



Arazi Örtüsü/Kullanımı haritalamasında farklı makine öğrenmesi algoritmalarının değerlendirilmesi: İzmir ili örneği¹

Evaluation of different machine learning algorithms for Land Cover and Land Use mapping: A case study of Izmir province²

Şevki Danacıoğlu^{a*} 

^aİzmir Bakırçay Üniversitesi, İnsan ve Toplum Bilimleri Fakültesi, Coğrafya Bölümü, İzmir, Türkiye

ORCID: Ş. D: 0000-0003-1118-352X

BİLGİ/INFO

Geliş/Received: 14.05.2023

Kabul/Accepted: 30.09.2023

Anahtar Kelimeler:

Arazi Örtüsü ve Arazi Kullanımı
Google Earth Engine
Makine Öğrenmesi
İzmir

Keywords:

Land Cover and Land Use
Google Earth Engine
Machine Learning
Izmir

*Sorumlu yazar/Corresponding author:

(Ş. Danacıoğlu) sevki.danacioglu@bakircay.edu.tr

DOI: 10.17211/tcd.1296893



Atf/Citation:

Danacıoğlu, Ş. (2023). Arazi Örtüsü/Kullanımı haritalamasında farklı makine öğrenmesi algoritmalarının değerlendirilmesi: İzmir ili örneği. *Türk Coğrafya Dergisi* (84),105-117
<https://doi.org/10.17211/tcd.1308233>

ÖZ/ABSTRACT

Doğal kaynak yönetimi ve mekânsal planlama süreçlerinde ayrıntılı, güncel ve doğru bilgilere dayanan arazi örtüsü ve arazi kullanımı (AÖAK) durumunun tespiti önemli rol oynamaktadır. Ancak, bölgesel ölçekte arazi kullanım dinamiklerinin izlenmesini engelleyen veri işleme süreci ve depolama gereksinimi gibi bazı sınırlılıklar vardır. Google Earth Engine (GEE), küresel ölçekte coğrafi verilerin işlenmesine olanak tanıyan açık kaynak kodlu, ücretsiz bir bulut platformudur. Bu araştırmanın amacı GEE üzerinde farklı makine öğrenmesi algoritmaları ile İzmir ili AÖAK haritasını elde etmek ve kullanılan sınıflandırma algoritmalarının sonuçlarını karşılaştırmaktır. Araştırmada 2022 yılına ait 10m mekânsal çözünürlüğe sahip Sentinel-2 çok bantlı uydu görüntüleri ile çeşitli uzaktan algılama indeksleri kullanılmıştır. Araştırmada kullanılan geniş ölçekteki AÖAK sınıfları 'Tarım Alanı', 'Orman Alanı', 'Beşeri Yüzeyler', 'Açık Yüzeyler' ve 'Su Yüzeyleri' şeklinde belirlenmiştir. Çalışmada Sınıflandırma ve Regresyon Ağacı (SRA), Destek Vektör Makinesi (DVM), Rastgele Orman (RO) makine öğrenmesi algoritmaları kullanılmış ve her bir sınıflandırıcının Üretici Doğruluğu (ÜD), Kullanıcı Doğruluğu (KD) ve Genel Doğruluğu (GD) ile Kappa Katsayısı hesaplanmıştır. Sonuç olarak %97,2 GD ve Kappa değeri %95,7 olan RO sınıflandırma algoritması, en yüksek sınıflandırma doğruluğuna sahiptir. %96,1 GD ve %94,9 Kappa değeri ile DVM algoritması ikinci en yüksek sınıflandırma doğruluğuna sahip algoritma olmuştur. SRA algoritmasının GD %93,3, Kappa değeri ise %91.4 olarak hesaplanmıştır. Sonuç olarak RO yönteminin SRA ve DVM yöntemlerine göre daha iyi sonuç verdiği tespit edilmiştir. Diğer yandan sınıflandırma modellerinde özellikle açık yüzeyler ile beşeri yüzeyler ve çıplak tarım alanları arasındaki yansıma örtüşmesinin bu sınıfların ayırt edilmesini güçleştirdiği görülmektedir.

Detection of land cover and land use (LCLU) based on detailed, current, and accurate information plays an important role in natural resource management and spatial planning processes. However, there are some limitations such as data processing and storage requirements that hinder monitoring of land use dynamics at the regional scale. GEE is an open-source, free cloud platform that enables processing of geographic data at the global scale. The aim of this research is to obtain the LCLU map of Izmir province using different machine learning algorithms on GEE and to compare the results of the classification algorithms used. Sentinel-2 multi-band satellite images with a spatial resolution of 10m for the year 2022 and various UA indices were used in the study. The broad-scale LCLU classes used in the study were determined as 'Agricultural Area', 'Forest Area', 'Human Surfaces', 'Open Surfaces' and 'Water Surfaces'. Classification and Regression Tree (CART), Support Vector Machine (SVM), and Random Forest (RF) machine learning algorithms were used in the study, and the Producer's Accuracy (PA), User's Accuracy (UA), Overall Accuracy (OA), and Kappa Coefficient of each classifier were calculated. As a result, the RF classification algorithm with a GD of 97.2% and a Kappa value of 95.7% had the highest classification accuracy. The SVM algorithm with a GD of 96.1% and a Kappa value of 94.9% was the second highest accuracy algorithm. The GD of the CART algorithm was calculated as 93.3% and the Kappa value was 91.4%. Therefore, it was found that the RF method produced better results than the CART and SVM methods. On the other hand, it is seen that the overlap of reflection between open surfaces and human surfaces and bare agricultural areas especially in classification models makes it difficult to distinguish these classes.

¹Bu çalışma İzmir Bakırçay Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından KBP.2022.006 nolu proje kapsamında desteklenmiştir.

²This work has been supported by İzmir Bakırçay University Scientific Research Projects Coordination Unit, under grant number KBP.2022.006.

Extended Abstract

Introduction

The significance of a planning process rooted in detailed, current, and accurate information pertaining to land cover and land use (LCLU) is steadily gaining importance (Smith & McDonald, 1998). Remote sensing (RS) and Geographic Information Systems (GIS) are regarded as key instruments for effectively monitoring the state of LCLU (Rogan & Chen 2004). The acquisition of high-resolution imagery through recent satellite missions has facilitated the implementation of advanced algorithms for land cover monitoring. There are different image classification approaches are employed (Tso & Mather 2009). The rapid advancement in the availability of high-resolution satellite imagery, facilitated by various space agencies, in conjunction with the progress in cloud storage and analysis systems, as well as the emergence of novel data analytics methods, has opened up new possibilities for creating land cover maps (Gómez et al., 2016).

There are certain limitations that hinder the monitoring of land use dynamics at a regional scale. Among these limitations, the intensive data processing and storage requirements are significant factors (Debella-Gilo & Gjertsen, 2021). These challenges can pose obstacles to the efficient analysis and monitoring of land use patterns over a wide area. Google Earth Engine (GEE) is experiencing increasing usage in various applications due to its numerous features and its ability to process high-dimensional datasets (Tamiminia et al., 2020). GEE offers a powerful platform for analyzing and visualizing geospatial data, making it suitable for a wide range of applications (Gorelick et al., 2017). The GEE platform provides the capability to employ different machine learning algorithms, including Decision Trees (DT), Classification And Regression Trees (CART), Support Vector Machines (SVM), and Random Forest (RF). These algorithms offer robust methodologies for analyzing geospatial data within the GEE framework. They can be effectively applied for tasks such as land cover classification, regression analysis, and predictive modeling (Loukika et al., 2021, Mahdianpari et al., 2019; Saah et al., 2019;).

The aim of this research is to obtain the LCLU map of İzmir province using different machine learning algorithms on the GEE platform, and to compare the results of the classification algorithms used. The research utilizes multi-band satellite imagery acquired from the Sentinel-2 satellite and various remote sensing indices within the GEE environment. By employing these data sources and algorithms, the study seeks to generate a detailed LCLU map of İzmir province and evaluate the performance of different classification algorithms in the context of the study area.

Data and Method

The study area of the research is the province of Izmir, which is approximately 12,000 km² and located between the latitudes of 37° 45' N and 39° 15' N and longitudes of 26° 15' E and 28° 20' E. In the study, atmospherically and geometrically corrected Sentinel-2 Level-2A images were used. Images with a maximum cloud cover of 5% between 01-30 July 2022 were preferred. 44 images were identified with the specified pro-

perties. Median filter was applied to the obtained images. The image classes were defined as 'Agricultural Area', 'Forest Area', 'Built-up Surfaces', 'Bare Surfaces', and 'Water Bodies'. The LCLU classes consisted of a total of 1200 pixels, ensuring that each class had at least 50 training samples. The training dataset was constructed by using 70% of the generated samples, while the remaining 30% was reserved for accuracy. High-resolution GEE images were employed in the creation of both the training and test datasets. The same training and validation datasets were used across all classification algorithms. Furthermore, spectral indices were computed as auxiliary data to improve the classification accuracy.

SVM is a supervised learning algorithm based on machine learning theory and widely used in the GEE platform. In this study, the C-SVC linear kernel SVM model was implemented using the "libsvm" method within the GEE platform. CART is a decision tree algorithm that is commonly preferred for solving various problems in domains such as RS applications, healthcare, engineering, and agriculture. The LCLU classification was performed based on the CART algorithm using the "smileCart" technique available in the GEE library. Another widely used method for LCLU classification is the RF algorithm. LCLU classification process was carried out using the "smileRandomForest" technique available in the GEE platform.

Results and Discussion

The size, nature, and distribution of the dataset, selected parameters, kernel functions, and the quality of the training and test datasets are directly associated with classification accuracy (Ibrahim, 2023, Li et al., 2019;). RF classification algorithm has the highest classification accuracy with an overall accuracy of 97.2% and a Kappa coefficient of 95.7%. The SVM algorithm has the second highest classification accuracy with an overall accuracy of 96.1% and Kappa coefficient of 94.9%. It is observed that the Agricultural Area class is particularly confused with other classes. The RF algorithm misclassifies Agricultural Areas as Bare Surfaces and Forest Areas, while the CART algorithm additionally classifies them as Water Surfaces. Therefore, for the Agricultural Area class, the RF algorithm achieves a producer's accuracy of 94.8% and a user's accuracy of 97.3%, while the SVM algorithm achieves a producer's accuracy of 98.8% and a user's accuracy of 96.6%.

The SVM algorithm exhibited better performance in distinguishing forest areas. However, the RF algorithm misclassified some Forest Areas as Agricultural Area. Similarly, the CART algorithm showed low performance in differentiating between Forest and Agricultural Areas, achieving a producer accuracy of 96.8% and a user accuracy of 95.3%. In the classification of Built-up Surfaces, the RF algorithm demonstrated more successful results. It achieved a producer accuracy of 98.3% and a user accuracy of 100% in distinguishing Built-up Surfaces. On the other hand, both the SVM and CART algorithms struggled with the classification of Built-up Surfaces, particularly in confusing bare surfaces and agricultural areas. Moreover, when differentiating between Built-up Surfaces, Agricultural Areas, and Bare Surfaces, the RF algorithm performed better compared to the other algorithms. Regarding the identification of water surfaces, the RF algorithm consistently provided superior

results, while the SVM and CART algorithms occasionally failed to distinguish them from Forest and Agricultural Areas.

The research has produced outputs that will serve as a fundamental basis for local, regional, and national planning, providing data for socio-economic and physical planning purposes. Within this scope, it is anticipated that the research's high level of generalizability will contribute significantly to decision-makers involved in spatial strategic planning and environmental management plans. This research's distinctive feature is its potential contribution to diverse objectives such as environmental monitoring, natural resource management, assessment of ecosystem services, and adaptation to climate change.

1. Giriş

İklim değişikliği ve yanlış arazi kullanımı faaliyetleri sonucunda toprak ve su kaynaklarının sürdürülebilirliğinin sağlanması güçleşmektedir (Howden vd., 2007). Bu bağlamda arazi kullanımının izlenmesi doğal kaynak yönetimi ve mekânsal planlama çalışmalarında önemli rol oynamaktadır. Arazi örtüsü ve arazi kullanımı (AÖAK) hakkında ayrıntılı, güncel ve doğru bilgilere dayanan bir planlama sürecinin önemi gün geçtikçe artmaktadır (Smith & McDonald, 1998). Böyle bir planlama sürecinde en önemli girdilerden biri AÖAK durumunda meydana gelen değişimin takip edilmesidir. Bu değişim biyofiziksel koşulların yanı sıra sosyo-ekonomik ve demografik değişikliklerin etkileşiminden kaynaklanmaktadır (Hurni vd., 2005; Tağıl, 2015). Bu çok yönlü faktörler arasındaki karmaşık etkileşimler AÖAK değişikliklerine ve bununla birlikte doğal süreçlerin işlevlerinde sorunlara yol açmaktadır. Öyle ki son birkaç on yılda insan faaliyetlerinin neden olduğu AÖAK değişiklikleri, gezegenimizin doğal sistemlerini etkileyen boyuta ulaşmıştır (Song vd., 2018). Verimli tarım arazilerinin kaybı, orman alanlarının degradasyonu, doğal yaşam habitatlarının yok edilmesi, hidrolojik sistemlerin bozunumu, sulak alanların tahribi ve düzensiz kalkınma uygulamaları gibi sorunların üstesinden gelmek için AÖAK takibi ve değişikliklerinin izlenmesi gerekmektedir (Meyer & Turner, 1992). Diğer yandan peyzaj dinamiklerinin anlaşılmasında ve sürdürülebilir yönetiminin karar verme süreçlerinde arazi kullanımı hakkında bilgi sahibi olmak gerekmektedir (Jamal & Ahmad, 2020).

AÖAK durumunun verimli bir şekilde izlenmesi için kullanılan araçların başında uzaktan algılama (UA) ve Coğrafi Bilgi Sistemleri (CBS) gelmektedir (Rogan & Chen 2004). UA, AÖAK özellikleri de dâhil olmak üzere CBS analizleri için kritik olan çeşitli tematik veriler için ana kaynaklardan biridir. Son yıllarda uzaktan algılama teknolojileri doğal ve beşeri bileşenlerin haritalanması, değerlendirilmesi ve izlenmesi gibi sürdürülebilir kaynak yönetimi süreçlerinde önemli bir araç olarak kullanılmaktadır (Pettorelli vd., 2014). Farklı görüntü sensörleri tarafından algılanan görüntülerin kullanılabilirliği ve bunların çözünürlüğü gibi konulardaki son gelişmeler ile farklı ölçeklerde UA görüntülerinin kullanımı gün geçtikçe yaygınlaşmaktadır.

Farklı arazi örtüsü özellikleri elektromanyetik radyasyonu farklı şekillerde yansıttığından, UA görüntüleri yeryüzündeki arazi örtüsünün temsili niteliğindedir (Aplin, 2003). Yeni uydu görevleri ile elde edilen ideal çözünürlükteki görüntüler, AÖAK izlenmesine izin veren gelişmiş algoritmaların uygulanmasına izin ver-

mektedir. Böylece UA görüntülerinden anlamsal kategorilerle etiketlenmiş tematik haritalar elde edilmektedir. Bu amaçla çeşitli görüntü sınıflandırma yaklaşımları kullanılmaktadır (Tso & Mather 2009). Her bir pikselin anlamlı bir sınıfla etiketlenmesini amaçlayan piksel tabanlı yöntemler günümüzde hala çok bantlı UA görüntülerinin analizinde aktif olarak kullanılmaktadır. Diğer yandan UA görüntülerinin iyileşen mekânsal çözünürlükleri ile ilgi duyulan nesne tabanlı yöntemler ise sınıflandırmayı piksel düzeyinde değil nesne düzeyinde analiz etmeye yönelik yaklaşımı temel almaktadır (Blaschke, 2010). Piksel görüntü sınıflandırma yaklaşımları, kontrollü ve kontrolsüz sınıflandırma şeklinde iki temel başlıkta ele alınmaktadır. Kontrolsüz sınıflandırma yöntemlerinde spektral olarak ayrılabilen kümeler algoritma tarafından otomatik olarak belirlenmektedir. Buna karşılık kontrollü sınıflandırma yöntemlerinde sınıfları tanımlayan eğitim verileri ile spektral ayırt edilebilirlik incelenmektedir (Danacıoğlu, 2019).

Çeşitli uzay ajansları tarafından sağlanan yüksek çözünürlüklü uydu görüntülerinin kullanılabilirliğinin hızla artması, bulut depolama ve analiz sistemlerinin gelişmesi ile veri analitiği yöntemlerindeki yeni yaklaşımlar, arazi örtüsü haritaları oluşturmak için yeni olanaklar açmaktadır (Gómez vd., 2016). Ancak, bölgesel ölçekte arazi kullanım dinamiklerinin izlenmesini engelleyen bazı sınırlılıklar vardır. Bunların başında, yoğun veri işleme süreci ve depolama gereksinimi gösterilmektedir (Debella-Gilo & Gjertsen, 2021). Büyük miktardaki coğrafi verinin işlenmesi sürecindeki bu sınırlılıkları ortadan kaldırmaya yönelik son yıllarda Amazon, Microsoft, Google gibi firmalar tarafından Amazon Web Services (AWS), Azure ve Google Earth Engine (GEE) gibi önemli girişimler gerçekleştirilmektedir. GEE, küresel ölçekte coğrafi verilerin işlenmesine olanak tanıyan açık kaynak kodlu, ücretsiz bir bulut platformdur (Gorelick vd., 2017). GEE, Landsat, MODIS, NOAA AVHRR, Sentinel gibi çeşitli coğrafi veri kaynaklarına ait, petabayt ölçeklerindeki uydu görüntülerinin, yüksek performanslı ve hızlı bir şekilde analizine olanak tanımaktadır. GEE'nin bir diğer özelliği, web tabanlı bir tümleşik geliştirme ortamı (IDE) aracılığıyla erişilebilen JavaScript API ile karmaşık komut dosyalarının yazılmasını, geliştirilmesini ve çalıştırılmasını sağlamasıdır (Kumar ve Mutanga, 2018). GEE, sağladığı diğer birçok özelliği ve yüksek boyuttaki verileri işleme yeteneği ile çeşitli uygulamalarda kullanımı gün geçtikçe artmaktadır (Tamiminia vd., 2020). AÖAK tespiti (Saah vd., 2019), kuraklık (Rembold vd., 2019), yüzey sularının incelenmesi (Acar vd., 2021), sulak alanların haritalanması (Mahdianpari vd., 2019), bitki örtüsü sınıflandırma (Chen vd., 2017), orman yangınları (Yılmaz vd., 2021) ve tarımsal rekolte tahmini (Chen vd., 2019) gibi çeşitli uygulama alanlarında GEE platformu kullanılmaktadır.

GEE, coğrafi büyük veri analizleri için güçlü bir platform sunsa da, bazı sınırlamaları bulunmaktadır. Bu platform, ücretsiz uydu görüntüleri, hesaplama yetenekleri ve kullanıcı dostu araçlar gibi avantajlar sunmaktadır. Bununla birlikte nesne tabanlı görüntü analizi ve kümeleme gibi analiz yöntemlerinde sınırlı sayıda algoritma bulunmaktadır. Özellikle gelişmiş segmentasyon ve kümeleme algoritmalarının eksikliği, bazı analizlerde doğruluk ve hassasiyet sorunlarına neden olabilecektir (Tamiminia vd., 2020). Ayrıca, GEE hesaplama sınırlamalarına sahiptir ve zaman sınırlamaları uzun süre çalışan işlemler için önemli bir faktördür. GEE'de hesaplama işlemleri kullanıcı tarafından yö-

netilemeyen bir iç hizmet tarafından yürütülmektedir ve bu durum kullanıcıların işlemler üzerinde tam kontrole sahip olmasını engellemektedir. GEE, verileri Google Drive, Google Cloud ve GEE kapsamında kaydetmeye olanak tanımaktadır ve bu seçeneklerin sınırlı kapasitesi, bazı büyük veri işleme işlemleri için bellek ve depolama sorunlarına neden olabilmektedir (Gorelick vd., 2017). Tüm bu sınırlamalara rağmen, GEE, çevresel analizler ve coğrafi büyük veri analizleri için güçlü bir araç olarak kullanılmaktadır.

Sahip olduğu yetenekleri ile GEE platformu AÖAK araştırmalarında sıkça tercih edilmektedir. GEE platformu üzerinde karar ağacı (KA), sınıflandırma ve regresyon ağacı (SRA), destek vektör makinesi (DVM), rastgele orman (RO) gibi farklı makine öğrenmesi algoritmaları kullanılabilir. Bunlar içerisinde en fazla tercih edilen yöntem RO algoritması olmakla birlikte, KA ve SRA sınıflandırıcılarının diğer algoritmalara göre daha yüksek doğrulukta sonuçlar verdiği görülmektedir. Loukika vd., (2021), GEE platformu üzerinde aynı alana ait Sentinel-2 ve Landsat 8 görüntülerini farklı makine öğrenmesi algoritmaları ile sınıflandırarak değerlendirmiştir. DVM, RO ve SRA algoritmalarının kullanıldığı çalışmada, Sentinel-2 görüntülerinde sırasıyla %93.8, %95.8 ve %86.4; Landsat 8 görüntülerinde ise %90.88, %94.85 ve %82.88 değerlerinde sınıflandırma doğruluğu elde edilmiştir. Bununla birlikte farklı indeksler sınıflandırma sürecine dâhil edilerek sınıflandırıcının doğruluğu artırılmaktadır. Nitekim Aghmand vd., (2021) farklı sensör görüntüleri ile farklı indeks sonuçlarından elde edilen görüntüleri kullanarak DVM sınıflandırıcısı ile AÖAK sınıflandırmasında, %96.62 doğruluğa ulaşmıştır.

Bu kapsamda araştırmanın amacı GEE üzerinde farklı makine öğrenmesi algoritmaları ile İzmir ili AÖAK haritasını elde etmek ve kullanılan sınıflandırma algoritmalarının sonuçlarını karşılaştırmaktır. Araştırmada Sentinel-2 uydusundan çekilen çok bantlı uydu görüntüleri ve çeşitli UA indeksleri kullanılmıştır. Çalışmada SRA, DVM ve RO makine öğrenmesi algoritmaları kullanılmış ve her bir sınıflandırıcı için Overall Accuracy ve Kappa Coefficient değerleri hesaplanarak elde edilen bulgular karşılaştırılarak değerlendirilmiştir. Buna göre araştırmada İzmir ilinde güncel AÖAK durumunun mekânsal dağılımı nasıldır? İzmir ilinde güncel AÖAK durumunun mekânsal dağılımını hangi makine öğrenmesi algoritması en yüksek doğrulukla sınıflandırmaktadır? Algoritmaların sınıflandırma başarıları farklı AÖAK sınıflarında nasıl bir değişim göstermektedir? sorularına cevap aranmıştır.

2. Materyal ve Yöntem

2.1. Çalışma Alanı

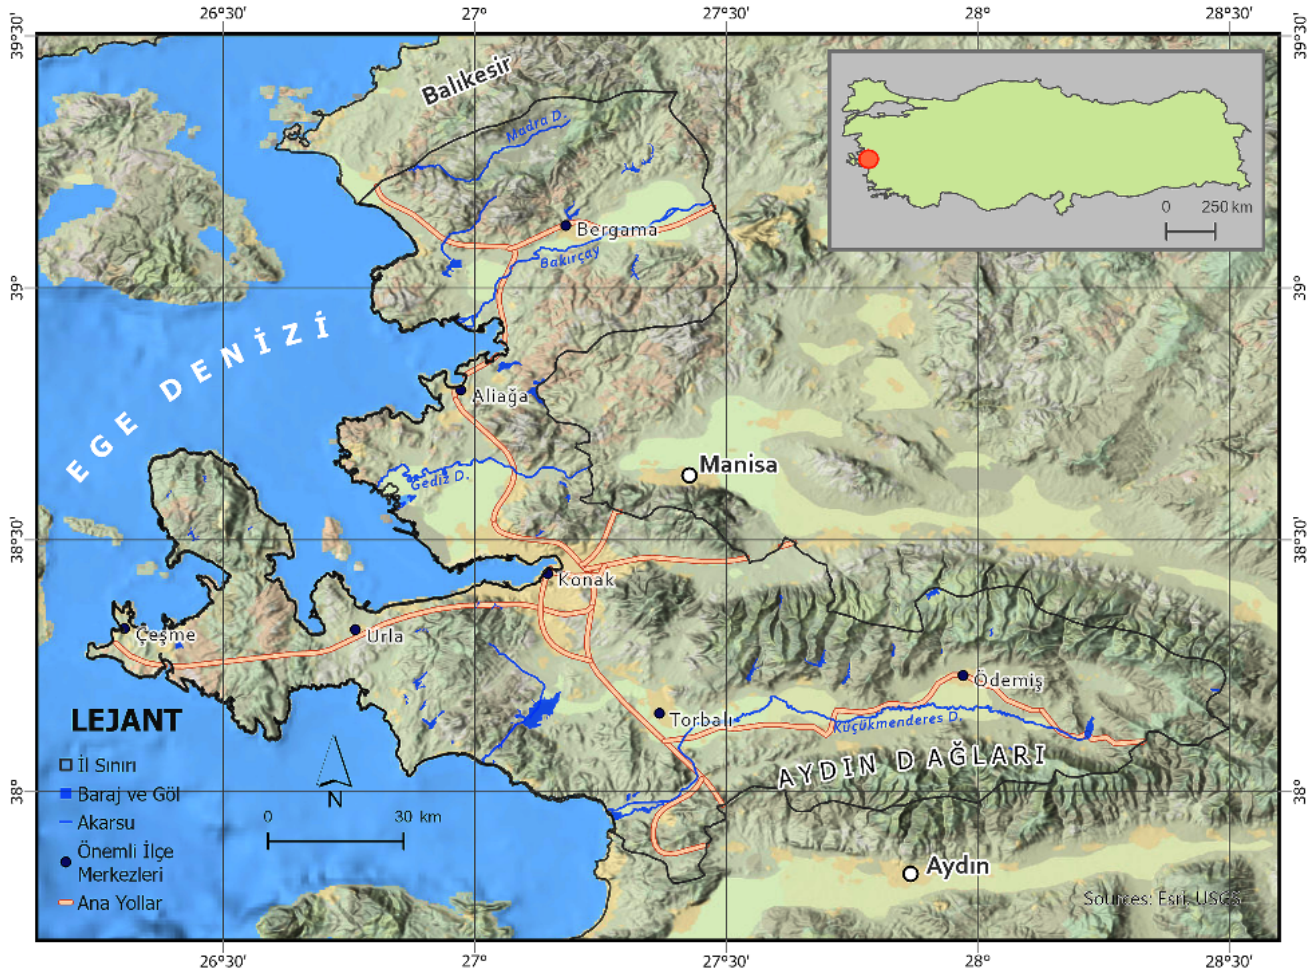
Araştırmanın çalışma alanı İzmir ili sınırlarını kapsamaktadır (Şekil 1). Ege bölgesinin kıyı bölgesinde, Asil Ege Bölümü sınırları içerisinde yer alan İzmir, kabaca kuzeyde Balıkesir, doğuda Manisa ve güneyde Aydın il sınırları ile çevrilmiştir. Kabaca 37° 45' K ve 39° 15' K enlemleri ile 26° 15' D ve 28° 20' D boylamları arasında yer alan il, yaklaşık 12.000 km² yüzölçümüne sahiptir. Çalışma alanı kış mevsiminde coğrafi konumuna bağlı olarak Batı rüzgârları sisteminin etki alanı içerisinde yer alırken; yaz mevsiminde ise bu sistemin kuzeye çekilmesi ile sıcak çekirdekli derin subtropikal yüksek basınç sisteminin etki alanı içindedir (Erinç, 1996). Ancak, yörede yeryüzü şekilleri ve bun-

ların uzanış doğrultuları yerel iklim koşullarının farklılaşmasına neden olmaktadır (Erlat, 2003). Buna göre çalışma alanı yaz mevsiminin sıcak ve kurak, kış mevsiminin ise ılık ve yağışlı olduğu tipik Akdeniz iklim özelliklerini taşımaktadır. Nitekim İzmir ili yıllık ortalama sıcaklığı 17.90C iken, yıllık ortalama yağış miktarı ise 713.8 mm'dir (MGM, 2022). İzmir'in floristik bakımından en önemli bölgesi Bozdağlar (2159 m) kütlesidir. Kuzeyinde Gediz ile güneyinde Küçük Menderes Ovaları arasında doğu-batı yönünde uzanış gösteren bu seri, birçok endemik bitkiyi barındırmaktadır. İzmir ili biyolojik çeşitlilik envanter ve izleme projesi kapsamında yapılan çalışmalar ve literatür değerlendirmelerine göre il genelinde 1938 taksonun yayılış gösterdiği; bunların 158 tanesinin endemik olduğu belirlenmiştir (İÇDR, 2022).

2021 yılı Adrese Dayalı Nüfus Kayıt Sistemi sonuçlarına göre, 30 ilçesi ve 4.425.789 nüfusu ile İzmir, Türkiye'nin nüfus açısından en kalabalık üçüncü şehridir (TÜİK, 2022). Bununla birlikte Tarım ve Orman Bakanlığı tarafından hazırlanan CORINE AÖAK Sınıflandırmasına göre %1,94'ü yapay alanlardan oluşmaktadır. (Tarım ve Orman Bakanlığı, 2022). Diğer alanların ise %42,26'sını tarım alanı, %50,31'ini orman ve yarı doğal alanlar, %0,51'ini sulak alan, %4,98'ini ise su yapıları olarak tespit edilmiştir. İzmir İl Tarım Müdürlüğü tarafından sağlanan verilere göre ise ilin topraklarının % 27,9'unu tarım alanları oluşturmaktadır (İÇDR, 2022).

2.2. Veri

Araştırma sahasında AÖAK özelliklerinin belirlenmesinde Sentinel-2 uydu görüntüleri kullanılmıştır. Sentinel optik görüntüleme uyduları, Avrupa Uzay Ajansı (ESA) tarafından Copernicus programı kapsamında uzaya gönderilen, her birinde iki uydunun yer aldığı toplamda yedi uydudan oluşan bir uydu filosudur. Sentinel-2 serisi, Haziran 2015 tarihinde fırlatılan Sentinel-2A ve Temmuz 2016 tarihinde fırlatılan Sentinel-2B uydularından oluşmaktadır. Birbirine 180° açıda bulunan ve aynı yörüngede bulunan iki uydu; 290 km şerit genişliği ve 5 günlük zamansal çözünürlüğü ile 56° güney-83° kuzey enlemler arasındaki kara ve kıyı alanları (20 km'e kadar) için görüntüleme yapmaktadır. Sentinel-2 uyduları 13 spektral bantta, 10 m, 20 m ve 60 m mekânsal çözünürlüğe ve 12.5m geometrik doğruluğa sahiptir (Wang, 2016). Araştırmada GEE tarafından atmosferik ve geometrik olarak düzeltilmiş şekilde kullanıma sunulan Sentinel-2 Level-2A görüntüleri kullanılmıştır. 2022 yılına ait 01 – 30 Temmuz aralığındaki, bulutluluğu en fazla %5 olan görüntüler tercih edilmiştir. Bulutluluğun sınıflandırma üzerindeki etkisini en aza indirmek için, farklı bulutluluk değerleri denenmiştir. Yeterli sayıda olduğu düşünülen görüntü sayısına ulaşıldığında, bulutluluk oranı %5 olarak filtrelenmiştir. Buna göre belirtilen özelliklerde 44 görüntü tespit edilmiştir. Elde edilen görüntülere, görüntü işlemede, özellikle orta ve yüksek çözünürlüklü görüntülerde sağladığı avantajlardan dolayı (Al-Amri vd., 2010) sıkça tercih edilen medyan filtresi kullanılmıştır. Böylece görüntü koleksiyonu içerisindeki her bir pikselin medyan değeri hesaplanarak tek bir görüntü oluşturulmuştur. Atmosfer altı yansıtım değerlerini içeren 2-A seviye görüntüleri, 13 farklı spektral banttan oluşan geniş bir spektral aralık sunmaktadır. Her bir bant, farklı dalga boylarında yansıma değerine sahip olması, geniş zamansal ve mekansal ölçekte olması ile çeşitli yüzey özelliklerini incelemek ve analiz etmek için kullanılmak-



Şekil 1. Araştırma alanının konum haritası.

Figure 1. Location map of the study area.

tadır (Varade vd., 2018). Buna göre indekslerin hesaplanmasında ve sınıflandırmada kullanılan Sentinel-2A görüntülerine ait özellikler Tablo 1'de verilmiştir.

2.3. Yöntem

Araştırma sahasında AÖAK sınıflandırmasını gerçekleştirmek için izlenen işlem adımları Şekil 2'de verilmiştir. Buna göre 2022 yılı Temmuz ayına ait görüntülerin sınıflandırılması amacıyla eğitim veri setleri oluşturulmuştur. Görüntü sınıfları 'Tarım Alanı', 'Orman Alanı', 'Beşeri Yüzeyle', 'Açık Yüzeyle' ve 'Su Yüzeyle' şeklinde belirlenmiştir. Bu kapsamda beş farklı AÖAK sınıfı için, her biri 50 eğitim örneğinden az olmamak kaydıyla, sınıflandırmada kullanılan bant sayısı dikkate alınarak belirlenen (Lillesand vd., 2018) alt limitin üzerinde eğitim seti oluşturulmuştur. Sınıfların alansal büyüklükleri ve GEE platformunun

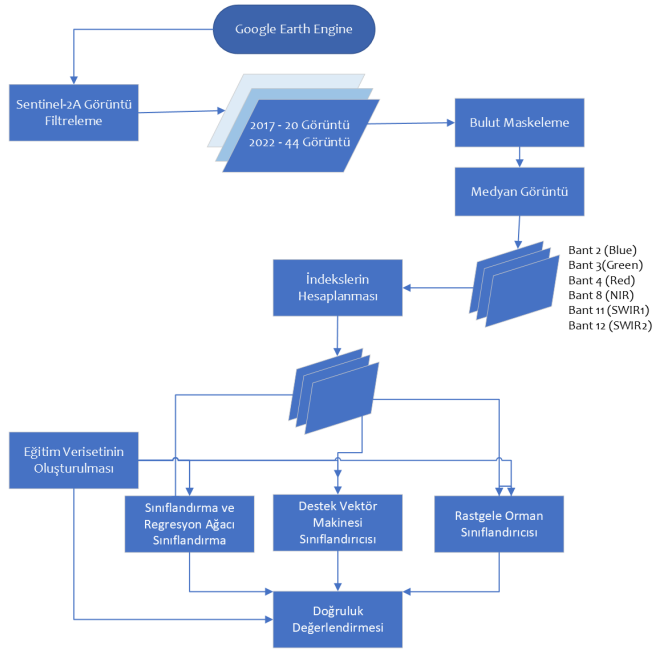
dosya limiti de dikkate alınarak hazırlanan eğim seti için toplamda 1200 pikselden oluşmaktadır. Oluşturulan eğitim setinin %70'i sınıflandırmada kullanılırken; %30'u test verisi olarak kullanılmıştır. Eğitim ve test veri setlerinin oluşturulmasında yüksek çözünürlüklü GEE görüntüleri kullanılmıştır. Tüm sınıflandırma algoritmalarında aynı eğitim ve doğrulama veri setleri kullanılmıştır. Ayrıca sınıflandırmada daha yüksek doğruluk elde etmek amacıyla ikincil veri olarak spektral indeksler hesaplanmıştır.

Spektral indeksler, UA görüntülerinden üretilen ölçümlerdir ve çevresel özelliklerin sınıflandırılmasında önemli rol oynamaktadır (Rogan & Chen, 2004). Bir özelliğin spektral yansıma değerlerinin diğer özelliklerle karşılaştırılması ile ortaya çıkan farklılıklar nesnelerin ayırt edilmesine katkı sağlamaktadır. Böylece ormanlar, tarım arazileri ve kentsel alanlar gibi farklı arazi

Tablo 1. Araştırmada kullanılan Sentinel-2A uydu görüntüsünün özellikleri.

Table 1. Sentinel-2 band information, which were used for LCLU classification.

Veri	Kaynak	Kullanılan Bantlar	Merkezi Dalga Boyu (nm)	Bant Genişliği (nm)	Mekânsal Çözünürlük (m)	Tarih Aralığı	Görüntü Sayısı
Sentinel-2A	Google Earth Engine	Bant 2 (Blue)	490	65	10	01- 30.7 2022	44
		Bant 3 (Green)	560	35	10		
	Bant 4 (Red)	665	30	10			
	Bant 8 (NIR)	842	115	10			
	USGS	Bant 11 (SWIR1)	1610	90	20		
		Bant 12 (SWIR2)	2190	180	20		



Şekil 2. Araştırmanın işlem adımları.

Figure 2. Methodology for LCLU classification on the GEE platform.

kullanım özelliklerini ayırt etmeye ya da belirli bitki türlerinin veya toprak türlerinin tanımlanmasına katkı sağlamaktadır (Diek vd., 2017; Waqar vd., 2012). Bu nedenle spektral indeksler, AÖAK özelliklerinin haritalanmasında, doğal kaynak yönetimi ve çevresel izleme gibi farklı uygulamalarda kullanılan etkili ve verimli bir araçtır (Huete vd., 2002). Bu kapsamda çalışmada AÖAK özelliklerinin belirlenmesinde çeşitli UA indeksleri kullanılmıştır. Literatür değerlendirmeleri sonucunda güncel ve örüntü tanımadaki yüksek doğruluk gösterdiği belirtilen indeksler tercih edilmiştir. Araştırmada kullanılan UA indeksleri Tablo2’de verilmiştir.

2.3.1. Destek vektör makinesi sınıflandırma yöntemi (DVM)

DVM, GEE platformunda kullanılan makine öğrenmesi teorisine dayalı kontrollü öğrenme algoritmasıdır. Karmaşık sınırları modelleyebilmesi, yüksek boyutlu az sayıda veri üzerinde çalışabilmesi ve geleneksel yöntemlere kıyasla daha başarılı sonuçlar üretebilmesi gibi avantajlara sahiptir (Mountrakis vd., 2011). DVM, farklı sınıflar arasındaki karar sınırını ayıran optimal bir hiperdüzlem bulmaya dayalı olarak çalışan, yaygın olarak kullanılan bir sınıflandırıcıdır (Hsu vd., 2003). Eğitim verilerini kernel fonksiyonu kullanarak daha yüksek boyuttaki bir özellik uzayına doğrusal olmayan şekilde yansıtan DVM modelleri, doğrusal, polinom, radyal tabanlı fonksiyon ve sigmoid kerneli olmak üzere dört temel gruba ayrılmaktadır (Çölkesen vd., 2015). Sınıflandırma yanlışlıklarını önlemek amacıyla DVM’de veri noktalarıyla karar sınırı arasındaki maksimum sınıra sahip bir hiperdüzlem hedeflenmektedir (Hsu vd., 2003). Buna en uygun hiperdüzlem ve sınır genişliğini sınırlandıran noktalara destek vektörleri adı verilmektedir. Bu durum, C faktörü adı verilen hata parametresine atanan değer ile kullanıcı tarafından kontrol edilmektedir. Bununla birlikte farklı DVM modelleri, farklı kernel fonksiyon parametrelerini kullanmaktadır. Ancak kernel fonksiyonları için hangi parametre değerlerinin en iyi sonucu vereceği net değildir (Pal & Mather, 2005). Bu parametreler veri setinin boyutundan etkilenebildiği gibi pratikte çapraz doğrulama işlemi ile elde edilmektedir (Hsu vd., 2003). Bu ça-

alışmada GEE platformu üzerinde “libsvm” yöntemi kullanılarak C-SVC doğrusal kernel DVM modeli uygulanmıştır. Modelde kernel fonksiyon parametresi olarak C maliyet değeri K-fold çapraz doğrulama işlemi (k=5) ile test edilerek “100” olarak belirlenmiştir.

2.3.2. Sınıflandırma ve regresyon ağacı sınıflandırma yöntemi (SRA)

SRA, UA uygulamaları yanı sıra sağlık, mühendislik, tarım gibi diğer birçok alanda çeşitli problemlerin çözümünde sıkça tercih edilen bir karar ağacı algoritmasıdır. SRA ile oluşturulan ağaç yapısında temel amaç “Eğerise” mantığıyla verinin doğru ve hızlı bir şekilde uygun sınıflara ayrılmasını sağlamaktır (Breiman vd., 1984). SRA algoritması, ikili dallanmalar ile her bir karar düğümünden itibaren ağacı iki alt dala ayırır ve karmaşık bir problemi daha basit alt problemlere dönüştürerek karar verme işlemini gerçekleştirmektedir. Karar düğümünde ağaçtaki dallanmanın hangi kriter veya değere göre olacağı konusunda çeşitli yaklaşımlar bulunmaktadır (Kavzoğlu vd., 2012). SRA algoritması bu bölünme işlemini gerçekleştirmek için Twoing kuralını kullanmaktadır (Breiman vd., 1984). Çalışmada SRA algoritmasına göre AÖAK sınıflandırması GEE kütüphanesinde yer alan “smileCart” tekniği ile gerçekleştirilmiştir.

2.3.3. Rastgele orman sınıflandırma yöntemi (RO)

AÖAK sınıflandırmalarında en yaygın kullanılan diğer bir yöntem RO algoritmasıdır. Torbalama tekniğini kullanan RO, her bir düğümde en iyi dalı kullanarak dallara ayırmak yerine, rastgele seçilen değişkenler arasından en iyisini kullanarak dallara ayırmaktadır (Breiman, 2001). RO algoritmasında her bir veri setini orijinal veri setinden yer değiştirmeli olarak üretilmektedir ve sonrasında rastgele seçilen özellikler ile ağaçlar geliştirilmektedir (Breiman, 2001; Pal, 2005). RO için ana giriş parametreleri geliştirilecek ağaç sayısı ve her bölünmedeki değişken sayısıdır. Kullanıcı tarafından ne kadar ağaç istenirse o kadar ağaçla çalışılmaktadır ancak çok fazla sayıda ağacın olması ile sınıflandırma doğruluğu arasında mutlak bir ilişki bulunmamaktadır (Pal, 2005). Yüksek sınıflandırma doğruluğu için en uygun ağaç sayısı olarak 100 veya 500; her bir düğümdeki bölünme için en uygun değişken sayısı olarak ise değişken sayısının karekökünün seçilmesi önerilmektedir (Belgiu & Dragut, 2016). Çalışmada GEE platformu üzerinde yer alan “smileRandomForest” tekniği ile AÖAK sınıflandırma işlemi gerçekleştirilmiştir. Geliştirilecek ağaç sayısı 100 olarak belirlenmiş ve her bir bölünmedeki değişken sayısı olarak önerilen yaklaşım dikkate alınarak, değişken sayısının karekökü tercih edilmiştir. Ağaç sayısı dışındaki tüm parametreler için uygulamanın varsayılan değerleri seçilmiştir (Belgiu & Dragut, 2016).

2.3.4. Sınıflandırma sonuçlarının doğruluk değerlendirilmesi

GEE platformunda sınıflandırma işlemleri sonrası doğrulukları analiz edilmiştir. Doğruluk analizi, sınıflandırılmış görüntü üzerindeki bir özelliğin, doğru olduğu kabul edilen bir referans veri ile uyumunu ölçmektedir (Campbell, 1996). Referans veri setinin büyüklüğünün ve örnekleme yönteminin belirlenmesine yönelik çeşitli yaklaşımlar bulunmaktadır (Congalton & Green, 2019). Yaygın görüş, eğitim veri setiyle çakışmayacak şekilde rastgele belirlenen noktalardan her bir sınıf için en az 50 noktanın kullanılması veya toplamda 250’den fazla referans nok-

Tablo 2. Araştırmada kullanılan UA indeksleri.**Table 2.** RS indices used in the study.

Spektral Sınıf	İndeks	Bantlar	Formül	Kaynak
Bitki Örtüsü ve Tarım	Simple Ratio (SR)	Red, NIR	(NIR / Red)	(Jordan, 1969)
	Normalize Edilmiş Bitki Örtüsü İndeksi (NDVI)	Red, NIR	$(NIR - Red) / (NIR + Red)$	(Rouse vd., 1973)
	Toprakla Düzeltilmiş Bitki Örtüsü İndeksi (SAVI)	Red, NIR	$((NIR - Red) / (NIR + RED + L)) * (1 + L) L=0.5$	(Huete, 1988)
	Geliştirilmiş Bitki Örtüsü İndeksi (EVI)	Blue, Red, NIR, SWIR1	$G*(NIR - Red) / (NIR + C1* Red - C2 * Blue + L)$ $G= (Gain Factor) =2.5,$ $C1=6, C2 =7.5, L=1$	(Huete vd., 2002)
	Normalize Edilmiş Nem İndeksi (NDMI)	NIR, SWIR1	$(NIR - SWIR1) / (NIR + SWIR1)$	(Wilson & Sader, 2002)
Açık Toprak Yüzeyleri	Toprak ve bitki örtüsü indeksi (SVI)	Blue, SWIR1	$(SWIR1 - Blue) / (SWIR1 + Blue)$	(Villa, 2012)
	Çıplak Toprak İndeksi (BSI)	Blue, Red, NIR, SWIR1	$(SWIR1 + Red) - (NIR + Blue) / (SWIR1 + Red) + (NIR + Blue)$	(Rikimaru vd., 2002)
	Çıplak Toprak İndeksi2 (BSI2)	Blue, Red, NIR, SWIR2	$(SWIR2 + Red) - (NIR + Blue) / (SWIR2 + Red) + (NIR + Blue)$	(Diek vd., 2017)
	Normalize Edilmiş Toprak İndeksi (NDSI)	SWIR2, Green	$(SWIR2 - Green) / (SWIR2 + Green)$	(Deng vd., 2015)
	Kurak Açık Toprak İndeksi (DBSI)	Green, Red, NIR, SWIR1	$((SWIR1 - Green) / (SWIR1 + Green)) - (NDVI)$	(Rasul vd., 2018)
	Modifiye Edilmiş Açık Yüzey İndeksi (MBI)	NIR, SWIR1, SWIR2	$((SWIR1 - SWIR2 - NIR) / (SWIR1 + SWIR2 + NIR)) + 0.5$	(Nguyen vd., 2021)
	Beşeri Yüzeyler	Normalize Edilmiş Yerleşik Alan İndeksi (NBAI)	Green, SWIR1, SWIR2	$((SWIR2 - SWIR1) / Green) / ((SWIR2 + SWIR1) / Green)$
Normalize Edilmiş Yerleşim Alan Fark İndeksi (NDBI)		NIR, SWIR1	$(SWIR1 - NIR) / (SWIR1 + NIR)$	(Zha vd., 2003)
Bitki Örtüsü ve Yerleşik Alan İndeksi (VIBI)		Red, NIR, SWIR1	$NDVI / (NDVI + NDBI)$	(Stathakis vd., 2012)
Yerleşik Alan İndeksi (BUI)		Red, NIR, SWIR1	$NDBI - NDVI$	(He vd., 2010)
Yerleşim alanları için bant oranı (BRBA)		Red, SWIR1	$(Red - SWIR1)$	(Waqar vd., 2012)
Kentsel İndeks (UI)		NIR, Green, SWIR1	$((SWIR2 - NIR) / (SWIR2 + NIR))$	(Kawamura, vd. 1997)
Su Yüzeyleri		Düzenlenmiş Normalize Su İndeksi (MNDWI)	Green, SWIR1	$(Green - SWIR1) / (Green + SWIR1)$
	Normalize Edilmiş Su İndeksi (NDWI)	Green, NIR	$(Green - NIR) / (Green + NIR)$	(McFeeters, 1996)
	Su yüzeyleri oranı indeksi (WRI)	Green, Red, NIR, SWIR1	$(Green + Red) / (NIR + SWIR1)$	(Shen & Li, 2010)

tasının olması şeklindedir (Hay, 1979; Congalton & Green, 2019). Bu kapsamda oluşturulan eğitim setine ait piksellerin %30'u sınıflandırma doğruluğunun test edilmesi amacıyla kullanılmıştır. Çalışmada görüntülerin sınıflandırma sonrasında doğruluklarının analizi için her bir sınıflandırıcının Genel Doğruluk (GD) değerleri hesaplanmıştır. GD, sonuçların kolay yorumlanmasına yardımcı olan en yaygın kullanılan metriktir (Plourde & Congalton, 2003). Ek olarak, sınıflandırıcının performansını daha detaylı değerlendirmek amacıyla Hata Matrisi, Kullanıcı Doğruluğu (KD), Üretici Doğruluğu (ÜD) ve Kappa değerleri GEE platformu kullanılarak hesaplanmıştır. Burada genel doğruluk, sınıflandırma sonuçlarındaki toplam doğru sınıflandırma sayısının, toplam sınıflandırma sayısına bölünmesiyle hesaplanmaktadır. Bu ölçüm, sınıflandırma modelinin genel performansını göstermektedir (Congalton & Green, 2019). Kullanıcı doğruluğu, modelin belirli bir sınıfı doğru bir şekilde tanımlama yeteneğini değerlendirmekte ve bu sınıfın gerçek varlık durumlarına ne kadar uygun olduğunu ölçerken; üretici doğruluğu ise belirli bir sınıfın gerçek durumlarına göre doğru bir şekilde tanımlandığı durumların, toplam olarak bu sınıfın sınıflandırılma sayısına oranını ifade etmektedir (Danacıoğlu, 2019). Kappa katsayısı ise, sınıflandırma modelinin ne kadar iyi olduğunu, rastgele tahminlere göre ne kadar başarılı olduğunu ve rastgelelik etkisini gösteren istatistiksel bir ölçüdür (Kayode vd., 2020).

3. Bulgular ve Tartışma

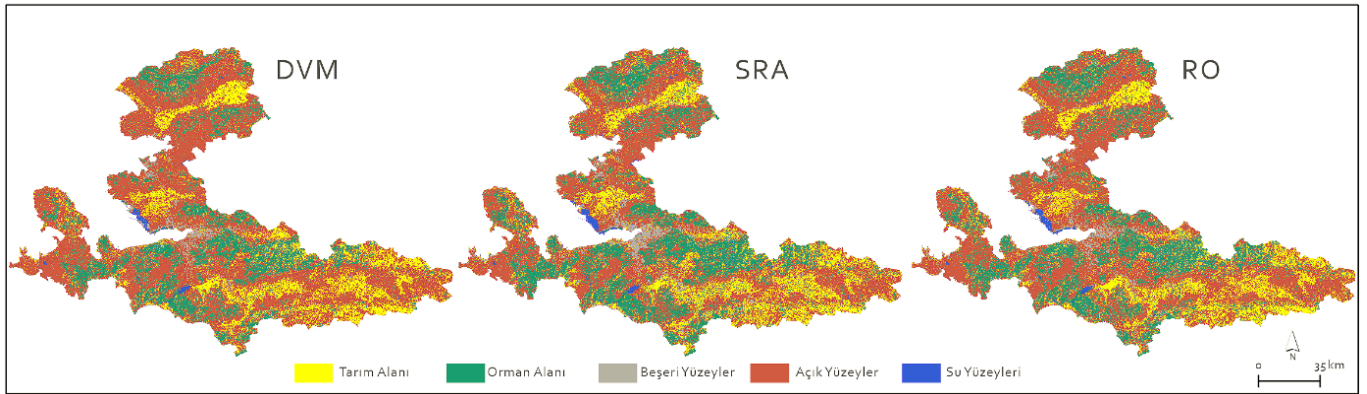
Çalışmada İzmir ili ölçeğinde Sentinel-2A çok bantlı uydu görüntülerini ve bunlardan elde edilen çeşitli UA indekslerini kullanarak çeşitli makine öğrenmesi tekniklerinin 10m mekânsal çözünürlükteki AÖAK özelliklerinin haritalanmasındaki doğruluk performansları incelenmiştir. Bu kapsamda 2022 yılı Temmuz ayına ait Sentinel-2A görüntülerinden en fazla %5 bulutluluk oranına sahip, ortorektifiye edilmiş görüntülerden Tablo 1'de belirtilen UA indeksleri hesaplanmıştır. Buna göre indeks sonuç bantları Blue, Green, Red, NIR, SWIR1 ve SWIR2 görüntü bantları ile birleştirilmiştir. Sonuç olarak elde edilen kompozit görüntü AÖAK özelliklerinin sınıflandırılmasında kullanılmıştır. Görüntü bantlarına ait temel istatistikler ve korelasyon değerleri Tablo 3'de verilmiştir.

DVM, SRA ve RO makine öğrenmesi algoritmaları ile kompozit görüntü sınıflandırılmıştır (Şekil 3). Elde edilen sınıflandırma sonuçları, GEE üzerine değerlendirilerek genel, kullanıcı ve üretici doğruluğu ile kappa katsayıları hesaplanmıştır (Tablo 5). Bu üç doğruluk değerinin hesaplanması ve sunulması, üretilen haritanın güvenilirliği bakımından önemlidir (Danacıoğlu, 2019). Diğer yandan doğruluk ölçütlerinin gerektiği gibi hesaplanabilmesi ve sınıflar arasındaki karışıklığın anlaşılabilmesi için hata matrisinin hazırlanması ve sunulması önemlidir (Congalton & Green, 2019). Bu bağlamda sınıflandırma sonuçlarına ait hata matrisi Tablo 4'de verilmiştir.

Tablo 3. Bant istatistikleri ve korelasyon değerleri.**Table 3.** Band statistics and correlation values.

B3	1,00																										
B4	0,98	1,00																									
B5	0,94	0,96	1,00																								
B8	0,24	0,31	0,22	1,00																							
B11	0,70	0,74	0,83	0,34	1,00																						
B12	0,79	0,81	0,89	0,23	0,96	1,00																					
SR	-0,61	-0,60	-0,71	0,48	-0,54	-0,65	1,00																				
NDVI	-0,72	-0,70	-0,80	0,38	-0,59	-0,70	0,95	1,00																			
SAVI	-0,65	-0,63	-0,73	0,50	-0,50	-0,63	0,97	0,99	1,00																		
EVI	-0,32	-0,31	-0,36	0,26	-0,26	-0,32	0,50	0,50	0,51	1,00																	
NDMI	-0,49	-0,47	-0,61	0,42	-0,70	-0,74	0,87	0,85	0,85	0,44	1,00																
SVI	-0,41	-0,36	-0,23	0,23	0,30	0,13	0,26	0,35	0,37	0,17	-0,13	1,00															
BSI	0,52	0,52	0,68	-0,37	0,73	0,77	-0,91	-0,88	-0,87	-0,45	-0,98	0,11	1,00														
BSI2	0,59	0,59	0,73	-0,37	0,71	0,79	-0,94	-0,93	-0,92	-0,48	-0,97	-0,01	0,99	1,00													
NDSI	-0,05	-0,04	0,12	-0,01	0,58	0,52	-0,20	-0,13	-0,12	-0,08	-0,58	0,81	0,54	0,47	1,00												
DBSI	0,53	0,53	0,69	-0,31	0,77	0,80	-0,87	-0,86	-0,84	-0,44	-0,98	0,16	0,99	0,97	0,59	1,00											
MBI	0,37	0,36	0,52	-0,43	0,67	0,66	-0,81	-0,75	-0,76	-0,40	-0,97	0,26	0,95	0,90	0,62	0,95	1,00										
NBAI	0,64	0,62	0,65	-0,30	0,42	0,64	-0,76	-0,82	-0,80	-0,40	-0,63	0,65	0,76	0,13	0,63	0,45	1,00										
NDBI	0,49	0,47	0,61	-0,42	0,70	0,74	-0,87	-0,85	-0,85	-0,44	-1,00	0,13	0,98	0,97	0,58	0,98	0,97	1,00									
VIBI	-0,06	-0,06	-0,07	0,04	-0,08	-0,08	0,09	0,09	0,09	0,05	0,10	-0,01	-0,10	-0,10	-0,06	-0,10	-0,10	-0,07	1,00								
BUI	0,64	0,62	0,74	-0,41	0,66	0,75	-0,95	-0,97	-0,96	-0,49	-0,95	-0,15	0,96	0,98	0,34	0,95	0,88	0,76	0,95	-0,10	1,00						
BRBA	0,59	0,59	0,57	-0,17	0,09	0,23	-0,55	-0,65	-0,64	-0,31	-0,20	-0,79	0,29	0,39	-0,53	0,24	0,07	0,60	0,20	-0,03	0,47	1,00					
UI	-0,01	-0,01	-0,01	0,01	-0,01	-0,01	0,01	0,01	0,01	0,01	0,01	0,00	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,02	-0,01	1,00					
MNDWI	0,36	0,34	0,21	-0,14	-0,33	-0,17	-0,18	-0,28	-0,29	-0,13	0,23	-0,97	-0,19	-0,06	-0,87	-0,24	-0,35	0,37	-0,23	0,02	0,06	0,79	0,00	1,00			
NDWI	0,69	0,67	0,71	-0,46	0,42	0,57	-0,91	-0,96	-0,96	-0,48	-0,76	-0,53	0,77	0,83	-0,05	0,73	0,64	0,83	0,76	-0,08	0,91	0,71	-0,01	0,46	1,00		
WRI	0,68	0,67	0,67	-0,35	0,27	0,42	-0,77	-0,87	-0,85	-0,42	-0,51	-0,72	0,56	0,65	-0,32	0,51	0,38	0,77	0,51	-0,06	0,74	0,91	-0,01	0,69	0,93	1,00	

	MIN	MAX	MEAN	STD	MIN	MAX	MEAN	STD	
B3	0,05	2,18	0,16	0,05	BSI2	-0,51	0,57	-0,07	0,12
B4	0,06	2,05	0,20	0,05	NDSI	-0,77	0,83	0,16	0,08
B5	0,07	1,90	0,21	0,07	DBSI	-0,75	0,69	-0,02	0,15
B8	0,08	1,76	0,39	0,07	MBI	-0,25	0,49	0,19	0,06
B11	0,10	1,60	0,36	0,08	NBAI	-0,30	0,35	-0,13	0,04
B12	0,10	1,63	0,28	0,08	NDBI	-0,71	0,64	-0,05	0,12
SR	0,33	8,23	2,01	0,74	VIBI	-315	341	1,17	4,31
NDVI	-0,50	0,78	0,30	0,15	BUI	-1,24	0,73	-0,35	0,25
SAVI	-0,42	0,75	0,24	0,12	BRBA	0,16	8,20	0,59	0,14
EVI	-0,94	0,87	0,32	0,33	UI	0,00	1,00	1,00	0,01
NDMI	-0,64	0,71	0,05	0,12	MNDWI	-0,80	0,77	-0,29	0,08
SVI	-0,74	0,83	0,37	0,08	NDWI	-0,70	0,63	-0,33	0,11
BSI	-0,41	0,53	0,00	0,10	WRI	0,20	3,70	0,55	0,13

**Şekil 3.** 2022 Yılı İzmir ili AÖAK sınıflandırma sonuçları.**Figure 3.** LCLU classification results for Izmir province in 2022.**Tablo 4.** 2022 Hata Matrisleri TA: Tarım Alanı, OA: Orman Alanı, BY: Beşeri Yüzeyler, AY: Açık Yüzeyler, SY: Su Yüzeyleri, T: Toplam**Table 4.** 2022 Error Matrices for LCLU classes TA (Agricultural Area), OA (Forest Area), BY (Built-up Surface), AY (Bare Surface), SY (Water Surface), T (Total).

2022 DVM							2022 SRA							2022 RO						
	TA	OA	BY	AY	SY	T		TA	OA	BY	AY	SY	T		TA	OA	BY	AY	SY	T
TA	86	0	0	2	1	89	TA	82	2	2	4	1	91	TA	83	2	1	2	0	88
OA	1	63	0	0	1	65	OA	3	61	0	0	1	64	OA	3	61	0	0	1	65
BY	0	0	81	3	0	84	BY	0	0	80	4	0	84	BY	0	0	83	1	0	84
AY	0	0	6	92	0	98	AY	1	0	5	88	0	94	AY	1	0	3	93	0	99
SY	0	0	0	0	25	25	SY	1	0	0	1	25	27	SY	0	0	0	0	26	26
T	87	63	87	97	27	352	T	87	63	87	97	27	352	T	87	63	87	97	27	352

Tablo 5'de görüldüğü üzere genel doğruluk %97,2 ve Kappa değeri %95,7 olan RO sınıflandırma algoritması en yüksek sınıflandırma doğruluğuna sahiptir. %96,1 genel doğruluk ve %94,9 Kappa değeri ile DVM algoritması ikinci en yüksek sınıflandırma doğruluğuna sahip algoritma olmuştur. Sınıflandırma sonuçları incelendiğinde özellikle Tarım Alanı sınıfının diğer sınıflar ile karıştığı görülmektedir. RO algoritmasının Tarım Alanlarını Açık Yüzeyler ve Orman Alanları olarak yanlış sınıflandırdığı; SRA'nın ise ayrıca Su Yüzeyleri sınıfı olarak sınıflandırdığı tespit edilmiştir. Bu kapsamda Tarım Alanı sınıfında RO algoritmasının %94,8 üretici doğruluğu ile %97,3 kullanıcı doğruluğuna; DVM algo-

ritmasının ise %98,8 üretici doğruluğu ve %96,6 kullanıcı doğruluğu elde edilmiştir.

Orman Alanlarının ayırt edilmesinde DVM algoritması daha iyi performans göstermiştir. RO algoritması bazı orman alanlarını tarım alanı olarak yanlış sınıflandırmıştır. SRA algoritması da benzer şekilde orman alanları ile tarım alanlarını ayırt etmede %96,8 üretici doğruluğu ve %95,3 kullanıcı doğruluğu ile düşük performans göstermiştir. Beşeri yüzeylerin ayırt edilmesinde ise RO algoritmasının daha başarılı sonuç verdiği görülmüştür. %98,3 üretici doğruluğu ve %100 kullanıcı doğruluğu ile beşeri

Tablo 5. Her bir sınıflandırma için hesaplanan Doğruluk ve Kappa Katsayısı bilgileri.**Table 5.** Accuracy and Kappa Coefficient values calculated for each classification algorithm.

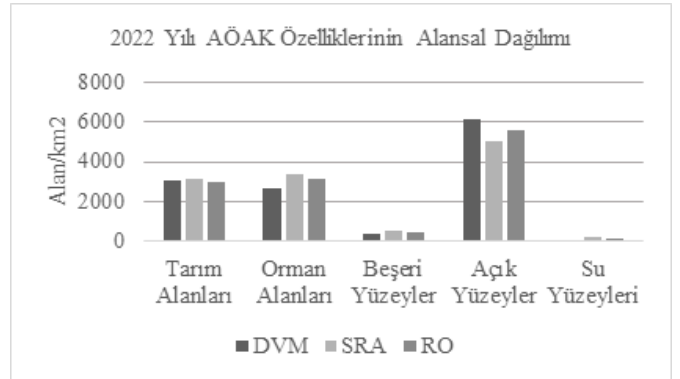
	2022 DVM		2022 SRA		2022 RO	
	Üretici Doğruluğu %	Kullanıcı Doğruluğu %	Üretici Doğruluğu %	Kullanıcı Doğruluğu %	Üretici Doğruluğu %	Kullanıcı Doğruluğu %
Tarım Alanı	98,8	96,6	94,2	90,1	94,8	97,3
Orman Alanı	100	96,9	96,8	95,3	97,5	95,2
Beşeri Yüzeyler	93,1	96,4	91,9	95,2	98,3	100
Açık Yüzeyler	94,8	93,8	90,7	93,6	98,6	96,0
Su Yüzeyleri	92,5	100	92,5	92,5	96,5	100
Genel Doğruluk %		96,1		93,3		97,2
Kappa Katsayısı %		94,9		91,4		95,7

yüzeylerin ayırt edilmesinde RO algoritması daha başarılı olmuştur. DVM ve SRA algoritmalarının beşeri yüzeyleri özellikle açık toprak yüzeyleri ve tarım alanları karıştırarak yanlış sınıflandırdığı görülmüştür. Beşeri yüzeyler ve tarım alanları ile açık toprak yüzeylerinin sınıflandırılmasında ise RO algoritması daha yüksek performans göstermiştir. Su yüzeylerinin ayırt edilmesinde de RO algoritmasının daha iyi sonuçlar verdiği; DVM ve SRA algoritmalarının bu alanları yer yer orman ve tarım alanlarından ayırt edemediği görülmüştür (Şekil 4).


Sınıflandırma sonuçlarının alansal durumu incelendiğinde, tüm makine öğrenmesi algoritmalarına göre İzmir ilinin büyük bir kısmı açık toprak yüzeylerinden meydana gelmektedir (Şekil 5). Bununla birlikte beşeri yüzeyler DVM, SRA ve RO algoritmalarına göre sırasıyla yaklaşık 379,1 km², 561,2 km² ve 487,0 km² olarak tespit edilmiştir. İl genelinde orman alanları DVM'ne göre 2667,3 km², SRA'na göre 3418,0 km² ve RO'na göre 3149,6 km² alanda yayılım göstermektedir. Tarım alanlarının il sınırları içerisindeki yayılımı ise DVM'ne göre 3044,0 km², SRA'na göre 3123,9 km² ve RO'na göre 2952,7 km² olarak belirlenmiştir.

4. Sonuç ve Değerlendirme

Araştırmada 2022 yılı Sentinel-2 çok bantlı uydu görüntüleri kullanılarak GEE platformunda SRA, DVM ve RO makine öğrenmesi algoritmalarının AÖAK haritalandırma performansları İzmir ili ölçeğinde analiz edilmiştir. Temel amaç, farklı sınıflandırma modellerinin performanslarını test etmek ve bölgesel ölçekte gerçekleştirilen AÖAK sınıflandırmalarında tahmin hata-

**Şekil 5.** Farklı makine öğrenmesi yöntemlerine göre İzmir ilinde AÖAK özelliklerinin alansal dağılımı.**Figure 5.** Spatial Distribution of LCLU Classes in İzmir Province According to Different Machine Learning Methods.

sını azaltmak için bir metodoloji geliştirmektir. Bu kapsamda literatürde yaygın olarak tercih edilen UA indisleri ile sınıflandırma doğruluğu artırılmaya çalışılmıştır. Her bir sınıflandırıcı için hesaplanan Genel Doğruluk ve Kappa Katsayısı değerlerine göre RO yöntemi SRA ve DVM yöntemlerine göre daha yüksek doğruluk değerine sahip olduğu görülmektedir. Diğer yandan sınıflandırma modellerinde özellikle açık yüzeyler ve beşeri yüzeyler ile çıplak tarım alanları arasındaki yansıma örtüşmesi bu sınıfların ayırt edilmesini güçleştirdiği görülmektedir. AÖAK sınıflarının fenolojik varyasyonlarını daha iyi yakalanmasının sınıflandırma doğruluğunun artırılmasına ve bu hataların düzeltilmesine katkı sağlayacağı düşünülmektedir. Ayrıca GEE

**Şekil 4.** Arazi örtüsü özelliklerinde farklı makine öğrenmesi algoritmaları tarafından verilen sonuçlar.**Figure 4.** Results of Different Machine Learning Algorithms for Land Cover Characteristics.

platformunda bulutlu pikselleri temizlemek için kullanılan yöntemler, bazen bulutlu pikselleri yanlışlıkla su veya kar; ya da tam tersi şekilde sınıflandırabilmektedir. Bu durumun AÖAK sınıflandırmasında hata kaynağı oluşturabileceği hususuna dikkat edilmelidir. Diğer yandan araştırma kapsamında çok sayıda bantın kullanılması ile GEE'nin bellek ve CPU limitleri göz önüne alınmalıdır. Bu durum yüksek çözünürlüklü verilerin işlenmesinde performans sorunlarına yol açabilmektedir (Shafizadeh-Moghadam vd., 2021).

Her algoritmanın kendi avantajları ve dezavantajları vardır. RO algoritması parametre değişikliklerinden daha az etkilenirken, SVM parametrelere daha duyarlıdır (Chang vd., 2019). Nitekim RO, farklı eğitim veri boyutlarında diğer makine öğrenmesi algoritmalarından daha iyi performans gösterirken, ardından sırasıyla DVM ve SRA algoritmaları gelmiştir. Literatürdeki bazı çalışmalar benzer şekilde DVM algoritmasının SRA algoritmasından daha iyi performans gösterdiğini iddia etmektedir (Shao & Lunetta, 2012). Bununla birlikte, bazı çalışmalar SRA algoritmasının DVM'den daha iyi performans gösterdiğini iddia etmektedir (Goldblatt vd., 2016). Veri setinin boyutu, niteliği, dağılımı; seçilen parametreler, çekirdek fonksiyonlar; eğitim ve test verisi setinin kalitesi gibi faktörler sınıflandırma doğruluğu ile doğrudan ilişkilidir (İbrahim, 2023; Li vd., 2019). Bu kapsamda en uygun yöntem en az duyarlı, en karmaşık ve en hızlı olan şekilde ifade edilmektedir (Congalton & Green, 2019).

GEE platformunun geniş çalışma alanlarında multispektral uydu görüntülerinin kullanımına olanak vermesiyle uygulanan mevcut yöntemler ve algoritmalar ile görüntü ön işleme görevlerinin performansı daha esnek hale gelmiştir (Gorelick vd., 2017; Tamiminia vd., 2020). Araştırmada bu sayede yerel, bölgesel ve ülkesel planlamalara temel oluşturacak, diğer sosyo-ekonomik ve fiziki planlamalara veri teşkil edecek çıktılar elde edilmiştir. Bu kapsamda araştırmanın genelleme düzeyi yüksek mekânsal strateji planları ve çevredüzeni planları için karar vericilere katkı sağlayacağı düşünülmektedir. Bu özelliği ile araştırma, çevresel izleme, doğal kaynak yönetimi, ekosistem hizmetlerini değerlendirme ve iklim değişikliğine uyum sağlama gibi farklı amaçlara katkı sağlayacaktır.

Çıkar Çatışması/Conflict of Interest: Yazar herhangi bir çıkar çatışması olmadığını beyan eder. *The author declare that there is no conflict of interest.*

Veri Erişebilirliği/Data availability: Araştırmanın sonuçları ve kaynak kodları bu adresteki GEE Web Uygulamasında paylaşılmıştır: <https://sevki.users.earthengine.app/view/izmirarazi>. *The results and source codes of the research were shared on the GEE Web Application at this URL: <https://sevki.users.earthengine.app/view/izmirarazi>.*

Kaynakça

Acar U., Yılmaz O. S., Çelen M., Ateş A. M., Gülgen F. & Balık Şanlı F. (2021). Determination of mucilage in the Sea of Marmara using remote sensing techniques with Google Earth Engine. *International Journal of Environment and Geoinformatics*, 8(4),423-434. <https://doi.org/10.30897/ije-geo.957284>

Aghlmand, M., Kalkan, K., Onur, M. İ., Öztürk, G. & Ulutak, E. (2021). Google Earth Engine ile arazi kullanımı haritalarının üretimi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(1), 38-47.

<https://doi.org/10.28948/ngumuh.795977>

Al-Amri S.S, Kalyankar N.V & Khamitkar S.D. (2010). A comparative study of removal noise from remote sensing image. *International Journal of Computer Science*, 7(1). <https://doi.org/10.48550/arXiv.1002.1148>

Aplin, P. (2003). Using remotely sensed data. In Clifford, N.J. & Valentine, G., (Eds.) *Key Methods In Geography*. Sage, 291–308.

Belgiu, M., & Dragut, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31.

Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>

Breiman, L., Friedman, J.H., Olshen, R.A., & Stone, C.J. (1984). *Classification and regression trees*, Wadsworth.

Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>

Campbell, J.B. (1996). *Introduction to remote sensing*. Second Edition. Virginia Polytechnic Institute and State University, The Guildford Pres.

Chang, K. T., Merghadi, A., Yunus, A. P., Pham, B. T., & Dou, J. (2019). Evaluating scale effects of topographic variables in landslide susceptibility models using GIS-based machine learning techniques. *Scientific Reports*, 9 (1), 1–21. <https://doi.org/10.1038/s41598-019-48773-2>

Chen, B., Xiao, X., Li, X., Pan, L., Doughty, R., Ma, J., Dong, J., Qin, Y., Zhao, B., Wu, Z., Sun, R., Lan, G., Xie, G., Clinton, N., & Giri, C. (2017). A mangrove forest map of China in 2015: Analysis of time series Landsat 7/8 and Sentinel-1A imagery in Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 104–120. <https://doi.org/10.1016/j.isprsjprs.2017.07.011>.

Chen, B., Jin, Y., & Brown, P. (2019). Automatic mapping of planting year for tree crops with Landsat satellite time series stacks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151, 176–188. <https://doi.org/10.1016/j.isprsjprs.2019.03.012>.

Congalton, R.G. & Green, K. (2019). *Assessing the accuracy of remotely sensed data: principles and practices*, (3rd ed.). CRC Press. <https://doi.org/10.1201/9780429052729>

Çölkesen, İ., Kavzoğlu, T., & Yomralıoğlu, T. (2015). *Uzaktan al-*

- gılanmış görüntülerde optimum bantların seçiminde destek vektör makinelerinin kullanımı. TUFUAB VIII. Teknik Sempozyumu, 21-23 Mayıs 2015, Konya.
- Danacıoğlu, Ş. (2019). Arazi kullanımı/arazi örtüsü ve uzaktan algılama. D.D. Yavaşlı ve M.K. Ölgen (Ed.), *Coğrafyada Uzaktan Algılama* içinde (s. 161-198). İstanbul: Kriter Yayınevi.
- Debella-Gilo M., & Gjertsen, A. K. (2021). Mapping seasonal agricultural land use types using deep learning on Sentinel-2 image time series. *Remote Sensing*, 13(2), 289. <https://doi.org/10.3390/rs13020289>
- Deng, Y., Wu, C., Li, M. & Chen, R. (2015). RNDSI: A ratio normalized difference soil index for remote sensing of urban/suburban environments, *International Journal of Applied Earth Observation and Geoinformation*, 39, 40-48. <https://doi.org/10.1016/j.jag.2015.02.010>.
- Diek, S., Fornallaz, F. Schaepman, M.E. & De Jong, R.. (2017). Barest pixel composite for agricultural areas using Landsat time series. *Remote Sensing*, 9(12), 1245. <https://doi.org/10.3390/rs9121245>
- Eriç, S., (1996). *Klimatoloji ve metotları*. İstanbul Üniversitesi Coğrafya Enstitüsü Yayınları No: 35.
- Erlat, E., (2003). *İzmir'in hava tipleri klimatolojisi*. Ege Üniversitesi Edebiyat Fakültesi Yayınları No:121.
- Goldblatt, R., You, W., Hanson, G., & Khandelwal, A.K. (2016). Detecting the boundaries of urban areas in India: A dataset for pixel- based image classification in Google Earth Engine. *Remote Sensing*, 8, 634. <https://doi.org/10.3390/rs8080634>
- Gómez, C., White, J.C., & Wulder, M.A. (2016). Optical remotely sensed time series data for land cover classification: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 116, 55–72. <https://doi.org/10.1016/j.isprsjprs.2016.03.008>
- Gorelick, N., Hancher, M.; Dixon, M.; Ilyushchenko, S.; Thau, D.; Moore, R. (2017). Google Earth Engine: Planetaryscale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hay, A.M. (1979). Sampling designs to test land use map accuracy. *Photogrammetric Engineering and Remote Sensing*, 45(4), 529-533.
- He, C., Shi, P., Xie, D. & Zhao, Y. (2010). Improving the normalized difference built-up index to map urban built-up areas using a semiautomatic segmentation approach. *Remote Sensing Letters*, 1, 213–221. <https://doi.org/10.1080/01431161.2010.481681>
- Howden, S.M., Soussana, J.-F., Tubiello, F.N., Chhetri, N., Dunlop, M., & Meinke, H. (2007). Adapting agriculture to climate change. *Proceedings of the National Academy of Sciences USA*, 104(50), 19691-19696. <https://doi.org/10.1073/pnas.0701890104>
- Hsu, C.W.; Chang, C.C. & Lin C.J. A. (2003). *A Practical guide to support vector classification*. University of National Taiwan, Department of Computer Science and Information Engineering., 1–12. <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>
- Huete, A.R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25, 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote sensing of environment*, 83(1-2), 195-213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Hurni, H., Tato, K., & Zeleke G. (2005). The implications of changes in population, land use, and land management for surface runoff in the upper Nile basin area of Ethiopia Mountain. *Research and Development*, 25 (2), 147-154. <https://doi.org/10.1659/0276-4741>
- Ibrahim, S. (2023). Improving land use/cover classification accuracy from random forest feature importance selection based on synergistic use of Sentinel data and digital elevation model in agriculturally dominated landscape. *Agriculture*, 13(1), 98. <https://doi.org/10.3390/agriculture13010098>
- İzmir Valiliği Çevre, Şehircilik ve İklim Değişikliği İl Müdürlüğü. (2022). İÇDR, İzmir ili 2021 yılı çevre durum raporu, <https://webdosya.csb.gov.tr/db/ced/icerikler/izmir-ilcdr-2021-20220811104124.pdf>
- Jamal, S. & Ahmad, W.S. (2020). Assessing land use land cover dynamics of wetland ecosystems using Landsat satellite data. *SN Applied Sciences*, 2, 1891. <https://doi.org/10.1007/s42452-020-03685-z>
- Jordan, C.F., (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50 (4), 663–666. <https://doi.org/10.2307/1936256>
- Kavzoğlu, T., Şahin, E.K., & Çölkesen, İ. (2012). Heyelan duyarlılığının incelenmesinde regresyon ağaçlarının kullanımı: Trabzon örneği, *Harita Dergisi*, 147, 21-33.
- Kayode A. Adepoju & Samuel A. A. (2020). Improving accuracy of Landsat-8 OLI classification using image composite and multisource data with Google Earth Engine, *Remote Sensing Letters*, 11(2), 107-116. <https://doi.org/10.1080/2150704X.2019.1690792>
- Kawamura, M., S. Jayamanna & Y. Tsujiko (1997). *Quantitative evaluation of urbanization in developing countries using satellite data*. Doboku Gakkai Ronbunshu. 580, 45–54.

- Li, Y., Li, C., Li, M. & Liu, Z. (2019). Influence of variable selection and forest type on forest aboveground biomass estimation using machine learning algorithms. *Forests*, 10, 1073. <https://doi.org/10.3390/f10121073>
- Lillesand, T.M., Kiefer, R.W. , & Chipman, J.W. (2018). *Uzaktan algılama ve görüntü yorumlama*. (K.Ş. Kavak, Çev.) Palme Yayınevi (Orijinal çalışma basım tarihi 2015).
- Loukika, K. N., Keesara, V. R., & Sridhar, V. (2021). Analysis of land use and land cover using machine learning algorithms on google earth engine for Munneru riverbasin, India. *Sustainability*, 13(24). <https://doi.org/10.3390/su13241375>
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, S., & Gill, E., (2019). The first wetland inventory map of newfoundland at a spatial resolution of 10 m using sentinel-1 and sentinel-2 data on the google earth engine cloud computing platform. *Remote Sensing*, 11, 43. <https://doi.org/10.3390/rs11010043>
- 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, 1425–1432. <https://doi.org/10.1080/01431169608948714>
- Meteoroloji Genel Müdürlüğü. (2022). *İllere ait mevsim normalleri (1991-2020)*. <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=IZMIR>
- Meyer, W. B. & Turner, B. L. (1992). Human population growth and global land-use/cover change. *Annual Review of Ecology and Systematics*, 23(1), 39–61. <https://doi.org/10.1146/annurev.es.23.110192.00035>
- Midekisa, A.; Holl, F.; Savory, D.J.; Andrade-Pacheco, R.; Gething, P.W.; Bennett, A. & Sturrock, H.J.W. (2017). Mapping land cover change over continental Africa using Landsat and Google Earth Engine cloud computing. *PLoS One*, 12, 1–15. <https://doi.org/10.1371/journal.pone.0184926>
- Mitran T., Meena R.S. & Chakraborty A. (2021). Geospatial technologies for crops and soils: an overview. In: Mitran T., Meena R.S., & Chakraborty A. (Eds.), *Geospatial Technologies For Crops And Soils*. Springer, Singapore. https://doi.org/10.1007/978-981-15-6864-0_1
- Mountrakis, G., Im, J., & Ogelo, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, 247-259. <http://dx.doi.org/10.1016/j.isprsjprs.2010.11.001>
- Mutanga, O., Dube, T. & Galal, O. (2017). Remote sensing of crop health for food security in Africa: Potentials and constraints, *Remote Sensing Applications: Society and Environment*, 8, 231-239. <https://doi.org/10.1016/j.rsase.2017.10.004>
- Nguyen C.T., Chidthaisong, A., Kieu Diem, P., & Huo, L-Z. (2021). A modified bare soil index to identify bare land features during agricultural fallow-period in Southeast Asia using Landsat 8. *Land*, 10(3):231. <https://doi.org/10.3390/land10030231>
- Pal M. (2005). Random forest classifier for remote sensing classification, *International Journal Of Remote Sensing*, 26(1), 217-222. <https://doi.org/10.1080/01431160412331269698>
- Pal, M., & Mather, P.M., (2005). Support vector machines for classification in remote sensing, *International Journal of Remote Sensing*, 26, 1007–1011. <https://doi.org/10.1080/01431160512331314083>
- Pettorelli, N., Laurance, W.F., O'Brien, T.G., Wegmann, M., Nagendra, H. & Turner, W. (2014). Satellite remote sensing for applied ecologists: opportunities and challenges. *Journal of Applied Ecology*, 51, 839-848. <https://doi.org/10.1111/1365-2664.12261>
- Plourde, L., & Congalton, R. G. (2003). Sampling method and sample placement: How do they affect the accuracy of remotely sensed maps. *Photogrammetric Engineering & Remote Sensing*, 69(3). https://www.asprs.org/wp-content/uploads/pers/2003journal/march/2003_mar_289-297.pdf
- Rembold, F., Meroni, M., Urbano, F., Csak, G., Kerdiles, H., Perez-Hoyos, A., Lemoine, G., Leo, O., & Negre, T. (2019). ASAP: A new global early warning system to detect anomaly hot spots of agricultural production for food security analysis. *Agricultural Systems*, 168, 247–257. <https://doi.org/10.1016/j.agsy.2018.07.002>
- Rogan, J. & Chen, D.M. (2004). Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in Planning*, 61, 301–325. [https://doi.org/10.1016/S0305-9006\(03\)00066-7](https://doi.org/10.1016/S0305-9006(03)00066-7)
- Rikimaru, A.; Roy, P.S. & Miyatake, S. (2002). Tropical forest cover density mapping. *Int Society for Tropical Ecology*, 43, 39-47. https://tropecol.org/pdf/open/PDF_43_1/43104.pdf
- Rasul A, Balzter H, Ibrahim GRF, Hameed HM, Wheeler J, Adamu B, Ibrahim S, & Najmaddin PM. (2018). Applying built-up and bare-soil indices from Landsat 8 to cities in dry climates. *Land*, 7(3):81. <https://doi.org/10.3390/land7030081>
- Rouse, J. W., R. H. Haas, D. W. Deering, & Schell, J. A. (1973). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation*, 44–47, College Station, TX: Remote Sensing Center, Texas A&M University.
- Saah, D., Johnson, G., Ashmall, B., Tondapu, G., Tenneson, K., Patterson, M., Poortinga, A., Markert, K., Quyen, N.H., & San Aung, K. (2019). Collect Earth: An online tool for systematic reference data collection in land cover and use applications. *Environmental Modelling & Software*, 118, 166–171. <https://doi.org/10.1016/j.envsoft.2019.05.004>

- Shafizadeh-Moghadam, H., Khazaei, M., Alavipanah, S. K., & Weng Q. (2021). Google Earth Engine for large-scale land use and land cover mapping: an object-based classification approach using spectral, textural and topographical factors, *GIScience & Remote Sensing*, 58(6), 914-928. <https://doi.org/10.1080/15481603.2021.1947623>
- Shao, Y. & Lunetta, R.S. (2012). Comparison of support vector machine, neural network, and cart algorithms for the land-cover classification using limited training data points. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70, 78–87. <https://doi.org/10.1016/j.isprsjprs.2012.04.001>.
- Shen, L., & Li, C. (2010). *Water body extraction from Landsat ETM+ imagery using adaboost algorithm*, 2010 18th International Conference on Geoinformatics, 2010. <https://doi.org/10.1109/GEOINFORMATICS.2010.5567762>
- Smith, C. & McDonald, G. (1998). Assessing the sustainability of agriculture at the planning stage. *Journal of Environmental Management*, 52, 15–37. <https://doi.org/10.1006/jema.1997.0162>
- Song, XP., Hansen, M.C., Stehman, S.V., Potapov, PV., Tyukavina, A. Vermote EF. & Townshend, JR. (2018). Global land change from 1982 to 2016. *Nature*, 560, 639–643. <https://doi.org/10.1038/s41586-018-0411-9>
- Stathakis, D., Perakis, K., & Savin, I. (2012). Efficient segmentation of urban areas by the VIBI. *International Journal of Remote Sensing*, 33(20):6361–6377. <https://doi.org/10.1080/01431161.2012.687842>
- Tağıl, Ş. (2015). Effect Of Topographic Habitat Characteristics On The Spatial Distribution Of Landuse Landcover In The Kapıdağ Peninsula Turkey. *Journal of Applied Science*, 15(6), 850–861. <https://doi.org/10.3923/jas.2015.850.861>
- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., & Brisco, B. (2020). Google Earth Engine for geobig data applications: A meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 152–170. <https://doi.org/10.1016/j.isprsjprs.2020.04.001>
- Tarım ve Orman Bakanlığı. (2022). *CORINE CBS*, <https://corinecbs.tarimorman.gov.tr>.
- Tso, B. & Mather P. (2009). *Classification methods for remotely sensed data*. CRC Press.
- TÜİK, Türkiye İstatistik Kurumu (2022). Adrese dayalı nüfus kayıt sistemi. <https://data.tuik.gov.tr/Bulten/Index?p=45500>
- Wang, Q., Shi, W.; Li, Z.; Atkinson, P.M. (2016). Fusion of sentinel-2 images. *Remote Sensing of Environment*, 187, 241–252, <https://doi.org/10.1016/j.rse.2016.10.030>.
- Waqar M.M., Mirza J.F., Mumtaz, R., & Hussain, E. (2012). *Development of new indices for extraction of built-up area & bare soil from Landsat data*. Open Access Scientific Reports 1: 136. <https://doi.org/10.4172/scientificreports.136>
- Villa, P. (2012). Mapping urban growth using soil and vegetation index and LANDSAT data: The Milan (Italy) city area case study, *Landscape and Urban Planning*, 107, 245-254. <https://doi.org/10.1016/j.landurbplan.2012.06.014>
- Xu, H. (2006). Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27, 3025–3033. <https://doi.org/10.1080/01431160600589179>
- Varade, D., Sure, A., & Dikshit, O., (2018). Potential of Landsat-8 and Sentinel-2A composite for land use land cover analysis. *Geocarto International*, 34(14),1552-1567. <https://doi.org/10.1080/10106049.2018.1497096>
- Yılmaz, O.S., Oruç, M.S., Ateş, A.M., & Gülgen, F. (2021). Orman yangın şiddetinin Google Earth Engine ve coğrafi bilgi sistemleri kullanarak analizi: Hatay-Belen örneği. *Journal of the Institute of Science and Technology*, 11(2), 1519-1532. <https://doi.org/10.21597/jist.817900>
- 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, 583–594. <https://doi.org/10.1080/01431160304987>