

## Yeni nesil multispektral ve hiperspektral uydu görüntülerinin arazi örtüsü / arazi kullanımı sınıflandırma performanslarının karşılaştırılması: Sentinel-2 ve PRISMA Uydusu

Buse Tırmanoğlu<sup>1</sup>, İrem İsmailoğlu<sup>1,2</sup>, Aylin Tuzcu Kokal<sup>\*3</sup>, Nebiye Musaoğlu<sup>3</sup>

<sup>1</sup> İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul, Türkiye

<sup>2</sup> İstanbul Teknik Üniversitesi, Uydu Haberleşme ve Uzaktan Algılama UYG-AR Merkezi, İstanbul, Türkiye

<sup>3</sup> İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü, İstanbul, Türkiye

### Anahtar Kelimeler

PRISMA  
Sentinel  
AÖ/AK  
Maksimum Olabilirlik  
Temel Bileşenler Analizi

### Araştırma Makalesi

Geliş: 06.06.2022  
Revize: 18.11.2022  
Kabul: 21.11.2022  
Yayınlanma: 12.01.2023



### Öz

Dünya gözlem uydularının gelişmesiyle Arazi Örtüsü/Arazi Kullanımı (AÖ/AK) sınıflandırması, ekosistemleri izlemede ve kaynak yönetiminde değerli bilgiler sağlayan önemli bir uygulama haline gelmiştir. Multispektral görüntüler ile AÖ/AK sınıfları belirli detayda çıkartılabilirken bazı uygulamalarda spektral çözünürlük nedeniyle sınıfların ayırt edilebilirliğinde problemler ortaya çıkabilmektedir. Hiperspektral uydu görüntüleri yüksek spektral çözünürlük sağladıklarından sınıfların ayırt edilebilirliğini arttırmaktadır. Bu çalışmada Marmara Denizi'ne önemli ölçüde deşarjı olan Susurluk Nehri ve çevresine ait 13.05.2021 tarihli PRISMA ve 14.05.2021 tarihli Sentinel-2 görüntülerinden sınıflandırma ile ekili tarım alanı, boş arazi, orman, yerleşim & sanayi, yol, göl, akarsu, bataklık sınıfları belirlenmiş ve sonuçları karşılaştırılmıştır. Öncelikle, Sentinel-2 görüntüsü 30 m mekânsal çözünürlüğe yeniden örneklenmiştir. Her iki görüntünün orijinal veri setleri, görüntüleme temel bileşenler analizi (TBA) ve minimum gürültü fraksiyonu (MGF) uygulanmış veri setleri olmak üzere toplamda altı veri setine Maksimum Olabilirlik algoritması (MOA) ve Destek Vektör Makineleri (DVM) yöntemleri uygulanmıştır. Doğruluk analizinde, hesaplanan F1 puanı, hassasiyet ve geri çağırma metrik sonuçları karşılaştırılmıştır. PRISMA veri setlerine MOA uygulanan görüntüler incelendiğinde, en düşük ortalama F1 puan değeri (0.712) orijinal görüntünün sınıflandırma sonucunda elde edilirken en yüksek değer (0.924) TBA sonucunun sınıflandırılması ile elde edilmiştir. Bunun sebebi, hiperspektral verilerde boyut indirgeme yöntemlerinin uygulanarak korelasyonu yüksek bantların elimine edilmesidir. PRISMA görüntüsünün sınıflandırma sonuçlarında spektral çözünürlüğün katkısı nedeniyle sınıfların büyük bölümünde Sentinel-2 sonuçlarına göre daha yüksek doğruluğa ulaşılmıştır.

## Comparison of land use / land cover classification performances of new generation multispectral and hyperspectral satellite images: Sentinel-2 and PRISMA Satellite

### Keywords

PRISMA  
Sentinel  
LU/LC  
Maximum Likelihood  
Principle Component Analysis

### Research Article

Received: 06.06.2022  
Revised: 18.11.2022  
Accepted: 21.11.2022  
Published: 12.01.2023

### Abstract

With the development of Earth observation satellites, Land Use/Land Cover (LU/LC) classification has become an important application. When hyperspectral images compared with multispectral images, hyperspectral satellite images increase the distinguishability of classes as they provide high spectral resolution. In this study, cultivation area, bare land, forest, residential & industrial, road, lake, river, marsh classes of Susurluk River and its surroundings which provide significant discharge to the Sea of Marmara were determined by classification from PRISMA and Sentinel-2 images that were acquired on 13.05.2021 and 14.05.2021, respectively. Firstly, Sentinel-2 satellite image was resampled to 30 m spatial resolution. Maximum likelihood (ML) and support vector machine (SVM) algorithms were applied to the total of six datasets, including the original dataset, PCA and MNF results of the both satellite images. F1-score, precision, recall metrics were compared to assess accuracies. It was concluded from the ML algorithm applied PRISMA results, the highest F1-score (0.924) was achieved by the PCA applied result, while the lowest F1-score (0.712) belongs to the original dataset. The reason is that high correlated spectral bands can be eliminated by using dimensionality reduction methods. Most of the classes were distinguished with higher accuracy by PRISMA image due to having high spectral resolution.

### \*Sorumlu Yazar

(tirmanoglu@itu.edu.tr) ORCID 0000-0001-8106-9445  
(iremism@cscrs.itu.edu.tr) ORCID 0000-0003-1394-6834  
(tuzcuay@itu.edu.tr) ORCID 0000-0003-2786-2033  
(musaoglune@itu.edu.tr) ORCID 0000-0002-8022-8755

### Kaynak Göster (APA)

Tırmanoğlu, B., İsmailoğlu, İ., Kokal, A. T., & Musaoğlu, N. (2023). Yeni nesil multispektral ve hiperspektral uydu görüntülerinin arazi örtüsü / arazi kullanımı sınıflandırma performanslarının karşılaştırılması: Sentinel-2 ve PRISMA Uydusu. *Geomatik*, 8(1), 79-90

## 1. Giriş

Sanayileşme ve artan nüfusa bağlı olarak gıda ve enerji gibi insanların temel ihtiyaçlarının karşılanabilmesi için yapılan antropojenik faaliyetlerdeki artış ekosistem üzerinde olumsuz etkilere neden olmaktadır (Yılmaz ve ark. 2018). Yeryüzünde meydana gelen değişiklikleri ve çevre kirliliğini sürekli gözlemleyip zamanında müdahale edebilmek için uzaktan algılama teknolojilerini kullanmak zamansal ve ekonomik açıdan önemli hâle gelmiştir. Günümüzde uydu görüntülerinden üretilen arazi örtüsü/arazi kullanımı (AÖ/AK) bilgisi; doğal kaynakların yönetimi, izlenmesi ve ekosistemin bütüncül olarak ele alınmasında değerli bir kaynak haline gelmiştir (Karakuş ve ark., 2017; Steinhäusen ve ark., 2018; ED Chaves ve ark., 2020; Apaydın ve Abdikan, 2021). Özellikle uydu platformlarına takılı algılayıcılarla yeryüzünde geniş alanlardan kısa sürede bilgi çıkartabilmesi uydu görüntülerinin AÖ/AK üretmede sıklıkla kullanılmasına olanak sağlamaktadır (Nguyen ve ark., 2020; Ahady ve Kaplan, 2022). Landsat ve Sentinel grubu uydulardan elde edilen görüntülerin ücretsiz erişilebilir olması da uygulamaların yaygınlaşmasında önemli bir parametredir (Çömert ve ark., 2019; Zabcı, 2021). 2015 yılında uzaya fırlatılan Sentinel-2 uydusundan sağlanan görüntüler, AÖ/AK sınıflarının belirlenmesinde oldukça sıklıkla kullanılmaktadır (ESA, 2022). Topaloğlu ve ark., (2016)'da Landsat 8 ve Sentinel-2 görüntülerinin AÖ/AK sınıflarını belirlemedeki doğruluklarını araştırdıkları çalışmalarında, Sentinel-2 görüntüleri 30 m mekânsal çözünürlüğe örneklenmiş olmalarına rağmen daha yüksek sınıflandırma doğruluğu elde etmişlerdir. Delalay ve ark. (2019)'da Sentinel-2 görüntülerinden AÖ/AK sınıflarının çıkartılmasında operasyonel bir yöntem geliştirmişler ve bu yöntemi Nepal'de dağlık bir bölgede uygulamışlardır. Ayrıca Sentinel-2 uydu görüntüleri kıyı bölgelerinde deniz, kayalık, bitki örtüsü ve inşaat alanlarının tespiti (Randazzo ve ark., 2021), tropik bölgelerde bulunan ormanların incelenmesi (Nguyen ve ark., 2020), şehir alanlarının incelenmesi (Zhang ve ark., 2021) gibi birçok çalışmada kullanılmaktadır.


Teknolojinin gelişmesiyle birlikte uydu platformlarına takılı sistemler ile dar bant aralıklarında algılama yapan yüzlerce banda sahip hiperspektral uydu görüntülerine erişmek mümkün hale gelmiştir (Akar ve Görmüş, 2019). Günümüzde İtalyan Uzay Ajansı (Agenzia Spaziale Italiana/ASI) tarafından geliştirilen PRecursore IperSpettrale della Missione Applicativa (PRISMA) uydusunun 30 m mekânsal çözünürlükte sağladığı hiperspektral uydu görüntülerine ücretsiz olarak erişmek mümkündür (Loizzo ve ark., 2018). Yeni nesil PRISMA uydu görüntülerinin yangın tespiti (Lazzeri ve ark., 2021), farklı orman tiplerinin belirlenmesi (Vangi ve ark., 2021), farklı AÖ/AK sınıflarının belirlenmesi (Tuzcu Kokal ve ark., 2022) vb. uygulamalarda kullanıldığı çalışmalar mevcuttur.

Bu çalışmada, Susurluk Nehri ve çevresine ait 13.05.2021 tarihinde algılanan PRISMA ve 14.05.2021 tarihinde algılanan Sentinel-2 uydu görüntülerine Maksimum Olabilirlik (MOA) algoritması ve Destek Vektör Makineleri (DVM) algoritması uygulanarak ekili tarım alanı, boş arazi, orman, yerleşim & sanayi, yol, göl,

akarsu, bataklık sınıfları olmak üzere sekiz farklı türde AÖ/AK sınıfları belirlenmiştir. Üretilen tematik haritaların doğrulukları istatistiksel olarak karşılaştırılmıştır.

## 2. Çalışma alanı ve kullanılan veriler

Bu çalışmada Susurluk Nehir Havza'sında bulunan önemli akarsulardan biri olan Susurluk Nehri ve çevresinin AÖ/AK durumu incelenmiştir. Konumu Şekil 1'de gösterilen Susurluk Nehri (Simav Çayı), Bursa, Balıkesir ve Bandırma illeri arasında yer almakta olup Ege Bölgesi'nden başlayıp Marmara Denizi'nin güneyine dökülmektedir. Yaklaşık uzunluğu 321 km olan Susurluk Nehri, Marmara Denizi'ne dökülen en uzun nehirdir (Öztürk ve Küçük, 2017). Çalışma alanı, büyük orman alanlarını içermekle birlikte Karacabey (Bursa) ilçe merkezini ve bir Ramsar alanı olan Uluabat Gölü'nün bir kısmını kapsamaktadır (Ramsar, 1998). Bu bağlamda değerlendirildiğinde, bölgenin ekili tarım alanı, boş arazi, orman, yerleşim & sanayi, yol, göl, akarsu, bataklık sınıfları gibi farklı tür AÖ/AK sınıflarını içermekte olduğu görülmektedir.



Şekil 1. Çalışma bölgesi konumu ve çalışmada kullanılan PRISMA (a) (PRISMA ASI, (2022)) ve Sentinel-2 (b) (Copernicus, (2022)) uydu görüntüleri

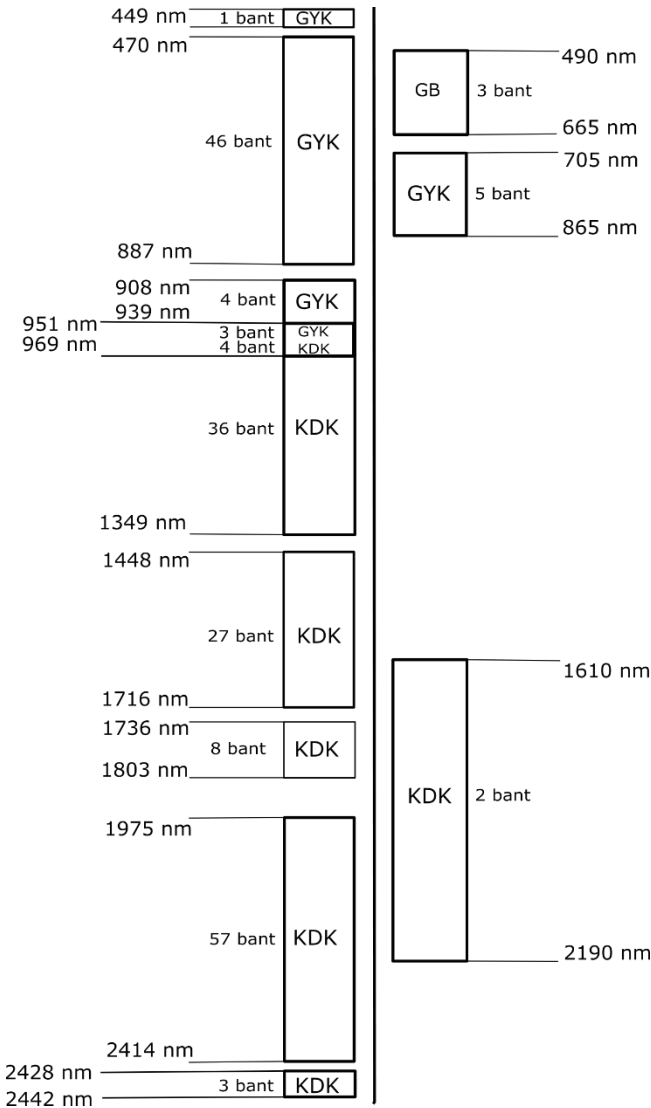
Farklı uydu görüntülerinin AÖ/AK sınıflarını belirlemedeki performanslarının değerlendirilmesinde özellikle çalışma alanı orman ve tarım alanlarını da kapsıyorsa verilerin eş zamanlı olarak algılanmış olması önem taşır. Bu çalışmada, teknik özellikleri Tablo 1'de verilen 13.05.2021 tarihinde algılanan PRISMA uydu görüntüsü ile 14.05.2021 tarihinde algılanan Sentinel-2 uydu görüntüsü kullanılmıştır. Sentinel-2 MultiSpectral Instrument (MSI) algılayıcısı, Avrupa Uzay Ajansı (European Spatial Agency/ESA) tarafından Copernicus programı kapsamında geliştirilen bir algılayıcıdır. Zamansal çözünürlüğü yüksek olan Sentinel-2 uydu görüntülerinin; dört adet 10 m, altı adet 20 m ve üç adet

60 m mekânsal çözünürlüğe sahip olmak üzere toplam 13 spektral bantı bulunmaktadır. 2019 yılında uzaya fırlatılan PRISMA uydusu da 30 m mekânsal çözünürlükte hiperspektral veri sağlamakta ve verilere

ücretsiz erişilebilmektedir. Şekil 2’de, PRISMA ve Sentinel-2 uydularının spektral aralıkları ve çalışmada kullanılan bant sayıları gösterilmektedir (Copernicus, 2022; PRISMA ASI, 2022).

**Tablo 1.** Sentinel 2A/2B ve PRISMA uydu görüntülerinin teknik özellikleri (SUHET, 2015; ASI, 2020; ASI, 2022; ESA, 2022)

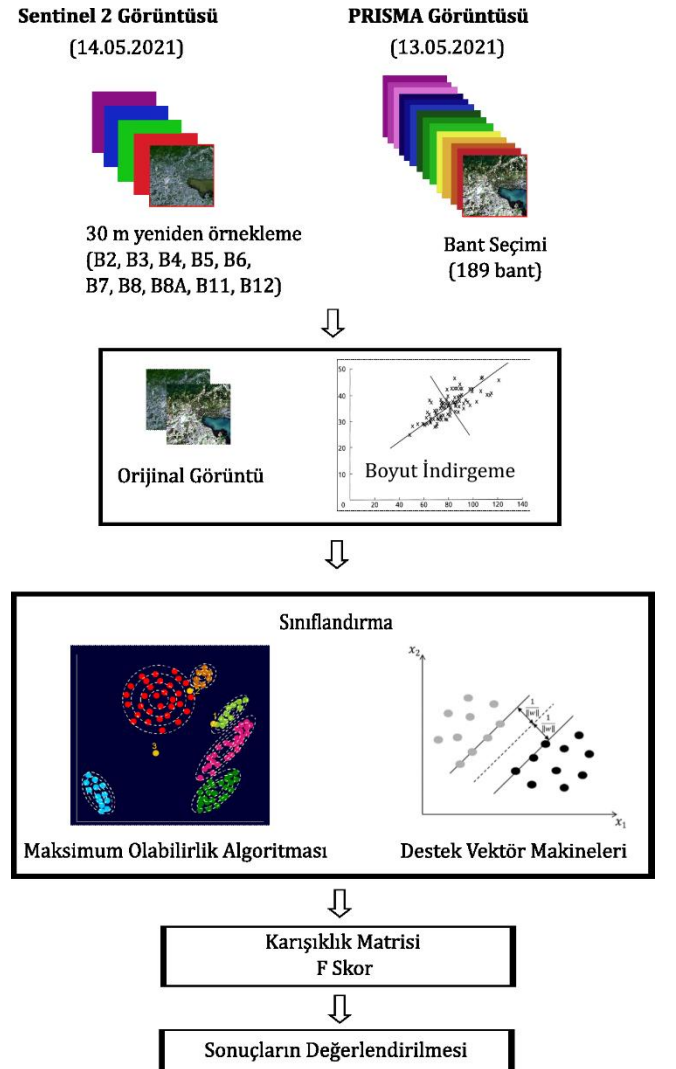
Özellik	Sentinel- 2A/2B	PRISMA
Kurum	ESA	ASI
Fırlatılma Tarihi	2015 /2017	2019
Şerit genişliği (km)	290	30
Mekânsal Çözünürlük (m)	Bant 2-4, Bant 8: 10 Bant 5-7, Bant 8A, Bant 11-12: 20 Bant1, Bant 9-10: 60	30
Spektral Bant Sayısı	13	240
Zamansal Çözünürlük	5 gün	29 gün (Yaklaşık)



**Şekil 2.** Çalışmada kullanılan PRISMA (solda) ve Sentinel-2 (sağda) uydularının spektral aralıkları ve bant sayıları (GB: Görünür Bölge; GYK: Görünür Yakın Kızılötesi; KDK: Kısa Dalga Kızılötesi)

### 3. Yöntem

Bu çalışmada uygulanan işlem adımları Şekil 3’de verilen akış şemasında gösterilmiştir.



**Şekil 3.** Akış şeması (MOA şekli Clevers, (2000) çalışmasından, Boyut İndirgeme modeli Holland, (2019), DVM şekli Awad ve Khanna, (2015) çalışmasından alınmıştır)

Sentinel-2 ve PRISMA görüntüleri atmosferik ve geometrik düzeltmeleri tamamlanmış olarak temin edildiği için belirtilen uydu görüntülerine ön işleme adımı uygulanmamıştır. Görüntülerin sınıflandırma

performanslarının eşit koşullarda karşılaştırılabilmesi için ilk adım olarak Sentinel-2 görüntüsü 30 metreye yeniden örneklenmiştir.

Boyut indirgeme ve sınıflandırma aşamalarından önce PRISMA verisinde gürültü bulunan bantlar, Sentinel-2 verisinde ise düşük mekânsal çözünürlüklü (60m) bantlar elimine edilmiştir. Uygulamada kullanılmış olan PRISMA veri seti GYK sensöründen bant 7, bant 10-55, bant 57-63 ve KDK sensöründen bant 3-42, bant 51-77, bant 79-86, bant 105-161, bant 163-165; Sentinel-2 veri seti ise bant 2-7, bant 8 - 8A ve bant 11-12 numaralı bantları içermektedir. Bant seçimi işleminin ardından boyut indirgeme yöntemlerinden biri olan ve yüksek korelasyonlu değişkenlerin korelasyonsuz değişkenlere dönüşmesini sağlayan Temel Bileşenler Analizi (TBA) (Hidalgo ve ark., 2021); sinyal-gürültü oranını (SGO/ Signal-to-Noise Ratio (SNR)) iyileştirmek ve veri işleme hızını arttırmak için literatürde tercih

edilen bir yöntem olan Minimum Gürültü Fraksiyonu (MGF) uygulanmıştır (Dabiri ve Lang, 2018).

Temel bileşenler dönüşümü uygulandıktan sonra varyansın büyük kısmı üretilen ilk üç bileşende bulursa da diğer üretilen bileşenler de bilgi içermektedir (Akça ve Doğan, 2002; Ringnér, 2008). Bu doğrultuda, kullandığımız boyut indirgeme yöntemleri (TBA ve MGF) sonucunda elde edilen bileşenler tek tek incelenmiş ve ilk 3 bandın yanı sıra, bilgi içerdiği tespit edilen bantlar da sınıflandırmaya girdi olarak alınmıştır.

Sınıflandırma yaklaşımı olarak, kontrollü ve parametrik sınıflandırma yöntemlerinden biri olan MOA (Fisher, 1912) ve makine öğrenmesi algoritmalarından biri olan DVM uygulanmıştır. Eşitlik 1’de formülü verilen MOA’da, normal dağılımı temel alan bir olasılık fonksiyonu tanımlandıktan sonra sınıfı belli olmayan piksel olasılık değerinin maksimum olduğu sınıfa atanmaktadır (Çetin, 2007; ERDAS, 2003; Sisodia ve ark., 2014; Tadesse ve ark., 2017).

$$D = \ln(a_c) - [0.5 * \ln(|Cov_c|)] - [0.5 * (X - M_c)^T (Cov_c^{-1}) * (X - M_c)] \quad (1)$$

D: Ağırlıklı uzaklık, c: Sınıf, X: Ölçü vektörü, M: Ortalama vektör, a: Sınıfına ait olma olasılığı, Cov: Kovaryans matrisi

DVM sınıflandırıcısı sınıflar arasındaki marjini optimize ederek hiper düzlem oluşturma temeline dayanmaktadır (Vapnik, 1979; 2013). Doğrusal hiperdüzlemlerin yeterli olmadığı durumlarda çekirdek fonksiyonlar kullanılarak girdi verisinden daha yüksek boyut elde edilerek sınıflar arasındaki ayrılabilirlik arttırılmaktadır (Aizerman, 1964). Bu çalışmada, kullanılan radyal tabanlı çekirdek fonksiyonunun formülü Eşitlik 2’de verilmiştir (Tso ve Mather, 2009).

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (2)$$

K: Kernel Fonksiyonu,  $\gamma$ : Gamma parametresi

Doğruluk analizi kapsamında, 240 adet rastgele test noktası baz alınarak literatürde yaygın olarak kullanılan hassasiyet, geri çağırma ve F1 puanı değerlendirme metrikleri hesaplanmıştır. Ayrıca tüm sınıflar için

ortalama F1 puanı ve doğruluk da hesaplanmıştır (Elmahdy ve ark., 2020). Hassasiyet (Eşitlik 3), geri çağırma (Eşitlik 4), F1 puanı (Eşitlik 5) ve doğruluk (Eşitlik 6); gerçek pozitif (True Positive/TP), yanlış pozitif (False Positive/FP), gerçek negatif (True Negative/TN) ve yanlış negatif (False Negative/FN) olacak şekilde dört parametre kullanılarak hesaplanmaktadır (Tharwat, 2020; Elmahdy ve ark., 2020). Geri çağırma, sınıflandırma sonucunda bir sınıftaki olası tüm pikselleri bulabilme ölçütü iken; hassasiyet, sınıflandırıcının hedef sınıfa ait pikselleri daha hassas algılayabilme ölçütüdür. F1 puanı, hassasiyet ve geri çağırma metriklerinin harmonik ortalamasıdır ve sınıflandırma performansını değerlendirmek için kullanılmaktadır (Ha ve ark., 2020). Sınıflandırma performansında en çok tercih edilen metriklerden biri olan doğruluk, doğru sınıflandırılmış örneklerin, toplam örnek sayısına oranı olarak tanımlanmaktadır (Tharwat, 2020).

$$\text{Hassasiyet} = TP / (TP + FP) \quad (3)$$

$$\text{Geri Çağırma} = TP / (TP + FN) \quad (4)$$

$$\text{F1 Puanı} = (2 * \text{Hassasiyet} * \text{Geri Çağırma}) / (\text{Hassasiyet} + \text{Geri Çağırma}) \quad (5)$$

$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN) \quad (6)$$

#### 4. Bulgular

Boyut indirgeme aşamasında her bir yaklaşımda üretilen bileşenlere ait toplam varyans yüzdeleri hesaplanmış (Tablo 2) ve istatistiksel olarak incelenmiştir. Bu incelemenin yanı sıra, tüm bileşenler görsel olarak da incelenerek uygun bileşenlerden oluşan veri setleri oluşturulmuştur.

TBA sonucunda Sentinel-2 MSI sensörüne ait 1,2,3,5,6,7 numaralı bileşenler; PRISMA uydusuna ait GYK sensöründen elde edilen 1,2,3,4,5,7 ve KDK sensöründen elde edilen 1,2,3,6,7,12 numaralı bileşenler

seçilmiştir. MGF uygulaması sonucunda ise Sentinel-2 MSI sensörüne ait 1,2,3,4,5,6,7 numaralı bileşenler; PRISMA görüntüsüne ait GYK sensöründen elde edilen 1,3,4,5,6,7,8,9 ve KDK sensöründen elde edilen 4,5,7,11,13 numaralı bileşenler sınıflandırma için girdi verisi olarak kullanılmıştır. Girdi verisi olarak seçilen bileşenlere ait çalışma bölgesinin merkezine yakınlaştırılmış görseller Şekil 4 ve Şekil 5’te gösterilmiştir.

Boyut indirgeme uygulaması sonucu oluşan bileşenlere ait görseller ve varyans değerleri birlikte incelendiğinde, düşük varyans değerine sahip olmasına



rağmen görsel açıdan anlamlı veri içeren bileşenlerin tespit edilmesi girdi veri setinin oluşturulması açısından oldukça kritik bir noktadır. Bu bağlamda, Sentinel-2 ve PRISMA görüntülerine boyut indirgeme yöntemlerinden TBA ve MGF uygulanmıştır.

TBA yöntemi uygulandıktan sonra elde edilen bileşenlerin görsel analizi sonucu Sentinel-2 görüntüsüne ait düşük varyanslı bileşenlerde (Şekil 4.c, d, e, f) yerleşim & sanayi ve yol sınıflarının ayırt edilebilirliğinin yüksek olduğu görülmüştür. Şekil 4.j, k, l incelendiğinde ise, PRISMA uydusunun GYK sensörü verisine uygulanan TBA sonucunda elde edilen düşük varyanslı bileşenlerinde yerleşim & sanayi ve tarım alanları sınıflarının ön plana çıktığı gözlemlenmiştir. Ayrıca, PRISMA uydusunun KDK sensörü verisine uygulanan TBA sonucuna ait 12. bileşenin düşük varyans değerine (0.004) sahip olmasına rağmen, yol ve yerleşim & sanayi gibi geçirimsiz yüzeylerin oldukça belirgin bir biçimde ayırt edilebildiği (Şekil 4.s) gözlemlenmiş ve bu bileşenin girdi verisine dahil edilmesinin sınıflandırmanın doğruluğuna olumlu yönde etki ettiği gözlemlenmiştir.


MGF yöntemi sonuçları incelendiğinde ise Sentinel-2 görüntüsünden üretilen varyanslı düşük bileşenlerin (Şekil 5.c, d, e, f, g) farklı sınıflar için ayırt edici veri içerdiği görülmüştür. Örnek olarak; Şekil 5.g’de yerleşim ve sanayi bölgelerinin ön plana çıktığı gözlemlenmiştir. PRISMA GYK sensörü verisinden elde edilen yüksek

varyansa sahip bileşenlerde (Şekil 5.h, i, j) akarsu sınıfı kolaylıkla ayırt edilebilirken, düşük varyansa sahip bileşenlerde (Şekil 5.m, n, o’da) ekili tarım arazileri ve boş arazi sınıfları kolaylıkla tespit edilmiş olup sınıflandırmada girdi verisi olarak kullanılmıştır. Şekil 5.k incelendiğinde ise endüstri ve yerleşim alanlarının ön plana çıktığı gözlemlenmiştir. Ayrıca, PRISMA KDK sensörü verisine MGF uygulandığında Şekil 5.p’de orman ve akarsu sınıfları bilgisi mevcut iken Şekil 5.u’da gösterilen bileşende endüstri, yerleşim ve yol sınıflarının kolaylıkla ayırt edilebildiği gözlemlenmiştir.


Faktör analizi, çok sayıda ilişkili değişkenler arasındaki ilişkinin kökenini analiz ederek az sayıda bağımsız faktör elde eden boyut indirgeme yöntemlerinden biridir. TBA ile verilerin dönüşümü amaçlanıp bileşenler üretilirken, faktör analizi ile verilerin bir modele uyumluluğu amaçlanıp faktörler üretilir (İlhan, 2007). Faktör sayısını belirlemek için birçok kriter kullanılmaktadır. Bu kriterlerden biri grafiksel bir test olan yamaç eğim testidir (Scree plot test) (Cattell, 1966). Yamaç eğim grafiğinde eğimin hızla azaldığı nokta belirlenerek dikkate alınması gereken faktör sayısı belirlenmektedir. Grafikte yatay eksen faktör sayısını belirtirken dikey eksen TBA aracılığıyla faktör varyansı ile elde edilen özdeğerleri belirtmektedir (Sarı, 2018). Sentinel-2 ve PRISMA uydu görüntülerine uygulanmış TBA ve MGF faktörlerinin özdeğerleri Şekil 6’da gösterilmiştir.

**Tablo 2.** TBA ve MGF sonucunda oluşan bileşenlere ait toplam varyans yüzdeleri (Sınıflandırma uygulaması için seçilen bileşenlere ait varyans değerleri gri renkte belirtilmiştir)

Bileşen No.	TBA			MGF		
	Sentinel-2	PRISMA (GYK Sensörü)	PRISMA (KDK Sensörü)	Sentinel-2	PRISMA GYK Sensörü	PRISMA (KDK Sensörü)
1	87.580	93.739	86.471	64.484	25.969	22.426
2	11.488	5.934	13.026	11.609	19.231	18.411
3	0.516	0.156	0.195	6.827	14.619	10.081
4	0.154	0.072	0.147	5.713	7.294	6.184
5	0.114	0.044	0.045	3.375	3.341	1.970
6	0.059	0.021	0.029	3.230	2.906	1.822
7	0.045	0.013	0.018	1.694	2.583	1.734
8	0.023	0.006	0.010	1.212	1.803	1.578
9	0.012	0.005	0.006	0.944	1.673	1.355
10	0.008	0.003	0.005	0.911	1.629	1.281
11		0.001	0.005		1.241	1.141
12		0.001	0.004		1.161	0.941
13		0.001	0.003		0.997	0.904
14		0.000	0.002		0.860	0.729
15		0.000	0.002		0.789	0.710
16		0.000	0.002		0.740	0.624
17		0.000	0.002		0.667	0.592
18		0.000	0.001		0.634	0.536
19		0.000	0.001		0.608	0.524
20		0.000	0.001		0.532	0.512



**Şekil 4.** TBA uygulaması sonucunda elde edilen ve sınıflandırma uygulamasında girdi verisi olarak kullanılan bileşenler: Sentinel-2 uydusu görüntüsü kullanılarak elde edilen 1(a), 2(b), 3(c), 5(d), 6(e), 7(f) numaralı bileşenler; PRISMA uydusunun GYK sensörü görüntüsüne ait 1(g), 2(h), 3(i), 4(j), 5(k), 7(l) numaralı bileşenler ve PRISMA uydusunun KDK sensörü görüntüsüne ait 1(m), 2(n), 3(o), 6(p), 7(r) ve 12(s) numaralı bileşenler



**Şekil 5.** MGF uygulaması sonucunda elde edilen ve sınıflandırma uygulamasında girdi verisi olarak kullanılan bileşenler: Sentinel-2 uydusu görüntüsü kullanılarak elde edilen 1(a), 2(b), 3(c), 4(d), 5(e), 6(f), 7(g) numaralı bileşenler; PRISMA uydusunun GYK sensörü görüntüsüne ait 1(h), 3(i), 4(j), 5(k), 6(l), 7(m), 8(n), 9(o) numaralı bileşenler ve PRISMA uydusunun KDK sensörü görüntüsüne ait 4(p), 5(r), 7(s), 11(t) ve 13(u) numaralı bileşenler

Şekil 6 incelendiğinde en fazla bilginin ilk bileşenlerde olduğu ve bileşenlerin özdeğerlerinin hızla azaldığı belirlenmiştir. İstatiksel olarak üretilen yamaç eğim grafikleri görsel analizler (Şekil 4 ve 5) ile desteklenmiştir. Bu kapsamda, eğimin az olduğu bileşenler ile eğimin yüksek olduğu bölgede bulunan bileşenler görsel olarak karşılaştırılmıştır. Eğimin yüksek olduğu bileşenler yüksek varyansa sahip olsa dahi yol, yerleşim, endüstri bölgelerinin sınıflandırılmasında, doğruluğu artırıcı verinin eğimin düşük olduğu bileşenlerde bulunduğu görülmüştür. Dolayısıyla, düşük varyansa sahip olan bileşenlerin yol, endüstri, yerleşim gibi sınıflar için özelleştiği ve bu bileşenlerin çalışma kapsamında yapılan detaylı

sınıflandırma işleminde doğruluğu yükselttiği tespit edilmiştir.

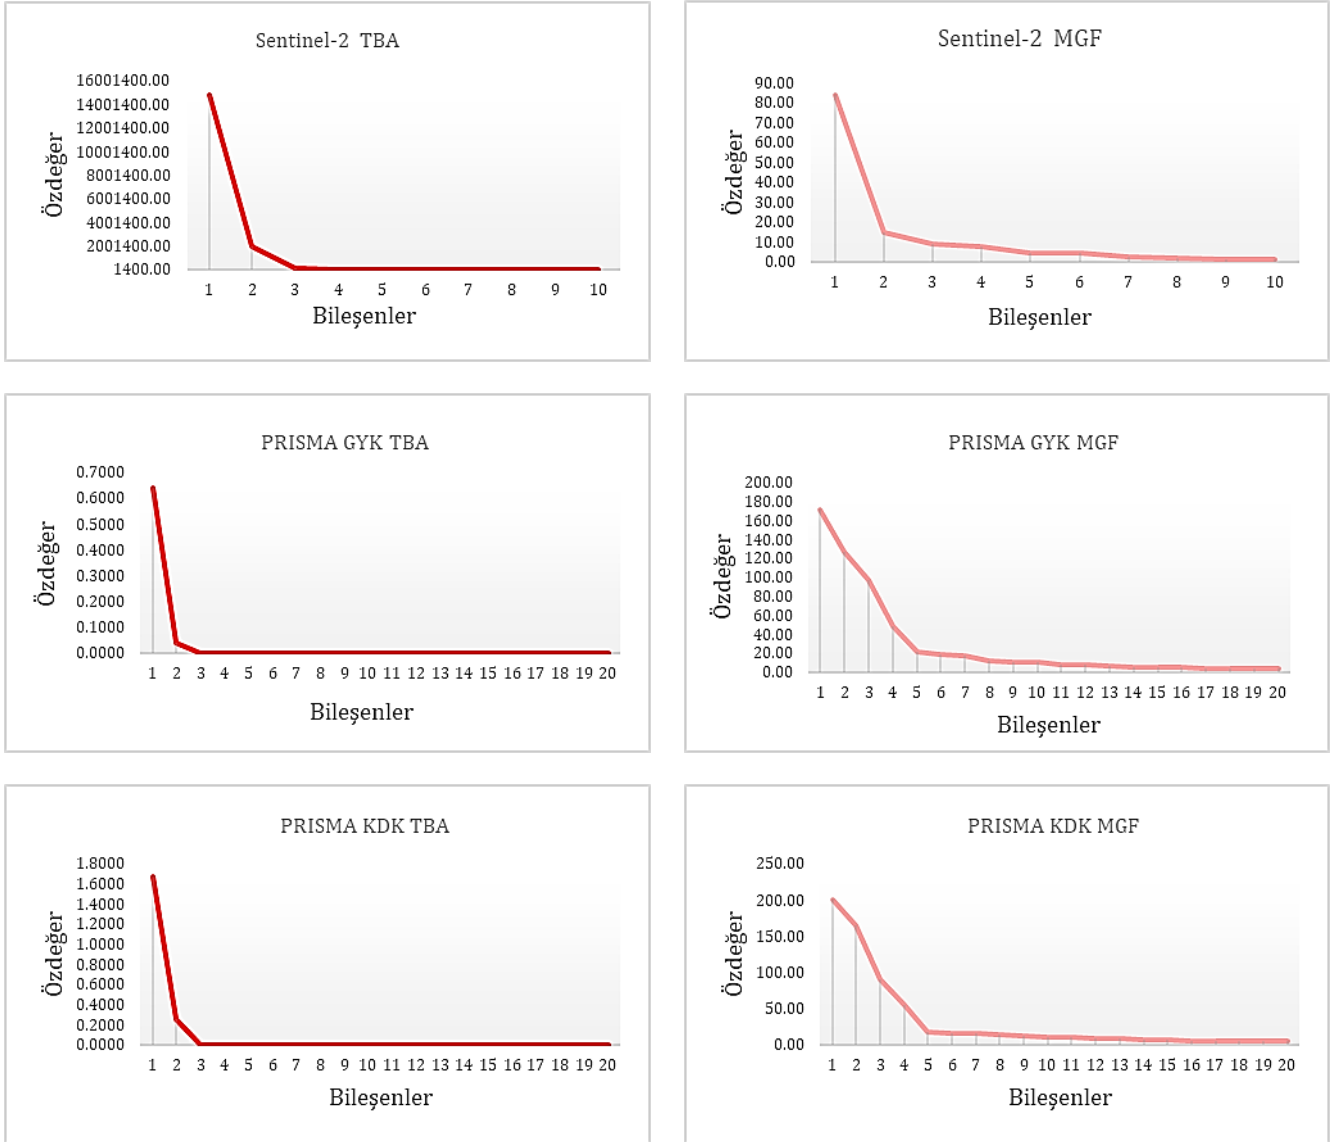
Uygun boyut indirgeme yaklaşımının ve bileşenlerinin belirlenmesinin ardından; Sentinel-2 ve PRISMA uydusu görüntülerine ait orijinal bantlara, TBA ve MGF sonucu elde edilmiş bileşenlerden oluşan veri setlerine, MOA ve DVM uygulanmış ve sınıflandırma sonucu elde edilen hassasiyet, geri çağırma ve F1 puanı değerleri Tablo 3, 4, 5 ve 6'da verilmiştir.

Sentinel-2 ve PRISMA uydusu görüntüleri sınıflandırmaları sonucunda tüm sınıflar için hesaplanan ortalama F1 puanı ve doğruluk değerleri de Şekil 7 'de gösterilmiştir.

Tüm doğruluk metrikleri incelendiğinde, Sentinel-2 uydu görüntüsüne ait orijinal bantlar üzerinde uygulanan MOA sınıflandırma sonuçları ile PRISMA görüntüsüne uygulanmış TBA sonucunda elde edilen bileşenlerden oluşturulan veri seti üzerinde uygulanan MOA sınıflandırma sonuçlarının yapılan çalışma kapsamında en yüksek doğruluk sonuçlarını verdiği belirlenmiştir. En yüksek sınıflandırma doğruluğu elde edilen sonuçlara ait tematik haritalar Şekil 8 ve Şekil 9'da gösterilmiştir.

Sınıflandırma sonuçları, Şekil 10. a, b'de bir örneği gösterildiği gibi Sentinel-2 uydu görüntüsünün 10 m

mekânsal çözünürlüğe sahip bantları ile karşılaştırılmıştır. Görsel inceleme sonucunda bazı bölgelerde nem oranı yüksek tarım arazileri (Şekil 10a) ve orman arazilerinin (Şekil 10b) PRISMA verisinde çoğunlukla "ekili tarım alanı" ve "orman" olarak doğru sınıflandırıldığı, ancak Sentinel-2'de bu bölgelerin "göl", "akarsu" ve "bataklık" gibi sınıflara atandığı belirlenmiştir. Ayrıca bir diğer çıkarım olarak, PRISMA verisinde yol sınıfının boş arazi sınıfı ile karıştığı, Sentinel-2 sonuçlarında ise yol deseninin daha net çıkartılabildiği ancak yer yer diğer sınıflarla karıştığı gözlemlenmiştir.



Şekil 6. Yamaç eğim test grafikleri

Tablo 3. Sentinel-2 için MOA sonuçlarına ait hassasiyet (H.), geri çağırma (G.) ve F1 puanı (F1) değerleri

Sınıf	Orijinal Görüntü			TBA			MGF		
	H.	G.	F1	H.	G.	F1	H.	G.	F1
Akarsu	0.90	1.0	0.95	0.70	0.91	0.79	0.87	0.96	0.91
Bataklık	0.93	0.90	0.92	0.83	0.76	0.79	0.93	0.90	0.92
Göl	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Orman	0.93	0.90	0.92	0.93	0.88	0.90	0.97	0.94	0.95
Ekili Tarım Alanı	0.90	0.84	0.87	0.87	0.84	0.85	0.90	0.84	0.87
Boş Arazi	0.93	0.88	0.90	0.93	0.82	0.88	0.97	0.78	0.87
Yol	0.77	1.0	0.87	0.73	1.0	0.85	0.77	1.0	0.87
Yerleşim & Sanayi	0.87	0.76	0.81	0.90	0.77	0.83	0.80	0.83	0.81



**Tablo 4.** PRISMA için MOA sonuçlarına ait hassasiyet (H.), geri çağırma (G.) ve F1 puanı (F1) değerleri

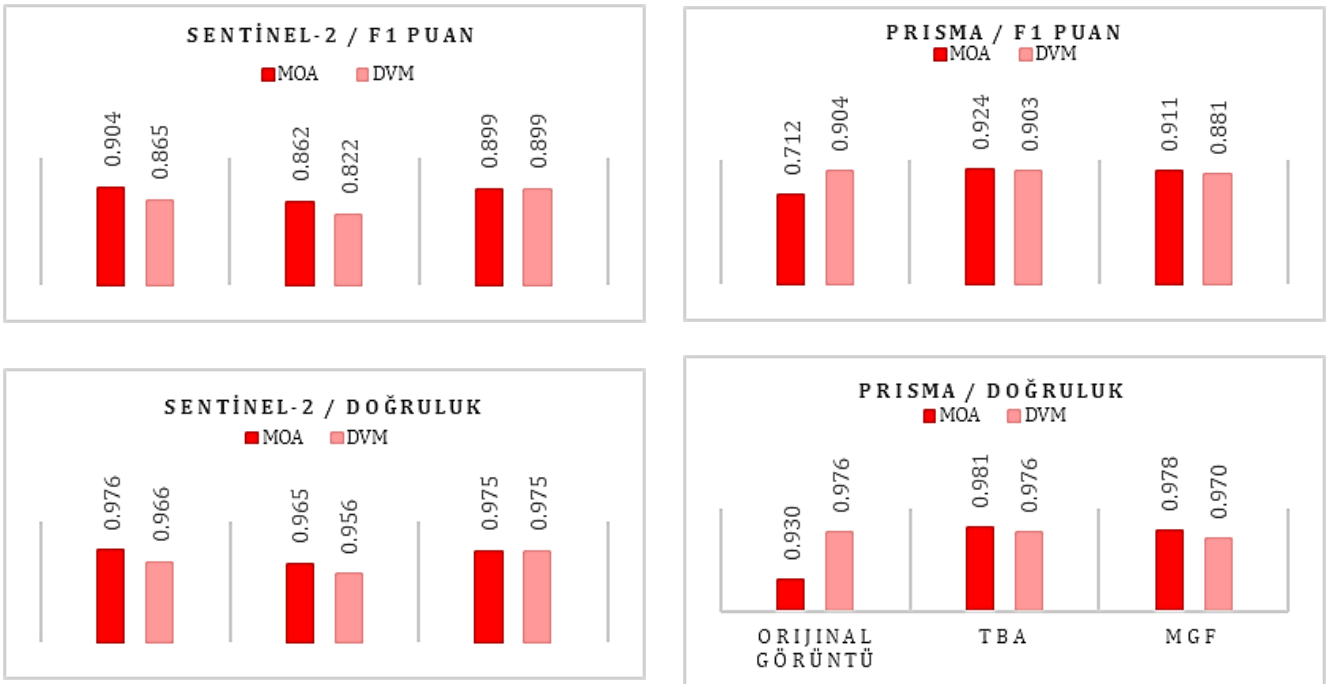
Sınıf	Orijinal Görüntü			TBA			MGF		
	H.	G.	F1	H.	G.	F1	H.	G.	F1
Akarsu	0.80	0.60	0.69	0.93	0.93	0.93	0.97	0.94	0.95
Bataklık	0.43	1.0	0.60	0.90	0.96	0.93	0.93	1.0	0.97
Göl	0.63	1.0	0.78	1.0	1.0	1.0	1.0	1.0	1.0
Orman	0.90	1.0	0.95	0.93	0.97	0.95	0.93	0.97	0.95
Ekili Tarım Alanı	0.97	0.57	0.72	1.0	0.86	0.92	0.97	0.88	0.92
Boş Arazi	0.87	0.72	0.79	0.97	0.94	0.95	0.97	0.85	0.91
Yol	0.33	1.0	0.50	0.70	1.0	0.82	0.63	1.0	0.78
Yerleşim& Sanayi	0.83	0.57	0.68	0.97	0.81	0.88	0.90	0.75	0.82

**Tablo 5.** Sentinel-2 için DVM algoritması sonuçlarına ait hassasiyet (H.), geri çağırma (G.) ve F1 puanı (F1) değerleri


Sınıf	Orijinal Görüntü			TBA			MGF		
	H.	G.	F1	H.	G.	F1	H.	G.	F1
Akarsu	0.87	1.0	0.93	0.77	1.0	0.87	0.87	0.96	0.91
Bataklık	0.97	0.91	0.94	0.90	0.93	0.92	0.93	0.90	0.92
Göl	1.0	1.0	1.0	1.0	0.97	0.98	1.0	1.0	1.0
Orman	0.97	0.88	0.92	0.97	0.85	0.91	0.97	0.94	0.95
Ekili Tarım Alanı	0.90	0.90	0.90	0.87	0.81	0.84	0.90	0.84	0.87
Boş Arazi	0.93	0.67	0.78	0.97	0.53	0.68	0.97	0.78	0.87
Yol	0.60	1.0	0.75	0.40	1.0	0.57	0.77	1.0	0.87
Yerleşim & Sanayi	0.70	0.72	0.71	0.73	0.92	0.81	0.80	0.83	0.81

**Tablo 6.** PRISMA için DVM algoritması sonuçlarına ait hassasiyet (H.), geri çağırma (G.) ve F1 puanı (F1) değerleri


Sınıf	Orijinal Görüntü			PCA			MNF		
	H.	G.	F1	H.	G.	F1	H.	G.	F1
Akarsu	0.83	0.93	0.88	0.77	0.96	0.85	0.73	0.92	0.81
Bataklık	0.97	0.97	0.97	0.93	0.90	0.92	0.93	0.93	0.93
Göl	1.0	0.97	0.98	1.0	0.94	0.97	1.0	0.97	0.98
Orman	0.97	0.94	0.95	0.97	0.91	0.94	0.97	0.88	0.92
Ekili Tarım Alanı	0.90	0.90	0.90	0.93	0.90	0.92	0.90	0.77	0.83
Boş Arazi	0.97	0.76	0.85	0.97	0.85	0.91	1.0	0.86	0.92
Yol	0.83	0.93	0.88	0.80	0.92	0.86	0.70	0.91	0.79
Yerleşim & Sanayi	0.77	0.88	0.82	0.87	0.87	0.87	0.83	0.86	0.85

**Şekil 7.** Sentinel-2 ve PRISMA uydu görüntüleri kullanılarak hesaplanan ortalama F1 puanı ve doğruluk değerleri (MOA: Maksimum Olabilirlik Algoritması, DVM: Destek Vektör Makineleri, TBA: Temel Bileşen Analizi, MGF: Minimum Görüntü Fraksiyonu)





**Şekil 8.** Sentinel-2 uydu görüntüsüne ait orjinal bantlar üzerinde uygulanan maksimum olabilirlik algoritmasına ait sınıflandırma sonucuna ait tematik harita



**Şekil 9.** PRISMA uydu görüntüsüne uygulanmış TBA sonucunda elde edilen bileşenlerden oluşturulan veri seti üzerinde uygulanmış maksimum olabilirlik algoritması sonucuna ait tematik harita

## 5. Tartışma ve Sonuç

Bu çalışmada, Susurluk Nehri ve çevresine ait multispektral ve hiperspektral uydu görüntülerine MOA ve DVM sınıflandırma yöntemleri uygulanarak ekili tarım alanı boş arazi, orman, yapı birimleri (yerleşim ve sanayi), yol, göl, akarsu, bataklık sınıfları olmak üzere toplamda sekiz sınıfın ayırt edilebilirlikleri incelenmiştir.

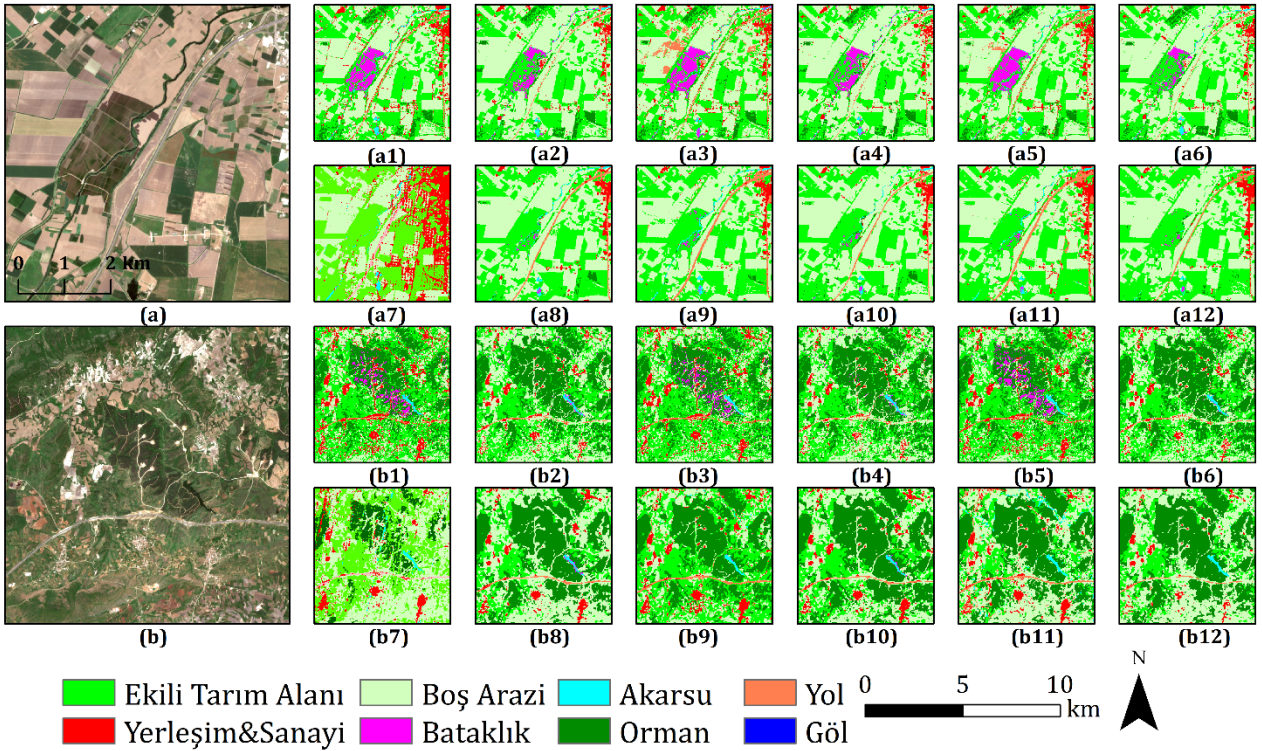
Değerlendirme metrikleri kapsamında ortalama F1 puanları ve doğruluk değerleri incelendiğinde; Sentinel-2 verisi için en yüksek ortalama F1 puanı (0.904) ve doğruluk değeri (0.976) orijinal görüntüsüne uygulanan MOA sonucunda elde edilmiştir. PRISMA uydu görüntüsü ile yapılan sınıflandırma sonuçları ele alındığında ise en yüksek doğruluk değeri (0.981) ve ortalama F1 puanı (0.924) TBA sonucu elde edilen bileşenler üzerine uygulanan MOA sonucunda elde edilmiştir ve bu sonuçlar, PRISMA ve Sentinel-2 uydu görüntülerine ait bütün metrikler ele alındığında elde edilen en yüksek değerlerdir.

PRISMA orijinal görüntüsüne uygulanan MOA sonucunda ise en düşük F1 puanı (0.712) ve doğruluk değeri (0.930) elde edilmiştir. Bu sonuç görsel olarak incelendiğinde bantlardaki gürültülerin sınıflandırma sonucuna yansıdığı gözlemlenmiş olup diğer sınıflandırma sonuçlarında böyle bir sonuca rastlanmamıştır.


Sentinel-2 ve PRISMA verilerine MOA uygulanması sonucunda hesaplanan hassasiyet, geri çağırma ve F1 puan değerleri sınıf bazında incelendiğinde; "göl" sınıfının Sentinel-2 için orijinal ve boyut indirgenmiş görüntülerde ve PRISMA için sadece boyut indirgeme yöntemleri uygulanmış görüntülerde %100 doğrulukla

sınıflandırıldığı belirlenmiştir. PRISMA uydu verisine ait TBA ve MGF bileşenleri kullanılarak sınıflandırılmış görüntülerde akarsu, bataklık, orman, ekili tarım alanları, boş arazi ve yerleşim & sanayi sınıflarının genel olarak metrik değerlerinin Sentinel-2'den daha yüksek olduğu tespit edilmiştir. Sentinel-2 ve PRISMA uydu görüntülerine ait tüm sınıflandırma sonuçları incelendiğinde yol sınıfı için hesaplanan geri çağırma değerlerinin yüksek (1.00) olduğu ancak hassasiyet değerlerinin ise düşük olduğu tespit edilmiştir. Bu durum düşük F1 puanlarına sebep olmuştur. Sınıflandırma sonuçlarına ait tematik haritalar incelendiğinde mekânsal çözünürlüğe bağlı olarak ara yolların hassas bir şekilde tespit edilmediği gözlemlenmiştir.

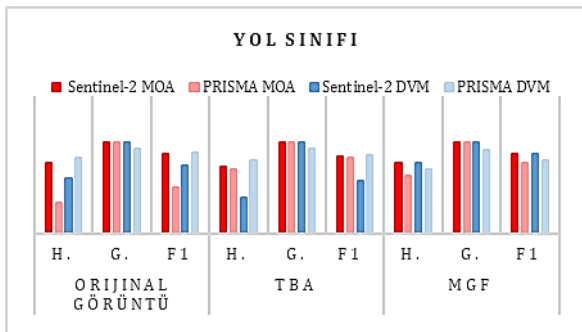
Sentinel-2 ve PRISMA verilerine DVM yöntemi uygulanması sonucunda hesaplanan hassasiyet, geri çağırma ve F1 puanları sınıf bazında incelendiğinde; akarsu ve göl sınıflarının Sentinel-2 sonuçları genelinde daha yüksek değerlere sahip olduğu (Şekil 11); yerleşim & sanayi, orman ve boş arazi sınıflarının ise PRISMA sonuçları genelinde daha iyi sonuç verdiği gözlemlenmiştir. Ekili tarım alanı sınıfının geri çağırma ve F1 puanı değerleri boyut indirgeme yöntemleri uygulanmış Sentinel-2 uydu görüntüsünde daha yüksek elde edilmiştir. Yol sınıfının metrik değerlerinin MGF uygulanmış Sentinel-2 uydu görüntüsünde daha yüksek olduğu görülmüştür. Aynı zamanda yol sınıfının Sentinel-2 uydu görüntüsünde tüm geri çağırma değerleri yüksek iken hassasiyet değerlerinin daha düşük olduğu tespit edilmiştir. Sentinel-2 uydu görüntülerinde yol sınıfının düşük hassasiyet değeri, düşük F1 puanına sebep olmuştur. Sonuçlar Şekil 12' de incelenebilir.



**Şekil 10.** a,b )Sentinel-2 referans görüntüsü; a1,b1) Sentinel-2 orijinal görüntüye uygulanmış MOA Sonucu; a2,b2) Sentinel-2 Orijinal Görüntüye Uygulanmış DVM Sonucu; a3,b3) Sentinel-2 TBA Sonucu Seçilen Bileşenlere Uygulanmış MOA Sonucu; a4,b4) Sentinel-2 TBA Sonucu Seçilen Bileşenlere Uygulanmış DVM Sonucu; a5,b5) Sentinel-2 MGK Sonucu Seçilen Bileşenlere Uygulanmış MOA Sonucu; a6,b6) Sentinel-2 MGK Sonucu Seçilen Bileşenlere Uygulanmış DVM Sonucu); a7,b7) PRISMA Orijinal Görüntüye Uygulanmış MOA Sonucu; a8,b8) PRISMA Orijinal Görüntüye Uygulanmış DVM Sonucu; a9,b9) PRISMA TBA Sonucu Seçilen Bileşenlere Uygulanmış MOA Sonucu; a10,b10) PRISMA TBA Sonucu Seçilen Bileşenlere Uygulanmış DVM Sonucu; a11,b11) PRISMA MGK Sonucu Seçilen Bileşenlere Uygulanmış MOA Sonucu; a12,b12) PRISMA MGK Sonucu Seçilen Bileşenlere Uygulanmış DVM Sonucu



**Şekil 11.** DVM algoritması sonucunda akarsu ve göl sınıfına ait metrik değerlerin karşılaştırılması



**Şekil 12.** Yol sınıfı için hesaplanan geri çağırma değerlerinin hassasiyet değerleriyle karşılaştırılması (DVM: Destek Vektör Makineleri, MOA: Maksimum Olabilirlik Algoritması, H: Hassasiyet, G: Geri Çağırma, F1: F1 puan, TBA: Temel Bileşen Analizi, MGF: Minimum Gürültü Fraksiyonu)

Li ve ark. (2014) kompleks AÖ/AK sınıflarını içeren Guangzhou'ya (Çin) ait Landsat uydu görüntülerini kullanarak iki adet kontrolsüz ve on üç adet kontrollü sınıflandırma algoritmasını karşılaştırdıklarında DVM sonucuna göre MOA sınıflandırıcısıyla daha yüksek doğruluk elde etmişlerdir. Li ve ark., (2014) çalışmasında ulaşılan sonuca benzer olarak bu makalede de uygulanan sınıflandırmaların tamamına yakınında MOA sınıflandırıcısı ile daha yüksek doğruluğa ulaşılmıştır.

Vangi ve ark. (2021) çalışmasında orman alanlarında PRISMA uydu görüntüsüyle Sentinel-2 uydu görüntüsüne göre daha yüksek doğruluğa sahip sonuçlar elde etmişlerdir. Bu çalışmada da Sentinel-2 uydu görüntüsü kullanılarak ve PRISMA uydu görüntüsü kullanılarak elde edilen en yüksek doğruluğa sahip sonuçların sınıf bazında doğrulukları incelendiğinde Vangi ve ark. (2021) çalışması sonunda elde edilen bulguyu destekler doğrultuda, orman sınıfı PRISMA uydu verisi (H:0.93, G:0.97, F1: 0.95) ile Sentinel-2 uydu verisine (H: 0.93, G: 0.90, F1: 0.92) göre daha yüksek doğrulukla sonuç üretmiştir.

Gelecekte yapılacak benzer çalışmalarda; farklı boyut azaltma yöntemleri ile farklı veri setleri üretilerek çeşitli makine öğrenmesi algoritmaları ve Evrimsel Sınır Ağları (Convolutional Neural Networks- CNN) gibi derin öğrenme yaklaşımlarıyla sınıflandırma doğrulukları artırılabilir.

## Bilgilendirme/Teşekkür

Bu çalışma, İtalyan Uzay Ajansı'nın (ASI) ©, Lisansı altında teslim edilen PRISMA Ürünleri kullanılarak gerçekleştirilmiştir. Yazarlar, 121G142 proje numaralı Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) Projesi'ne ve MDK-2021-43054 numaralı İstanbul Teknik Üniversitesi Bilimsel Araştırmalar Projesine desteği için teşekkür etmektedir.

## Araştırmacıların Katkı Oranı

**Buse Tırmanoğlu:** Literatür taraması, Makale yazımı, Düzenleme, Analiz-Uygulama; **İrem İsmailoğlu:** Düzenleme, Analiz-Uygulama; **Aylin Tuzcu Kokal:** Literatür taraması, Makale yazımı, Düzenleme; **Nebiye Musaoğlu:** Makale yazımı, Düzenleme

## Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

## Kaynakça

Ahady, A. B. & Kaplan, G. (2022). Classification comparison of Landsat-8 and Sentinel-2 data in Google Earth Engine, study case of the city of Kabul. *International Journal of Engineering and Geosciences*, 7(1), 24-31.

Aizerman, M. A. (1964). Theoretical foundations of the potential function method in pattern recognition learning. *Automation and remote control*, 25, 821-837.

Akar, Ö. & Tunç Görmüş, E. (2019). Göktürk-2 ve Hyperion EO-1 Uydu Görüntülerinden Rastgele Orman Sınıflandırıcısı ve Destek Vektör Makineleri ile Arazi Kullanım Haritalarının Üretilmesi. *Geomatik*, 4(1), 68-81.

Akça, M. D., & Doğan, S. (2002). Sayısal görüntülerde ana bileşenler dönüşümü. *Harita dergisi*, 69(128), 1-15.

Apaydın, C., & Abdikan, S. (2021). Fındık bahçelerinin Sentinel-2 verileri kullanılarak piksel tabanlı sınıflandırma yöntemleriyle belirlenmesi. *Geomatik*, 6(2), 107-114.

ASI, (2020). PRISMA Products Specification Document, [Erişim Tarihi: 10.05.2022], [http://prisma.asi.it/missionselect/docs/PRISMA%20Product%20Specifications\\_Is2\\_3.pdf](http://prisma.asi.it/missionselect/docs/PRISMA%20Product%20Specifications_Is2_3.pdf)

ASI, (2022). Hyperspectral Satellite, Capable of Observing from the Optical to the Near Infrared, Roma, [Erişim Tarihi: 12.05.2022], <https://www.asi.it/en/earth-science/prisma/>

Awad, M., & Khanna, R. (2015). Support vector machines for classification. In *Efficient learning machines* (pp. 39-66). Apress, Berkeley, CA.

Cattell, R. B. (1966). The scree test for the number of factors. *Multivariate behavioral research*, 1(2), 245-276.

Çetin, M. (2007). Sündiken Kütlesi'ndeki Yükselti-İklim Kuşaklarının ve Orman Toplumlarının Özelliklerinin Uydu Görüntüleri ile Belirlenmesi. Doktora Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 146p.

Clevers, J. G. P. W. (2000). Centre for Geo Information, Maximum likelihood classification. Wageningen University and Research Centre, Hollanda. [Erişim Tarihi: 12.05.2022]: <http://www.geo-informatie.nl/courses/grs20306/lectures/default.htm>

Çömert, R., Matcı, D. K., & Avdan, U. (2019). Object based burned area mapping with random forest algorithm. *International Journal of Engineering and Geosciences*, 4(2), 78-87.

Copernicus, (2022). Copernicus Open Access Hub, [Erişim Tarihi: 11.05.2022], <https://scihub.copernicus.eu/dhus/#/home>

Dabiri, Z., & Lang, S. (2018). Comparison of independent component analysis, principal component analysis, and minimum noise fraction transformation for tree species classification using APEX hyperspectral imagery. *ISPRS International Journal of Geo-Information*, 7(12), 488.

Delalay, M., Tiwari, V., Ziegler, A. D., Gopal, V., & Passy, P. (2019). Land-use and land-cover classification using Sentinel-2 data and machine-learning algorithms: operational method and its implementation for a mountainous area of Nepal. *Journal of Applied Remote Sensing*, 13(1), 014530.

ED Chaves, M., CA Picoli, M., & D. Sanches, I. (2020). Recent applications of Landsat 8/OLI and Sentinel-2/MSI for land use and land cover mapping: A systematic review. *Remote Sensing*, 12(18), 3062.

Elmahdy, S., Mohamed, M., & 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), 1715.

ERDAS, (2003). ERDAS Field Guide™, 7.Baskı, GIS & Mapping, LLC, Atlanta, Georgia, USA, [Erişim Tarihi: 13.05.2022], <http://www.geoservis.ftn.uns.ac.rs/downloads/ISP/FieldGuide.pdf>

ESA, (2022). Sentinel-2 Colour Vision for Copernicus. [Erişim Tarihi: 12.05.2022], [https://www.esa.int/Applications/Observing\\_the\\_Earth/Copernicus/Sentinel-2](https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2)

Fisher, R. A. (1912). On an absolute criterion for fitting frequency curves. *Messenger of mathematics*, 41, 155-156.

Ha, N. T., Manley-Harris, M., Pham, T. D., & 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), 355.

Hidalgo, D. R., Cortés, B. B., & Bravo, E. C. (2021). Dimensionality reduction of hyperspectral images of vegetation and crops based on self-organized maps. *Information Processing in Agriculture*, 8(2), 310-327.

Holland, S. M. (2019). Principal Components Analysis (PCA). Department of Geology University of Georgia, Athens, GA, 30602-2501. [Erişim Tarihi: 12.05.2022] <http://strata.uga.edu/software/pdf/pcaTutorial.pdf>

İlhan, F. (2007). Faktör Analizi ve Tarımsal Araştırmalarda Elde Edilen Verilere Uygulanması



- Üzerine Bir Çalışma. Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, 55p.
- Karakuş, P., Karabork, H., & Kaya, S. (2017). A comparison of the classification accuracies in determining the land cover of Kadirli Region of Turkey by using the pixel based and object based classification algorithms. *International Journal of Engineering and Geosciences*, 2(2), 52-60.
- Lazzeri, G., Frodella, W., Rossi, G., & Moretti, S. (2021). Multitemporal Mapping of Post-Fire Land Cover Using Multiplatform PRISMA Hyperspectral and Sentinel-UAV Multispectral Data: Insights from Case Studies in Portugal and Italy. *Sensors*, 21(12), 3982.
- Li, C., Wang, J., Wang, L., Hu, L., & Gong, P. (2014). Comparison of classification algorithms and training sample sizes in urban land classification with Landsat thematic mapper imagery. *Remote sensing*, 6(2), 964-983.
- Loizzo, R., Guarini, R., Longo, F., Scopa, T., Formaro, R., Facchinetti, C., & Varacalli, G. (2018, July). PRISMA: The Italian hyperspectral mission. In *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium* (pp. 175-178). IEEE.
- Nguyen, H. T. T., Doan, T. M., Tomppo, E., & McRoberts, R. E. (2020). Land Use/land cover mapping using multitemporal Sentinel-2 imagery and four classification methods—A case study from Dak Nong, Vietnam. *Remote Sensing*, 12(9), 1367.
- Öztürk, E., & Küçük, F. (2017). Simav Çayı'nın balık faunası. *Süleyman Demirel Üniversitesi Eğirdir Su Ürünleri Fakültesi Dergisi*, 13(2), 132-152.
- PRISMA ASI, (2022). WSO2 Identity Server, [Erişim Tarihi: 12.05.2022], <https://prisma.asi.it/>
- Ramsar, (1998). Ramsar Sites Information Service, Lake Uluabat, [Erişim Tarihi: 11.05.2022], <https://rsis.ramsar.org/ris/944>
- Randazzo, G., Cascio, M., Fontana, M., Gregorio, F., Lanza, S., & Muzirafuti, A. (2021). Mapping of Sicilian Pocket Beaches Land Use/Land Cover with Sentinel-2 Imagery: A Case Study of Messina Province. *Land*, 10(7), 678.
- Ringnér, M. (2008). What is principal component analysis?. *Nature biotechnology*, 26(3), 303-304.
- Sarı, E. (2018). Doğrulayıcı Faktör Analizi ve Rüzgâr Enerjisi Ölçeğine Uygulaması. Bursa Uludağ Üniversitesi Yüksek Lisans Tezi. Sosyal Bilimleri Enstitüsü, Bursa, 71p.
- Sisodia, P. S., Tiwari, V., & Kumar, A. (2014, May). Analysis of supervised maximum likelihood classification for remote sensing image. In *International conference on recent advances and innovations in engineering (ICRAIE-2014)* (pp. 1-4). IEEE.
- Steinhausen, M. J., Wagner, P. D., Narasimhan, B., & Waske, B. (2018). Combining Sentinel-1 and Sentinel-2 data for improved land use and land cover mapping of monsoon regions. *International journal of applied earth observation and geoinformation*, 73, 595-604.
- SUHET, (2015). ESA Standard Document Sentinel-2 User Handbook. European Space Agency Agence Spatiale Européenne, [Erişim Tarihi: 11.05.2022]. [http://sentinel.esa.int/documents/247904/685211/Sentinel-2\\_User\\_Handbook](http://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook)
- Tadesse, H. K., Qu, J. J., Aguirre, A. A., Komba, M., & Maggioni, V. (2017). Land use classification and analysis using radar data mining in Ethiopia. *International Journal of Advanced Remote Sensing and GIS*, 1(6), 2006-2022.
- Tharwat, A. (2020). Classification assessment methods. *Applied Computing and Informatics*, 17(1), 168-192.
- Topaloğlu, R. H., Sertel, E., & Musaoğlu, N. (2016). Assessment of classification accuracies of Sentinel-2 and Landsat-8 data for land cover/use mapping. *International archives of the photogrammetry, remote sensing & spatial Information Sciences*, 41.
- Tso, B., & Mather, P. M. (2009). Classification methods for remotely sensed data. US, CRC Press.
- Tuzcu Kokal, A., İsmailoğlu, İ., & Musaoğlu, N. (2022). Comparison of LANDSAT-9 and Prisma Satellite Data for Land Use/Land Cover Classification. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 46, 197-201.
- Vangi, E., D'Amico, G., Francini, S., Giannetti, F., Lasserre, B., Marchetti, M., & Chirici, G. (2021). The new hyperspectral satellite PRISMA: Imagery for forest types discrimination. *Sensors*, 21(4), 1182.
- Vapnik, V. (2013). The nature of statistical learning theory. Springer Science & Business Media.
- Vapnik, V. N. (1979). Reconstruction of Dependences from Empirical Data.
- Yılmaz, O. S., Gülgen, F., Güngör, R., & Kadı, F. (2018). Uzaktan algılama teknikleri ile arazi kullanım değişiminin incelenmesi: Köprübaşı İlçesi örneği. *Geomatik*, 3(3), 234-241.
- Zabcı, C. (2021). Çok bantlı Landsat 8-OLI ve Sentinel-2A MSI uydu görüntülerinin karşılaştırmalı jeoloji uygulaması: Örnek çalışma alanı olarak Doğu Anadolu Fayı boyunca Palu-Hazar Gölü bölgesi (Elazığ, Türkiye). *Geomatik*, 6(3), 238-246.
- Zhang, T., Su, J., Xu, Z., Luo, Y., & Li, J. (2021). Sentinel-2 satellite imagery for urban land cover classification by optimized random forest classifier. *Applied Sciences*, 11(2), 543.

