

SERA ALANLARININ BELİRLENMESİNDE GEE PLATFORMU KULLANILARAK SPEKTRAL İNDEKSLER İLE RO VE DVM ALGORİTMALARININ KARŞILAŞTIRILMASI

Ramazan GÜNGÖR¹, Füsün BALIK ŞANLI², Ali Murat ATEŞ³, Osman Salih YILMAZ⁴

¹Öğr. Gör., ¹Manisa Celal Bayar Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, 45900, Demirci, Manisa, ramazan.gungor@cbu.edu.tr

²Prof.Dr., Yıldız Teknik Üniversitesi, Harita Mühendisliği Bölümü, 34220, Esenler, İstanbul, fbalik@yildiz.edu.tr

³Dr. Öğr. Üye., Manisa Celal Bayar Üniversitesi, Bilgisayar ve Öğr. Tek. Bölümü, 45900, Demirci, Manisa, murat.ates@cbu.edu.tr

⁴Doç. Dr., Manisa Celal Bayar Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, 45900, Demirci, Manisa, osmansalih.yilmaz@cbu.edu.tr

ÖZET

Tarım uygulamalarının sürdürülebilirliği açısından arazi kullanımı ve yönetimi kararlarının doğru bir şekilde alınması oldukça önemlidir. Özellikle tarımsal faaliyetlerin çok yoğun yürütüldüğü sera alanları, arazi kullanım kararları ve yerel ekosistem üzerinde fazlasıyla etkilidir. Bu nedenle sera alanlarının haritalanması ve izlenmesi, tarımsal verimliliğin artırılmasının yanı sıra çevreye olan zararların azaltılması bakımından da büyük önem arz etmektedir. Uzaktan algılama verileri sera alanlarının izlenmesi ve haritalanması konusunda büyük bir potansiyele sahiptir. Bu doğrultuda, obje ve piksel tabanlı sınıflandırma yöntemleri ve spektral indeksleri içeren farklı görüntü işleme teknikleri kullanılmaktadır. Bu çalışma, sera tespitinde kullanılan spektral indeksler ve makine öğrenmesi algoritmalarının sınıflandırma performansının karşılaştırılması amacıyla Antalya ili sınırları içerisinde gerçekleştirilmiştir. Çalışma kapsamında, Google Earth Engine (GEE) platformunda orta mekânsal çözünürlüklü Sentinel-2 (MSI) uydu görüntüleri, Destek Vektör Makineleri (DVM) ve Rasgele Orman (RO) makine öğrenmesi algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma aşamasında Sentinel-2 (MSI) geleneksel bantlarına, Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) ve Plastik Sera İndeksi (PSI) bant olarak eklenmiştir. Elde edilen sonuçlara göre en yüksek sınıflandırma doğruluğu PSI ve RO sınıflandırıcısı kullanılarak üretilmiştir. Genel doğruluk (GD) değeri %88,10, Kappa(κ) istatistik değeri ise 0.804 olarak hesaplanmıştır. Geleneksel bantlar ve DVM kullanılarak GD %84.31, κ 0.741, NDVI ve DVM kullanılarak GD %84.34, κ 0.756 olarak hesaplanmıştır. Ayrıca sınıflandırma doğrulukları arasındaki farkların anlamlılığını ölçmek için sonuçlara McNemar istatistik testi uygulanmıştır. McNemar testi sonuçlarına göre sınıflandırma doğrulukları arasındaki farkların istatistiksel olarak anlamlı olduğu belirlenmiştir.

Anahtar Sözcükler: Destek Vektör makineleri, Google Earth Engine, PSI, Rasgele Orman, Sınıflandırma doğruluğu

ABSTRACT

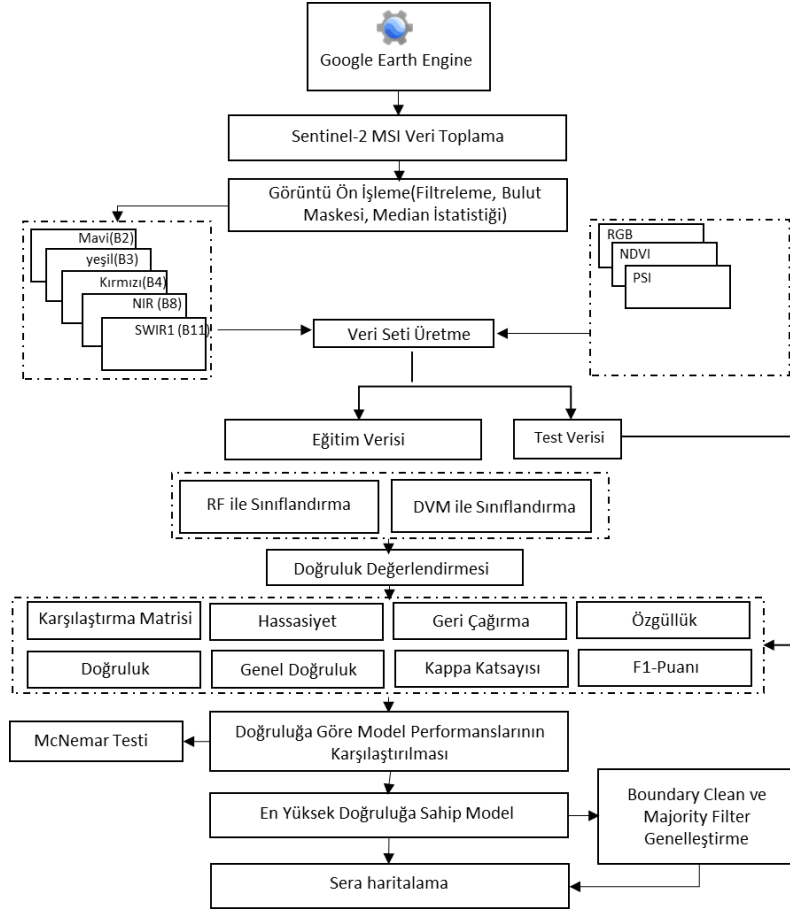
DETECTION OF GREENHOUSE AREAS USING SPECTRAL INDICES ON THE GEE PLATFORM BY COMPARING RF AND SVM ALGORITHMS

Accurate land use and management decisions are crucial for the sustainability of agricultural practices. Greenhouse areas, where agricultural activities are intensively conducted, significantly impact land use decisions and the local ecosystem. Therefore, mapping and monitoring greenhouse areas are essential not only for increasing agricultural productivity but also for reducing environmental damage. Remote sensing data holds great potential for the monitoring and mapping of greenhouse areas. In this context, various image processing techniques, including object and pixel-based classification methods and spectral indices, are used. This study was conducted within the borders of Antalya province to compare the classification performance of spectral indices and machine learning algorithms used in greenhouse detection. Within the scope of the study, medium spatial resolution Sentinel-2 (MSI) satellite images were classified on the Google Earth Engine (GEE) platform using Support Vector Machines (SVM) and Random Forest (RF) machine learning algorithms. During the classification phase, traditional Sentinel-2 (MSI) bands were supplemented with the Normalized Difference Vegetation Index (NDVI) and Plastic Greenhouse Index (PSI) as additional bands. According to the results obtained, the highest classification accuracy was achieved using the PSI and RF classifier. The overall accuracy (OA) was calculated as 88.10%, and the Kappa (κ) statistic value was 0.804. Using traditional bands and SVM, the OA was 84.31%, κ was 0.741, and using NDVI and SVM, the OA was 84.34%, κ was 0.756. Additionally, the McNemar statistical test was applied to measure the significance of the differences in classification accuracies. According to the McNemar test results, the differences in classification accuracies were found to be statistically significant.

Keywords: Support Vector Machines, Google Earth Engine, PGI, Random Forest, Accuracy of Classification

1. GİRİŞ

Arazi örtüsü ve arazi kullanımına (AÖ/AK) yönelik sınıflandırmanın yapılması, gelişmekte olan ülkeler için kritik bir öneme sahiptir. Çünkü arazi kaynaklarının sınırlı olması ve artan nüfus kaynakların verimsiz kullanılmasına neden olmaktadır. Özellikle küresel ısınma ve iklim değişikliği ile ortaya çıkan besin ihtiyacı ve bu ihtiyacın kaynağı olan tarımsal arazilerin sınıflandırılması, izlenmesi ve koruma altına alınması sürdürülebilir bir arazi yönetimi için oldukça önemlidir. Bu doğrultuda, AÖ/AK haritalarının üretilmesi ve izlenmesi için uzaktan algılama (UA) teknikleri oldukça pratiktir ve kapsamlı çözümler sunar (Elmahdy vd., 2020). Farklı uydu platformları sayesinde düşük, orta ve yüksek mekânsal çözünürlüğün yanı sıra radyometrik, zamansal ve spektral çözünürlükte görüntüler üretilmektedir (Leach



Şekil 2. Uygulama adımları

Ayrıca Sentinel-2 mavi (M), yeşil (Y), kırmızı (K) ve yakın kızılötesi (NIR) bantlar ile NDVI ve PSI indekslerini (Çizelge 1) içeren 3 farklı veri seti oluşturulmuştur. İkinci adımda bir JavaScript kodu yazılarak oluşturulan veri setleri ayrı ayrı RO ve DVM algoritmaları ile sınıflandırılmıştır. Üçüncü adımda üretilen sınıflandırma haritalarının sınıflandırma doğrulukları daha yüksek çözünürlüğe sahip (WorldView ve GeoEye) görüntüleri barındıran Google Earth platformu üzerinden kontrol edilmiştir. Kontrol sonucunda hata matrisi yardımı ile her sınıfın ve tüm sınıflandırmanın doğruluk metrikleri üretilmiştir. Bu kapsamda genel doğruluk (GD), Kappa (κ) istatistik değeri, F1-Skoru (F1-S), geri çağırma (Gç), hassasiyet (Hs), özgüllük (Öz) ve doğruluk (Dğ) hesaplanmıştır (Çizelge 2). Uygulamanın son adımında ise en fazla doğruluğa sahip algoritma ve indeks seçilerek sınıflandırmaya ait tematik harita üretilmiş ve sınıflara ait alanlar belirlenmiştir.

Çizelge 1. Sınıflandırmada kullanılan spektral indeksler

$NDVI = (\rho_{NIR} - \rho_K) / (\rho_{NIR} + \rho_K)$	(1)	(Rouse vd., 1974)	Sentinel-2 MSI uydu görüntülerinde; Mavi (B2), Yeşil (B3), Kırmızı(B4), Yakın Kızılötesi (B8), Kısa Dalga Yakın Kızılötesi 1 (B11) dir.
$PSI = 100 \times \frac{\rho_M \times (\rho_{NIR} - \rho_K)}{1 - Ortalama(\rho_M + \rho_Y + \rho_{NIR})}$	(2)	(Yang vd., 2017)	
$PSI = 0$ NDVI > 0.73; $PSI = 0$ NDBI > 0.005			

Çizelge 2. Hesaplanan doğruluk metrikleri ve McNemar testi

$GD = \frac{S_t}{S_n} \times 100$	(3)	S_t , herhangi bir sınıfın doğru sınıflandırılmış pikselidir. n, hata matrisindeki toplam piksel sayısıdır. r satır sayısıdır. S_{ij} , i'inci satır ve j'inci sütun toplamıdır.	(Aronoff 1982)
$\kappa = nS_t - \sum_{i=1}^r \frac{S_{ij}^2}{n^2} - \sum_{i=1}^r S_{ij}$	(4)		(Cohen 1960)

Geri çağırma=GP/(GP+YN)	(5)	Burada yanlış negatif (YN), yanlış pozitif (YP), gerçek pozitif (GP) ve gerçek negatif (GN) gözlemlerin sayısıdır.	(Elmahdy vd., 2020)
Hassasiyet=GP/(GP+YP)	(6)		
F1-Puanı=(2 x Hassasiyet x Geri çağırma)/(Hassasiyet + Geri çağırma)	(7)		
Özgüllük=GN/(GN+YP)	(8)		
Doğruluk=(GP+GN)/(GP+GN+YP+YN)	(9)		
(McNemar) $\chi^2 = \frac{(n_{ij} - n_{ji})^2}{n_{ij} + n_{ji}}$	(10)	Burada n_{ij} , i. sınıflandırıcının hatalı j. sınıflandırıcının doğru sınıflandırdığı piksel sayısı, n_{ji} ise j. sınıflandırıcısının hatalı i. sınıflandırıcısının doğru sınıflandırdığı piksel sayısını ifade etmektedir.	(Foody 2004)

4. SONUÇLAR VE TARTIŞMA

Bu çalışmada, farklı spektral yansıma özelliklerine sahip sera alanlarının oldukça fazla olduğu, Antalya ili seçilmiştir. Çalışma kapsamında kontrollü sınıflandırma için yerleşim, su yüzeyi, tarım, bitki örtüsü, açık arazi ve sera olarak 6 adet sınıf belirlenmiştir (Şekil 3). Kullanılan MÖ algoritmaları ve spektral indekslere göre toplam 6 adet sınıflandırma haritası üretilmiştir. Sınıflandırmalara ilişkin doğruluklar incelendiğinde en yüksek doğruluk %88,10 GD, 0.804 κ istatistik değeri ile PSI ve RO algoritması kullanılarak elde edilmiştir (Çizelge 3). Renkli görüntünün DVM algoritması ile sınıflandırılmasında GD %84.31, κ 0.741 hesaplanmıştır. Ancak renkli görüntüye NDVI indeksi eklendiğinde GD %84.34, κ 0.756 olarak hesaplanmıştır. Burada NDVI indeksinin sınıflandırmanın doğruluğunu artırdığı görülmüştür. Genel doğruluğun yanı sıra, sınıflandırma doğruluklarının araştırılmasında her sınıf için F1-Skor hesaplanmıştır. Sera sınıfı için en yüksek F1-Skor değeri PSI indeksi ve RO algoritması kullanılarak 0.947, yerleşim için en yüksek F1-Skor NDVI indeksi ve DVM kullanılarak 0.815, su yüzeyi için en yüksek F1-Skor NDVI indeksi ve DVM kullanılarak 0.923, açık arazi için en yüksek F1-Skor PSI indeksi ve RO kullanılarak 0.930, bitki örtüsü için en yüksek F1-Skor PSI indeksi ve DVM kullanılarak 0.948, tarım için en yüksek F1-Skor PSI indeksi ve DVM kullanılarak 0.672 hesaplanmıştır (Çizelge 3). DVM algoritmasının kentsel alanlarda sınıflandırma performansının diğer sınıflandırma algoritmalarına göre düşük olduğu bilinmektedir (Ouma vd., 2022). Ancak bu çalışmada kullanılan veri setlerinin DVM'nin sınıflandırma doğruluğuna pozitif katkı sağladığı tespit edilmiştir. Yine aynı şekilde kullanılan veri setlerinin RO algoritmasının performansını da artırdığı belirlenmiştir. Bu durum RO algoritmasının az sayıda eğitim verisi ile yüksek performans gösterme yeteneğini de ispatlamaktadır. Sınıflandırma doğrulukları arasındaki farklar McNemar testi ile incelenmiştir. Karşılaştırmalar neticesinde en yüksek doğruluğa sahip PSI ve RO algoritması ile yapılan sınıflandırma, diğer MÖ ve veri setleri ile yapılan sınıflandırmalar ile karşılaştırıldığında tüm χ^2 değerleri 3.84 eşik değerinden büyük çıkmıştır (Çizelge 4). Yani sınıflandırma sonuçları arasındaki farklar istatistiksel olarak anlamlıdır (Çölkesen vd., 2014).

KAYNAKLAR

- Aronoff, S.**, 1982. Classification accuracy: a user approach. *Photogrammetric Engineering and Remote Sensing*, 48(8): 1299–1307.
- Castaldi, F., Palombo, A., Santini, F., Pascucci, S., Pignatti, S., ve Casa, R.**, 2016. Evaluation of the potential of the current and forthcoming multispectral and hyperspectral imagers to estimate soil texture and organic carbon. *Remote Sensing of Environment*, 179, 54–65.
- Cohen, J.**, 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1): 37–46.
- Çölkesen, İ., Yomralioğlu, T., ve Kavzoğlu, T.**, 2014. Classification of Multispectral High-Resolution Satellite Imagery Using Rotation Forest Algorithm. *V. Remote Sensing and Geographic Information Systems Symposium*.
- Elmahdy, S., Mohamed, M., ve Ali, T.**, 2020. Land use/land cover changes impact on groundwater level and quality in the northern part of the United Arab Emirates. *Remote Sensing*, 12(11).
- Foody, M. G.**, 2004. Thematic Map Comparison: Evaluating the Statistical Significance of Differences in Classification Accuracy. *Photogrammetric Engineering and Remote Sensing*, 70(5): 627–633.
- Ha, N. T., Manley-Harris, M., Pham, T. D. ve Hawes, I.**, 2020. A comparative assessment of ensemble-based machine learning and maximum likelihood methods for mapping seagrass using sentinel-2 imagery in Tauranga Harbor, New Zealand. *Remote Sensing*, 12(3).
- Koc-San, D.**, 2013. Evaluation of Different Classification Techniques for the Detection of Glass and Plastic Greenhouses from WorldView-2 Satellite Imagery. *Journal of Applied Remote Sensing*, 7(1).
- Ouma, Y., Nkwae, B., Moalafhi, D., Odirile, P., Parida, B., Anderson, G., ve Qi, J.**, 2022. Comparison of Machine Learning Classifiers for Multitemporal and Multisensor Mapping of Urban LULC Features. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 43(B3-2022), 681–689.
- Rouse, J. W., Haas, R. H., Schell, J. A., ve Deering, D. W.**, 1974. Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ*, 351(1): 309.
- Leach, N., Coops, N. C., ve Obrknezev, N.**, 2019. Normalization method for multi-sensor high spatial and temporal resolution satellite imagery with radiometric inconsistencies. *Computers and Electronics in Agriculture*, 164, 104893.
- Yang, D., Chen, J., Zhou, Y., Chen, X., Chen, X., ve Cao, X.**, 2017. Mapping plastic greenhouse with medium spatial resolution satellite data: Development of a new spectral index. *ISPRS Journal of Photogrammetry and Remote Sensing*, 128: 47–60.

Beyan

Bu çalışma Ramazan Güngör'ün doktora tezinden üretilmiştir.