landsat satellite images were processed in four periods of 2000, 2007, 2014 and 2021 and were recovered using a single-channel surface temperature algorithm. Temperatures were high in 2000 due to the type of roofs of buildings and the dirt around the city. Decreased in 2007 and 2014 due to the use of roofs that reflect light. In 2021, due to severe manipulations around the city and the destruction of vegetation and change it into built-up bare soil cover caused the temperature to rise again in the suburbs.

Khorramabad Şehrindeki (Luristan-İran) Arazi Yüzey Sıcaklığı Değişimlerinin CBS Tabanlı Değerlendirilmesi

Anahtar Kelimeler:

Arazi yüzey sıcaklığı
Bitki örtüsü
Yansıtıcı çatı
Uzaktan algılama
Landsat

ÖZ

Uzaktan algılama uygulamalarının gelişmesi, çeşitli çevresel çalışmalarda kullanılmasına yol açmıştır. Bu çalışmalardan biri de kentsel çalışmalar ve özellikle arazi yüzey sıcaklığıdır. Bu çalışmada İran'ın Khorramabad şehrinde arazi yüzey sıcaklığındaki değişimler incelenmiş ve arazi sıcaklık değişimlerinin sebepleri araştırılmıştır. Bu amaçla Landsat uydu görüntüleri 2000, 2007, 2014 ve 2021 olmak üzere dört periyotta işlenmiş ve tek kanallı yüzey sıcaklığı algoritması kullanılarak iyileştirilmiştir. 2000 yılında binalardaki çatı tipi şehrin çevresindeki kirlilik nedeniyle sıcaklıklar yüksekti. 2007 ve 2014 yılları arasında ışığı yansıtan çatıların kullanılması nedeniyle bu sıcaklıklar azalmıştır. 2021 yılında, şehrin etrafındaki şiddetli manipülasyonlar ve bitki örtüsünün yok edilmesi ve çıplak toprak örtüsüne dönüştürülmesi banliyölerde sıcaklığın yeniden yükselmesine neden olmuştur.

* Corresponding Author

*(khamesimaybodi@yahoo.com) ORCID ID 0000-0001-8267-3628

Cite this article

Khamesi-Maybodi, M.H. (2022). GIS-based assessment of land surface temperature changes over Khorramabad city (Lorestan, Iran). *Turkish Journal of Remote Sensing*, 4(2), 87-95.

1. INTRODUCTION

Land surface temperature (LST) is one of the key parameters in the physics of surface processes from local to global scale (Li et al., 2013). The most pressing problem on Earth, especially in urban areas, is rising surface temperatures due to the conversion of vegetation surfaces to impermeable surfaces (Mallick et al., 2008; Pal & Ziaul, 2017). Increasing heat storage capacity at the urban level creates urban heat islands (UHIs) where built-up areas are warmer than adjacent rural areas (Rizwan et al., 2008; Tran et al., 2017). Increasing heat storage capacity at the urban level creates urban heat islands (UHIs) where built-up areas are warmer than adjacent rural areas (Rizwan et al., 2008; Tran et al., 2017).

Global warming is one of the major consequences of human activities in which excessive use of fossil fuels as energy sources increases the concentration of greenhouse gases (GHGs) such as CO₂, CH₄, N₂O and water vapor in the atmosphere, which in itself increases the average surface temperature of the earth (Al-Ghussain, 2019). Direct global warming is difficult to detect because most people experience only local climate change and do not understand long-term global climate trends; Thus, local analysis of climate change may play an important role in adapting behavior and supporting climate change policies (Marx et al., 2007; Spence et al., 2011; Howe et al., 2013). Direct global warming is difficult to detect because most people experience only local climate change and do not understand long-term global climate trends; Thus, local analysis of climate change may play an important role in adapting behavior and supporting climate change policies (Marx et al., 2007; Spence et al., 2011; Howe et al., 2013).

The problem of optimal control for deliberate intervention in the Earth's climate system is considered with the aim of stabilizing the global temperature (Soldatenko & Yusupov, 2019). To date, the goal of measures taken to stabilize global temperature rise (temperature control) below 2° C is probably insufficient (Da Cunha & Eames, 2016). If this goal is to be achieved, more efforts must be made to decarbonize global energy consumption (which still relies heavily on fossil fuel sources) (Hawkes, 2014). Heat island changes depend on many factors, including land use changes (Maleki et al., 2020; Zare Naghadehi et al., 2021), population changes (Manoli et al., 2019), altitude changes (Mathew et al., 2017). Vegetation changes (Gui et al., 2019) and

Related research has confirmed that there is an exchange of energy between the Earth's surface and the near-surface atmosphere, and that LST retrieved

from thermal infrared remote sensing has a high correlation with air temperature (Shen et al., 2020). Hence, the use of satellite data for LST retrieval is widely used to estimate air temperature (Feizizadeh & Blaschke, 2012; Cammalleri et al., 2012; Hooker et al., 2018; Collados-Lara et al., 2020; Goldblatt et al., 2021). Investigating the city's heat island from the past (Bornstein, 1968; Myrup, 1969; Oke, 1982; Kim, 1992) to the present (Mirzaei, 2015; Yin et al., 2018; He, 2019; Chakraborty, 2020; Halder et al., 2021; Li et al., 2022), has been one of the hottest topics in urban research, especially urban climate. With this introduction, some related research results are presented below.

Hashemi Darebadami et al. (2019) used Modis images to analyze the spatial-temporal of the heat island and its relationship with environmental parameters in Tehran. The results showed that the heat island had daily and seasonal spatial and temporal fluctuations. Maleki et al. (2017) studied the changes of the thermal island of Kermanshah in the period 1393-1397, which showed that the use of reflective roofing has reduced the average temperature. Mansourmoghaddam et al. (1400) in an article on the heat island of Yazd in the period 1990-2020 and concluded that changes in the thermal island boundaries are strongly dependent on land use changes. Hoffmann et al. (2012) examined monthly changes in the city's thermal island; The results showed that the UHI changes were different for different months. The results of Zhang et al. (2013) research showed that changes in land use / land cover and population change led to significant changes in the spatial and temporal patterns of the thermal island due to the loss of water bodies and vegetation levels. A study in the United States found interesting results that indicated the approach of a heat island in urban and rural areas due to changes in rural areas (Scott et al., 2018).

2. STUDY AREA

Khorramabad city is the capital of Lorestan province and the center of Khorramabad city, which is located in the southwest of the country and among the Zagros valleys. This city shares borders with Selseleh city from the north, Andimeshk city from the south, Doroud and Aligudarz cities from the east, and Durah and Poldakhtar cities from the west and southwest. The climate of this city is also temperate and semi-humid Mediterranean (Nikpour et al., 2020). According to the results of the 2016 census, the population of this city was more than 370000 people (Statistics Center of Iran, 2016) and is the 23rd most populous city in Iran (Moradipour et al., 2020). Figure 1 shows a map of the study area.

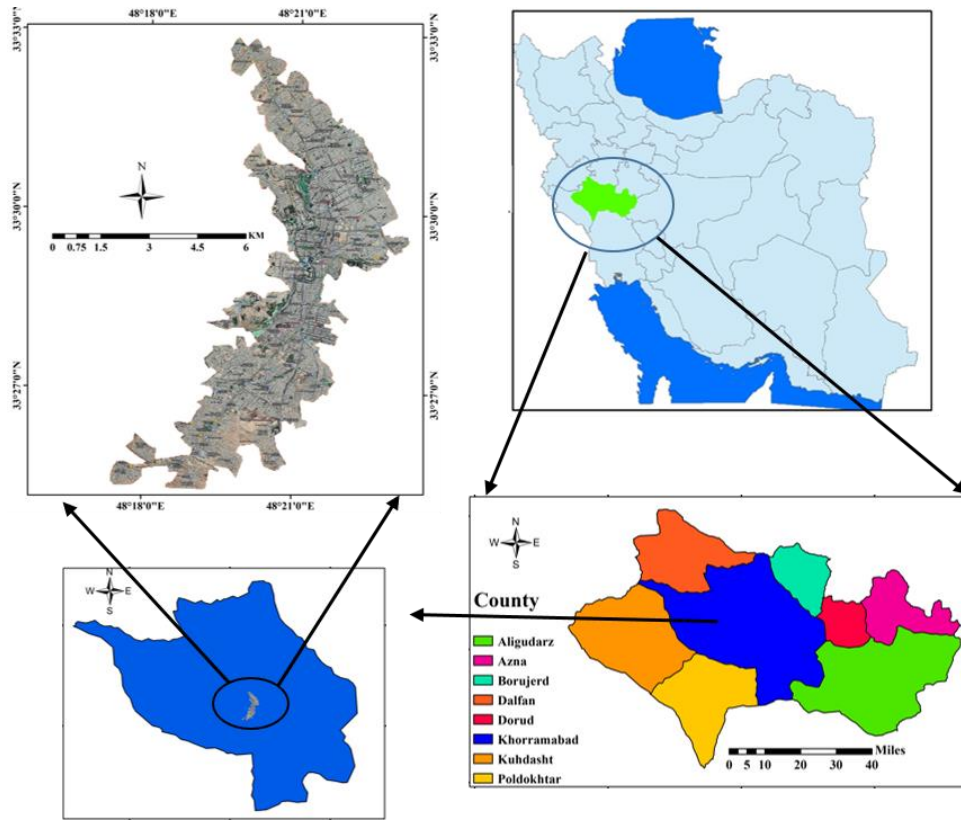


Figure 1. The case study area

3. METODOLOGY

In this study, Landsat satellite images were used to study the temperature changes trend in Khorramabad city. The information about the date and characteristics of the images used in Table 1 is presented. Due to the fact that these images were from two different sensors, the images were register relative to each other to eliminate the effect of geometric distortions. The landsat_gapfill plugin in ENVI software was used to correct the 2007 image Scan Line Corrector (SLC) (Brooks et al., 2018). Also,

other preprocessing required to obtain ground surface temperature included spectral radiance (Rajeshwari & Mani, 2014) and reflection coefficient (Sekertekin, 2019).

The amount of income, quality of housing, population aging and youth population. According to past studies, effects of each variable (positive or negative) has been determined. For positive effect we use the symbol of “+” and for negative the symbol of “-”. The name of criteria, effectiveness, explanation for each one, extraction method and source for every index is available in Table 1.

Table 1. Images used

S. No	Landsat Name	Landsat Scene ID	Path	Row	Image Acquisition Date
1	ETM+	LE07_L1TP_166037_20000529_20170211	166	37	29/05/2000
2	ETM+	LE07_L1TP_166037_20070618_20170103	166	37	18/06/2007
3	OLI	LC08_L1TP_166037_20140528_20170422	166	37	28/05/2014
4	OLI	LC08_L1TP_166037_20210531_20210608	166	37	31/05/2021

3.1 Brightness Temperature

$$T = \frac{K2}{\ln\left(\frac{K1}{L\lambda} + 1\right)} \quad (1)$$

Here T is the brightness temperature of the sensor surface in Kelvin (K), $L\lambda$ is high spectral

radiation [$W / (m^2 sr \mu m)$], K2 is the calibration coefficient in Kelvin, K1 is the calibration coefficient in Kelvin [$W / (m^2 sr \mu m)$]. Is The coefficients for Landsat sensors are presented in Table 2.

Table 2. Coefficients K1 and K2 for Landsat sensors

Coefficient / sensor	Landsat 4 and 5TM	Landsat 7 ETM+	Landsat 8 Band 10	Landsat 8 Band 11
K1[W/(m ² Sr μm)]	76/607	09/666	08/1321	1201/14
K2 [kelvin]	56/1260	71/1282	89/777	89/480

3.2 NDVI Vegetation Index

NDVI index plays a large role in energy interactions between the earth and the atmosphere, this index is widely used in the process of retrieving the surface temperature of the earth and can be calculated through Equation 2 (Maleki et al., 2018).

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (2)$$

In this regard, ρ_{NIR} is the near-red infinity band reflection and ρ_{RED} is the red band reflection.

$$\begin{aligned} \varepsilon &= a + b\rho_{red} \quad (FVC = 0) \\ \varepsilon &= \varepsilon_s(1 - FVC) + \varepsilon_v FVC \quad (0 < FVC < 1) \\ \varepsilon &= 0.99 \quad (FVC = 1) \end{aligned}$$

ρ_{red} the red band reflectance of the OLI sensor (band 4), a and b are the linear correlation coefficients of the red band reflectance with the surface emissivity, ε_s the radiant power of the soil and ε_v the surface emissivity of the vegetation.

3.5 Land Surface Temperature Retrieval from Single Channel (SC) Algorithm

The SC algorithm used to recover LST from Landsat satellite thermal images was developed by Jiménez-Muñoz et al. (2003) and then (2014). This algorithm applies to all Landsat in the same way with relation 5.

$$T_s = \gamma \left[\frac{1}{\varepsilon} (\psi_1 L_{sen} + \psi_2) + \psi_3 \right] + \delta \quad (5)$$

In this, T_s is the surface temperature, ε is the land surface emissivity of the surface and L_{sen} is the radiance at the sensor surface. The parameters γ and δ are obtained from Equation 6.

$$\gamma \approx \frac{T_{sen}^2}{b_\gamma L_{sen}}; \quad \delta \approx T_{sen} - \frac{T_{sen}^2}{b_\gamma} \quad (6)$$

In this, T_{sen} is the brightness temperature of the sensor surface, b_γ , which is 1256, 1277 and 1324 for Landsat 5, 7 and 8, respectively (Cristóbal et al.,

3.3 Vegetation Fraction Cover (FVC)

Fraction Vegetation Cover was estimated from Equation 3. This index can be calculated with the NDVI index and the minimum and maximum values of this index, according to Equation 3.

$$FVC = \left[\frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \right]^2 \quad (3)$$

Where $NDVI_{min}$ is the lowest NDVI and $NDVI_{max}$ is the highest NDVI (dense vegetation).

3.4 Surface Emissivity

By calculating the vegetation fraction (FVC), the surface emissivity from Equation (4) is calculated.

$$\begin{aligned} \xrightarrow{TIRS1} &= 0.979 - 0.046r_{OLI-B4} \\ \xrightarrow{TIRS2} &= 0.982 - 0.027r_{OLI-B4} \\ \xrightarrow{TIRS1} &= 0.971(1-FVC) + 0.987FVC \\ \xrightarrow{TIRS2} &= 0.977(1-FVC) + 0.989FVC \end{aligned} \quad (4)$$

2018; Sekertekin & Bonafoni, 2020). Ψ_3 [and Ψ_2] [and Ψ_1] are atmospheric functions that are obtained for Landsat according to Equation 7 (Galve et al, 2022).

$$\begin{bmatrix} \psi_1 \\ \psi_2 \\ \psi_3 \end{bmatrix} = \begin{bmatrix} 0.04019 & 0.02916 & 1.01523 \\ -0.38333 & -1.50294 & 0.20324 \\ 0.00918 & 1.36072 & -0.27514 \end{bmatrix} \begin{bmatrix} W^2 \\ W \\ 1 \end{bmatrix} \quad (7)$$

4. RESULTS AND DISCUSSION

After conducting the research stages, the results of land surface temperature in four time periods were determined. Figure 2 shows a map of the land surface temperature in 2000. The map is divided into five classes, the first class of temperatures below 35 degrees and the last class of temperatures above 50 degrees Celsius. According to Figure 2, the urban peripheral had higher temperatures, this is because the area around the city had not yet been built in 2000, and according to studies, bare soil has a higher temperature. This continues almost to the center of the city; Because in these parts, the houses have not been built densely yet. Cool areas on the map are often vegetation.




Figure 2. Land surface temperature map of Khorramabad in 2000

According to the information presented in Table 3, the highest area of the city by the fourth class, (the range between 45-50 degrees Celsius), which is about 46% of the city in this area. Then the temperature range is more than 50 degrees, which covers more than 25% of the city.

Table 3. Area of temperature classes of 2000

Class	Area(ha)	Percent
1	942041	2.4%
2	2711531	6.88%
3	7668090	19.47%
4	18110126	45.98%
5	9952428	25.27%

Figure 3 shows the LST map of the city for 2007; According to this figure, it can be seen that the third temperature class (40-45 degrees Celsius) has expanded a lot compared to 2000, but the fourth temperature class still has a wide range.




Figure 3. Land surface temperature map of Khorramabad in 2007

According to the results presented in the table, the highest temperature range is related to the temperature class of 40-45 degrees with more than 46% of the largest area of the city, but still the temperature range of 45-50 degrees has a large range and more than 40% of the city covered.

Table 4. Area of temperature classes of 2007

Class	Area(ha)	Percent
1	75510	0.19%
2	3906204	9.92%
3	18285953	46.43%
4	15833731	40.2%
5	1282817	3.26%

The land surface temperature map for 2014 shows that the temperatures in the city have progressed towards cooling so that the expansion of the temperature class is 35-40 degrees compared to previous periods, which is quite evident in Figure 4. But the peripheral of the current city area are still the hottest areas because in 2014 the buildings were single and made up mostly of soil.

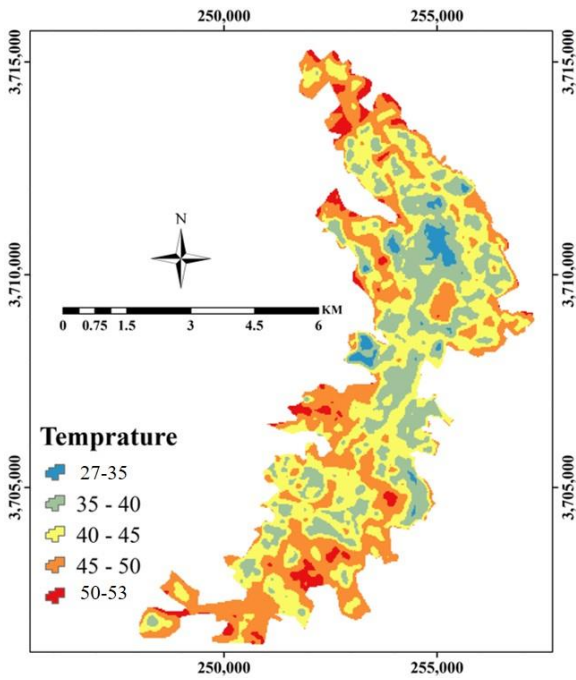


Figure 4. Land surface temperature map of Khorramabad in 2014

Table 5 shows the statistical information of the area and percentage of range covered by each of the temperature classes. According to the information presented in this table, the temperature class has expanded 35-40 degrees and the area of 40-45- and 45-50-degrees classes has been reduced.

Table 5. Area of temperature classes of 2014

Class	Area(ha)	Percent
1	892747	2.11%
2	9221182	23.41%
3	14753712	37.46%
4	12880867	32.71%
5	1698706	4.31%

According to Figure 5, the temperature in the city has risen sharply as temperature classes below 40 °C are seen in the map as very small areas. But on the other hand, the temperature zones above 40 degrees have increased, which can be said that the greatest increase is related to the temperature class above 50 degrees.

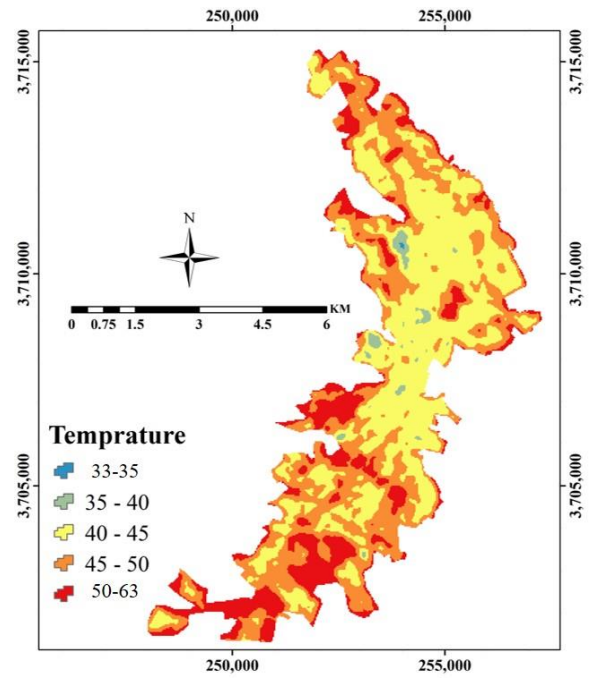


Figure 5. Land surface temperature map of Khorramabad in 2021

Looking at the statistics presented in Table 6, we will see that the area of the temperature class above 50 degrees has more than quadrupled. On the other hand, the temperature range of less than 40 degrees has been greatly reduced and its temperature zones have been increased to the temperature zones of other classes.

Table 6. Area of temperature classes of 2021

Class	Area(ha)	Percent
1	11833	0.03%
2	473322	1.2%
3	16798862	42.65%
4	15037108	38.18%
5	7063090	17.94%

5. CONCLUSION

Studying how the land surface temperature changes is one of the interesting research topics that many researches are done in the world every year. The thermal island actually shows how cities have higher temperatures than their surroundings. In this study, the land surface temperature changes in the city of Khorramabad in the periods of 2000, 2007, 2014 and 2021 were investigated. The study of the obtained results shows an interesting pattern of temperature changes in the city of Khorramabad. In the first period (2000), a large area of the study area had a temperature range above 50 degrees, which was due to the fact that, firstly, the peripheral sections in 2000 were bare soil zones, which during various studies it has been shown that bare soil often has a higher temperature than the surrounding land uses. Secondly, the roofs of Iranian urban houses in the past (around 2000 and before) were mostly covered with black asphalt and sometimes the roofs of houses were made of dirt. The interesting thing

about the next two periods (2007 and 2014) is that lower temperatures have risen in the city center; This is due to the use of a type of roof covering in recent years, which often has colors that reflect sun radiation (In the past, bitumen and asphalt were used to cover the roof, but in recent years, the use of Waterproofing with colors that reflect sun radiation has reduced LST). Regarding the temperature changes in 2021, the central part of the city is still cooler than the around one's for the reasons mentioned. But the high temperature spread around the city (where in previous times it was not a city, but today it has become a city) this is because the vegetation in these areas has been completely destroyed for construction and replaced by buildings and bare soil (bare soil that are being prepared for construction).

Author contributions

The author declares that has contributed 100% to the article.

Conflicts of Interest

The author declare no conflict of interest.

Declaration of research and publication ethics

In the study, the authors declare that there is no violation of research and publication ethics and that the study does not require ethical committee approval.

REFERENCES

- Al-Ghussain, L. (2019). Global warming: review on driving forces and mitigation. *Environmental Progress & Sustainable Energy*, 38(1), 13-21.
- Bornstein, R. D. (1968). Observations of the urban heat island effect in New York City. *Journal of Applied Meteorology and Climatology*, 7(4), 575-582.
- Brooks, E. B., Wynne, R. H., & Thomas, V. A. (2018). Using window regression to gap-fill Landsat ETM+ post SLC-Off data. *Remote Sensing*, 10(10), 1502.
- Cammalleri, C., Anderson, M. C., Ciraolo, G., D'urso, G., Kustas, W. P., La Loggia, G., & Minacapilli, M. (2012). Applications of a remote sensing-based two-source energy balance algorithm for mapping surface fluxes without in situ air temperature observations. *Remote Sensing of Environment*, 124, 502-515.
- Chakraborty, T., Hsu, A., Manya, D., & Sheriff, G. (2020). A spatially explicit surface urban heat island database for the United States: Characterization, uncertainties, and possible applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, 168, 74-88.
- Collados-Lara, A. J., Fassnacht, S. R., Pardo-Igúzquiza, E., & Pulido-Velazquez, D. (2020). Assessment of high-resolution air temperature fields at rocky mountain national park by combining scarce point measurements with elevation and remote sensing data. *Remote Sensing*, 13(1), 113.
- Cristóbal, J., Jiménez-Muñoz, J. C., Prakash, A., Mattar, C., Skoković, D., & Sobrino, J. A. (2018). An improved single-channel method to retrieve land surface temperature from the Landsat-8 thermal band. *Remote Sensing*, 10(3), 431.
- Da Cunha, J. P., & Eames, P. (2016). Thermal energy storage for low and medium temperature applications using phase change materials—a review. *Applied energy*, 177, 227-238.
- Feizizadeh, B., & Blaschke, T. (2012, July). Thermal remote sensing for land surface temperature monitoring: Maraqeh County, Iran. In 2012 IEEE International Geoscience and Remote Sensing Symposium (pp. 2217-2220). IEEE.
- Galve, J. M., Sánchez, J. M., García-Santos, V., González-Piqueras, J., Calera, A., & Villodre, J. (2022). Assessment of Land Surface Temperature Estimates from Landsat 8-TIRS in A High-Contrast Semiarid Agroecosystem. Algorithms Intercomparison. *Remote Sensing*, 14(8), 1843.
- Goldblatt, R., Addas, A., Crull, D., Maghrabi, A., Levin, G. G., & Rubinyi, S. (2021). Remotely sensed derived land surface temperature (LST) as a proxy for air temperature and thermal comfort at a small geographical scale. *Land*, 10(4), 410.
- Gui, X., Wang, L., Yao, R., Yu, D., & Li, C. A. (2019). Investigating the urbanization process and its impact on vegetation change and urban heat island in Wuhan, China. *Environmental Science and Pollution Research*, 26(30), 30808-30825.
- Halder, B., Bandyopadhyay, J., & Banik, P. (2021). Monitoring the effect of urban development on urban heat island based on remote sensing and geo-spatial approach in Kolkata and adjacent areas, India. *Sustainable Cities and Society*, 74, 103186.
- Hashemi Darebadami, S., Darvishi Boloorani, A., AlaviPanah, S. K., Maleki, Mohammad., & Bayat, R. (2019). Investigation of changes in surface urban heat-island (SUHI) in day and night using multi-temporal MODIS sensor data products (Case Study: Tehran metropolitan). *Journal of*

- Applied researches in Geographical Sciences*, 19(52), 113-128.
- Hawkes, A. D. (2014). Long-run marginal CO2 emissions factors in national electricity systems. *Applied Energy*, 125, 197-205.
- He, B. J. (2019). Towards the next generation of green building for urban heat island mitigation: Zero UHI impact building. *Sustainable Cities and Society*, 50, 101647.
- Hoffmann, P., Krueger, O., & Schlünzen, K. H. (2012). A statistical model for the urban heat island and its application to a climate change scenario. *International Journal of Climatology*, 32(8), 1238-1248.
- Hooker, J., Duveiller, G., & Cescatti, A. (2018). A global dataset of air temperature derived from satellite remote sensing and weather stations. *Scientific data*, 5(1), 1-11.
- Howe, P. D., Markowitz, E. M., Lee, T. M., Ko, C. Y., & Leiserowitz, A. (2013). Global perceptions of local temperature change. *Nature climate change*, 3(4), 352-356.
- Jiménez-Muñoz, J. C., & Sobrino, J. A. (2003). A generalized single-channel method for retrieving land surface temperature from remote sensing data. *Journal of geophysical research: atmospheres*, 108(D22).
- Jiménez-Muñoz, J. C., Sobrino, J. A., Skoković, D., Mattar, C., & Cristóbal, J. (2014). Land surface temperature retrieval methods from Landsat-8 thermal infrared sensor data. *IEEE Geoscience and remote sensing letters*, 11(10), 1840-1843.
- Kim, H. H. (1992). Urban heat island. *International Journal of Remote Sensing*, 13(12), 2319-2336.
- Li, K., Chen, Y., & Gao, S. (2022). Uncertainty of city-based urban heat island intensity across 1112 global cities: Background reference and cloud coverage. *Remote Sensing of Environment*, 271, 112898.
- Li, Z. L., Tang, B. H., Wu, H., Ren, H., Yan, G., Wan, Z., ... & Sobrino, J. A. (2013). Satellite-derived land surface temperature: Current status and perspectives. *Remote sensing of environment*, 131, 14-37.
- Maleki, M., Ahmadi, Z., & Dosti, R. (2019). Kermanshah land surface temperature changes in during 1393-1397 periods. *Geography and Human Relationships*, 2(3), 309-319.
- Maleki, M., Tavakoli Sabour, S-M & Javan, F. (2018). Analysis of the Effects of Dam Construction on Vegetation of Peripheral Areas in Different Heights and Slopes. Case: Sulayman Shah and Gushan Dam. *Spatial Locational Researches*, 2(2), 102-117.
- Maleki, M., Van Genderen, J. L., Tavakkoli-Sabour, S. M., Saleh, S. S., & Babaei, E. (2020). Land use/cover change in dinevar rural area of West Iran during 2000-2018 and its prediction for 2024 and 2030. *Geogr. Tech*, 15, 93-105.
- Mallick, J., Kant, Y., & Bharath, B. D. (2008). Estimation of land surface temperature over Delhi using Landsat-7 ETM+. *J. Ind. Geophys. Union*, 12(3), 131-140.
- Manoli, G., Fatichi, S., Schläpfer, M., Yu, K., Crowther, T. W., Meili, N., ... & Bou-Zeid, E. (2019). Magnitude of urban heat islands largely explained by climate and population. *Nature*, 573(7772), 55-60.
- Mansourmoghaddam, M., Rousta, I., Zamani, M., Mokhtari, M. H., Karimi Firozjahi, M., & Alavipanah, S. K. (2021). Study and prediction of land surface temperature changes of Yazd city: Assessing the proximity and changes of land cover. *Journal of RS and GIS for Natural Resources*, 12(4), 1-27.
- Marx, S. M., Weber, E. U., Orlove, B. S., Leiserowitz, A., Krantz, D. H., Roncoli, C., & Phillips, J. (2007). Communication and mental processes: Experiential and analytic processing of uncertain climate information. *Global Environmental Change*, 17(1), 47-58.
- Mathew, A., Khandelwal, S., & Kaul, N. (2017). Investigating spatial and seasonal variations of urban heat island effect over Jaipur city and its relationship with vegetation, urbanization and elevation parameters. *Sustainable cities and society*, 35, 157-177.
- Mirzaei, P. A. (2015). Recent challenges in modeling of urban heat island. *Sustainable cities and society*, 19, 200-206.
- Moradipour, F., Moghimi, E., Beglou, M. J., & Yamani, M. (2020). Assessment of urban geomorphological heritage for urban geotourism development in Khorramabad City, Iran. *Geoheritage*, 12(2), 1-20.
- Myrup, L. O. (1969). A numerical model of the urban heat island. *Journal of Applied Meteorology and Climatology*, 8(6), 908-918.

- Nikpour, Amer., Soleymani, Mohamad & Mohammadyari, Behnaz (2020) Spatial pattern of factors influencing the formation of poverty zones (Case Study: Khorramabad City). *Urban Economics*, 5(1), 113-126.
- Oke, T. R. (1982). The energetic basis of the urban heat island. *Quarterly Journal of the Royal Meteorological Society*, 108(455), 1-24.
- Pal, S., & Ziaul, S. K. (2017). Detection of land use and land cover change and land surface temperature in English Bazar urban centre. *The Egyptian Journal of Remote Sensing and Space Science*, 20(1), 125-145.
- Rajeshwari, A., & Mani, N. D. (2014). Estimation of land surface temperature of Dindigul district using Landsat 8 data. *International Journal of Research in Engineering and Technology*, 3(5), 122-126.
- Rizwan, A. M., Dennis, L. Y., & Chunho, L. I. U. (2008). A review on the generation, determination and mitigation of Urban Heat Island. *Journal of environmental sciences*, 20(1), 120-128.
- Scott, A. A., Waugh, D. W., & Zaitchik, B. F. (2018). Reduced Urban Heat Island intensity under warmer conditions. *Environmental Research Letters*, 13(6), 064003.
- Sekertekin, A. (2019). Validation of physical radiative transfer equation-based land surface temperature using Landsat 8 satellite imagery and SURFRAD in-situ measurements. *Journal of Atmospheric and Solar-Terrestrial Physics*, 196, 105161.
- Sekertekin, 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), 294.
- Shen, H., Jiang, Y., Li, T., Cheng, Q., Zeng, C., & Zhang, L. (2020). Deep learning-based air temperature mapping by fusing remote sensing, station, simulation and socioeconomic data. *Remote Sensing of Environment*, 240, 111692.
- Soldatenko, S. A., & Yusupov, R. M. (2019). Optimal control for the process of using artificial sulfate aerosols for mitigating global warming. *Atmospheric and Oceanic Optics*, 32(1), 55-63.
- Spence, A., Poortinga, W., Butler, C., & Pidgeon, N. F. (2011). Perceptions of climate change and willingness to save energy related to flood experience. *Nature climate change*, 1(1), 46-49.
- Statistics Center of Iran (2016). Population information.
- Syariz, M. A., Jaelani, L. M., Subehi, L., Pamungkas, A., Koenhardono, E. S., & Sulisetyono, A. (2015). Retrieval of sea surface temperature over Poteran Island water of Indonesia with Landsat 8 TIRS image: A preliminary algorithm. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40, 87.
- Tran, D. X., Pla, F., Latorre-Carmona, P., Myint, S. W., Caetano, M., & Kieu, H. V. (2017). Characterizing the relationship between land use land cover change and land surface temperature. *ISPRS Journal of Photogrammetry and Remote Sensing*, 124, 119-132.
- Yin, C., Yuan, M., Lu, Y., Huang, Y., & Liu, Y. (2018). Effects of urban form on the urban heat island effect based on spatial regression model. *Science of the Total Environment*, 634, 696-704.
- Zare Naghadehi, S., Asadi, M., Maleki, M., Tavakkoli-Sabour, S. M., Van Genderen, J. L., & Saleh, S. S. (2021). Prediction of Urban Area Expansion with Implementation of MLC, SAM and SVMs' Classifiers Incorporating Artificial Neural Network Using Landsat Data. *ISPRS International Journal of Geo-Information*, 10(8), 513.
- Zhang, H., Qi, Z. F., Ye, X. Y., Cai, Y. B., Ma, W. C., & Chen, M. N. (2013). Analysis of land use/land cover change, population shift, and their effects on spatiotemporal patterns of urban heat islands in metropolitan Shanghai, China. *Applied Geography*, 44, 121-133.



© Author(s) 2022.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>