




Türkiye Uzaktan Algılama Dergisi

<https://dergipark.org.tr/tr/pub/tuzal>

e-ISSN 2687-4997



Sentinel-2A Verileriyle Trabzon İli 2019-2020 Yılları Arasında Ortaya Çıkan Sınıflandırma Farklarının Çeşitli Algoritmalarla Değerlendirilmesi

Hasan Bilgehan Makineci*¹, Esmâ Nur Akosman¹

¹Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Konya, Türkiye

Anahtar Kelimeler:

Sentinel-2a
NDVI
Sınıflandırma Yöntemleri
Rastgele Orman

ÖZ

Çevre durum raporları yayımlandıkları yıllar itibarıyla ilgili şehrin ve çevresinin durumunu ortaya koyan önemli dokümanlardır. Trabzon İli ve çevresini kapsayan 2021 çevre durum raporundan yola çıkarak 1/100000 ölçekli çevre düzenleme planı (ÇDP) sınıflandırmasında yeşil alanların azalmakta olduğu fark edilmiştir. Bu çalışmada Trabzon İli yeşil alanların değişiminin 2019-2020 yılları arasında farklı kontrollü-kontROLSÜZ sınıflandırma yöntemleri ve makine öğrenmesi algoritmalarından rastgele orman (RO) algoritmasıyla incelenmesi sağlanmıştır. Değişimin izlenmesinde Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), kontrollü, kontROLSÜZ ve RO algoritmasıyla sınıflandırma işlemleri gerçekleştirilmiştir. Çalışma alanının Sentinel-2A uydu veri setleriyle, 2019 yılı Mayıs ile 2020 yılı Mayıs ayları arasındaki, 10 m mekânsal çözünürlükteki bant kompozitleri kullanılarak ve NDVI işlemi gerçekleştirilerek sınıflandırma sonuçları değerlendirilmiştir. Sonuç olarak gerçekleştirilen kontrollü sınıflandırma işlemi sonucunda 2019 yılı için genel doğruluk oranı %100.0 iken 2020 yılı için genel doğruluk oranı %81.31 olarak elde edilmiştir. Uydu görüntülerinde makine öğrenmesi algoritmalarından RO algoritmasıyla sınıflandırma işlemi de gerçekleştirilmiştir ve genel doğruluk oranı %97.6 olarak elde edilmiştir.

Evaluation of Classification Differences Occurring Between 2019-2020 in Trabzon Province with Sentinel-2A Data Using Different Algorithms

Keywords:

Sentinel-2a
NDVI
Classification Methods
Random Forest

ABSTRACT

Environmental status reports are important documents that reveal the situation of the relevant city and its surroundings as of the years they were published. Based on the 2021 environmental status report covering Trabzon Province and its surroundings, it has been noticed that green areas are decreasing in the 1/100000 scale environmental arrangement plan (EAP) classification. This study examined the change in the green regions in Trabzon Province with different controlled-uncontrolled classification methods and random forest (RF) algorithm, one of the machine learning algorithms, between 2019 and 2020. In monitoring the change, classification processes were carried out with Normalized Difference Vegetation Index (NDVI), controlled, uncontrolled, and RO algorithm. Classification results were evaluated using the Sentinel-2A satellite data sets of the study area between May 2019 and May 2020, using band composites with 10 m spatial resolution and performing NDVI processing. As a result, as a result of the controlled classification process, the general accuracy rate for 2019 was 100.0%, while the general accuracy rate for 2020 was 81.31%. Classification of satellite images was also carried out with the RO algorithm, one of the machine learning algorithms, and the overall accuracy rate was obtained as 97.6%.

Makale Bilgileri/Article Info

Geliş /Received: 31/10/2023
Kabul/Accepted: 29/11/2023
Yayınlanma/Published: 30/12/2023

Alıntı/Citation:

Makineci, H.B., Akosman, E.N. (2023). Sentinel-2A Verileriyle Trabzon İli 2019-2020 Yılları Arasında Ortaya Çıkan Sınıflandırma Farklarının Çeşitli Algoritmalarla Değerlendirilmesi. Türkiye Uzaktan Algılama Dergisi, 5 (2), 78-88.

1. GİRİŞ

Türkiye'nin doğal bitki örtüsü, insanların yaşamsal faaliyetlerini gerçekleştirebilmesi ve barınma ihtiyacını karşılaması amacıyla zamanla deformasyona uğramıştır. Bu deformasyonlar doğal bitki örtüsünü olumsuz yönde etkilemektedir (Dönmez ve Aydınözü, 2013). Doğal bitki örtüsünün tahrip edilmesinde en büyük nedenlerden birisi kentleşmedir. Hava kirliliği, su kirliliği ve toprak erozyonu kentleşmenin çevre üzerindeki olumsuz sonuçlarından bazıları iken, yeşil alanların yok olması toprak erozyonunun en belirgin göstergesidir (Aksoy ve Ergun, 2009).

Arazi örtüsü kullanımı bölgelerin fiziksel, sosyolojik ve idari yapısına göre değişim göstermektedir. Bu kapsamda doğal bitki örtüsünün tahrip edilmemesi için karar vericilerin bu konuyla ilgili stratejik planlar oluşturmaları gerekmektedir. 20. Yüzyılın sonlarından itibaren gelişen uzaktan algılama teknikleri ve Coğrafi Bilgi Sistemleri (CBS), birçok noktada daha verimli, daha hızlı, daha hassas kararlar verebilmeyi sağlamaktadır (Dereli, 2019). Arazi kullanım haritaları, birçok bilimsel ve çevresel uzaktan algılama uygulamaları için önemli bilgiler temin etmektedir. Teknolojinin ilerlemesi ve uyduların çoğalmasıyla birlikte uydu görüntüleri bu haritaların hızlı ve güvenilir bir şekilde yapılmasına yardımcı olmaktadır (Belward, 2014). Bu anlamda arazi kullanım haritalarının hızlı ve güvenilir olarak üretilmesinde görüntü sınıflandırma işlemi en yaygın kullanılan uzaktan algılama tekniklerinden biridir (Akar ve Görmüş, 2019).

Bitki örtüsü değişimlerinin yıllara göre izlenebilmesi için çeşitli görüntü sınıflandırma yöntemleri mevcuttur (Karakuş, 2017). Görüntü sınıflandırması piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma olmak üzere iki kısma ayrılmaktadır (Jensen, 2006; Platt ve Rapoza, 2008; Weih ve Riggan, 2010; Myint ve ark., 2011; Whiteside vd., 2011). En Çok Benzerlik (EÇB) yöntemi en çok kullanılan sınıflandırma algoritmalarından biridir (Akar ve Güngör, 2013). Her banttaki her sınıf için görüntü verisi EÇB algoritması tarafından normal dağılımda kabul edilir. Bir EÇB prosedüründe, belirli bir piksel birkaç kategoriden birine girebilir. Sonuç olarak, her pikselin olasılığı belirlenir ve daha sonra en yüksek olasılığa sahip sınıfa atanır (Akar ve Güngör, 2013). Fakat nesne tabanlı tekniklerde pikseller, daha doğru sonuçlar üretmek için uzamsal özelliklerine göre gruplandırılır. Nesnelerin spektral özelliklerinin yanı sıra şekli ve dokusu gibi temel özelliklerine göre sınıflandırma obje tabanlı sınıflandırma yöntemlerine uygundur (Dronova vd., 2011) Şekil, yoğunluk ve ölçek gibi kriterlerden üretilen bilgi gruplarını gösteren objelere göre görüntüyü parçalara ayıran obje tabanlı sınıflandırma yöntemlerinde elde edilen parçalar ayrı ayrı sınıflara tanımlanır. Böylece objeler farklı üyelik değerleri ile birden fazla sınıfa tanımlanabilmektedir (Matinfar, 2007).

Piksel ve nesne tabanlı yöntemlere alternatif olarak, uydu fotoğraflarından daha doğru ve güvenilir bilgiler elde etmek için günümüzde birkaç öğrenme tabanlı algoritma geliştirilmektedir. En popüler öğrenme tabanlı algoritmalar K-En Yakın Komşuluk, Destek Vektör Makinesi (DVM), Karar Ağacı (KA), Rastgele Orman (RO) ve Yapay Sınır Ağlarıdır (YSA). Bu algoritmalara makine öğrenme teknikleri denir. Makine öğrenimi teknikleri, istatistiksel tekniklerin aksine verilerin dağılımı hakkında herhangi bir varsayımda bulunmadıkları için parametrik değildir. Tahmin edici ve ilgili cevaplar arasındaki ilişkiler, veriye dayalı makine öğrenimi teknikleri kullanılarak öğrenilir. Makine öğrenimi tekniklerinin amacı, girdi verilerinden ve yeterince büyük parametrelerden çıkarılan karar kurallarını kullanarak veri için en iyi modeli belirlemektir (Breiman, 2001).

RO, ağaç tipi sınıflandırıcılar topluluğu olarak tanımlanabilir. RO, torbalama yöntemine rastgelelik özelliğinin eklenmesiyle geliştirilen bir versiyondur (Breiman, 2001). Her düğümde rastgele seçilen en iyi değişkeni kullanarak her düğümü birleştirmek yerine, RO tüm değişkenler arasında en iyi dalı kullanarak her düğümü dallandırır. Her bir veri kümesini oluşturmak için orijinal veri kümesinden yer değiştirme ve ağaçlar oluşturmak için rastgele özellik seçimi kullanılır. Gelişmiş alanlarda hiçbir ağaç budanmamaktadır (Archer 2008; Breiman 2001). Bu taktik nedeniyle RO'nun hassasiyeti rakipsizdir. Hızlı ve fazla takılmaya karşı dirençli olan RO ile gerektiği kadar ağaç kullanılabilir (Breiman ve Cutler 2005). Sınıflandırmada birincil düğümden kaç ek düğümün izole edilebileceğine karar veren faktör sayısı ve ağacın kullanıcı tarafından ne kadar büyütüleceğini belirleyen ağaç sayısı seçilir. Rastgele ormanların birçok gerçek dünya sorunu için iyi performans gösterdiği kanıtlanmıştır (Breiman 2001, Comert ve vd. 2019, Sevgen 2019).

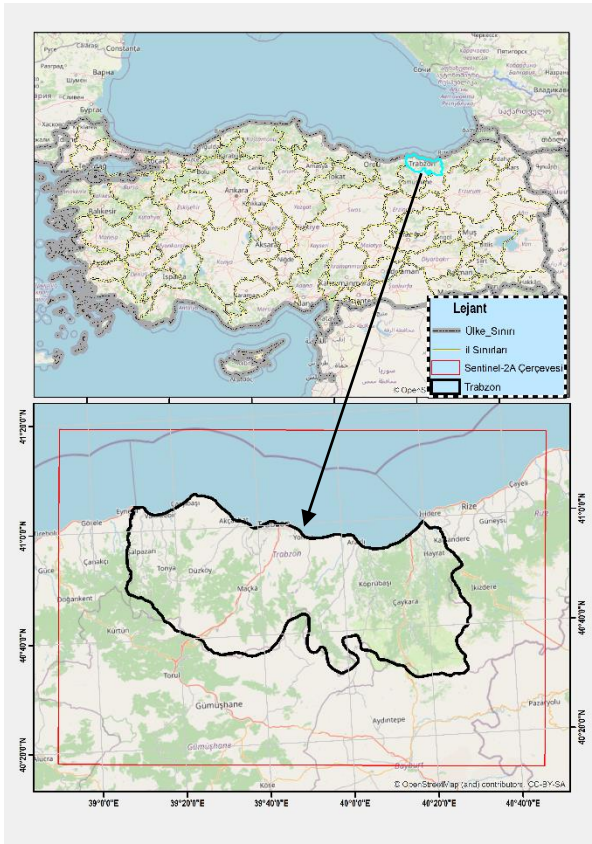
Bu çalışmada Copernicus programı kapsamında geliştirilen Sentinel uydu sistemlerinden optik algılayıcıya sahip Sentinel-2A uydusunun 2019 ve 2020 yılları mayıs ayına ait Sentinel-2 MSI (Multispectral Instrument), Level-2a uydu görüntüleri kullanılmıştır. Bu çalışmada 2019-2020 yılları arasında yayınlanan ÇDP'ye göre Trabzon İli yeşil alan değişimlerinin makine öğrenmesi algoritmalarından biri olan RO algoritmasıyla ve kontrollü kontrolsüz farklı sınıflandırma yöntemleriyle yüksek doğrulukla belirlenmesi amaçlanmıştır. Görüntülerin sınıflandırılmasında öncelikle 10m çözünürlüğe sahip bantlarla Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) analizi gerçekleştirilmiştir. Mekânsal çözünürlüğü 10m olan bant kompozitleri kullanılarak kontrollü sınıflandırma yöntemlerinden biri olan ve yaygın olarak kullanılan EÇB yöntemiyle kontrollü sınıflandırma işlemi gerçekleştirilmiştir. Aynı zamanda çalışmada görüntülerin sınıflandırılması işleminde makine öğrenmesi algoritmalarından biri olan RO algoritması kullanılmıştır. Trabzon İli çevre

durum raporlarında görülen yeşil alanlarla alakalı sorunların araştırılmış olması da çalışmanın önemini ortaya koymaktadır.

2. YÖNTEM

2.1. Çalışma Alanı

Bu çalışmada belirlenen araştırma alanı Trabzon İli olarak belirlenmiştir. Trabzon, 41° 0' 9.7092" kuzey enlemi ve 39° 43' 0.3468" doğu boylamında bulunmaktadır. Trabzon'un genel yamaç eğimleri %12'nin üzerindedir. Başlıca tarım ürünleri fındık, çay, patates, mısır, tütün, buğday ve fasulyedir. Fındıktan sonra armut, kiraz ve turuncgiller oldukça fazla yetişir. Çalışma bölgesinin haritadaki yeri Şekil 1.'de belirtilmiştir.



Şekil 1. Çalışma alanı

2.2. Uzaktan Algılama Verileri

Çalışma alanının yeşil alan değişiminin belirlenmesine yönelik yapılan görüntü sınıflandırması için Sentinel-2A uydu görüntüleri ve bu görüntülerden elde edilen NDVI analizi, kontrolsüz, kontrollü sınıflandırma ve RO algoritmasıyla sınıflandırma materyal olarak kullanılmıştır.

Avrupa Uzay Ajansı (ESA), orta mekânsal çözünürlüklü çok bantlı bir algılayıcı olan Sentinel-2 uydusunu kullanıcılara sunmuştur. Sentinel-2 uydusu, yüksek mekânsal çözünürlüğü, yeni spektral bantları, geniş alanlı veri toplama ve beş gün içinde veri alma kapasitesi nedeniyle birçok uygulamada çok işlevseldir (Malenovský vd., 2012).

Sentinel-2 uydu görüntüleri toplamda 13 farklı banttan oluşmasına rağmen, özellikle hem kısa dalga hem de yakın kızılötesi bantların koyu yeşil görünen bitki örtüsünü vurgulamada başarılı olmasından dolayı çoğunlukla bitki gelişiminin izlenmesi gibi tarımsal uygulamalarda sırası ile B2, B3, B4, B8 ve B11 (mavi (B), yeşil (G), kırmızı (R), yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bantları kullanılmaktadır (URL-1) (Tablo 1).

Tablo 1. Sentinel-2 uydu görüntüleri, bantlara göre çözünürlükleri ve kullanım alanları (URL-2)

Bant	Açıklama	Mekânsal Çözünürlük (m)
B1	Ultra Mavi	60
B2	Mavi	10
B3	Yeşil	10
B4	Kırmızı	10
B5	(VNIR)*	10
B6	(VNIR)	20
B7	(VNIR)	20
B8	(VNIR)	10
B8A	(VNIR)	20
B9	(SWIR)**	60
B10	(SWIR)	60
B11	(SWIR)	20

*Görünür ve yakın kızılötesi

**Kısa dalga kızıl ötesi

Her beş günde bir, 10, 20 ve 60 m mekânsal çözünürlüklerle veriler toplanmaktadır. Atmosfer koşullarının veriler üzerinde etkisi olduğundan, elde edilen tüm veriler kullanılmaya uygun değildir. Uydu görüntülerindeki bulutluluk oranları, özellikle tarımsal amaçlar için kullanılabilirliklerini kısıtlamaktadır (Torunlar vd., 2021). Araştırmada, atmosfer altı yansıma değerlerine sahip Sentinel-2A uydu görüntüsü seviyesi 2A verileri kullanılmıştır. NDVI indeksi, birkaç uydu resmi bantı kullanılarak oluşturulmuştur ve görüntü sınıflandırmasının doğruluğunu geliştirmek için ek veri olarak kullanılmıştır.

2.3. Çevre Durum Raporu ve Çevre Düzeni Planı

Çalışmada Çevre, Şehircilik ve İklim Değişiklikleri Bakanlığı Mekânsal Planlama Genel Müdürlüğü'nün yayınlamış olduğu Ordu-Trabzon-Rize-Giresun-Gümüşhane-Artvin Planlama Bölgesi 1/100.000 ölçekli Çevre Düzeni Planı'na (ÇDP) Trabzon İline ait plan paftalar sayısallaştırılarak kullanılmıştır. Ayrıca Trabzon Valiliği, Çevre ve Şehircilik İl Müdürlüğü ÇED Hizmetleri ve Çevre İzinleri Şube Müdürlüğü tarafından hazırlanan Çevre Durum Raporu dikkate alınarak kullanılmıştır (URL-3).

2.4. NDVI Analizi

NDVI, herhangi bir alanda yer alan bitki örtüsünün yoğunluğunu, sağlıklı veya sağlıklı olmama durumunu analiz ederek ortaya koyan bir indekstir. Uzaktan algılamada bitki örtüsünün durumunun izlenmesinde en çok tercih edilen yöntemlerden biri olan NDVI analizi, uydu görüntülerinin çeşitli bantlarını kullanarak gerçekleştirilmektedir. NDVI değerleri Eşitlik 1'deki standart formül ile hesaplanmaktadır (Carlson, & Ripley, 1997; Karakuş, 2017; Kaya & Polat, 2021).

$$\frac{(NIR-RED)}{(NIR+RED)} \quad (1)$$

NDVI analizi sonucunda elde edilen değerler -1 ile +1 arasında değişmektedir. Sağlıklı ve yoğun bitki örtüsünün fazla olduğu yerlerde indeks değerleri +1'e doğru yaklaşırken, sağlıklı ve zayıf bitki örtüsünün fazla olduğu yerlerde indeks değeri 0'a doğru yaklaşmaktadır. NDVI 0 değerinden düşük durumlarda genelde yeşil bitki varlığından söz edilmemektedir (Carlson, & Ripley, 1997; Kaya & Polat, 2021)

2.5. Kontrolsüz Sınıflandırma Yöntemi

Bir kullanıcı bir görüntüde bulunan arazi örtüsünün sayısından emin olmadığında, denetimsiz veya kontrolsüz sınıflandırma olarak da bilinen sınıflandırma, uygulamak için iyi bir tekniktir. Denetimsiz sınıflandırma, yalnızca sınıf numaralarını kullanarak piksellerin sınıflandırılmasını sağlar. Iso kümesi denetimsiz sınıflandırma adı verilen bir coğrafi işlem teknolojisi, müdahale olmadan girdi raster bantlarına dayalı olarak verileri sınıflandırır (Nijhawan, vd., 2017; Lemenkova, 2021).

Denetimsiz piksel tabanlı görüntü sınıflandırma yöntemi, kullanıcıdan bağımsız bir yöntem kullanır. Bu teknik, bir algoritmadaki pikselleri, spektral değerlerinin ne kadar benzer olduğuna bağlı olarak kümeler halinde gruplandırır. Her piksel, spektral değerlerin nasıl gruplandığına bağlı olarak algoritma tarafından sınıflandırılır. Raster sınıflandırması otomatik bir süreç olmasına rağmen, kullanıcıların hangi özelliğin veya nesnenin kategorize edildiğini belirlemek için sınıflandırılmış kümeleri kaydetmesi gerekir (Vlachou, vd., 2016).

2.6. En Çok Benzerlik Yöntemi

İstatistiksel temeli olan bir sınıflandırma yaklaşımı EÇB yönteminde ortalama değerler, varyans ve kovaryans değerlerinin tümü dikkate alınır. Bu değerlendirme aşamasında sınıf kontrol kümelerindeki verilerin normal bir dağılıma sahip olması beklenir. Sınıflandırılması gereken pikseller, olasılık yoğunluk fonksiyonları oluşturulduktan sonra sınıflandırma aşamasında üyelik olasılıkları en büyük olan sınıflara atanır. İlgili pikseller, kendileri için türetilen sınıfların olasılık değerlerinin önceden

belirlenmiş eşik değerinin altına düşmesi durumunda belirsiz olarak etiketlenir. (Myung, 2003; Çölkesen, 2009; Günlü, 2012; Topaloğlu vd.; 2016).

2.7. Rastgele Orman Algoritması

Denetimli sınıflandırma tekniklerinden biri de RO algoritmasıdır. Hem sınıflandırma hem de regresyon problemleri RO kullanır. Sınıflandırma aşaması boyunca sınıflandırma değerini iyileştirmek için algoritma çok sayıda karar ağacı oluşturur. Karar ormanı, RO algoritması tarafından üretilen bireysel karar ağaçlarından oluşur. Burada karar ağaçları, rastgele seçilen veri kümesinin alt kümelerine bağlanır. En yüksek oyu alan sınıf, RO'daki her ağaç tarafından modelin tahmini olarak seçilir (Breiman, 2001; Breiman ve Cutler 2005).

RO pek çok veri seti için Adaboost ve DVM'den daha kesin sonuçlara sahiptir ve oldukça kısa sürede sonuç verir. Veri biliminde, RO modelinin bu kadar iyi çalışmasının nedeni bir komite olarak faaliyet gösteren çok sayıda nispeten ilişkisiz modelin (ağaç), bireysel kurucu modellerden herhangi birinden daha iyi performans göstermesidir. RO algoritmasında işlem akışı 3 adımdan oluşur:

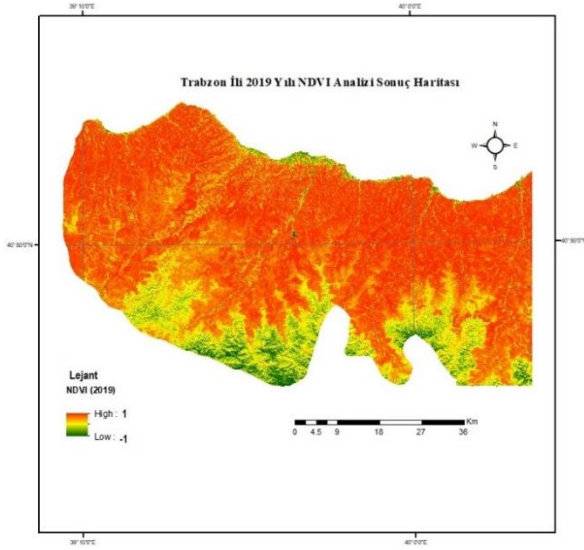
- Adım 1: RO' da, "k" kayıt sayısına sahip veri kümesinden n sayıda rastgele kayıt alınır.
- Adım 2: Her örnek için ayrı ayrı karar ağaçları oluşturulur.
- Adım 3: Her karar ağacı bir çıktı üretir.
- Adım 4: Nihai çıktı, çoğunluk oylamasına veya sınıflandırma ve regresyon ortalamasına göre değerlendirilir (Akar & Güngör, 2013; Akar & Görmüş, 2017; Makineci, 2023).

3. BULGULAR

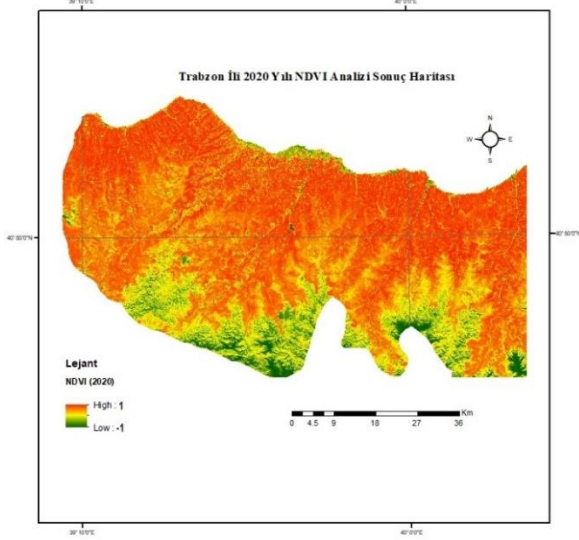
Çalışma alanını kapsayan 2019 ve 2020 yılları mayıs aylarına ait uydu görüntüleri, alanı sınırlarınca kesilerek sınıflandırmada kullanılmıştır. Bu işlemler için; CBS yazılımı olan ArcMap programı kullanılmıştır.

Uydu görüntüleri üzerinden NDVI analizi gerçekleştirilmiştir. Bu aşamada indirilen uydu görüntülerinin WGS84 UTM Zone-37N projeksiyon sistemine dönüşümü sağlandıktan sonra 10m çözünürlüğe sahip olan 4. ve 8. bantlar CBS yazılımına aktarılmıştır.

NDVI işlemi tamamlanan uydu görüntüsünden çalışma bölgesi olan Trabzon İli, İl sınırları kullanılarak kesilmiştir. NDVI analizi işlemi 2019 ve 2020 yılına ait uydu görüntülerinin her ikisine de sırasıyla uygulanmıştır. NDVI analizi sonucu oluşan haritalar Şekil 2 ve Şekil 3'te sunulmaktadır.



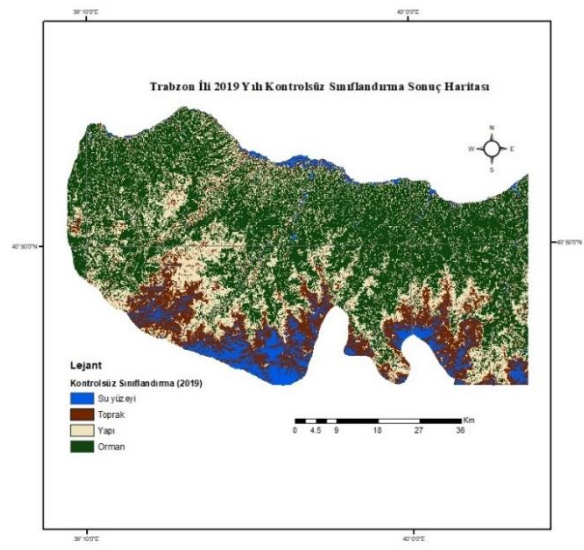
Şekil 2. Trabzon İli 2019 yılı NDVI haritası



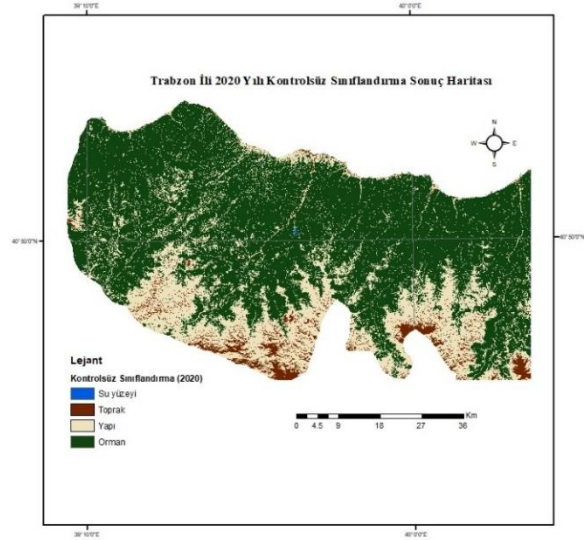
Şekil 3. Trabzon İli 2020 yılı NDVI haritası

NDVI analizi sonucu yıllara göre elde edilmiş olan uydu görüntülerinde CBS yazılımında bulunan kontrolsüz piksel tabanlı sınıflandırma (iso cluster unsupervised classification) aracı kullanılarak kontrolsüz sınıflandırma işlemi gerçekleştirilmiştir. Yıllara göre NDVI değişimine baktığımızda 2019 yılında bitkilerin 2020 yılına oranla daha sağlıklı olduğu tespit edilmiştir.

Yapılan kontrolsüz sınıflandırma işleminde 4 adet sınıf belirlenmiştir. Bunlar; su yüzeyi, toprak, yapı ve orman sınıflarıdır. Kontrolsüz sınıflandırma daha önce de belirtildiği gibi kullanıcının müdahalesinin bulunmadığı ve tamamen yazılım tarafından yapılan bir sınıflandırma yöntemi olduğundan CBS yazılımında gerçekleştirilmiştir. Sonuç haritalar aşağıda verilmiştir (Şekil 4 ve 5).



Şekil 4. Trabzon İli 2019 yılı kontrolsüz sınıflandırma haritası



Şekil 5. Trabzon İli 2020 yılı kontrolsüz sınıflandırma haritası

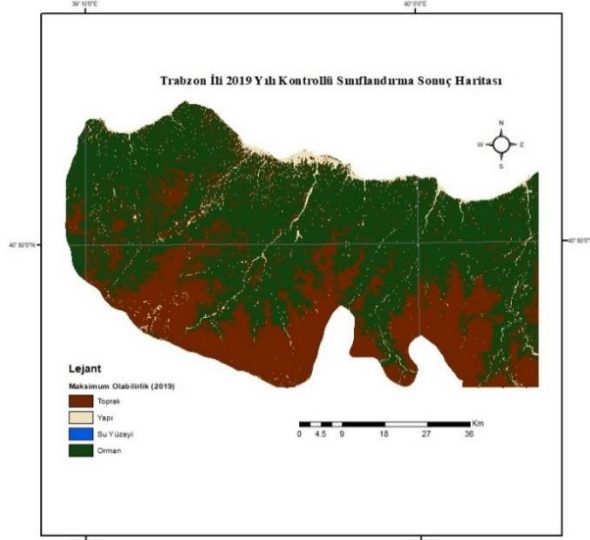
2019 ve 2020 yılları mayıs ayı verileri kullanılarak yapılan kontrolsüz sınıflandırma işlemi sonucunda oluşan haritaların karşılaştırılması sonucunda azımsanamayacak büyüklükte bir fark olduğu görülmüştür.

Çalışmada kontrollü sınıflandırma işlemlerinde 10m. mekânsal çözünürlüğe sahip bantlar kullanılmıştır. Toplamda 11 banttan oluşan uydu görüntüsünün RGB değerleri 4-3-2 şekline yani gerçek renk kompozitine dönüştürülmüştür. Gerçek renk kompozitini gösteren bu sıralama yardımıyla daha önce kontrolsüz sınıflandırmada oluşturulan sınıflar (su yüzeyi, toprak, yapı ve orman) CBS yazılımında, görüntü sınıflandırması gerçekleştirilmiştir.

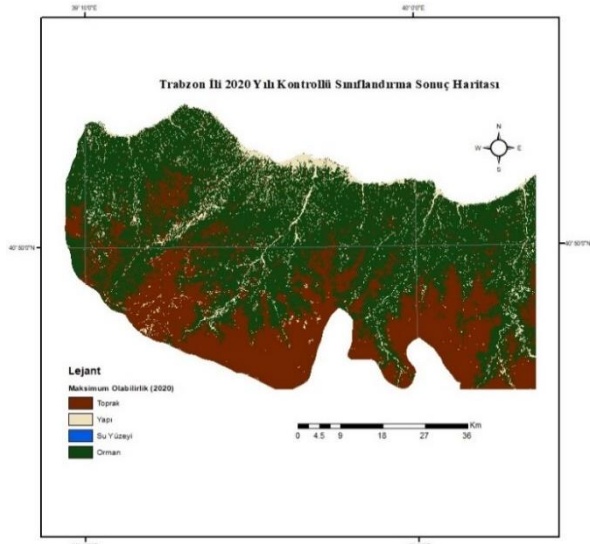
Daha sonra tanıtılan sınıflara ait alanlar sınıf başlıkları altında toplanmış ve sınıflar kayıt altına alınmıştır. Gerçek renk kompozitinin yanı sıra sınıfların tanıtılmasında eş zamanlı olarak bitki indeksini gösterir renk kompoziti, temel harita

(basemap) ve NDVI analizi sonucu oluşan haritadan da yararlanılmıştır.

Kontrollü sınıflandırmanın doğruluk derecesinin yüksek olması için her renk tonunun sınıflandırmaya dahil edilmesine özen gösterilmiştir. Bu sayede program denetimli piksel tabanlı sınıflandırmada, tanıtımı yapılan renkleri kolaylıkla ayırt etmiştir. Sınıfların tanıtılmasının ardından kontrollü sınıflandırma yöntemlerinden biri olan ve sıklıkla kullanılan EÇB yöntemine göre sınıflandırma işlemi gerçekleştirilmiştir. Kontrollü sınıflandırmanın gerçekleştirilmesinin ardından sınıflara uygun renklendirme işlemi yapılmıştır. Sonuç haritaları aşağıda verilmiştir (Şekil 6 ve 7).



Şekil 6. Trabzon İli 2019 yılı kontrollü sınıflandırma haritası



Şekil 7. Trabzon İli 2020 yılı kontrollü sınıflandırma haritası

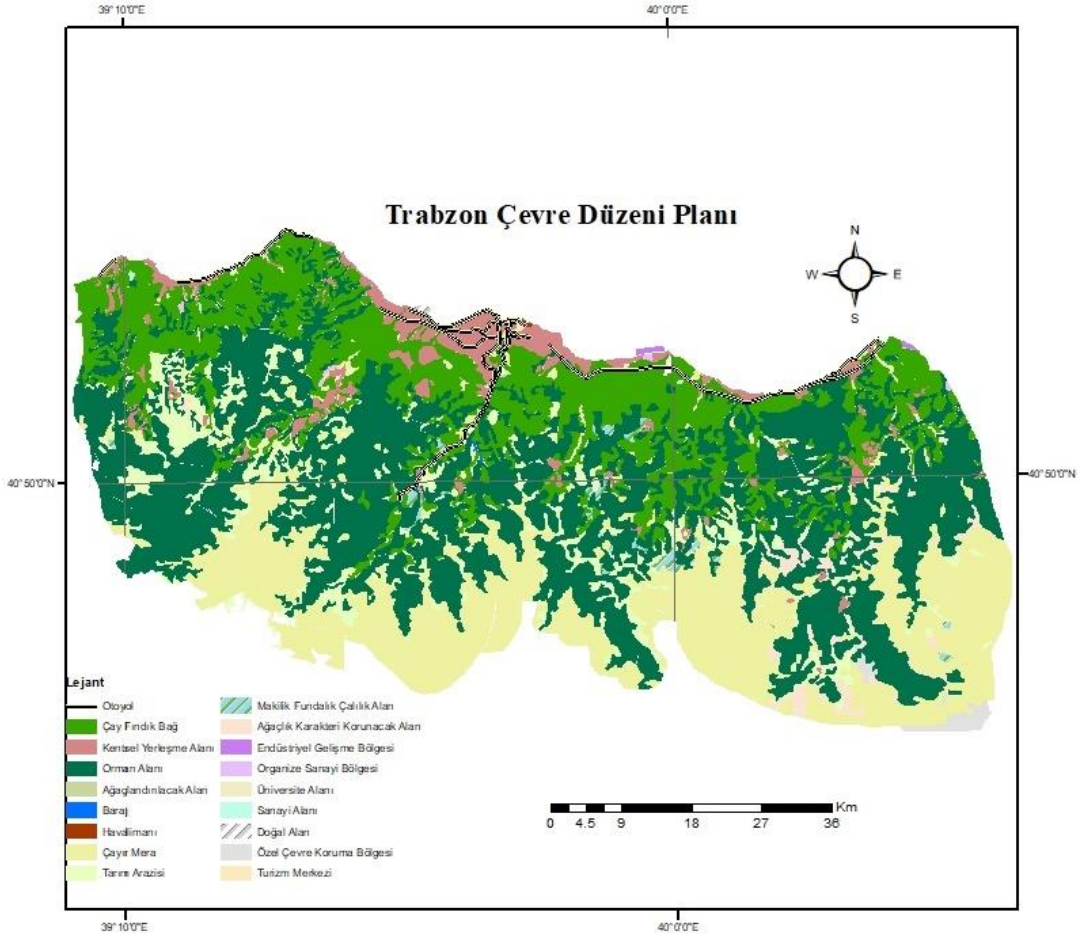
2020 yılı hata matrisinden hesaplanan 0.705761 kappa değeri; sınıflandırma işleminin, tamamen rastgele sınıflandırmada oluşacak hataların %70.6'ından arındırıldığını göstermektedir. 2019 yılı hata matrisinden hesaplanan 1.00 kappa değeri ise; sınıflandırma işleminin, tamamen rastgele sınıflandırmada oluşacak hataların %100'ünden arındırıldığını göstermektedir. Bu durum aşırı öğrenme nedeniyle oluşmaktadır ve istenilmeyen bir durumdur. Bu çalışmada yeşil alanların yapılan kontrollü ve kontrolsüz sınıflandırma işlemleriyle karşılaştırılması amacıyla Çevre, Şehircilik ve İklim Değişiklikleri Bakanlığı Mekânsal Planlama Genel Müdürlüğü'nün yayınlamış olduğu Ordu-Trabzon-Rize-Giresun-Gümüşhane-Artvin Planlama Bölgesi 1/100.000 ölçekli ÇDP'de Trabzon İline ait plan paftaları kullanılmıştır (Şekil 8).

Kontrollü sınıflandırma sonucu oluşan görüntülerin, CBS yazılımında rastgele üretilmiş olan 100 adet test noktası ile doğruluk değerlendirmesi yapılmıştır. Üretilen test ve kontrol noktalarına ilişkin değerlendirmeler gerek yerinde gerekse altlık harita üzerinden gerçekleştirilmiştir. 2019 ve 2020 yılı mayıs ayına ilişkin veri setleri için genel doğruluk ve kappa istatistikleri Tablo 2'de verilmiştir.

Tablo 2. Doğruluk analizi sonuçları

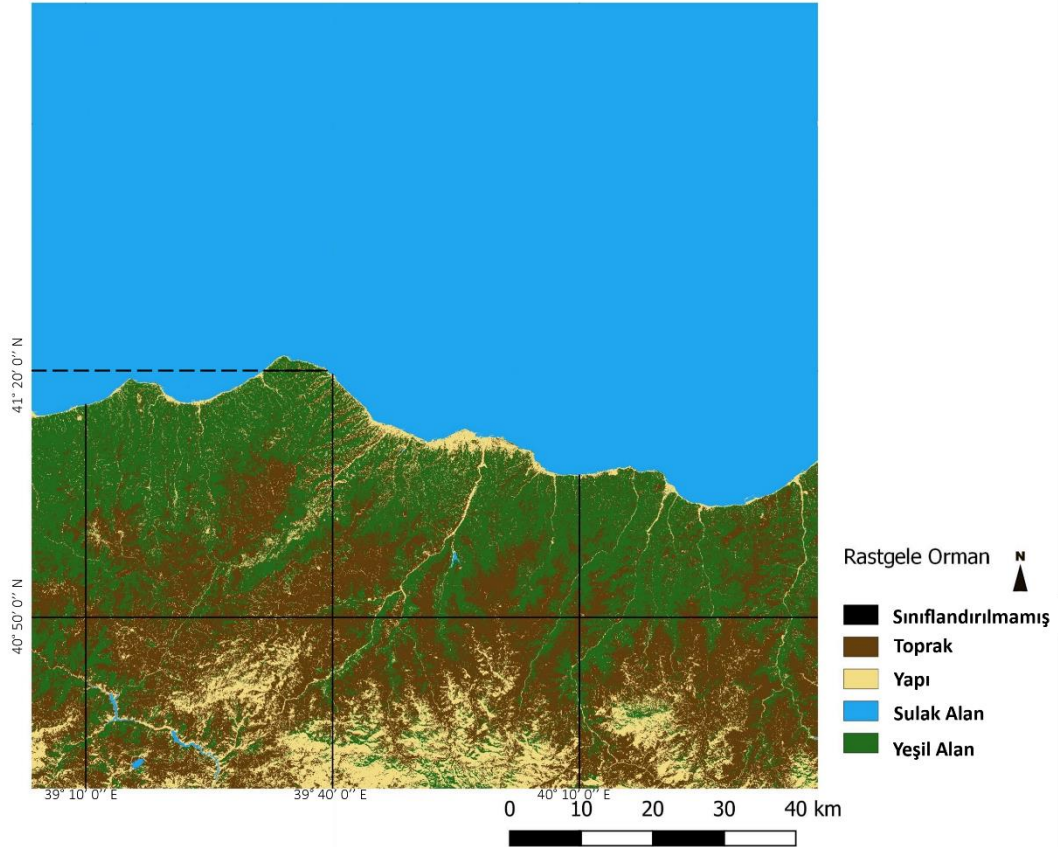
Algoritma	Yıl	Genel Doğruluk	Kappa
EÇB	2019	%100	1.00
EÇB	2020	%81.3	0.71

Burada 2019 yılına ait veri setiyle yapılan kontrollü sınıflandırma sonucu bulunan genel doğruluk değeri aşırı öğrenme (overlearning) sonucu oluşmuştur. Aşırı öğrenme, yinelemeli bir eğitim algoritması çalıştırıldığında, algoritma çok uzun süre çalıştırıldığında veya mevcut veri miktarı çok olduğunda meydana gelebilir. Bu çalışmada öncelikle 2020 yılına ait veri setinde daha sonra 2019 yılına ait veri setinde kontrolsüz sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 8. Trabzon ili ÇDP

Trabzon İli Rastgele Orman Algoritmasıyla Sınıflandırma



Şekil 9. RO algoritmasıyla sınıflandırma işlemi sonucu oluşan harita

Çalışmada RO algoritmasıyla sınıflandırma işlemi QGIS yazılımında gerçekleştirilmiştir. Daha önce kontrollü sınıflandırmada kullanılan sınıf alanları QGIS yazılımına yüklenmiştir. RO penceresinde giriş bandı seti 1, eğitim örneklerinin sayısı 5000, ağaç sayısı 100 olarak belirlenmiş ve sınıflandırıcıyı değerlendir seçeneği aktif edilmiştir ardından çalıştır komutuyla RO işlemi başlatılmıştır. Elde edilen harita Şekil 9’da sunulmuştur.

Şekil 9 incelendiğinde RO algoritmasıyla yapılan sınıflandırmanın çok yüksek derecede doğruluğa sahip olduğu görülmüştür. Daha önceki adımlarda yapılan sınıflandırma yöntemleri sonucu oluşan sonuç ürünlerle karşılaştırıldığında özellikle su yüzeyi sınıfındaki farklılık dikkat çekmektedir. Diğer sınıflandırma yöntemlerinde su yüzeyini ifade etmeyen bazı bölgeler su yüzeyi olarak sınıflandırılmışken RO yöntemiyle yapılan sınıflandırmada böyle bir şey söz konusu değildir. Bu sınıflandırma yöntemi sonucunda baraj olarak belirtilen yerler ormanlık ve toprak alanlardan, deniz olarak belirtilen yerler yapı alanlarından ayrı olarak sınıflandırılmıştır. RO algoritmasıyla sınıflandırma işlemi sonucu oluşan hata matrisi Tablo 3.’deki gibidir.

Tablo 3. RO algoritmasıyla sınıflandırma sonucu oluşan hata matrisi

Toprak			
Doğruluk	Hassasiyet	Korelasyon	Hata Oranı
0.978	0.952	0.943	0.022
Gerçek Pozitifler	Yanlış Pozitifler	Gerçek Negatifler	Yanlış Negatifler
1201	60	3690	49
Su Yüzeyi			
Doğruluk	Hassasiyet	Korelasyon	Hata Oranı
1.00	1.00	1.00	0.00
Gerçek Pozitifler	Yanlış Pozitifler	Gerçek Negatifler	Yanlış Negatifler
1250	0	3750	0
Yapı			
Doğruluk	Hassasiyet	Korelasyon	Hata Oranı
0.986	0.974	0.962	0.014
Gerçek Pozitifler	Yanlış Pozitifler	Gerçek Negatifler	Yanlış Negatifler
1211	33	3717	39
Orman			
Doğruluk	Hassasiyet	Korelasyon	Hata Oranı
0.989	0.979	0.969	0.011
Gerçek Pozitifler	Yanlış Pozitifler	Gerçek Negatifler	Yanlış Negatifler
1219	26	3724	31

4. SONUÇLAR

Bu çalışmada 2019-2020 yılları arasını kapsayan çevre durum raporuna ve bakanlık tarafından yayınlanan ÇDP’ye göre Trabzon İli yeşil

Bu çalışmada RO algoritmasıyla yapılan sınıflandırma sonucunda elde edilmiş olan doğruluk oranı %97.62’dir (Tablo 4). Bu oran oldukça yüksektir. Bu uygulamada toplamda 10000 adet örnek kullanılmıştır ve RO algoritması bu örnek verilerle 0.369 cm hata oranıyla sonuç vermiştir. KOH değerinin 0’a yakın olması istenilmektedir. Bu varsayım, RO algoritması sonucu elde ettiğimiz bulguların doğruluğunun yüksek olduğu görülmektedir (Tablo 4).

Tablo 4. RO algoritması sonucu elde edilen ölçütler

Test verisinden elde edilen doğru tahminler (%)	97.6
Toplam örnek sayısı (adet)	10000
KOH (cm)	0.37

RO algoritması bu aşamaya kadar rastgele gözlemleri seçmiş ve bir karar ağacı oluşturmuştur. RO algoritmasının son aşaması olan nihai çıktı, sınıflandırmada bulunan doğru tahminlerin ortalamasına göre elde edilmiştir. Dağıtım her sınıf için eşit oranda gerçekleştirilmiştir.

alan değişimlerinin makine öğrenmesi algoritmalarından biri olan RO algoritmasıyla ve kontrollü kontrolsüz farklı sınıflandırma yöntemleriyle yüksek doğrulukla belirlenmesi amaçlanmıştır. Uygulamada Trabzon İli’ne ait Mayıs

2019 ve 2020 tarihli Sentinel-2a uydu görüntüleri kullanılmış ve bu uydu görüntüleri dört farklı sınıf belirlenerek CBS yazılımı ile sınıflandırılmıştır. Çalışmada kontrolsüz sınıflandırma da kullanılmak üzere 10m mekânsal çözünürlüğe sahip bant kompozitlerinden NDVI analizi gerçekleştirilmiştir. Kontrollü sınıflandırmada EÇB yöntemi kullanılmış ve sınıflandırma dört farklı sınıf ile gerçekleştirilmiştir. RO algoritmasıyla sınıflandırma ise açık kaynak kodlu QGIS yazılımı ile dört farklı sınıf belirlenerek yapılmıştır.

Kontrolsüz sınıflandırma işlemi sonucu oluşan haritalarda su yüzeyi diğer sınıflara en çok karışan sınıf olmuştur. Bu durum uydu görüntülerinin çözünürlüklerinin çok yüksek olmamasından kaynaklı olduğu düşünülmüştür. Kontrollü sınıflandırma işlemi sonucu oluşan haritalarda ise sınıfların birbirine karışımı oldukça düşük derecededir. Bu durumun sebebi kontrolsüz sınıflandırmada olduğunun aksine kontrollü sınıflandırmada kullanıcı tarafından ürün sınıflarının programa tanıtılmasıdır. Yapılan kontrollü sınıflandırma işleminde 2019 yılı genel doğruluk oranı %100.00, kappa değeri 1.00 iken 2020 yılı için genel doğruluk oranı %81.31, kappa değeri ise 0.71 olarak bulunmuştur. Burada 2019 yılı için elde edilen doğruluk oranı ve kappa değeri aşırı öğrenme (overlearning) sonucu olmakla beraber zararlı bir durumdur.

Çalışmada sınıflandırma sonucu oluşan haritalarla karşılaştırılmak üzere Trabzon iline ait ÇDP kullanılmıştır. Karşılaştırma sonucunda özellikle kentsel yerleşme alanlarında bir büyümenin olduğu görülmüştür. Kontrollü sınıflandırma sonucu üretilen haritalar karşılaştırıldığında da 2019 yılında yeşil alan olarak sınıflandırılan alanların bir kısmının 2020 yılında kentsel yerleşme alanı olarak sınıflandırıldığı tespit edilmiştir. Buradan 2019 ve 2020 yılları arasındaki zaman aralığında yeşil alanlar üzerinde kentsel yerleşimin oluştuğu sonucuna varabiliriz.

RO algoritmasıyla sınıflandırma sonucunda KOH değeri 0.37 cm olarak bulunmuştur ve bu değer 0'a yakın olması sınıflandırmanın iyi bir performans gösterdiği anlamına gelmektedir. Aynı zamanda oluşan sonuç haritada su yüzeyinin diğer sınıflarla hiç karışmadığı görülmüştür.

Üç sınıflandırma yöntemi için tüm sınıflar incelendiğinde; yeşil alan sınıfının tespitinde en yüksek doğruluk değerini veren RO algoritmasıdır. RO algoritmasından sonra en yüksek doğruluk değerine sahip kontrollü sınıflandırma yöntemi ikinci, en düşük doğruluk değerine sahip kontrolsüz sınıflandırma yöntemi ise üçüncü sırada yer almaktadır. Sonuç olarak RO algoritması ile Sentinel-2a görüntülerinden iyi bir yeşil alan sınıflandırma performansının elde edilebileceği gösterilmiş ve 2019-2020 yılları arasında geçen zamanda yeşil alanların azalırken kentsel yerleşme alanlarının arttığı gözlemlenmiştir.

Teşekkür

Araştırmada kullanılan Sentinel-2 uydu verilerini ücretsiz sağlayan Avrupa Uzay Ajansı (ESA) ve Çevre Düzeni Planını ücretsiz sağlayan Çevre, Şehircilik ve İklim Değişiklikleri Bakanlığı Mekânsal Planlama Genel Müdürlüğü'ne teşekkürlerimizi sunarız.

Araştırmacıların katkı oranı beyan özeti

E. Akosman: Veri analizi, Araştırma, Modelleme, Makale yazımı;
H. B. Makineci: Konsept Oluşturma, Veri temini, Makale düzenleme, Makalenin dil bilgisi kontrolü.

Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

Araştırma ve yayın etiği beyanı

Yapılan çalışmada yazarlar, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

KAYNAKÇA

- Akar, Ö., & Güngör, O. (2012). Rastgele Orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi Ve Jeoinformasyon Dergisi*(106), 139-146. <https://doi.org/10.9733/jgg.241212.1t>
- 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. <https://doi.org/10.29128/geomatik.476668>
- Aksoy Y., Ergun N., (2009). Kentleşme Ve Yeşil Alan Sorunu Üzerine Bir Araştırma İstanbul Kenti Bakırköy İlçesi Örneği, *Tübav Bilim Dergisi*, Cilt:2, Sayı:4, Sayfa:426-438.
- Antoine L., Christophe S., Thomas C., (2016). Monitoring urban areas with sentinel-2a data: application to the update of the copernicus high resolution layer imperviousness degree, *Remote Sens*. 2016, 8(7), 606.
- Apaydın C., Abdikan S., (2021). Fındık Bahçelerinin Sentinel-2 Verileri Kullanılarak Piksel Tabanlı Sınıflandırma Yöntemleriyle Belirlenmesi. *Geomatik Dergisi – 2021; 6(2); 107-114.*
- Belward A.S. ve Skoien, J.O. (2015). Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. *ISPRS Journal of*

- Photogrammetry and Remote Sensing, vol. 103, no. May 2015, 115-128, 2014.
- Breiman, L. (2001). Random forests, machine learning, 2001 Kluwer Academic Publishers, 45(1), 5-32.
- Breiman, L. ve Cutler, A. (2005). Random Forest, http://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm (15.11.2009).
- Carlson, T. N., & Ripley, D. A. (1997). On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote sensing of Environment*, 62(3), 241-252.
- Çölkesen, İ. ve Yomralıoğlu, T. (2014). Arazi Örtüsü ve Kullanımının Haritalanmasında WorldView-2 Uydu Görüntüsü ve Yardımcı Verilerin Kullanımı, *Harita Dergisi*, Temmuz 2014 (152): 12-24.
- Dereli M. A., (2019). Sentinel-2a uydu görüntüleri ile Giresun İl merkezi için kısa dönem arazi örtüsü değişiminin belirlenmesi, *AKU J. Sci. Eng.* 19 (2019) 025501(361-368).
- Dönmez Y., Aydınöz D., (2013). Bitki Özellikleri Açısından Türkiye. İstanbul Üniversitesi Edebiyat Fakültesi Coğrafya Bölümü Coğrafya Dergisi Sayı 24, Sayfa 1-17, İstanbul, 2012.
- Fırat A. S., (2014). Doğayı Ve İnsanı Yoksullaştırıcı Kentleşme Pratikleri. *Tesam Akademi Dergisi - Turkish Journal of TESAM Academy* Temmuz - July 2014. 1 (2) . 31-64 ISSN: 2148 – 2462.
- Jensen, J. R., Garcia-Quijano, M., Hadley, B., Im, J., Wang, Z., Nel, A. L., Teixeira, E., Davis, B. A., 2006, Remote Sensing Agricultural Crop Type For Sustainable Development In South Africa, *Geocarto International*, 21 (2), 5-18.
- Karagöl S., Bayram B., Erdem F., Bakırman T., (2021). Aktarımlı Öğrenme ile SENTINEL-2 Görüntülerinden Kıyı Çizgisi Bölütlemesi. *Türkiye Uzaktan Algılama Dergisi – 2021; 3(1); 01-07.*
- Karakuş, P., 2017, Çok zamanlı uydu görüntü verileri ile tarımsal ürünlerin belirlenmesi ve verim tahmini, Doktora Tezi, Selçuk Üniversitesi.
- Karakuş P., Karabörk H., (2020). Crop Cover Fraction Estimation Based On Digital Images from 2014-2016: A Case Study of Kadirli in Osmaniye Province. *Turkish Journal of Remote Sensing – 2020; 2(2); 50-57.*
- Karasu, S., Hacıoğlu, R. & Altan, A. (2018). Prediction of Bitcoin Prices with Machine Learning Methods using Time Series Data, 26th signal Processing and Communications Applications Conference.
- Kaya, Y., & Polat, N. (2021). Bitki İndeksleri Kullanarak Buğday Bitkisinin Rekolte Tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(1), 99-110.
- Lemenkova, P. (2021). ISO Cluster classifier by ArcGIS for unsupervised classification of the Landsat TM image of Reykjavík. *Bulletin of Natural Sciences Research*, 11(1), 29-37.
- Makineci, H. B. (2023). Spatio-temporal change detection of built-up areas with Sentinel-1 SAR data using random forest classification for Arnavutköy İstanbul. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(2), 626-636.
- Malenovský, Z., Rott, H., Cihlar, J., Schaepman, E. M., García-Santos, G., Fernandes, R. and Berger, M. (2012). Sentinels for science: Potential of Sentinel-1, -2 and -3 missions for scientific observations of ocean, cryosphere, and land, *Remote Sens. Environ.*, no. 120, p. 91–101.
- Matinfar H.R., Sarmadian F., AlaviPanah S.K., Heck R.J., (2007), Comparisons of object-oriented and pixel-based classification of land use/land cover types based on landsat7, etm+ spectral bands (case study: arid region of Iran), *American-Eurasian J. Agric. & Environ. Sci.*, 2 (4), 448-456.
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S. ve Weng, Q. H., 2011, Perpixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery, *Remote Sensing of Environment*, 115 (5), 1145-1161.
- Myung I.J. 2003. Tutorial on maximum likelihood estimation. *Journal of Mathematical Psychology*, 47 90–100.
- Nijhawan, R., Srivastava, I., & Shukla, P. (2017, June). Land cover classification using supervised and unsupervised learning techniques. In *2017 international conference on computational intelligence in data science (ICCIDS)* (pp. 1-6). IEEE.
- Platt, R. V. ve Rapoza, L., (2008). An evaluation of an object-oriented paradigm for land use/land cover classification, *Professional Geographer*, 60 (1), 87-100.
- Tektaş Y., Polat N., (2021). HEC-RAS İle Taşkın Modelleme ve Sentinel-2 Uzaktan Algılama Görüntüsünden Taşkın Hasar Analizi: Diyarbakır İli Çakmak Deresi Çınar Bölgesi

Örneği. Türkiye Uzaktan Algılama Dergisi – 2021; 3(1); 28-35.

Torunlar H., Tuğaç M. G., Duyan K., (2021). Nesne Tabanlı Sınıflandırma Yönteminde Sentinel-2A Uydu Görüntüleri Kullanılarak Tarımsal Ürün Desenlerinin Belirlenmesi; Konya-Karapınar Örneği. Türkiye Uzaktan Algılama Dergisi – 2021; 3(2); 36-46.

Vlachou, S., Georgaki, M., Pagkratis, C., & Poulos, M. (2016). Unsupervised Clustering Evaluation on Services of Public Library. *WSEAS Transactions on Advances in Engineering Education*, 13, 44-49.

Weih, R. C. ve Riggan, N. D., (2010). Object-Based Classification Vs. Pixel-Based Classification: Comparative Importance of Multi-Resolution Imagery, Geobias, Geographic Object-Based Image Analysis, 38-4-C7.

Whiteside, T. G., Boggs, G. S. ve Maier, S. W., (2011). Comparing object-based and pixel-based classifications for mapping savannas,

International Journal of Applied Earth Observation and Geoinformation, 13 (6), 884-893.

Yılmaz M., (2018). Tarımsal Yaz Ürünlerin Sentinel-2 Uydu Görüntülerinden Rastgele Orman Algoritması İle Nesne-Tabanlı Sınıflandırılması.

Yiğit A. Y., Uysal M., (2019). Nesne Tabanlı Sınıflandırma Yaklaşımı Kullanılarak Yolların Tespiti. Türkiye Fotogrametri Dergisi– 2019; 1(1); 17-24.

URL-1: <https://customscripts.sentinelhub.com/customscripts/sentinel2/composites/> [Erişim tarihi: 22.06.2022]

URL-2: <https://blog.esri.com.tr/2019/02/25/sentinel-2-uydu-goruntuleriyle-esri-sentinel-2-explorer-web-uygulamasi-araciligiyla-calismak/> [Erişim tarihi: 24.06.2022].

URL-3: https://webdosya.csb.gov.tr/db/ced/icerikler/2020_trabzon_cdr-20210616135008.pdf [Erişim tarihi: 23.11.2023].



© Author(s) 2023.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>