

YÜKSEK MEKÂNSAL ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜLERİNDEN NESNE TABANLI SINIFLANDIRMA YAKLAŞIMI İLE ÇAY ALANLARININ ÇIKARILMASI

F. Bedir ^{a,*}, O. Yiğit ^a, B.B. Bilgilioglu ^{a,b}, R. Çömert ^a

^a Harita Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Gümüşhane Üniversitesi,
29000 Bağlarbaşı Gümüşhane, Türkiye - (frhtbedir, onryigit08)@gmail.com
(bahabilgilioglu, rcomert)@gumushane.edu.tr

^b ITU, Geomatik Mühendisliği Bölümü, İnşaat Fakültesi, 80626 Maslak İstanbul, Türkiye - bilgilioglu16@itu.edu.tr

Anahtar sözcükler: Nesne Tabanlı Görüntü Analizi, Rastgele Orman, Çay Bahçesi, Çözünürlük, K-En Yakın Komşuluk

ÖZET

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.

1. GİRİŞ

Türkiye’de çay sektörü Doğu Karadeniz Bölgesi ve Türkiye ekonomisi için önemli bir sektördür. Çay Doğu Karadeniz Bölgesi’nde dar bir alanda yetiştirilmesine rağmen üretimimizin 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 nesnelerin 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 çalışmalarını 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 ölçekli 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 toplama 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 konulmuştur (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 algoritması kullanılmıştır.

2. ÇALIŞMA ALANI VE VERİ SETİ


Bu çalışma kapsamında Artvin ili Hopa ilçesine ait 289km²'lik alandan çay alanlarının tespiti için yaklaşık olarak 8 km²'lik bir alan test alanı olarak seçilmiştir. Çalışmada veri seti olarak 07

Eylül 2015 tarihli Worldview-2 yüksek çözünürlüklü görüntü kullanılmıştır.

2.1 Çalışma Alanı

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 8km²'lik bir alan test alanı olarak seçilmiştir. İlçenin doğusunda Gürcistan Cumhuriyeti, Batısında Arhavi ilçesi Güneyinde Borçka ilçesi ve Kuzeyinde Karadeniz vardır.



Şekil 1. Çay alanlarının haritalanması için test alanı olarak

2.2 Worldview-2 Uyduları

Çay alanlarının sınıflandırılmasında temel veri olarak kullanılan Worldview-2 uydusu 2009 yılı Ekim ayında fırlatılmış olup, dünyanın 8 spektral banda sahip ilk yüksek çözünürlüklü gözlem uydusudur. Güneş senkronizasyonlu 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.


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

Tablo 1. WorldView-2 uydusunun teknik özellikleri (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 da algılama yapabilmektedir.

Çalışma kapsamında, sınıflandırma ve tematik harita üretiminde temel uydü görüntüsü olarak, çalışma bölgesini içerisine alan 07 Eylül 2015 tarihinde kaydedilen WV-2 uydü görüntüsü kullanılmıştır. Uydü görüntüsünün 2 m konumsal çözünürlüğe sahip 8 spektral bandı ile görüntü kaynaştırma işleminin gerçekleştirilmesi amacıyla 0,5 m konumsal çözünürlüğe sahip pankromatik bandı da değerlendirmeye alınmıştır.

3. YÖNTEM

Çay alanlarının haritalanması için nesne tabanlı kontrollü sınıflandırma yöntemi kullanılmıştır. Kontrollü sınıflandırmada makine öğrenme algoritmalarından en yaygın olarak kullanılan yöntemlerden olan rastgele orman ve K-en yakın komşuluk algoritmaları kullanılarak sınıflandırma işlemi gerçekleştirilmiş, sınıflandırma sonuçları değerlendirilmiştir. Çalışma kapsamında uygulanan yöntemin iş akışı Şekil 2’de verilmiştir.



Sekil 2. Çalışma kapsamında uygulanan yöntemin iş akış şeması

Çay alanlarının haritalanmasına geçmeden önce sınıflandırmada kullanılacak bantlara görüntü keskinleştirme işlemi uygulanarak 2 m mekânsal çözünürlüğü sahip bantların çözünürlüğü 0.5 m mekânsal çözünürlüğe getirilmiştir. Görüntü keskinleştirme işleminde gerçekleştirilmesinde yüksek geçirgenli filtre yöntemi uygulanmıştır.

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. 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 3 temel parametre vardır. Bunlar ölçek, şekil ve bütünlük parametreleridir. Bu parametreler oluşacak görüntü nesnelerinin boyutlarını ve şekillerini belirlemektedir.

Sınıflandırma işleminde, oluşturulan görüntü nesnelerine 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 nesneleri 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. Bu çalışmada sınıflandırma algoritması olarak rastgele orman ve k-en yakın komşuluk 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. UYGULAMA


Uygulama aşamasında görüntü keskinleştirme için ERDAS Imagine programından yararlanılmıştır. segmentasyon, eğitim verisi toplama ve sınıflandırma işlemleri eCognition Developer 9.0 yazılımının da gerçekleştirilmiştir. Yapılan sınıflandırmanın doğruluğunun değerlendirilmesi ve harita üretimi ArcGIS 10.3 yazılımı kullanılarak yapılmıştır.

4.1 PAN-Keskinleştirme

Görüntü keskinleştirme işleminde yüksek çözünürlüğe sahip pankromatik banda yüksek geçirgenli filtre uygulanmış daha sonra 2 m mekânsal çözünürlüğe sahip 8 spektral bandı ile yüksek geçirgenli görüntü birleştirilmiş ve 0,5 m mekânsal çözünürlüğe sahip multi spektral görüntüler elde edilmiştir. Sınıflandırma işleminde bu görüntü kullanılmıştır.

4.2 Segmentasyon

Bu çalışmada segmentasyon yöntemi olarak en çok kullanılan yöntem olan çoklu çözünürlüklü segmentasyon yöntemi kullanılmıştır. Spektral heterojenite için her bir bandın ağırlıklı ortalama standart sapması 1 olarak değerlendirmeye alınmıştır. Mekânsal heterojenlik parametreleri deneme yanılma yolu ile belirlenmiş ve Çalışma amacına en uygun görüntü nesnelerini elde edebilmek için ölçek:30, şekil:0,8, yoğunluk:0,6 olarak belirlenmiştir. Segmentasyon sonucu 100426 adet görüntü nesnesi elde edilmiştir.



Şekil 3. Segmentasyon sonucu oluşturulan görüntü nesneleri

4.3 Sınıf hiyerarşisinin ve eğitim verisinin oluşturulması

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 nesneleri 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 nesnelerinden seçilmesine özen gösterilmiştir. Bu bağlamda toplanan eğitim verisi sayılarının sınıflara göre dağılımı Tablo 2’de belirtilmiştir.

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

Tablo 2. sınıflara ait toplanan eğitim verisi sayısı

4.4 Sınıflandırma

Görüntü nesnesi oluşturma ve eğitim verisi toplama aşamasından sonra toplanan eğitim verilerine göre görüntü nesneleri sınıflandırılmıştır. Sınıflandırma işlemi Rastgele Orman (RO) ve K-En Yakın Komşuluk (KNN) algoritmaları ile aynı eğitim verisi ve spektral özellikler kullanılarak ayrı ayrı yapılmıştır. Sınıflandırılan görüntüde 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, KNN algoritmasında ise K parametresi 1 alınarak sınıflandırma

işlemi gerçekleştirilmiştir. Sınıflandırma da kullanılan indeksler Tablo 3’te belirtilmiştir.

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	$\frac{YEŞİL}{(KIRMIZI + YEŞİL + MAVİ)}$

Tablo 3. Kullanılan İndeksler

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

RASTGELE ORMAN SINIFLANDIRMA HARİTASI



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

K-EN YAKIN KOMŞULUK SINIFLANDIRMA HARİTASI



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

4.5 Doğruluk analizi

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.

Sınıflar	Çay	Diğer	Gölge	Çayır-Mera	Orman	Σ
Çay	56	0	0	3	17	76
Diğer	1	24	3	1	0	29
Gölge	0	1	81	1	7	90
Çayır -Mera	2	1	0	14	2	19
Orman	3	2	2	11	69	87
Σ	62	28	86	30	95	301
Kullanıcı doğruluğu (%)	73,68	82,76	90	73,68	79,31	
Üretici doğruluğu (%)	90,32	85,71	94,19	46,67	72,63	
Genel Doğruluk(%)=81,06 Kappa:0,7495						

Tablo 4. RF Sınıflandırma Sonucu Hata Matrisi

Sınıflar	Çay	Diğer	Gölge	Çayır-Mera	Orman	Σ
Çay	48	1	0	4	10	63
Diğer	1	22	0	1	0	24
Gölge	0	2	78	1	5	86
Çayır -Mera	4	0	1	13	6	24
Orman	9	3	7	11	74	104
Σ	62	28	86	30	95	301
Kullanıcı doğruluğu (%)	76,19	91,67	90,70	54,17	71,15	
Üretici doğruluğu (%)	77,42	78,57	90,70	43,33	77,89	
Genel Doğruluk(%)=78,07 Kappa:0,7080						

Tablo 5. KNN Sınıflandırma Sonucu Hata Matrisi

5. TARTIŞMALAR

Bu 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 nesneleri 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 %90,68, 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 söylemek mümkündür.

6. SONUÇ VE ÖNERİLER

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. Elde edilen tüm sonuçlar Tablo'4 ve Tablo'5 verilmiştir. 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 deęerleri, standart sapmaları ve spektral bantlardan üretilen bant indeksleri kullanılmıřtır. Çalışma kapsamında dokusal ve geometrik girdi parametreler kullanılmamıřtır. Gelecek çalışmalarda bu parametrelerin sınıflandırmaya dahil edilmesi ve başarılarının araştırılması çay alanlarının haritalanmasındaki başarı yüzdesinin artırılması için önemlidir.

7. KAYNAKÇA

Akar, Ö., Güngör, O., 2012, Eř Dizimlilik Matrisi ve Rastgele Orman Sınıflandırıcısı İle Çay ve Fındık Alanlarının Sınıflandırılması ,Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birlięi VII. Teknik Sempozyumu (TUFUAB'2013), 23-25 Mayıs 2013, KTÜ, Trabzon.

Breiman, L., 2001, Random Forests, Machine learning, 2001 Kluwer Academic Publishers, 45(1), 5-32.

Çölkesen, İ., 2015, Yüksek Çözünürlüklü Uydu Görüntüleri Kullanarak Benzer Spektral Özelliklere Sahip Doğal Nesnelerin Ayırt Edilmesine Yönelik Bir Metodoji Geliřtirme.

Çölkesen, İ., Kavzoęlu T., 2016, Nesne-Tabanlı Sınıflandırmada Filtreleme Tabanlı Özellik Seçimi Algoritmalarının Kullanımı Ve Sınıflandırma Doğruluęuna 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 multi-sensor 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.

Kalkan, K. ve Maktav, D., 2010, Nesne Tabanlı Ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (IKONOS ÖRNEęİ), II. Uzaktan Algılama ve Coęrafi 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.

Çelik, Y. B., 2015, Mısır Ve Pamuk Ekili Alanların Çok Zamanlı Uydu Görüntüleri Ve Obje Tabanlı Sınıflandırma Yöntemi İle Tespiti.

URL-1, http://www.nik.com.tr/content_sistem_uydu.asp?id=31. 21 Ağustos 2011.