





Google Earth Engine ile arazi kullanımı haritalarının üretimi Producing land use maps with Google Earth Engine

Majid Aghlmand¹ , Kaan Kalkan^{2,*} , Mehmet İnanç Onur¹ , Gürkan Öztürk³ ,
Ecem Ulutak⁴ 

¹ Eskişehir Teknik Üniversitesi, İnşaat Mühendisliği Bölümü, Eskişehir, Türkiye

² TÜBİTAK Uzay Teknolojileri Araştırma Enstitüsü, Ankara, Türkiye

³ Eskişehir Teknik Üniversitesi, Endüstri Mühendisliği Bölümü, Eskişehir, Türkiye

⁴ Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, Eskişehir, Türkiye

Özet

Sürekli gelişen şehirler, nüfus artışı ve iklimsel koşullar gibi ekosistem de meydana gelen olumsuz etkenler ile arazi kullanımı değişime uğramaktadır. Uzaktan algılama uyduları tarafından üretilen veriler, yeryüzü araştırmalarda önemli bir rol oynamaktadır. Arazi örtüsü/kullanımı haritaları bu veriler kullanılarak hazırlanmaktadır. Arazi örtüsü haritaları, su ve biyokimyasal döngüler, enerji değişimleri veya biyolojik çeşitlilik değişiklikleri gibi çevresel süreçleri daha iyi anlamamıza yardımcı olur. Bu çalışma, Google Earth Engine bulut platformunda arazi kullanım haritalarının üretilebilirliğini test etmek amacıyla gerçekleştirilmiştir. Bu amaçla 01/01/2019 ve 01/01/2020 tarihleri arasında Landsat 8, Sentinel 1 ve Sentinel 2 uyduları tarafından çekilen tüm görüntüler kullanılmıştır. Daha sonra 5 farklı indeks; NDVI (Normalleştirilmiş fark bitki örtüsü endeksi), EVI(Gelişmiş Bitki Örtüsü Endeksi), NDWI (Normalleştirilmiş fark su endeksi), NDBI (Normalleştirilmiş fark oluşturma endeksi) ve UI (Kentsel indeks) hesaplanmış ve 19 farklı veri kombinasyonu dikkate alınmıştır. Daha sonra bu kombinasyonların her biri Destek Vektör Makineleri yöntemi(LibSVM) kullanılarak 5 sınıfa (Şehir alanı-yollar, su, ormanlık-koruluk, tarım dışı araziler ve tarım arazileri) ayrılmıştır. Her sınıflandırma için genel doğruluk ve Kappa Katsayısı hesaplanmış ve sonuçlar karşılaştırılmıştır. En iyi sınıflandırma, Landsat8, Sentinel-2, Sentinel-1 (VV), Landsat 8'den NDVI, Sentinel-2'den NDVI, NDBI, UI ve NDWI veri kombinasyonuna aittir. Bu kombinasyonda toplam doğruluk 96.62 ve kappa katsayısı 95.76 olmuştur.

Anahtar kelimeler: Arazi kullanım haritaları, Eskişehir, Google Earth Engine, Kontrollü sınıflandırma, Uzaktan algılama

1 Giriş

Küresel iklim değişikliğinin sonuçları gün geçtikçe kendisini hissettirmektedir [1]. Gelişen şehirler ve büyüyen insan nüfusu ile birlikte arazi kullanımlarının değerlendirilmesi ve analizi oldukça önemlidir. Küresel iklim değişikliğinin neden ve sonuçları ile alınması gereken önlemler belirlenmelidir [2]. Uzaktan algılama ve uydu görüntüleri sayesinde arazi kullanımının gözlemi ve analizini yapabilmek mümkündür. Son birkaç yıl içerisinde ortaya çıkan orta ve yüksek çözünürlüklü uydu görüntüleri ile uzaktan algılama yöntemleri ve uygulamalarına yenileri eklenmiştir [3, 4].

Uzaktan algılama görüntülerinden üretilen arazi örtüsü haritaları, arazi kaynakları yönetimi, kentsel planlama, hassas tarım ve çevre koruma gibi birçok alanda önemli bir rol oynamaktadır [5-8]. Arazi örtüsü haritaları, su ve biyokimyasal döngüleri, enerji değişimleri veya biyolojik

Abstract

Land use are changing due to negative factors occurring in the ecosystem such as continuously developing cities, population growth, and climatic conditions. Data produced by remote sensing satellites play an essential role in ground-based research. Land cover maps are prepared using this data. Land cover maps help us better understand environmental processes such as water and biogeochemical cycles, energy changes, or biodiversity changes. This study was carried out to test the producibility of land use maps on the Google Earth Engine cloud platform. All images acquired between 01/01/2019 and 01/01/2020 from Landsat 8, Sentinel 1, and Sentinel 2 were used in this study. Then 5 different indices NDVI, NDWI, NDBI, Ui, and EVI were calculated, and 19 different combinations of data were considered. Then, for each of these combinations, classification was performed by the LibSVM method in 5 classes: Urban Roads, Water, Forest-Grove, Non-agricultural Lands, and Agricultural Lands. Overall Accuracy and Kappa Coefficient were calculated for each classification, and results were compared. The best classification with Overall Accuracy 96.62 and Kappa Coefficient 95.76 belongs to the data combination of Landsat 8, Sentinel-1(VV), Sentinel-2, NDVI, NDBI, UI and NDWI from Sentinel-2 and NDVI from Landsat 8.

Keywords: Land use maps, Eskişehir, Google Earth Engine, Supervised classification, Remote sensing

çeşitlilik değişiklikleri gibi çevresel süreçleri daha iyi anlamamıza yardımcı olur [9].

Arazi örtüsü, temel iklim değişkeni olarak kabul edilmiştir ve ayrıca uzaktan algılama temel biyo-çeşitlilik değişkeni olarak önerilmiştir [10, 11]. Arazi örtüsünün, tematik ve yüksek çözünürlükte görüntülenebilir olması dünya yüzeyinin kolay bir şekilde izlenmesini ve karşılaştırma yapılmasını sağlamaktadır [12].

Bu sayede yeni nesil arazi kullanım analizleri ve haritaları ortaya çıkmıştır [13, 14]. Arazi kullanım haritalaması birkaç basamaktan oluşmaktadır. Bu basamaklar; verilerin seçilmesi, verilerin işlenmesi ve sınıflandırma işlemleridir. Eğer seçilen alan, ulusal veya bölgesel olarak seçilmiş ve oldukça büyük ise, verinin işlenmesinde sorunlar yaşanabilmektedir. Bir yıla ait büyük bir alanda pek çok uydu görüntüsünden yararlanılması gerektiği için bulutluluk oranı, verilerin büyüklüğü ve işlenmesi aşamalarında zorluklar yaşanabilmektedir.

* Sorumlu yazar / Corresponding author, e-posta / e-mail: kalkaan@gmail.com (K. Kalkan)

Geliş / Recieved: 16.09.2020 Kabul / Accepted: 02.01.2021 Yayınlanma / Published: 15.01.2021

doi: 10.28948/ngumuh.795977

Ücretsiz olarak uydu görüntüsü elde etmek gün geçtikçe daha kolay hale gelmektedir. Copernicus programı [15] buna bir iyi örnektir. Sentinel-1 [16] ve Sentinel-2 [17] European Space Agency (ESA) Copernicus'a ait olan, iklim değişimi, güvenlik ve acil durum müdahalesi gibi durumlarda kullanılan ve veri sürekliliğini sağlamak için kullanılan uydulardır Sentinel-1 uydusunda bulunan radar sensörü bulutlardan etkilenmemektedir. Sentinel-1, Sentinel-2 ve Landsat 8 [18] uydu görüntülerine Google Earth Engine (GEE) [19] üzerinden kolay bir şekilde erişim sağlanabilmektedir. GEE uygulaması görüntüleri işlemede yerel saklama yerine bulut ortamında veriyi işlemeyi sağlamaktadır. Bu sayede bilgisayar özelliklerine bakılmaksızın istenilen sayıda görüntü sayısı çok daha hızlı ve kolay bir şekilde yapılabilmektedir. Bu tip platformlar sayesinde araştırmacılar büyük alanlarda büyük boyutta verileri analiz ederek sonuç elde edebilmektedir GEE büyük ölçekli verilerde hem donanımsal olarak güçlü bilgisayarlarla olan ihtiyacı azalmakta hem de kısa bir zaman diliminde analizi gerçekleştirerek kullanıcıların tasarruf yapmalarını sağlamaktadır [20]. GEE uygulamasında yer alan veri setleri oldukça zengindir. Farklı uydulara ait pek çok tarih aralığında bulunan uydu görüntülerini kullanabilmek mümkündür [21]. GEE kullanırken piksel seçimlerinde mean, median, min, max v.b. farklı yöntemler bulunmaktadır. Aynı zamanda GEE aracı ile bulut oranlarının az olduğu bölgeleri seçerken kod panelinden yararlanılarak bulutluluk oranının istenildiği şekilde seçilebilmesi mümkündür [22].

Farklı arazi örtüsü sınıfları göz önüne alınarak, uzaktan algılama alanında kullanılan birçok farklı yöntem değerlendirilerek, uzaktan algılanmış görüntülerde spektral ve spektral-uzamsal özelliklerin kullanımı farklı çalışmalarda araştırılmıştır [23–25].

NDVI(Normalleştirilmiş fark bitki örtüsü endeksi) ve EVI(Gelişmiş Bitki Örtüsü Endeksi) gibi indekslerin arazi kullanımı haritalamasında kullanımı bu haritaların üretilmesinde verimliliği arttırmaktadır. Bu indeksler sayesinde farklı alanların biyokütelleri hakkında bilgi edilebilmektedir. Ayrıca, yaprak alan indeksi, biyokütle, kapalılık, fotosentez aktivitesi ve üretkenliği gibi analizler gerçekleştirilebilir [26, 27]. NDWI(Normalleştirilmiş fark su endeksi) su alanlarının bulunmasında ve bitkilerdeki su içeriğinin tespitinde verimli bir şekilde kullanılan bir indekstir [28]. Uydu görüntülerinde, yapılaşmış alanlar ile toprak alanlarını ayırt etmek genellikle zordur, bu arazi kullanımı türlerinin ayrılmasında doğruluğu arttıran

NDBI(Normalleştirilmiş fark oluşturma indeksi) ve Ui(Kentsel indeks) gibi indeksler kullanılmaktadır [29, 30].

Bu çalışma, Landsat 8, Sentinel-1 ve Sentinel-2 uydularından elde edilen verileri kullanarak Eskişehir ili arazi kullanımı haritalarının üretiminde en iyi doğruluğu elde etmek amacıyla yapılmıştır. Bu amaçla, 01/01/2019 ve 01/01/2020 döneminde bu üç uydudan çekilen tüm görüntüler işleme alınmıştır. Ayrıca, sınıflandırmada NDVI, EVI, NDWI, NDBI ve Ui indeksleri hesaplanmıştır. Sınıflandırmanın temel verisini Landsat 8 oluşturacak şekilde planlanarak, tüm katmanların çözünürlüğü 30 metreye yeniden örneklenmiştir. Ardından, GEE'de LIBSVM yöntemini seçerek sınıflandırma farklı kombinasyonlarda adım adım gerçekleştirilmiştir. Her sınıflandırma için Overall Accuracy ve Kappa Coefficient değerleri hesaplanmış ve sonuçlar karşılaştırılmıştır.


2 Materyal ve metod

2.1 Çalışma alanı

Çalışma alanı olarak Eskişehir ili seçilmiştir (Şekil 1). Eskişehir kuzeyinde Karadeniz, kuzeybatıda Marmara, batı ve güneybatıda Ege bölgesi ile komşu olmakla birlikte İç Anadolu Bölgesi'nin kuzeybatısında yer almaktadır. Eskişehir'in deniz yüksekliği ise 792 metredir. Eskişehir'in Seyitgazi, Sarıcakaya, Mihallıçık ilçelerinde farklı iklimler görülse de Eskişehir'in genel coğrafi karakteri İç Anadolu Bölgesine benzemektedir. Eskişehir'in alanı yaklaşık 13,653 km²'dir. Eskişehir'in kuzeyinde Bozdağ ve Sündiken dağları, güneyinde Emirdağ, doğuda Orta Asya vadisi ve batısında Türkmen dağları bulunmaktadır. Türkiye'nin tüm alanı ile Eskişehir oranlandığında Eskişehir ili Türkiye'nin %1.8'ini oluşturmaktadır [31]

2.2 Google Earth Engine (GEE)

GEE, bulut tabanlı coğrafi veri işleme platformudur ve tüm analizleri çok kısa bir sürede gerçekleştirmeyi sağlamaktadır. Google destekli platformda bulunan ve toplanan veriler herkesin erişimine açık olarak sunulmuştur. Ağaç, orman ve su alanları, arazi kullanımındaki değişiklikleri veya tarım alanlarının sağlığını değerlendirmek için GEE'yi kullanabilmek mümkündür. GEE, son 40 yıl içerisinde küresel ölçekli birçok veriyi sunmaktadır. Platform veri sunmakla kalmayıp aynı zamanda analiz yapmayı sağlayan oldukça güçlü araçlar içermektedir [32–35].



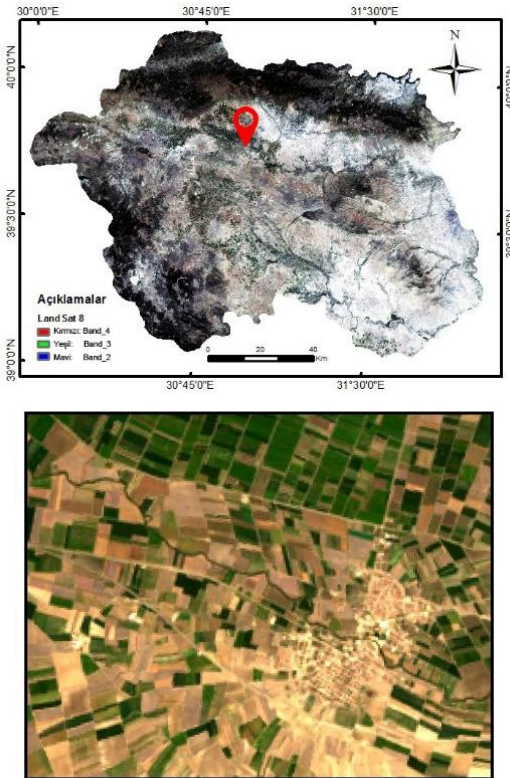
Şekil 1. Çalışma alanı

Landsat 8, Sentinel-1 ve Sentinel-2 verileri GEE'de mevcuttur. Bu çalışmada Landsat 8, Sentinel-1 ve Sentinel-2 verileri kullanılmıştır. GEE içerisindeki veriler, kullanıcıya hazır halde sunulmaktadır ve herhangi bir ön-işleme sürecinden geçirilmesi gerekmeyecek şekilde analizlerde kullanılabilir. Bu çalışmada kullanılan Sentinel-1 SAR GRD görüntüleri, termal gürültü giderme, radyometrik kalibrasyon ve arazi düzeltmesi gibi ön-işleme süreçlerinden geçirilmiştir. Sentinel-2 görüntülerine ise Level-1C ve Level-2A formatında erişilebilmektedir. Bu çalışmada Level-2A verileri kullanılmıştır. Landsat 8 verileri 3 ayrı ön-işleme seviyesinde sunulmaktadır; yüzey yansıtımı (Surface Reflectance), atmosfer üstü yansıtım (Top of Atmosphere) ve ham görüntüler. Bu çalışmada atmosferik düzeltmesi yapılmış yüzey yansıtımı verileri kullanılmıştır [36].

Çalışmada, 5 farklı indeks hesaplanmıştır. NDVI, EVI, NDWI, NDBI ve UI her biri hakkında bilgiler aşağıda verilmiştir.

2.3 Landsat 8

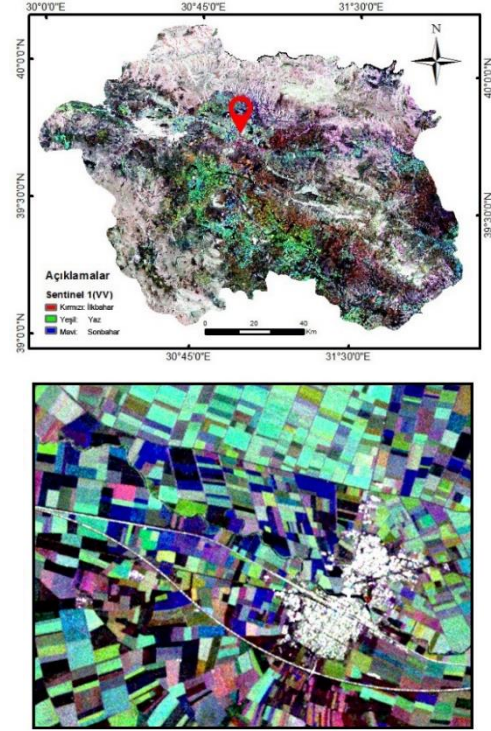
GEE'de bulunan Landsat 8 verileri, LaSRC yönetime ile atmosferik düzeltmesi gerçekleştirilmiş ve CFMASK algoritması ile hesaplanan bulut, gölge, su ve kar maskelerini içermektedir [36]. Landsat 8'den 2, 3, 4, 5, 6 ve 7 bantlar kullanılmıştır. Eskişehir iline ait olan görüntüler üzerinde çalışılmıştır(Şekil 2). Her mevsimden veriler üzerinde analiz gerçekleştirilmiştir. En iyi görüntü ve analizi yapabilmek için ilk olarak maske algoritması uygulanmıştır daha sonra medyan değerler hesaplanmıştır.




Şekil 2. Landsat 8 uydu görüntüsü

2.4 Sentinel-1

Bu çalışmada Sentinel-1 uydusunun VV ve VH bantları kullanılmıştır. Her bir mevsim için görüntü sayısı sırasıyla 87, 90, 88 ve 93'tür. Her bir mevsim için ayrı görüntüler ve görüntülerin medyanları kullanılarak hesaplanmıştır.



Şekil 3. Sentinel-1 VV uydu görüntüsü



Şekil 4. Sentinel-1 VH uydu görüntüsü

Her bir mevsim için RGB bantları Şekil 3 ve 4’de gösterilmiştir. Şekil 5’de renklerin ve mevsimlerin kombinasyonu görüntülenebilir. Bu kombinasyon tüm veri setlerinde kullanılmıştır.



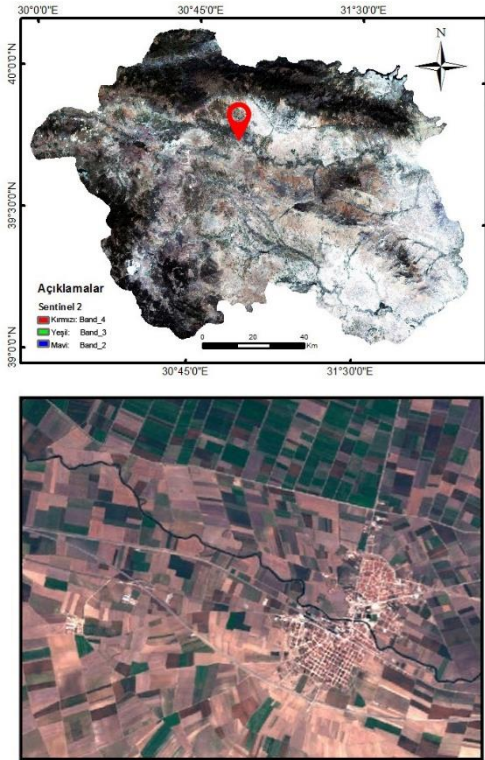
Şekil 5. Kırmızı, yeşil,mavi kombinasyonu [14]

Tablo 1. Sentinel-1 uydu bilgisi

İsim	Tanımlama	Dalga boyu	Çözünürlük
HH	Single co-polarization, horizontal transmit/horizontal receive	5.405 GHz	10 metre
HV	Dual-band cross-polarization, horizontal transmit/vertical receive	5.405 GHz	10 metre
VV	Single co-polarization, vertical transmit/vertical receive	5.405 GHz	10 metre
VH	Dual-band cross-polarization, vertical transmit/horizontal receive	5.405 GHz	10 metre

2.5 Sentinel-2

Sentinel-2 yüksek çözünürlüklü, geniş alanlı ve çok spektrumlu Copernicus arazi gözlem çalışmalarını destekleyen ve su, bitki örtüsü, toprak gibi alanların gözlemlenmesini sağlayan uydudur (Şekil 6).



Şekil 6. Sentinel-2 uydu görüntüsü

2.6 İndeksler

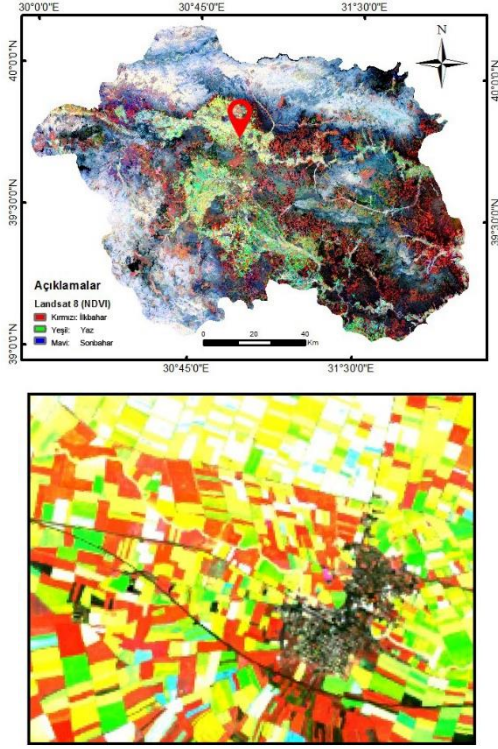
NDVI, EVI, NDBI, NDWI ve Ui indeksleri Sentinel-2 uydusu kullanılarak hesaplanmıştır. Sadece NDVI indeksi hesaplanırken Landsat-8 uydusu görüntüsü kullanılmıştır. Her bir indeks için formüller Tablo 2’de gösterilmiştir. İndeks hesaplarını yapabilmek için ilk olarak ilgili tarih aralıklarına ait görüntüler belirlenmiştir. Daha sonra, her bir görüntü için indeks hesabı yapılmıştır. Son görüntü “maximum value composite” algoritması kullanılarak piksel başına düşen maksimum değerler alınarak üretilmiştir.

Tablo 2. Araştırma kullanılan indeks bilgileri ve formülleri

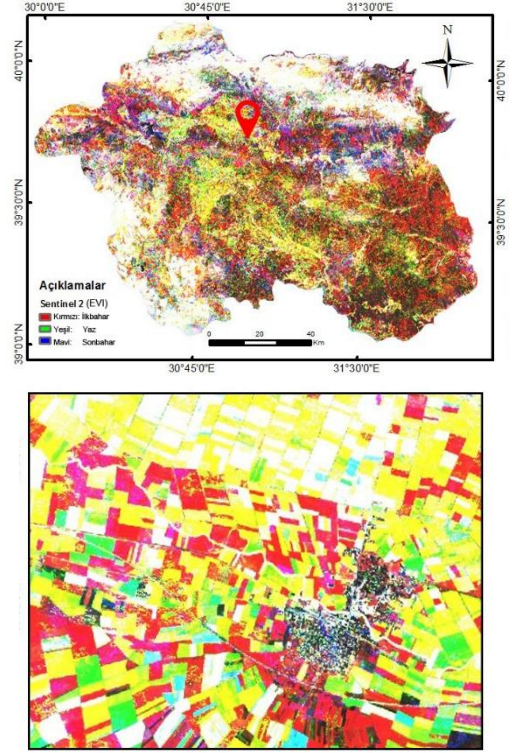
Tür	İndeks	Formül
Normalleştirilmiş fark bitki örtüsü indeksi[26]	NDVI	$\frac{NIR - RED}{NIR + RED}$
Gelişmiş Bitki Örtüsü Endeksi[27]	EVI	$G * \frac{NIR - RED}{NIR + C1 * RED - C2 * Blue + L}$
Normalleştirilmiş fark su indeksi[28]	NDWI	$\frac{Green - NIR}{Green + NIR}$
Normalleştirilmiş fark oluşturma indeksi[29]	NDBI	$\frac{SWIR1 - NIR}{SWIR1 + NIR}$
Kentsel İndeks[30]	UI	$\frac{SWIR2 - NIR}{SWIR2 + NIR}$

Şekil 7’de Landsat-8 uydusu kullanılarak hesaplanan NDVI sonuçları görülmektedir ve Şekil 8’de ise Sentinel-2 uydusu kullanılarak hesaplanan NDVI sonuçları görülmektedir. Aşağıda bulunan görüntüde her bir mevsim için hesaplanan NDVI için RGB renk bantları kombinasyonlarından yararlanılmıştır.

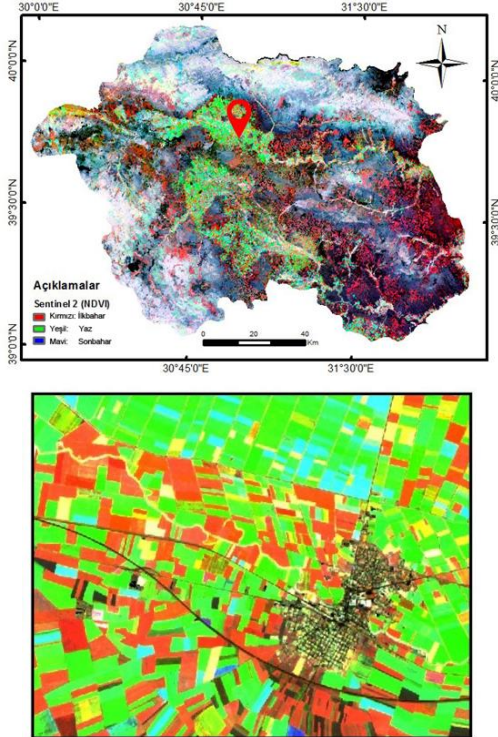
Eğer tarım arazileri ile çalışma yapılacak ise, sarı ile işaretli alanlar ilkbahar aylarında maksimum NDVI değerine sahip olan alanlardır. Yeşil ile işaretli olanlar, yaz aylarında maksimum NDVI değerine sahiptir ve mavi ile işaretli alanlar ise, sonbahar aylarında maksimum değere sahip alanlardır. Beyaz işaretli olan alanlar ise, her bir sezona ait 3 ay içerisinde en yüksek değere sahip olan alanlardır. NDVI hesaplanması Landsat-8’e ait 103 görüntü kullanılarak hesaplanmıştır. Aynı indeks Sentinel-2’ye ait 952 görüntü kullanılarak da hesaplanmıştır.



Şekil 7. NDVI - Landsat 8




Şekil 9. EVI - Sentinel-2



Şekil 8. NDVI - Sentinel-2

Aynı zamanda, her bir mevsim için EVI indeksi hesaplanmıştır. Şekil 9'da EVI indeksin hesaplanması sonucunda ortaya çıkan sonuç görülmektedir. Her bir mevsime ait olan EVI indeks sonucunun daha iyi görünebilmesi için RGB bantlardan yararlanılmıştır.



NDBI, UI ve NDWI indeksleri Tablo 2'de verilen formüller ile hesaplanmıştır. Bu 3 indeks her bir mevsim için değil sadece yaz mevsim verileri kullanılarak hesaplanmıştır. Aşağıda bulunan Şekil 10, 11 ve 12'de GEE üzerinde hesaplanan indekslerin sonuçları verilmiştir.





Şekil 10. NDBI - Sentinel-2

Tablo 3. Araştırma kullanılan tüm verilerin detaylı bilgileri

VERİ SETİ	Tarih Aralığı	Görüntü Sayısı	İşlem
	2019-01-01 - 2019-04-01	27	Median
USGS Landsat 8 Surface Reflectance Tier 1	2019-04-01 - 2019-07-01	27	Median
	2019-07-01 - 2019-10-01	29	Median
	2019-10-01 - 2020-01-01	20	Median
	2019-01-01 - 2019-04-01	234	Median
Sentinel-2 MSI: MultiSpectral Instrument, Level-2A	2019-04-01 - 2019-07-01	234	Median
	2019-07-01 - 2019-10-01	244	Median
	2019-10-01 - 2020-01-01	240	Median
	2019-01-01 - 2019-04-01	87	Median
Sentinel-1 SAR GRD: C-band Synthetic Aperture Radar Ground Range Detected, log scaling(VH)	2019-04-01 - 2019-07-01	90	Median
	2019-07-01 - 2019-10-01	88	Median
	2019-10-01 - 2020-01-01	93	Median
	2019-01-01 - 2019-04-01	87	Median
Sentinel-1 SAR GRD: C-band Synthetic Aperture Radar Ground Range Detected, log scaling(VV)	2019-04-01 - 2019-07-01	90	Median
	2019-07-01 - 2019-10-01	88	Median
	2019-10-01 - 2020-01-01	93	Median
	2019-01-01 - 2019-04-01	234	Max
Sentinel-2 EVI	2019-04-01 - 2019-07-01	234	Max
	2019-07-01 - 2019-10-01	244	Max
	2019-10-01 - 2020-01-01	240	Max
	2019-01-01 - 2019-04-01	234	Max
Sentinel-2 NDVI	2019-04-01 - 2019-07-01	234	Max
	2019-07-01 - 2019-10-01	244	Max
	2019-10-01 - 2020-01-01	240	Max
	2019-01-01 - 2019-04-01	27	Max
Landsat 8 NDVI	2019-04-01 - 2019-07-01	27	Max
	2019-07-01 - 2019-10-01	29	Max
	2019-10-01 - 2020-01-01	20	Max
Santinel-2 NDBI	2019-04-01 - 2019-07-01	234	Max
Santinel-2 Ui	2019-04-01 - 2019-07-01	234	Max
Santinel-2 NDWI	2019-04-01 - 2019-07-01	234	Max



Şekil 11. UI - Sentinel-2



Şekil 12. NDWI - Sentinel-2

2.7 Sınıflandırma metotları

GEE platformunda birçok farklı sınıflandırma yöntemi bulunmaktadır. Destek Vektör Makineleri (SVM) bunlardan bir tanesidir. SVM algoritması başarılı algoritmalarından birisi olarak bilinmektedir [37] ve son 10 yılda birçok çalışma SVM yöntemini parametrik olmayan kontrollü sınıflandırma çalışmalarında kullanmıştır [38-40]. Kısıtlı veri olması durumunda SVM yöntemi, Maksimum Olabilirlik gibi diğer geleneksel yöntemlere nazaran çok daha iyi sonuç vermektedir [41, 42]. SVM sınıfları en iyi şekilde ayıran hiper düzlemleri kullanarak sınıflandırma işlemini yapmaktadır [43]. Bu çalışmada Destek Vektör Makineleri Kitaplığı (LibSVM) yöntemi kullanılmıştır [44].

Bu metotta ilk olarak farklı sınıflara ait eğitim noktaları seçilir. Bu çalışmada 5 farklı sınıflandırma alanı belirlenmiştir bunlar; Şehir alanı-yollar, su, ormanlık-koruluk, tarım dışı araziler ve tarım arazileri olarak gösterilebilir. Aşağıda verilen Formül 1 ile örnek alanlarının sayısı belirlenmiştir. Bu formül her bir sınıf için 410 adet noktanın belirlenmesi ile uygulanmıştır. Bu noktaların seçimi Sentinel 2 ve Landsat 8'in görüntüleri incelenerek ve Google Earth Engine'in yüksek çözünürlüklü görüntüsü ile eşleştirilerek yapılmıştır. Daha sonra noktaların %70'i eğitim için ve %30'u ise test için rastgele seçilmiştir (Tablo 4).

$$N = \frac{Z^2(p)(q)}{E^2} \quad (1) [14]$$

Yukarıdaki formülde p tüm sınıflandırmanın beklenen doğruluğudur, $q = 100 - p$, E izin verilen hata sınırı ve $Z = 2$ %95 güven aralığında 1.96'nın standart sapmasıdır.

Tablo 4. Sınıflandırma bilgileri ve noktaların sayıları

No.	Sınıf adı	Eğitim Noktaları	Test Noktaları
1	Şehir alanı-yollar	287	123
2	Su	287	123
3	Ormanlık-koruluk	287	123
4	Tarım dışı araziler	287	123
5	Tarım arazileri	287	123

Google Earth Engine ile verilerin filtrelenmesi; tarih aralığı, coğrafi alan, bulut yüzdesi ve uydu görüntülerinde belirli özellikler seçilerek yapılır. Bu çalışmada, bu filtrelerden bazıları görüntü çağrılmasında kullanılmış ve özellikle indislerin hesaplanmasında Maximum Valio Composite algoritması kullanılmıştır.

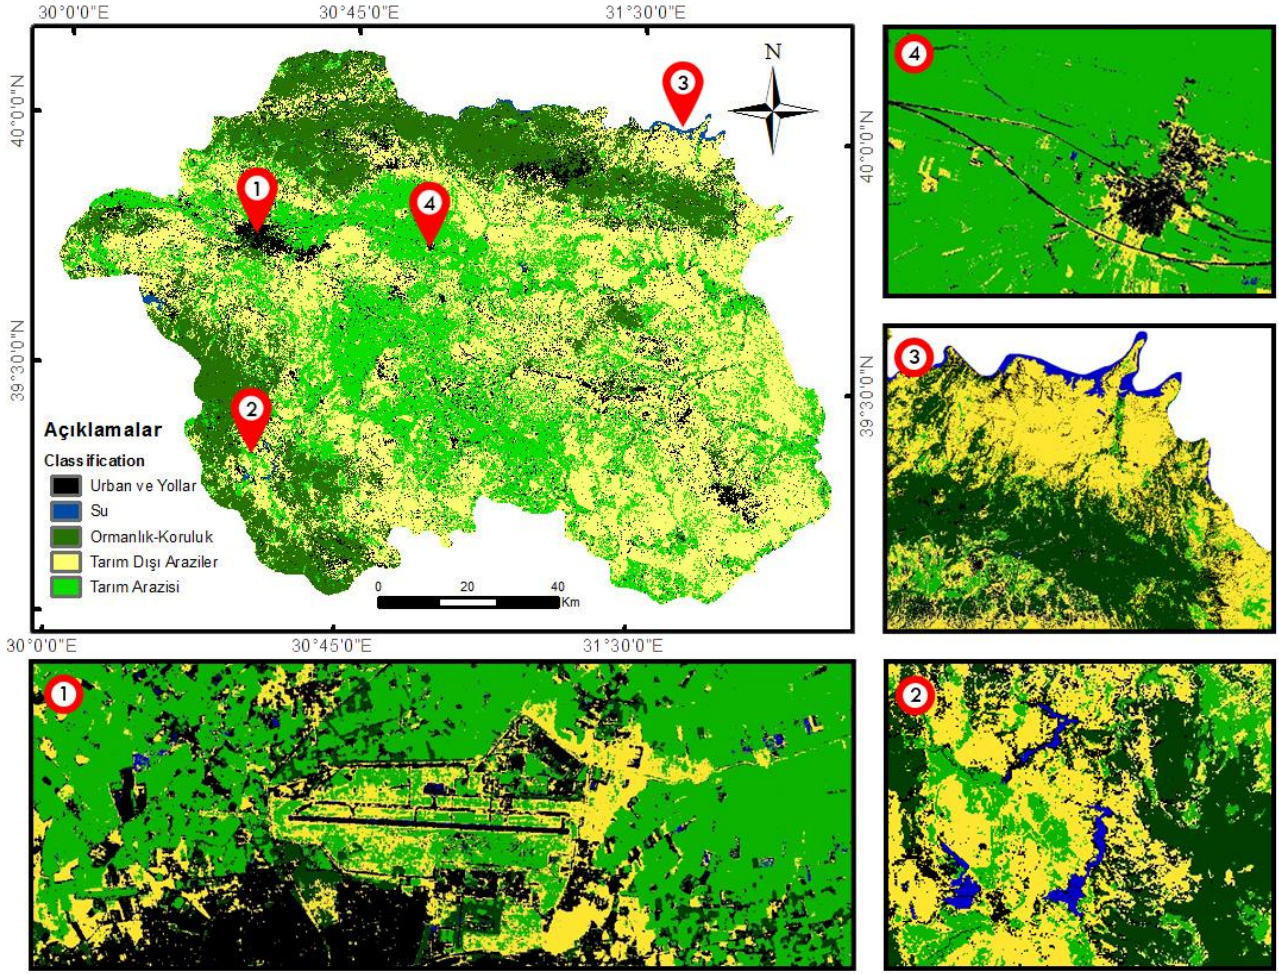
3 Bulgular ve tartışma

Veri kombinasyonlarının ve katmanların seçimi aşama aşama yapılmıştır. İlk olarak, sınıflandırma işlemi yapılmıştır ve sonuçların iyileştirilmesi için diğer veriler eklenmiştir. İlk olarak Landsat 8, Sentinel 1 ve Sentinel 2 uydularının görüntüleri ayrı ayrı sınıflandırılmış, daha sonra, diğer araştırmacılar tarafından yapılan araştırmalara dayanarak başka katmanlar eklenmiştir. Testin en yüksek doğruluğunu elde etmeye çalışılması için literatürde olan kombinasyonlara ilave yeni kombinasyonlar eklenmiştir. Tablo 5'de sınıflandırma ve farklı bileşiklerin sonuçları görülebilmektedir. Aynı zamanda, her bir kombinasyon için genel doğruluk ve kappa katsayısı hesaplanmıştır.

Tablo 5. Farklı kombinasyonlar ve her bir kombinasyon için hesaplanan Genel doğruluk ve Kappa katsayısı bilgileri

No.	Kombinasyon	Band	Genel doğruluk	Kappa katsayısı
1	L8 + S2 + S1VV + L8NDVI + S2NDVI + S2Ui + S2NDBI + S2NDWI	55	96.62	95.76
2	L8 + S2 + S1VV + S1VH	48	94.44	93.03
3	L8 + S2 + S1VH	44	94.41	93
4	L8 + S2 + S1VV + S1VH + L8NDVI + S2NDVI + S2Ui + S2NDBI + S2NDWI + S2EVI	63	93.91	92.39
5	L8 + S2 + S1VV + S1VH + L8NDVI + S2NDVI + S2Ui + S2NDBI + S2NDWI	59	93.75	92.18
6	L8 + S2	40	93.30	91.61
7	L8NDVI + S2NDVI + S1VV + S1VH + S2Ui + S2NDBI + S2NDWI	59	93.24	91.55
8	L8 + S1VV + S1VH	32	92.91	91.13
9	L8 + S2 + S1VV	44	92.09	90.12
10	S2 + S1VV + S1VH + S2NDVI + S2Ui + S2NDBI + S2NDWI + S2EVI	35	91.42	89.25
11	L8NDVI + S2NDVI + S1VV + S1VH + S2Ui + S2NDBI + S2NDWI + S2EVI	63	90.61	88.25
12	S1VV + S1VH + S2NDVI	12	91.27	89.07
13	L8 + S1VV	28	89.23	86.49
14	S2 + S1VV + S1VH	24	89.16	86.43
15	L8NDVI + S2NDVI + S1VV	12	88.09	85.1
16	S2 + S2NDVI	20	87.46	84.34
17	S2	16	85.35	81.66
18	S1VV + S1VH	8	81.76	77.2
19	L8	24	75.88	69.88

S1VV: Sentinel-1(VV); S1VH: Sentinel-1(VH); S2: Sentinel-2; L8: Landsat 8; L8NDVI: Landsat 8(NDVI); S2NDVI: Sentinel-2(NDVI); S2Ui: Sentinel-2(Ui); S2NDBI: Sentinel-2(NDBI); S2NDWI: Sentinel-2(NDWI); S2EVI: Sentinel-2(EVI)



Şekil 13. L8 + S2 + S1VV + L8NDVI + S2NDVI + S2Ui + S2NDBI + S2NDWI sınıflandırma sonuçları

Tablo 5'de görüldüğü üzere, eğer sınıflandırma için sadece Landsat 8 uydu görüntüleri ve bantları kullanıldığında, genel doğruluk 75.88 ve Kappa değeri 69.88 olmaktadır. Eğer sınıflandırmada Sentinel-1 görüntüleri (VV ve VH bantları) kullanılırsa, genel doğruluğu ve Kappa sırasıyla 81.76 ve 77.2 olarak bulunmaktadır. Bu sınıflandırmada sadece 8 bant kullanılmıştır. Bu bantlar, medyan algoritmasının kullanılması sonucu elde edilen 358 görüntünün VV ve VH bantlarıdır.

Sentinel-2 uydusu görüntülerinin kullanılmasında ise, genel doğruluk ve Kappa sırasıyla 85.35 ve 81.66'ya yükselmektedir. 16 adet katman sayısı ve sınıflandırma yapılmıştır. Medyan değeri 952 görüntü üzerinden elde edilmiştir.

Sonuçlar, bilgi katmanları eklenerek ve diğer uydu görüntüleri kullanarak, veriler birbirleriyle kombinlenerek ve farklı indeksler eklenerek, sınıflandırma doğruluğunun önemli ölçüde artırılabilceğini göstermektedir. Örneğin, Landsat ve Sentinel 2 uydu verileri birleştirilirse, genel doğruluk ve Kappa 93.30 ve 91.61'e yükselmektedir. Ayrıca, Sentinel 1 uydusunun VV ve VH bantlarını eklenirse, toplam doğruluğun 94.44'e, Kappa'nın ise 93.03'e yükseldiği görülmektedir.

Endekslerin kullanımı sınıflandırma kalitesini artırmaktadır. Farklı indeksler hesaplayıp bunları bilgi

katmanlarına ekleyerek sınıflandırma kalitesini artırmak da mümkündür. Sonuçlar göstermektedir ki; eğer 4 farklı indeksin hepsi hesaplanarak (NDVI, NDBI, Ui ve NDWI) ve Landsat 8, Sentinel 2 ve Sentinel 1-VV uydu verileri bir arada kullanıldığında doğruluk 96.62 ve kapa 95.76 olarak elde edilmektedir. Şekil 13'de sınıflandırma sonuçları verilmiştir. Bu kombinasyonda, Landsat 8 ve Sentinel 2 uydu bantlarının her biri kullanılarak NDVI hesaplanmıştır. Fakat diğer indeks hesaplamalarında sadece Sentinel 2 uydu bantları kullanılmıştır. Sentinel uydu VH bandı bu veri kombinasyonunda kullanılmamıştır çünkü bu bandın kullanılması genel doğruluğu ve Kappa'yı sırasıyla 93.75 ve 92.18'e düşürmüştür. Ayrıca, bantlar arasında EVI endeksi varsa, genel doğruluk ve Kappa 84 ve 80.07'ye düşmektedir.

Landsat 8 ve Sentinel 2 uydu bantları kullanılmadan sadece Sentinel 1 uydu verileri ile NDVI, NDWI, NDBI ve Ui sınıflandırması yapıldığı zaman genel doğruluğun ve Kappa katsayısının sırasıyla 91.61 ve 88.25'e yükseldiği görülmektedir.

4 Sonuç ve öneriler

Bu çalışma, Landsat 8, Sentinel-1 ve Sentinel-2 uydularından elde edilen verileri kullanarak Eskişehir ili arazi örtüsü haritasının üretiminde en iyi doğruluğu elde etmek amacıyla yapılmıştır. Bu amaçla, 01/01/2019 ve

01/01/2020 döneminde bu üç uydudan çekilen tüm görüntüler işleme alınmıştır. Ayrıca, sınıflandırmada NDVI, EVI, NDWI, NDBI ve UI indeksleri hesaplanmıştır. Her sınıflandırma için Overall Accuracy ve Kappa Coefficient değerleri hesaplanmış ve sonuçlar karşılaştırılmıştır. Bu çalışma GEE platformunda yapılmıştır. GEE farklı kombinasyonları denemeyi sağlayan bununla birlikte sonuçları en kısa sürede ve en iyi şekilde almayı olanak sağlamaktadır. Sonuçlar, en iyi sınıflandırma sonucunun L8 + S2 + S1VV + L8NDVI + S2NDVI + S2Ui + S2NDBI + S2NDWI kombinasyonunun elde edildiğini göstermektedir.

Bu kombinasyonun sınıflandırılması ve hesaplanarak sonucu vermesi 60 dakikadan az sürede gerçekleştirmektedir. Eğer bu kombinasyon ve sınıflandırmayı sıradan bir bilgisayar üzerinde yazılım kullanarak yapılmaya çalışıldığında sonucu almak aylarca sürebilmektedir. Birçok bilgisayar bu analizleri yapabilmek için yeterli kapasiteye sahip değildir. GEE, araştırmacılara sayısız veri sunmaktadır. Aynı zamanda hazır kodların bulunduğu veya kendi kod bloklarını yazabilecekleri bir platform sunmaktadır. Bu çalışmanın farklı veriler ve sınıflandırma yöntemleri kullanarak diğer çalışmalara yol gösterici olması öngörülmektedir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %6

Kaynaklar

- [1] J. Liu, C. Zhang, L. Kou, and Q. Zhou, Effects of climate and land use changes on water resources in the Taoyer river. *Advances in Meteorology*, 2017, Article ID 1031854, 13 pages 2017. <https://doi.org/10.1155/2017/1031854>
- [2] G. Cai, H. Ren, L. Yang, N. Zhang, M. Du, and C. Wu, Detailed urban land use land cover classification at the metropolitan scale using a three-layer classification scheme. *Sensors*, 19(14), 3120, 2019. <https://doi.org/10.3390/s19143120>
- [3] A. A. Vaighan, N. Talebbeydokhti, and A. M. Bavani, Assessing the impacts of climate and land use change on streamflow, water quality and suspended sediment in the Kor River Basin, Southwest of Iran. *Environ Earth Sci*, 76(15), 543, 2017. <https://doi.org/10.1007/s12665-017-6880-6>
- [4] L. Li, Y. Chen, X. Yu, R. Liu, and C. Huang, Sub-pixel flood inundation mapping from multispectral remotely sensed images based on discrete particle swarm optimization. *ISPRS J. Photogramm. Remote Sens.*, 101, 10–21, 2015. <https://doi.org/10.1016/j.isprsjprs.2014.11.006>
- [5] X. Zhang, L. Han, L. Han, and L. Zhu, How well do deep learning-based methods for land cover classification and object detection perform on high resolution remote sensing imagery?. *Remote Sens.*, 12(3), 417, 2020. <https://doi.org/10.3390/rs12030417>
- [6] C. Zhang, P. A. Harrison, X. Pan, H. Li, I. Sargent, and P. M. Atkinson, Scale Sequence Joint Deep Learning (SS-JDL) for land use and land cover classification. *Remote Sens. Environ.*, 237:111593, 2020. <https://doi.org/10.1016/j.rse.2019.111593>
- [7] C. Zhang, S. Wei, S. Ji, and M. Lu, Detecting large-scale urban land cover changes from very high resolution remote sensing images using cnn-based classification. *ISPRS Int J Geo-Information*, 8(4), 189, 2019. <https://doi.org/10.3390/ijgi8040189>
- [8] K. Hussein, K. Alkaabi, D. Ghebreyesus, M. U. Liaqat, and H. O. Sharif, Land use/land cover change along the Eastern Coast of the UAE and its impact on flooding risk. *Geomatics, Nat Hazards Risk*, 11(1), 112–30, 2020. <https://doi.org/10.1080/19475705.2019.1707718>
- [9] E. F. Lambin, H. J. Geist, and E. Lepers, Dynamics of land-use and land-cover change in tropical regions. *Annu. Rev. Environ. Resour.*, 28(1), 205–41, 2003. <https://doi.org/10.1146/annurev.energy.28.050302.105459>
- [10] Essential Climate Variables, World Meteorological Organization (WMO). <https://public.wmo.int/en/programmes/global-climate-observing-system/essential-climate-variables> Accessed: Jan. 05, 2021.
- [11] N. Pettorelli et al., Framing the concept of satellite remote sensing essential biodiversity variables: challenges and future directions. *Remote Sens. Ecol. Conserv.*, 2(3), 122–31, 2016. <https://doi.org/10.1002/rse2.15>
- [12] E. F. Lambin and H. J. Geist, *Land-Use and Land-Cover Change: Local Processes and Global Impacts*. Springer Science & Business Media, 2008.
- [13] L. Carrasco, A. W. O’Neil, R. D. Morton, and C. S. Rowland, Evaluating combinations of temporally aggregated Sentinel-1, Sentinel-2 and Landsat 8 for land cover mapping with Google Earth Engine. *Remote Sens.*, 11(3), 288, 2019. <https://doi.org/10.3390/rs11030288>
- [14] J. R. Jensen, *Introductory Digital Image Processing: A Remote Sensing Perspective*. Prentice-Hall Inc., 1996.
- [15] The Copernicus Open Access Hub, European Space Agency. <https://scihub.copernicus.eu/> Accessed: Jan. 05, 2021
- [16] Sentinel-1, European Space Agency. <https://sentinel.esa.int/web/sentinel/missions/sentinel-1> Accessed: Jan. 05, 2021.
- [17] Sentinel-2, European Space Agency. <https://sentinel.esa.int/web/sentinel/missions/sentinel-2> Accessed: Jan. 05, 2021.
- [18] Landsat 8, U.S. Geological Survey. <https://www.usgs.gov/land-resources/nli/landsat/landsat-8> Accessed: Jan. 05, 2021.
- [19] N. Gorelick, M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, and R. Moore, Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sens. Environ.*, 202, 18–27, 2017. <https://doi.org/10.1016/j.rse.2017.06.031>
- [20] X. Wang et al., Tracking annual changes of coastal tidal flats in China during 1986–2016 through analyses of Landsat images with Google Earth Engine. *Remote Sens. Environ.*, 202, 18–27, 2017. <https://doi.org/10.1016/j.rse.2017.06.031>

- Sens. Environ., 238, 110987, 2020. <https://doi.org/10.1016/j.rse.2018.11.030>
- [21] N. You and J. Dong, Examining earliest identifiable timing of crops using all available Sentinel 1/2 imagery and Google Earth Engine. *ISPRS J. Photogramm. Remote Sens.*, 161, 109–23, 2020. <https://doi.org/10.1016/j.isprsjprs.2020.01.001>
- [22] G. Mateo-García, L. Gómez-Chova, J. Amorós-López, J. Muñoz-Marí, and G. Camps-Valls, Multitemporal cloud masking in the Google Earth Engine. *Remote Sens.*, 10(7), 1079, 2018. <https://doi.org/10.3390/rs10071079>
- [23] Q. Weng, Z. Mao, J. Lin, and W. Guo, Land-use classification via extreme learning classifier based on deep convolutional features. *IEEE Geosci Remote Sens Lett.*, 14(5), 704–8, 2017. <https://doi.org/10.1109/LGRS.2017.2672643>
- [24] K. Islam, M. Jashimuddin, B. Nath, and T. K. Nath, Land use classification and change detection by using multi-temporal remotely sensed imagery: The case of Chunati wildlife sanctuary, Bangladesh. *Egypt J Remote Sens Sp Sci.*, 21(1), 37–47, 2018. <https://doi.org/10.1016/j.ejrs.2016.12.005>
- [25] J. R. B. Fisher, E. A. Acosta, P. J. Denny-Frank, T. Kroeger, and T. M. Boucher, Impact of satellite imagery spatial resolution on land use classification accuracy and modeled water quality. *Remote Sens Ecol Conserv.*, 4(2), 137–49, 2018. <https://doi.org/10.1002/rse2.61>
- [26] T. Hu, J. Yang, X. Li, and P. Gong, Mapping urban land use by using landsat images and open social data. *Remote Sens.*, 8(2), 151, 2016. <https://doi.org/10.3390/rs8020151>
- [27] B. Matsushita, W. Yang, J. Chen, Y. Onda, and G. Qiu, Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: A case study in high-density cypress forest. *Sensors.*, 7(11), 2636–51, 2007. <https://doi.org/10.3390/s7112636>
- [28] W. Li et al., A comparison of land surface water mapping using the normalized difference water index from TM, ETM+ and ALL. *Remote Sens.*, 5(11), 5530–49, 2013. <https://doi.org/10.3390/rs5115530>
- [29] T. L. Dammalage and N. T. Jayasinghe, Land-use change and its impact on urban flooding: A case study on Colombo district flood on May 2016. *Eng. Technol. Appl. Sci. Res.*, 9(2), 3887–91, 2019. <https://doi.org/10.48084/etasr.2578>
- [30] H. Li et al., Mapping urban bare land automatically from Landsat imagery with a simple index. *Remote Sens.*, 9(3), 249, 2017. <https://doi.org/10.3390/rs9030249>
- [31] S. Ergen, A. Çelik, N. Çalışkan ve V. Yıldırım, Eskişehir istatistikleri. Eskişehir Büyükşehir Belediyesi Yayını, Eskişehir, 2018. http://www.eskisehir.bel.tr/dosyalar/istatistiklerle_eskisehir/2018.pdf
- [32] J. Koskinen et al., Participatory mapping of forest plantations with Open Foris and Google Earth Engine. *ISPRS J. Photogramm. Remote Sens.*, 148, 63–74, 2019. <https://doi.org/10.1016/j.isprsjprs.2018.12.011>
- [33] Y. Wang, J. Ma, X. Xiao, X. Wang, S. Dai, and B. Zhao, Long-term dynamic of Poyang Lake surface water: A mapping work based on the Google Earth Engine cloud platform. *Remote Sens.*, 11(3), 313, 2019. <https://doi.org/10.3390/rs11030313>
- [34] M. Venkatappa, N. Sasaki, R. P. Shrestha, N. K. Tripathi, and H.-O. Ma, Determination of vegetation thresholds for assessing land use and land use changes in Cambodia using the Google Earth Engine cloud-computing platform. *Remote Sens.*, 11(13), 1514, 2019. <https://doi.org/10.3390/rs11131514>
- [35] P. R. Mirelva and R. Nagasawa, Application of Sentinel-1 data for classifying croplands using Google Earth Engine. *Int. J. Geoinformatics.*, 15(3), 2019.
- [36] Earth Engine Data Catalog. Google. <https://developers.google.com/earth-engine/datasets> Accessed: January 2021.
- [37] D. Poursanidis, N. Chrysoulakis, and Z. Mitraka, Landsat 8 vs. Landsat 5: A comparison based on urban and peri-urban land cover mapping. *Int. J. Appl. Earth Obs. Geoinf.*, 35, 259–69, 2015. <https://doi.org/10.1016/j.jag.2014.09.010>
- [38] G. M. Foody and A. Mathur, Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification. *Remote Sens. Environ.*, 93(1–2), 107–17, 2004. <https://doi.org/10.1016/j.rse.2004.06.017>
- [39] M. Pal and P. M. Mather, Support vector machines for classification in remote sensing. *Int. J. Remote Sens.*, 26(5), 1007–11, 2005. <https://doi.org/10.1080/01431160512331314083>
- [40] W. Li, R. Dong, H. Fu, J. Wang, L. Yu, and P. Gong, Integrating Google Earth imagery with Landsat data to improve 30-m resolution land cover mapping. *Remote Sens. Environ.*, 237, 111563, 2020. <https://doi.org/10.1016/j.rse.2019.111563>
- [41] P. Mantero, G. Moser, and S. B. Serpico, Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Trans. Geosci. Remote Sens.*, 43(3), 559–70, 2005. <https://doi.org/10.1109/TGRS.2004.842022>
- [42] G. Mountrakis, J. Im, and C. Ogole, Support vector machines in remote sensing: A review. *ISPRS J. Photogramm. Remote Sens.*, 66(3), 247–59, 2011. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- [43] S. Park, J. Im, S. Park, C. Yoo, H. Han, and J. Rhee, Classification and mapping of paddy rice by combining Landsat and SAR time series data. *Remote Sens.*, 10(3), 447, 2018. <https://doi.org/10.3390/rs10030447>
- [44] C.-C. Chang, LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2, 3, article:27: 1–27, 2011. <https://doi.org/10.1145/1961189.1961199>

