

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, Uydur 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

Kaynak Göster(APA);

(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

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 yöntemlerden 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

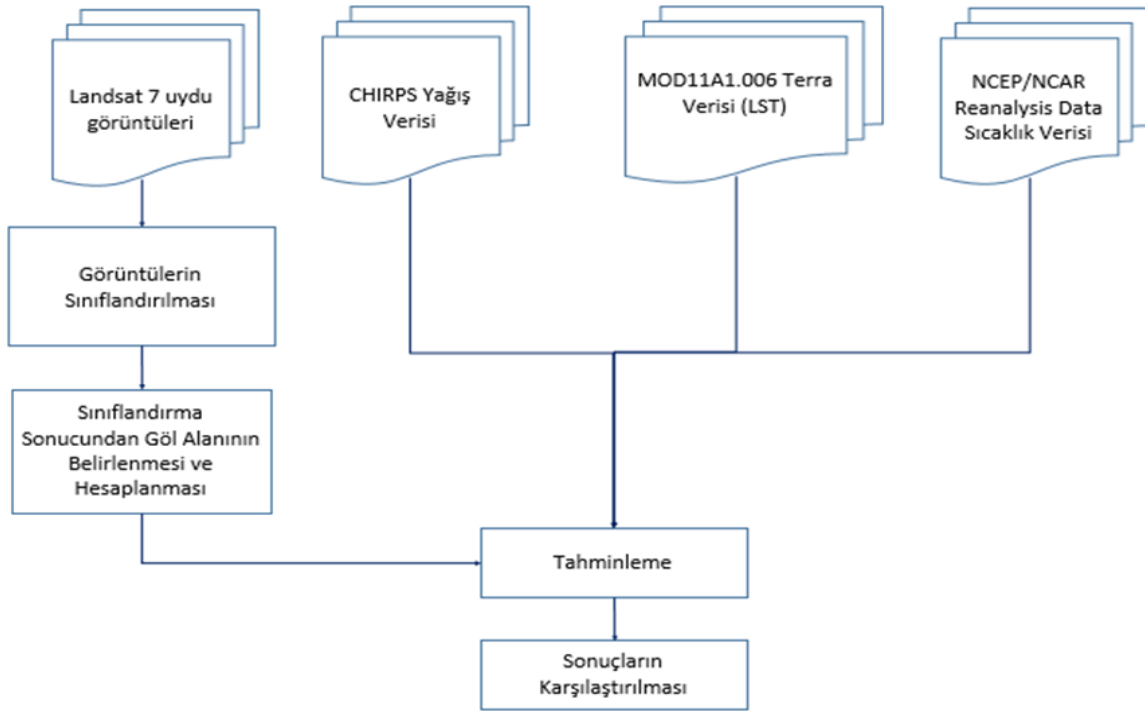
Veri	Kaynak	Tarih
Uydu Görüntüleri	Landsat 7	14/02/2002
		03/10/2005
		04/09/2010
		22/03/2015
		19/03/2020
		05/09/2021
Yağış	CHIRPS Daily	Tüm çalışma yılları için "01 Şubat-31 Mayıs" tarihleri arasındaki yağışların ortalaması
Hava Sıcaklığı	NCEP/NCAR Reanalysis Data, Surface Temperature	Tüm çalışma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

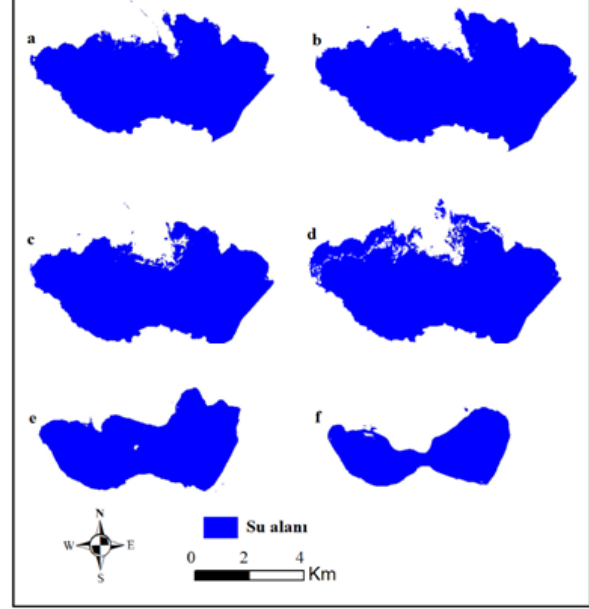
BART, regresyon ağaçlarını kullanarak parametrik olmayan fonksiyon tahminine Bayes yaklaşımıdır. BART, olasılığı hesaplamak için kullanılan Bayes teoremini kullanır. Öncelik ve olasılığa dayalı olarak, çıktı/tahminler üretilir. Bilinmeyen regresyon fonksiyonunun nokta ve aralık tahminlerinin yanı sıra 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

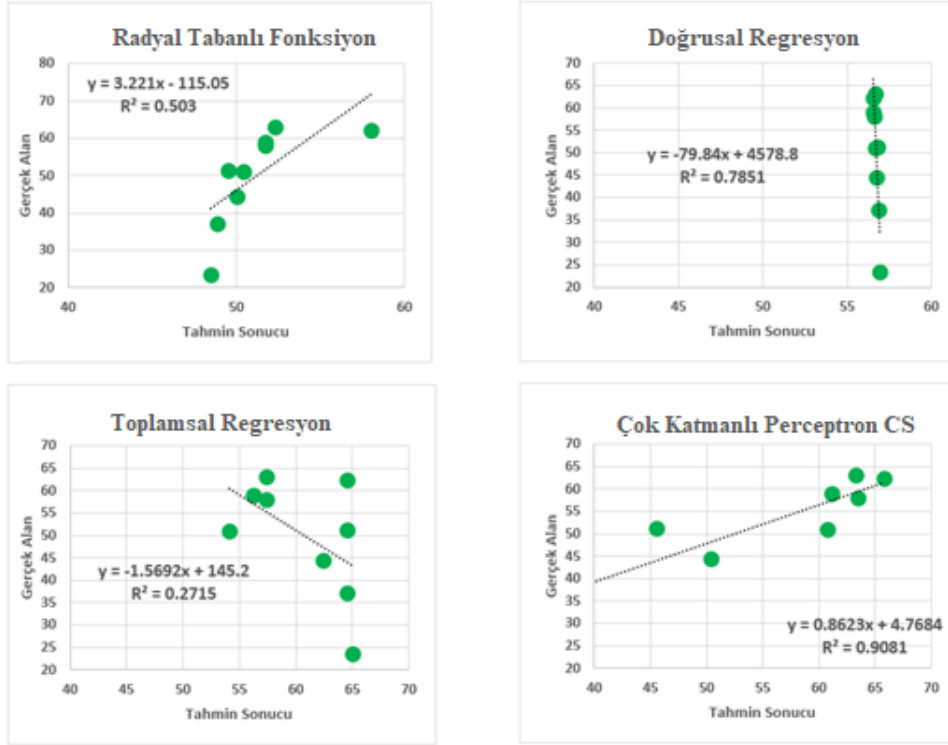
doğrultuda elde edilen verilerden 2002-2012 yılları arasındaki veriler kullanılarak 2013-2021 yıllarına ait alanlar tahminlenmiştir. Elde edilen sonuçlar Tablo 3’ de verilmiştir.

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/>