



Yüksek mekânsal çözünürlüklü uydu görüntülerinden nesne tabanlı sınıflandırma yaklaşımı ile çay bahçelerinin çıkarılması

Burhan Baha Bilgilioglu^{*1,2}, Resul Çömert¹, Onur Yiğit¹, Ferhat Bedir¹

¹Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Gümüşhane

²İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü, İstanbul

ÖZ

Anahtar Kelimeler:

Nesne Tabanlı Görüntü
Analizi
Rastgele Orman
K-NN
Çay Bitkisi

Ülkemizde özellikle Doğu Karadeniz bölgesinde yetişmekte olan çay bitkisi bölgede yaşayan halkın geçim kaynağının büyük bir kısmını oluşturmaktadır. Ancak Doğu Karadeniz Bölgesinde yağışlara bağlı olarak meydana gelen heyelanlar çay alanlarının sürekli hasara uğramasına neden olmaktadır. Bu doğrultuda çay alanlarının zamansal izlenmesi ve takibi için haritalanması önemli bir konu olarak karşımıza çıkmaktadır. Bu çalışmada yüksek çözünürlüklü WorldView-2 uydu görüntüleri kullanılarak çay bahçelerinin belirlenmesi amaçlanmıştır. Bu kapsamda çalışma alanı olarak Artvin ili Hopa ilçesinde 8 km² 'lik bir alan test alanı olarak seçilmiştir. Çay alanlarına ait tematik harita üretimi için nesne tabanlı görüntü analizi uygulanmıştır. Segmentasyon aşamasında çoklu çözünürlükle segmentasyon algoritması kullanılmıştır. Sınıflandırma aşamasında ise makine öğrenme algoritmalarından k- en yakın komşuluk ve rastgele orman algoritması kullanılmıştır. Elde edilen sonuçlar incelendiğinde rastgele orman algoritmasının k-en yakın komşuluk algoritmasına göre daha iyi sonuçlar verdiği tespit edilmiştir.

Extraction of tea gardens by object-based classification approach from high spatial resolution satellite images

Keywords:

Object Based Image
Analysis
Random Forest
K-NN
Tea Plant

ABSTRACT

The tea plant, which grows especially in the Eastern Black Sea region, constitutes a large part of the livelihood of the people living in this region. However, landslides that occur due to rainfall in the Eastern Black Sea Region cause continuous damage to the tea areas. In this respect, mapping of tea areas for temporal monitoring and observation is an important issue. In this study, it was aimed to determine tea gardens by using high resolution WorldView-2 satellite images. For this purpose, 8 km² area was selected as a test area in Hopa district of Artvin province. Object-based image analysis was applied for the production of thematic maps of tea gardens. Multiresolution segmentation algorithm was used in the segmentation step. In the classification step, the K-nearest neighbor and random forest algorithm were used. When the obtained results were examined, it was found that random forest algorithm gave better results than K-nearest neighbor algorithm.

*Sorumlu Yazar

*(bahabilgilioglu@gumushane.edu.tr) ORCID ID 0000-0001-6950-4336
(rcomert@gumushane.edu.tr) ORCID ID 0000-0003-0125-4646
(onryigit08@gmail.com) ORCID ID 0000-0002-8502-9296
(frhtbedirr@gmail.com) ORCID ID 0000-0002-1738-8166

Kaynak Göster(APA);

BİLGİLİOĞLU, B., ÇÖMERT, R., YİĞİT, O., BEDİR, F. (2019). Yüksek mekânsal çözünürlüklü uydu görüntülerinden nesne tabanlı sınıflandırma yaklaşımı ile çay bahçelerinin çıkarılması. *Türkiye Uzaktan Algılama Dergisi*, 1 (1), 21-27. Retrieved from <https://dergipark.org.tr/tr/pub/tuzal/issue/50531/647401>

1. GİRİŞ

Türkiye’de çay sektörü Doğu Karadeniz Bölgesi ve Türkiye ekonomisi için önemli bir sektördür. Çay Doğu Karadeniz Bölgesi’nde dar bir alanda yetişme olanağı bulmasına rağmen yaşıntımızın her alanında temel içecek maddesi olarak önemli bir yere sahiptir. Ayrıca çayın aradığı iklim şartlarında farklı tarım ürünleri yetiştirme imkânlarının çok fazla olmaması bölge halkı için çayın önemini arttırmıştır (Harman, 2013). Karadeniz Bölgesinde yağışların etkisiyle birçok heyelan meydana gelmekte ve çay alanlarında ciddi hasarlar oluşturmaktadır. Bu sebepten dolayı çay alanlarının haritalanması ve zamansal izlenmesi önemli bir konu olarak karşımıza çıkmaktadır.

Geçmişten günümüze kadar tabiat içerisindeki doğal nesnelere ya da tabiatı oluşturan türlerin çeşitliliğinin belirlenmesi ve kayıt altına alınması önemli bir araştırma konusu olmuştur (He ve Legendre, 2002). Arazi üzerinde geleneksel yöntemler ile envanter toplama çalışmaları yüksek zaman, maliyet ve iş gücü gerektirmektedir. Arazinin topografyasından kaynaklı veri toplamada yaşanabilecek zorluklar ve geniş alanlarda yürütülen çalışmalar geleneksel yöntemler ile arazi çalışmalarının gerçekleştirilmesi zorlaşmaktadır. Aynı şekilde büyük ölçekte bitki türlerinin haritalanmasında hava fotoğraflarının yorumlanması da zaman gerektiren pahalı bir yöntemdir. Arazi çalışmalarının gerçekleştirilmesinde yaşanan bu zorluklar uzaktan algılama teknolojilerinin kullanımıyla aşılabilmekte, çok geniş alanlara ait bitki örtüsünün haritalanması hatta bitki türlerinin birbirinden ayırt edilmesi noktasında uydu görüntülerinin kullanımı önemli avantajlar sağlayabilmektedir (Çölkesen, 2015). Özellikle son yıllarda yüksek çözünürlükte mekânsal ve spektral bilgi üreten ve bu bilgiyi topluma sunan yüksek çözünürlüklü uyduların gelişmesi mekânsal bilgi üretiminde çok büyük kolaylık sağlamaktadır. Uydu görüntülerinin fiyatlarının düşmesi ve kullanıma sunulması da birçok uygulamanın yapılmasını kolaylaştırmıştır (Kalkan, 2010).

Yüksek çözünürlüklü uydu görüntülerinin ortaya çıkmasıyla birlikte tematik harita üretiminde klasik piksel tabanlı sınıflandırma yaklaşımı yerine nesne-tabanlı yaklaşımın kullanımı ön plana çıkmış ve yöntemin sınıflandırma doğruluğu üzerindeki olumlu etkileri ortaya koyulmuştur (Duro, 2012).

Klasik piksel ve obje tabanlı yaklaşımlara alternatif olarak uydu görüntülerinden daha doğru ve güvenilir bilgi çıkarmak için çeşitli öğrenme tabanlı algoritmalar geliştirilmektedir. Uzaktan algılama alanından uydu görüntülerinin sınıflandırılmasında en yaygın kullanılan öğrenme tabanlı algoritmalar Rastgele Orman (RO), Torbalama, Hızlandırma, Karar Ağacı, Yapay Sinir Ağları, Destek Vektör Makinesi (DVM) ve K-En Yakın Komşuluk’ tur (Akar ve Güngör, 2012).

Bu çalışmada temel olarak WorldView-2 uydu görüntüleri kullanılarak nesne-tabanlı sınıflandırma yaklaşımı ile çay alanlarına ait tematik harita üretimi

problemi ele alınmış ve uydusunun çay alanlarının sınıflandırılması üzerindeki etkisi araştırılmıştır. Segmentasyon sonucu elde edilen görüntü nesnelere ilişkin tanımlanan özellikler tespit edilmiş sınıflandırma probleminin çözümüne katkı sağlayacak en etkili özellikleri içeren veri setlerinin sınıflandırılması ve tematik harita üretiminde makine öğrenme algoritmalarından Rastgele Orman (RO) ve k-En Yakın Komşuluk (K-NN) algoritması kullanılmıştır.

2. ÇALIŞMA ALANI VE VERİ SETİ

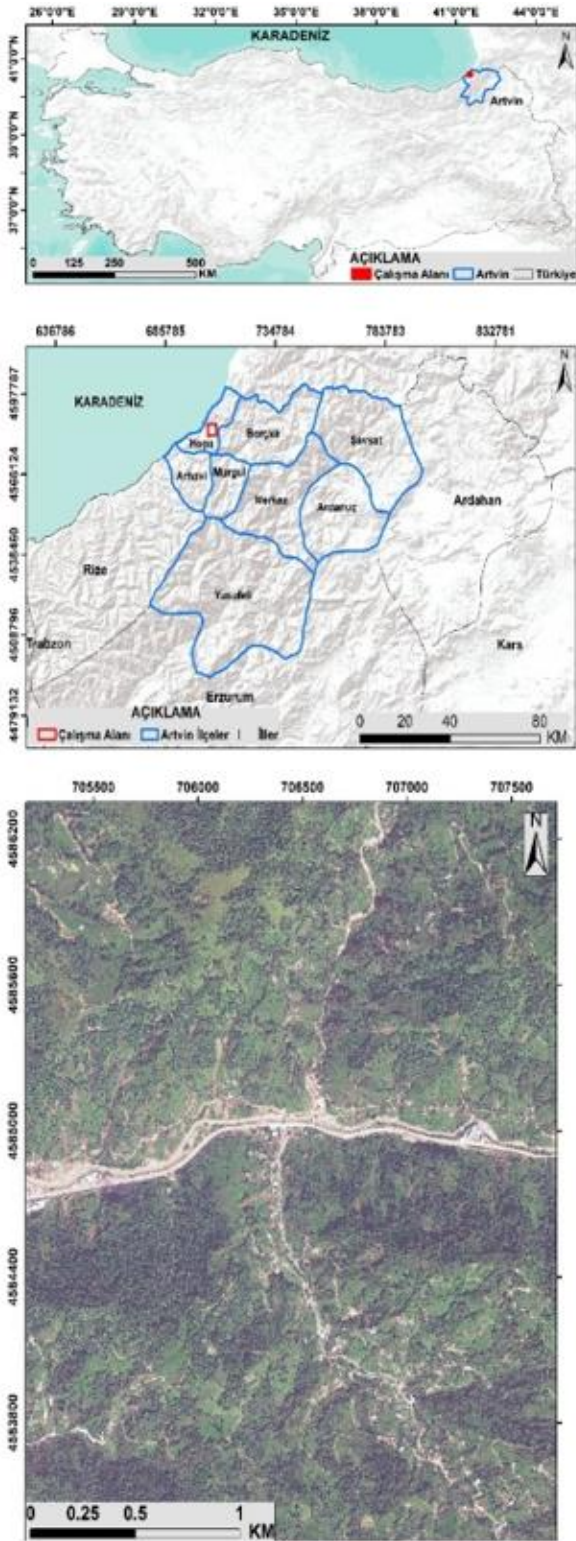
2.1. Çalışma Alanı

Türkiye, çay üretim bahçeleri alanı bakımından, dünyada 7. kuru çay üretimi yönünden de 5. sıradadır. Bir yılda kişi başına çay tüketiminde ise 4. sırada yer almaktadır (Özden, 2009). Doğu Karadeniz Bölgesinde bulunan Trabzon, Rize, Artvin, çay yetiştiriciliği için başta gelen illerdir. Bu bölgelerde yağışlara bağlı olarak heyelanlara sıkça rastlanmakta bunun sonucunda ise çay alanları hasara uğramaktadır. Hasara uğrayan çay alanlarının tespiti ve zamansal izlenebilmesi için çaylık alanların haritalanması önemli bir konu olmuştur. Bu nedenle Artvin ili Hopa ilçesine ait yaklaşık 8 km²’lik bir alan uygulama alanı olarak seçilmiştir. İlçenin doğusunda Gürcistan Cumhuriyeti, Batısında Arhavi ilçesi Güneyinde Borçka ilçesi ve Kuzeyinde Karadeniz vardır.

2.2. Veri Seti

Çalışmada veri seti olarak 07 Eylül 2015 tarihli Worldview-2 yüksek mekânsal çözünürlüklü görüntü kullanılmıştır. Worldview-2 uydusu 2009 yılı Ekim ayında fırlatılmış olup, dünyanın 8 spektral banda sahip ilk yüksek çözünürlüklü gözlem uydusudur. Güneş senkronizasyonu olan Worldview-2 uydusu, 770 km yükseklikte konumlandırılmış olup hem 0.50 m mekânsal çözünürlüklü pankromatik, hem de 2m. Mekânsal çözünürlükte çok bantlı (renkli) olarak görüntüler sağlayabilmektedir. Worldview-2 uydusu ortalama 1.1 günlük yeniden ziyaret etme süresine sahiptir (URL-1).

Tablo 1’de Worldview-2 görüntüsünün spektral bantları ve dalga boyu aralıkları gösterilmiştir (URL-1 2019). WV-2 diğer yüksek çözünürlüklü uydularda da mevcut olan ve standart bantlar olarak tanımlanan kırmızı, yeşil, mavi ve yakın kızılötesi (NIR1) bantlarda görüntüleme yapabilmektedir. Bu bantlara ek olarak 400-450nm dalga boyu aralığındaki kıyı, 585-625nm aralığındaki sarı, 705-745nm aralığındaki kırmızı kenar ve 860- 1040nm aralığında ikinci bir yakın kızılötesi (NIR2) bantlarda sahiptir.



Şekil 1. Çalışma alanı

Çalışma kapsamında, çay alanlarının çıkarılması işleminde uydu görüntüsünün spektral bantları kullanılmıştır. Sınıflandırma işlemine geçilmeden önce spektral bantlara görüntü keskinleştirme işlemi uygulanarak 2 m çözünürlük bantlar 0.5 m mekânsal çözünürlüğe sahip pankromatik bant ile kaynaştırılmış ve tüm bantların 0.5 metre mekânsal çözünürlüğe sahip olması sağlanmıştır.

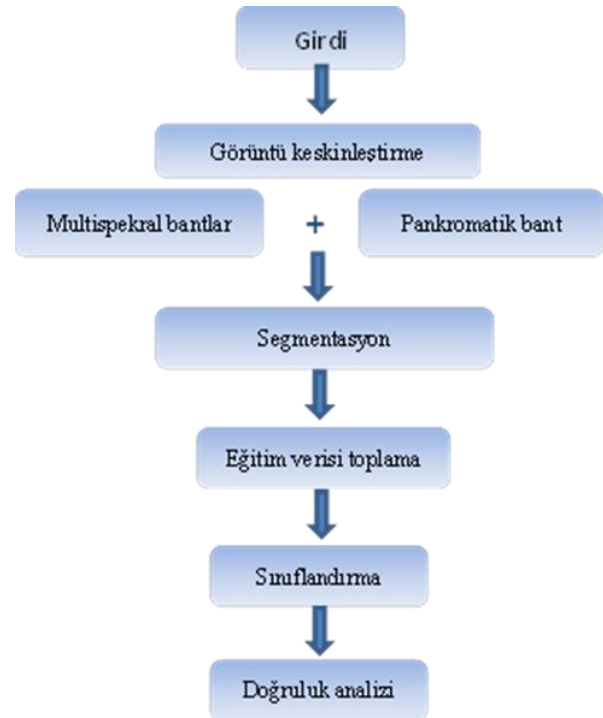
Tablo 1. WorldView-2 uydusunun teknik özellikleri (URL-1)

Yörünge	Yükseklik: 770 kilometre
	Tip: Güneş senkronizasyonlu
	Periyod: 100 dakika
Spektral Çözünürlük	Pankromatik: 450- 800 nm
	Kıyı: 400-450nm
	Mavi: 450-510nm
	Yeşil: 510-580nm
	Sarı: 585-625nm
	Kırmızı: 705-745nm
	Kırmızı kenar: 705-745nm
	Yakın kızılötesi-1: 770-895nm
Yakın kızılötesi-2:860-1040nm	
Mekânsal Çözünürlük	Pankromatik: 0,5m
	Multispektral: 2m
Radyometrik Çözünürlük	11 bit

Çalışma kapsamında, çay alanlarının çıkarılması işleminde uydu görüntüsünün spektral bantları kullanılmıştır. Sınıflandırma işlemine geçilmeden önce spektral bantlara görüntü keskinleştirme işlemi uygulanarak 2 m çözünürlük bantlar 0.5 m mekânsal çözünürlüğe sahip pankromatik bant ile kaynaştırılmış ve tüm bantların 0.5 metre mekânsal çözünürlüğe sahip olması sağlanmıştır.

3. YÖNTEM

Çay alanlarının haritalanması için nesne tabanlı kontrollü sınıflandırma işlemi uygulanmıştır. Çalışma kapsamında uygulanan iş akışı Şekil 2'de gösterilmiştir.



Şekil 2. Çalışma kapsamında uygulanan yöntemin iş akışı şeması

Sınıflandırma işleme öncesi sınıflandırma işleminde kullanılacak bantlara görüntü

keskinleştirme işlemi uygulanmıştır. Bu kapsamda spektral bantların keskinleştirilmesi için yüksek geçirgenli filtre (HPF) yöntemi uygulanmıştır (Pohl, 1998).

Nesne-tabanlı sınıflandırma genel olarak görüntü segmentasyonu ve sınıflandırma aşamalarında oluşur. Segmentasyon işlemi görüntüyü oluşturan piksellerin taşıdıkları konumsal ve spektral değerlere göre gruplandırılarak homojen görüntü nesnesi oluşturulmasıdır. Segmentasyon nesne tabanlı sınıflandırmanın ilk ve en önemli aşamasıdır (Benz ve Schreier, 2001; Jensen, 2005). Literatürde segmentasyon işlemi için çok sayıda algoritma bulunmasına rağmen en çok kullanılan yöntem çoklu çözünürlüklü segmentasyon yöntemidir. Çoklu çözünürlüklü segmentasyon yöntemi bölge geliştirme algoritması temeline dayanan bir yöntemdir. Algoritmada kullanılan heterojenlik ölçüsü, bir mekânsal bileşene ve bir spektral bileşene sahiptir. Algoritma ile doğru bir segmentasyon yapmak için belirlenmesi gereken 5 temel parametre olsa da algoritmanın çalışabilmesi için 3 parametrenin tanımlanması yeterlidir (Bilgilioglu vd. 2019). Bunlar ölçek, şekil ve bütünlük parametreleridir. Bu parametreler oluşacak görüntü nesnelerinin boyutlarını ve şekillerini belirlemektedir (Baatz ve Schape, 2001).

Sınıflandırma işleminde, oluşturulan görüntü nesnelere ilişkin spektral, dokusal, geometrik ve içeriksel birçok özellik tanımlanabilmekte ve sınıflandırmada bu özelliklerden yararlanabilmektedir (Çölkesen, 2016). Nesne tabanlı sınıflandırma kontrollü ve kural tabanlı sınıflandırma olmak üzere iki farklı şekilde uygulanabilmektedir. Kural tabanlı sınıflandırmada sınıflandırılacak her bir sınıf için kural seti geliştirilmekte ve bu kural setlerine göre görüntü nesnelere ilgili sınıfa atanmaktadır. Kontrollü sınıflandırma işleminde ise öncelikle sınıflar belirlenmekte, belirlenen sınıflara göre eğitim verileri toplanmakta ve seçilen rastgele orman, destek vektör makineleri, k-en yakın komşuluk gibi bir sınıflandırma algoritmasına göre sınıflandırma işlemi yapılabilmektedir (Jensen, 2005). Bu çalışmada sınıflandırma algoritması olarak rastgele orman (RO) ve K-en yakın komşuluk (K-NN) algoritması seçilmiştir.


RO algoritması, sınıflandırmada çok iyi performans sergilediği için toplu öğrenme yöntemlerine göre sıklıkla tercih edilmekte olan bir yöntemdir. RO algoritması, oluşturulacak karar ağacının eğitimi için orijinal eğitim veri seti içerisinde tanımlanan (spektral özellikler, bant oranları) özelliklere ait rastgele alt kümeler (karar ağacı) oluşturulur. Her bir karar ağacı sınıflandırma sonucu bir oy alır ve tüm ağaçlardan en çok oy alan karar ağacı (en düşük hata oranına sahip) belirlenerek sınıflandırmaya esas ağaç yapısı tespit edilir. Sınıf etiketi bilinmeyen herhangi bir örnek, tüm ağaç tahminlerinde en fazla oy alan sınıfa atanması suretiyle sınıflandırılır. Rastgele orman

sınıflandırıcısı için kullanıcı tarafından belirlenen iki temel parametre mevcuttur. Bu parametreler, en iyi bölünmeyi belirlemek için her bir düğümde kullanılan değişkenlerin sayısı (m) ve geliştirilecek ağaçların sayısı (N)'dir. Breiman, (2002)'a göre, m değişken değeri seçilirken, m değerinin M (toplam değişken sayısı) değişkeninin kareköküne eşit olarak alınması genellikle optimum sonuçlar verir (Akar ve Güngör, 2012).

KNN, kontrollü öğrenme sınıflandırma ve regresyon için kullanılan algoritmalarından biridir. En basit makine öğrenme algoritması olarak kabul edilir. Algoritma belirlenen eğitim verilerinden yararlanarak sınıflandırılacak verinin, mevcut verilere göre Öklid uzaklığı hesaplanıp, k (bilinmeyen noktanın en yakın komşularının miktarı) sayıda yakın komşuluğa bakılarak öznitelik değerine göre komşuların sınıfına atanır (Köktürk, 2012).

4. BULGULAR VE TARTIŞMALAR

Çalışma kapsamında öncelikle görüntü keskinleştirilmesi uygulanan spektral nesne tabanlı görüntü analizinin segmentasyon aşaması için girdi katmanlar olarak kullanılmıştır. Segmentasyon yöntemi olarak en çok kullanılan yöntem olan çoklu çözünürlüklü segmentasyon yöntemi kullanılmıştır. Spektral heterojenite için her bir bandın ağırlığı 1 olarak değerlendirmeye alınmıştır. Mekânsal heterojenlik parametreleri deneme yanılma yolu ile belirlenmiş ve çalışma amacına en uygun görüntü nesnelere elde edebilmek için ölçek:30, şekil:0,8, bütünlük: 0,6 olarak belirlenmiştir. Segmentasyon sonucu 100426 adet görüntü nesnesi elde edilmiştir (Şekil 3).



Şekil 3. Segmentasyon sonucu oluşturulan görüntü nesnelere

Segmentasyon aşamasından sonra sınıflandırma aşamasına geçilmiştir. Sınıflandırma yöntemi ile tematik harita üretiminde çalışmanın amacına uygun olarak sınıfların belirlenmesi oldukça önemlidir. Çalışma alanında farklı sınıfa ait olup birbirine benzer spektral özellik taşıyan nesnelere doğru sınıfa atamak için yeşil alanlar; orman, çayır- mera, açık çay ve koyu çay olarak 4 sınıfa ayrılmıştır. Çalışmada çay alanlarının haritalanması dikkate alındığından test alanında

bulunan toprak, yol, bina ve yapay yüzeyler için diğer adında bir sınıf oluşturulmuştur. Ayrıca görüntüde bulunan gölgelerin diğer sınıfların doğru sınıfa atanmasına etkisini azaltmak için gölge sınıfı oluşturulmuştur.

Sınıflandırmada kullanılacak sınıflar belirlendikten sonra sınıflandırma işlemi için gerekli olan eğitim verisi toplanmıştır. Eğitim verisi toplanırken, toplanan eğitim veri setinin oluşturulan sınıfları doğru temsil etmesine için homojen görüntü nesnelere seçilmesine özen gösterilmiştir. Bu doğrultuda toplanan eğitim verisi sayılarının sınıflara göre dağılımı Tablo 2’de belirtilmiştir.

Tablo 2. Sınıflara ait toplanan eğitim verisi sayısı

Sınıflar	Eğitim verisi
Açık çay	172
Koyu çay	214
Orman	628
Çayır-Mera	212
Gölge	192
Diğer	52

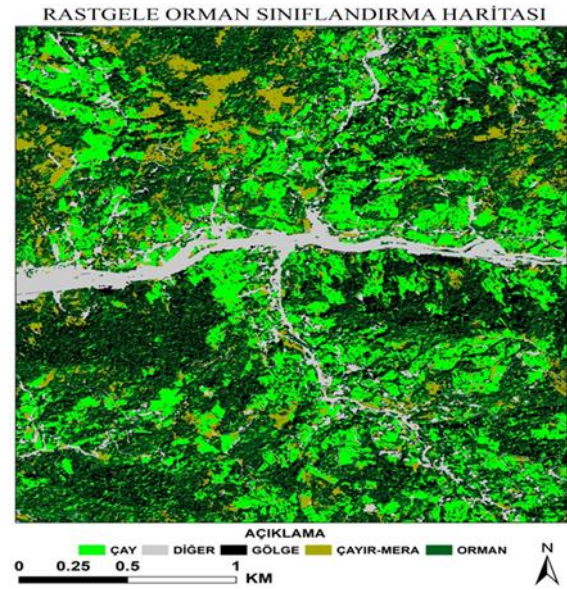
Görüntü nesnesi oluşturma ve eğitim verisi toplama aşamasından sonra toplanan eğitim verilerine göre görüntü nesnelere sınıflandırılmıştır. Sınıflandırma işlemi Rastgele Orman (RO) ve K-En Yakın Komşuluk (KNN) algoritmaları ile aynı eğitim verisi ve aynı değişkenler kullanılarak ayrı ayrı yapılmıştır. Sınıflandırılan görüntüde son işlem olarak açık çay sınıfı, koyu çay sınıfına atanarak tek bir sınıf oluşturulmuştur.

Sınıflandırma işleminde ortalama bant değerleri, parlaklık, maksimum fark ve bazı indeksler olmak üzere 22 parametre kullanılmıştır. Rastgele orman algoritmasında ağaç sayısı 1100, minimum değişken sayısı 5 alınmıştır. KNN algoritmasında ise K parametresi 1 alınarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma da kullanılan indeksler Tablo 3’te belirtilmiştir.


Tablo 3. Sınıflandırma aşamasında kullanılan İndeksler

İNDEKSLER	TANIMLAMA/FORMÜL
Normalleştirilmiş Fark Bitki Örtüsü İndeksi-1 (NDVI-1)	$\frac{(NIR2 - KIRMIZI)}{(NIR2 + KIRMIZI)}$
Homojen Olmayan Özellik Farkı (NHFD)	$\frac{(KIRMIZI KENAR - KIYI)}{(KIRMIZI KENAR + KIYI)}$
Orman ve Bitki İndeksi (FCI)	$\frac{(NIR1 - KIRMIZI KENAR)}{(NIR1 + KIRMIZI KENAR)}$
Yeşil Oran	$\frac{YEŞİL}{(KIRMIZI + YEŞİL + MAVİ)}$

Sınıflandırma işleminde kullanılan parametrelere göre Rastgele orman (RO) ve K-En Yakın Komşuluk (KNN) algoritmaları kullanılarak oluşturulan tematik haritalar Şekil 4 ve Şekil 5’de gösterilmektedir.



Şekil 4. Rastgele Orman Algoritması ile elde edilen sonuç sınıflandırma haritası



Şekil 5. K-En Yakın Komşuluk Algoritması ile elde edilen sonuç sınıflandırma haritası

Sınıflandırma sonuçlarının değerlendirilmesinde görüntü üzerine rastgele 301 adet nokta atılmıştır. Her sınıf için atılan rastgele nokta sayısı, o sınıfın görüntü üzerinde kapladığı alanla orantılı olacak şekilde belirlenmiştir. Her bir tematik haritanın genel doğruluğu aynı 301 nokta kullanılarak test edilmiştir. Her bir sınıflandırma sonucunun doğruluğu, en yaygın kullanılan sınıflandırma sonrası doğruluk analizleri yöntemlerinden biri olan hata matrisi kullanılarak değerlendirilmiştir. Elde edilen sonuçlar Tablo ve Tablo 5’de gösterilmiştir.

Tablo 4. Rastgele orman sınıflandırma işlemi sonucu elde edilen doğruluk değerleri

Sınıflar	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Çay	90,32	73,68
Orman	79,31	72,63
Çayır-Mera	70,68	46,67
Gölge	90	94,19
Diğer	82,76	81,71
Genel Doğruluk(%)=81,06 Kappa:0,7495		

Tablo 5. K-NN sınıflandırma işlemi sonucu elde edilen doğruluk değerleri

Sınıflar	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Çay	76,19	77,42
Orman	71,15	77,89
Çayır-Mera	54,17	43,33
Gölge	90,70	90,70
Diğer	91,67	78,57
Genel Doğruluk(%)=78,07 Kappa:0,7080		

Çalışma kapsamında çay alanlarının iki farklı makine öğrenme algoritmasının yüksek mekansal çözünürlüklü uydu görüntüleri ile haritalanması gerçekleştirilmiştir. Yapılan sınıflandırma işlemi sonucunda elde edilen haritalar incelendiğinde özellikle çayır – mera alanları ile çay alanlarının birbirine karıştığı gözlemlenmiştir. Ayrıca ormanlık alanlarda renk tonu olarak çay alanlarına benzer, küçük görüntü nesnelere ile temsil edilen alanlarında yer yer çay alanı olarak çıkarıldığı gözlemlenmiştir. Ayrıca görüntü tarihine ve çalışma sahasının topoğrafik özelliklerine bağlı olarak görüntüde bulunan gölgeler bazı çay bahçelerinin kenarlarında yanlış sınıflandırmaya neden olmuştur.

Çay alanlarının haritalanmasında kullanılan RO ve K-NN algoritmaları ile elde edilen sonuçlar hata matrisine göre değerlendirilmiştir. Hata matrisi sonuçları incelendiğinde RO ile yapılan sınıflandırmada çay alanlarının sınıflandırılmasında üretici doğruluğu %90,32, üretici doğruluğu %73,68 olarak elde edilmiştir. K-NN ile yapılan sınıflandırmada ise çay alanlarının sınıflandırma doğrulukları üretici doğruluğu için %76,19, kullanıcı doğruluğu için %77,42 olarak elde edilmiştir. Yapılan sınıflandırmanın genel doğrulukları incelendiğinde, RO için bu değerler %81,06 ve 0.75 olarak elde edilirken, K-NN ile %78.07 ve 0.71 olarak elde edilmiştir. Elde edilen bu sonuçlara göre RO

algoritmasının daha iyi sonuçlar verdiğini gözlemlenmiştir.

5. SONUÇ

Bu çalışmada 2015 yılına ait Worldview-2 uydu görüntüsü nesne tabanlı olarak sınıflandırılmış ve çay alanlarını gösteren tematik harita oluşturulmuştur. Sınıflandırmada Rastgele Orman ve K- En Yakın Komşuluk algoritması kullanılmış ve sınıflandırma performansları doğruluk analizleri ile test edilmiştir. RO sınıflandırıcısı ile sınıflandırılmaları sonucu %81,06, KNN sınıflandırıcısı ile sınıflandırılmaları sonucu %78,07 genel sınıflandırma doğruluğu elde edilmiştir. Buna göre RO sınıflandırma doğruluğu KNN sınıflandırma doğruluğuna göre %3 oranında arttığı gözlemlenmiştir. Ayrıca çay alanlarından elde edilen doğruluk değerlendirildiğinde çay alanlarının RO sınıflandırma işleminde KNN sınıflandırma işlemine göre % 12,9 oranında artış görülmüştür. Elde edilen sonuçlar RO algoritması ile sınıflandırmanın K-En Yakın Komşuluk algoritmasına göre başarısını ortaya koymuştur. Yapılan uygulamanın sınıflandırma aşamasında sınıfların ayırt edilebilmesi için girdi parametre olarak spektral bantların ortalama değerleri, standart sapmaları ve spektral bantlardan üretilen bant indeksleri kullanılmıştır. Çalışma kapsamında dokusal ve geometrik girdi parametreler kullanılmamıştır. Gelecek çalışmalarda bu parametrelerin sınıflandırmaya dahil edilmesi ve başarılarının araştırılması gerçekleştirilecektir.

BİLGİLENDİRME/TEŞEKKÜR

Bu çalışma 10. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği Teknik Sempozyumunda (TUFUAB-2019) Türkiye Uzaktan Algılama Dergisinde makale olarak basılması için seçilmiş bildiridir.

KAYNAKÇA

- Akar, Ö., Güngör, O., 2012, Eş Dizimlilik Matrisi Ve Rastgele Orman Sınıflandırıcısı İle Çay Ve Fındık Alanlarının Sınıflandırılması ,Türkiye Ulusal Fotogrametri Ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu (TUFUAB'2013), 23-25 Mayıs 2013, KTÜ, Trabzon.
- Baatz, M., & Schape, A. (2001). Multiresolution Segmentation: An Optimization Approach For High Quality Multi-Scale Image Segmentation. *Angewandte Geographische Informationsverarbeitung*, (Pp. 12-23): Wichmann-Verlag, Heidelberg

- Benz, U., & Schreier, G. (2001). Definiens Imaging GmbH: Object Oriented Classification And Feature Detection. IEEE Geoscience And Remote Sensing Society Newsletter, 9, 16-20
- Bilgilioglu, B. B., Ozturk, O., Sariturk, B., ve Seker, D. Z. (2019). Object Based Classification Of Unmanned Aerial Vehicle (Uav) Imagery For Forest Fires Monitoring. Feb-Fresenius Environmental Bulletin, 1011.
- Breiman, L., 2001, Random Forests, Machine Learning, 2001 Kluwer Academic Publishers, 45(1), 5-32.
- Çelik, Y. B., 2015, Mısır Ve Pamuk Ekili Alanların Çok Zamanlı Uydu Görüntüleri Ve Obje Tabanlı Sınıflandırma Yöntemi İle Tespiti.
- Çölkesen, İ., 2015, Yüksek Çözünürlüklü Uydu Görüntüleri Kullanarak Benzer Spektral Özelliklere Sahip Doğal Nesnelerin Ayırt Edilmesine Yönelik Bir Metodoji Geliştirme.
- Çölkesen, İ., Kavzoğlu T., 2016, Nesne-Tabanlı Sınıflandırmada Filtreleme Tabanlı Özellik Seçimi Algoritmalarının Kullanımı Ve Sınıflandırma Doğruluğuna Etkilerinin İncelenmesi, Uzaktan Algılama-Cbs Sempozyumu, Adana, Türkiye: Ekim 5, 7.
- Duro, D. C., Franklin, S. E., Dube, M. G., 2012, Multi-Scale Object-Based Image Analysis And Feature Selection Of Multisensor Earth Observation Imagery Using Random Forests. International Journal Of Remote Sensing, 33(14), 4502-4526.
- Harman, C., 2014, KARADENİZ BÖLGESİ'NDEKİ ENDEMİK TARIM ÜRÜNLERİ: FINDIK, ÇAY VE KİVİ'NİN ÜRETİMİ, PAZARLANMASI VE TÜKETİMİ ,Giresun Üniversitesi Fen Bilimleri Enstitüsü , Yüksek Lisans Tezi ,Giresun, 1-39s.
- He, F. L., Legendre, P., 2002, Species Diversity Patterns Derived From Species-Area Models. Ecology, 83(5), 1185-1198.
- Jensen, J. (2005). Thematic Information Extraction: Pattern Recognition. Introductory Digital Image Processing: A Remote Sensing Perspective, 337-406
- Kalkan, K. Ve Maktav, D., 2010, Nesne Tabanlı Ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (IKONOS ÖRNEĞİ), II. Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri Sempozyumu, 11 - 13 Ekim 2010, Gebze - KOCAELİ.
- Köktürk, F., 2012, K-En Yakın Komşuluk, Yapay Sinir Ağları Ve Karar Ağaçları Yöntemlerinden Sınıflandırma Başarısının Karşılaştırılması, Bülent Ecevit Üniversitesi, Sağlık Bilimleri Enstitüsü , Doktora Tezi, Zonguldak 15-22s.
- Özden, D. (2009). Türkiye Siyah Çay Sektör Raporu. Avrupa Birliği Komisyonu, İşletmeler ve Sanayi.
- Pohl, C., & Van Genderen, J. L. (1998). Review Article Multisensor Image Fusion In Remote Sensing: Concepts, Methods And Applications. International Journal Of Remote Sensing, 19(5), 823-854..
- URL-1,
http://www.nik.com.tr/content_sistem_uydu.asp?id=31. 21 Ağustos 2011