

Türkiye Uzaktan Algılama Dergisi

Cilt:1

Sayı:1

Aralık,2019

ISSN:2687-4997



Türkiye Uzaktan Algılama Dergisi



Dergi Hakkında

Türkiye Uzaktan Algılama Dergisi(TUZAL) bilim ve teknolojiadaki gelişmelere paralel olarak Uzaktan Algılama alanındaki yeniliklerle ilgili yapılan çalışmaları yayınlayan ve Uluslararası İndeks ve Veri tabanlarında taranan bir dergidir.

Amaç & Kapsam

TUZAL Dergisi,

- ✚ Uzaktan Algılama alanında ulusal ve uluslararası gelişmeleri Harita, jeoloji, Çevre, Elektrik ve Elektronik, Bilgisayar vb. mühendislik alanı ile ilgilenen bilim insanlarının bilgisine sunmak,
- ✚ Konu ile doğrudan veya dolaylı etkinliklerde bulunan bilim insanları, araştırmacılar, mühendisler ve diğer uygulayıcılar arasındaki bilgi ve deneyim paylaşımını güçlendirecek ve hızlandıracak, kolay erişilebilen, geniş katılımlı bir tartışma ortamı sağlamak ve bunları yayma olanağı yaratmak,
- ✚ Türkiye'nin teknolojik ve ekonomik kalkınmasında rol oynayabilecek Uzaktan Algılama teknolojilerine ilişkin sorunların daha etkin bir şekilde çözüme kavuşturulması açısından büyük önem taşıyan kurumlar arası işbirliğinin başlatılmasına ve geliştirilmesine katkıda bulunmak,
- ✚ Türkçe'nin Uzaktan Algılama alanında bilim dili olarak geliştirilmesini ve yabancı sözcüklerden arındırılmasını özendirmek amaçlarına sahiptir.

TUZAL Dergisinin kapsamı;

- ✓ Temel Uzaktan Algılama Uygulamaları,
- ✓ RADAR/SAR/LIDAR,
- ✓ Hiperspektral uzaktan algılama,
- ✓ Görüntü sınıflandırma ve analiz yöntemleri,
- ✓ Radyometrik düzeltme için atmosferik modellemenin geliştirilmesi,
- ✓ Küresel modelleme, izleme ve sürdürülebilir kalkınma için küresel veri tabanı ve değişim göstergelerinin belirlenmesi,
- ✓ Laboratuvar ve yerinde test yöntemleri kullanarak veri ve bilginin kontrolü,
- ✓ Uzaktan algılama ve CBS yöntemlerinin entegrasyonu,
- ✓ Afet ve risk etkilerinin azaltılması için bilgi desteği: erken uyarı sistemleri, etki değerlendirmesi, izleme, esneklik ve risk azaltma çalışmaları,
- ✓ Çevre kirliliği: değerlendirme ve etki çalışmaları,
- ✓ Jeoloji, Joemorfoloji ve Pedolojide Yeryüzü Bilimi Uygulamaların ile uzaktan algılanmış girdilerin entegrasyonu,
- ✓ Sürdürülebilir tarımsal üretim ve tarımın korunması için tarım ürünlerinin büyümesinin çok boyutlu izlenmesi,
- ✓ İklim değişikliği çalışmaları,
- ✓ Arazi kullanımı/örtüsünün küresel ve bölgesel dinamikleri, biyo-çeşitlilik, bozulma,
- ✓ Çölleşme ve kuraklık çalışmaları,
- ✓ Topraklar, bitki örtüsü ve iç, kıyı ve okyanus sularında karbon akıları,
- ✓ Su kalitesi çalışmaları vb.

Yayınlanma Sıklığı

Yılda 2 sayı(Haziran-Aralık)

ISSN

2687-4997

WEB

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

İletişim

osmanorhan44@gmail.com / osmanorhan@mersin.edu.tr / tuzaldergisi@gmail.com



Türkiye Uzaktan Algılama Dergisi



EDİTÖR

Dr. Öğr. Üyesi Osman ORHAN

Mersin Üniversitesi, FBE / Uzaktan Algılama ve Coğrafi Bilgi Sistemleri
Mersin

EDİTÖR YARDIMCILARI

Dr. Öğr. Üyesi Resul ÇÖMERT

Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi/ Harita Mühendisliği
Gümüşhane

EDİTÖR KURULU

- Prof. Dr. Dursun Zafer ŞEKER, İstanbul Teknik Üniversitesi
- Prof. Dr. Nebiye MUSAOĞLU, İstanbul Teknik Üniversitesi
- Prof. Dr. Taşkın KAVZOĞLU, Gebze Teknik Üniversitesi
- Prof. Dr. Semih EKERCİN, Aksaray Üniversitesi
- Prof. Dr. Hakan KARABÖRK, Konya Teknik Üni.
- Prof. Dr. Ömer MUTLUOĞLU, Konya Teknik Üni.
- Prof. Dr. Ferruh YILMAZTÜRK, Aksaray Üniversitesi
- Doç. Dr. Uğur AVDAN, Eskişehir Teknik Üniversitesi
- Doç. Dr. Saygın ABDİKAN, Bülent Ecevit Üniversitesi
- Doç. Dr. Enes YİĞİT, Karamanoğlu Mehmet Bey Üniversitesi
- Doç. Dr. Murat UYSAL, Afyon Kocatepe Üniversitesi
- Dr. Öğr. Üyesi Akif DURDU, Konya Teknik Üniversitesi
- Dr. Öğr. Üyesi Mustafa YALÇIN, Afyon Kocatepe Üniversitesi
- Dr. Öğr. Üyesi Lutfiye KARASAKA, Konya Teknik Üniversitesi
- Dr. Öğr. Üyesi Süleyman Şefa BİLGİLİOĞLU, Aksaray Üniversitesi
- Dr. Öğr. Üyesi Nizar POLAT, Harran Üniversitesi
- Dr. Öğr. Üyesi Mehmet Ali DERELİ, Giresun Üniversitesi
- Dr. Ali İhsan ŞEKERTEKİN, Çukurova Üniversitesi

DANIŞMA KURULU

- Prof. Dr. Murat YAKAR, Mersin Üniversitesi
- Prof. Dr. Ferruh YILDIZ, Konya Teknik Üniversitesi
- Prof. Dr. Hacı Murat YILMAZ, Aksaray Üniversitesi
- Prof. Dr. Caner ÖZDEMİR, Mersin Üniversitesi
- Prof. Dr. İbrahim YILMAZ, Afyon Kocatepe Üni.

TUZAL Dergisi Dil Editörleri

Dr. Öğr. Üyesi Pınar KARAKUŞ

Osmaniye Korkut Ata Üniversitesi, Harita Müh. Bölümü / Osmaniye

Arş. Gör. Merve Kolikpınar

Ardahan Üniversitesi, Türk Dili ve Edebiyatı Bölümü / Ardahan

Mizanpaj

Arş. Gör. Ahmet Tarık TORUN

Aksaray Üniversitesi, Harita Müh. Bölümü / Aksaray

Arş. Gör. Hasan Bilgehan MAKİNECİ

Konya Teknik Üniversitesi, Harita Müh. Bölümü / Konya

İçindekiler

Contents

Araştırma Makaleleri;

Research Articles;

S. No

-
- 1- *Yapay açıklılı radar görüntüleme algoritmalarının karşılaştırılması*
(Comparison of the synthetic aperture radar imaging algorithms)
Enes YİĞİT
- 8- *Sentinel-2A ürünlerinin yanmış orman alanlarının haritalanmasındaki başarının*
araştırılması
(Investigation of the success of Sentinel-2A products in mapping of burned forest areas)
İbrahim Halil SAYLAN & Resul ÇÖMERT
- 16- *Sınıflandırma yöntemiyle sulak alanların değişimi analizi: Dipsiz Lagün örneği* *(Analysis of*
wetland exchange using classification methods: A case study of Dipsiz Lagoon example)
Şafak BOZDUMAN
- 21- *Yüksek mekânsal çözünürlüklü uydu görüntülerinden nesne tabanlı sınıflandırma yaklaşımı*
ile çay bahçelerinin çıkarılması
(Extraction of tea gardens by object-based classification approach from high spatial
resolution satellite images)
Burhan Baha BİLGİLİOĞLU, Resul ÇÖMERT, Onur YİĞİT, Ferhat BEDİR
- 28- *Uzaktan algılama verilerinin derin öğrenme algoritmaları ile sınıflandırılması*
(Classification of remote sensing data with deep learning algorithms)
Mustafa Emre DÖŞ & Murat UYSAL



Yapay açıklıklı radar görüntüleme algoritmalarının karşılaştırılması

Enes Yiğit^{1*}

¹Karamanoğlu Mehmetbey Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Karaman

Anahtar Kelimeler:

Uzaktan Algılama
Yer-Bazlı YAR
Uyumlanmış Filtre
Algoritması
Geriye İzdüşüm
Algoritması
w-k algoritması

ÖZ

Bu çalışmada yapay açıklıklı radar görüntülerinin oluşturulmasında kullanılan yöntemlerden, Uyumlanmış Filtre, Geriye-İzdüşüm ve w-k algoritmalarının görüntü oluşturmadaki performansları karşılaştırılmıştır. Kıyaslamada çözünürlük, işlem süresi, sinyal-gürültü oranı, sinyal-karışıklık oranı ve tümleşik yan lop oranı gibi parametreler dikkate alınmıştır. Algoritmalar hem benzetim verilerine hem de 14- 18 GHz bandında ölçülen gerçek yer-bazlı yapay açıklıklı radar verilerine uygulanmıştır. Elde edilen sonuçlar, hangi tekniğin amaçlanan hedef için daha yararlı olduğu konusunda karşılaştırmalı veriler sağlamaktadır.

Comparison of the synthetic aperture radar imaging algorithms

Keywords:

Remote sensing
Ground-Based SAR
Matched Filter Algorithm
Back projection Algorithm
w-k algorithm

ABSTRACT

In this study, the performances of the matched filter, back-projection and w-k algorithms used in the reconstruction of the synthetic aperture radar images are compared. In the comparison, the parameters such as resolution, processing time, signal-to-noise ratio, signal-to-clutter ratio and integrated side lobe ratio are considered. The reconstruction algorithms are applied to both simulation data and real ground-based synthetic aperture radar data measured in 14-18 GHz band. The obtained results provide comparative data on which technique is more useful for the desired purpose.

1. GİRİŞ

Yapay Açıklıklı Radar (YAR), son 70 yıldır genellikle hava veya uzay-tabanlı sistemler ile yeryüzü veya yeraltı hedeflerinin yüksek çözünürlüklü elektromanyetik (EM) görüntülerinin oluşturulmasında kullanılan bir sinyal işleme tekniğidir (Bennet ve Cumming, 1979). Kullanılan dalga boyu, anten açıklığı ve görüntülenecek hedefin genişliğine bağlı olarak uzak alan ve yakın alan YAR görüntüleme uygulamaları yapılmıştır. Uzak alan uygulamalarında kullanılan uydu ve uçak temelli YAR sistemleri oldukça karmaşık yapıya sahip olup maliyetli platform gereksinimlerinden dolayı genel olarak karmaşık ve pahalı sistemlerdir (Bennet ve Cumming, 1979). Diğer yandan son yıllarda uygulanmaya başlanan düşük maliyetli ve pratik Yer-bazlı YAR (YB-YAR) sistemleri ile mağara girişi, tünel, köprü, su kanalı, otoyol, yer-altı mayını, bitkisel örtü gibi küçük ölçekli yapılara ait radar görüntüleri başarıyla elde edilmiştir (Leva ve ark., 2003; Zhou ve ark., 2004, Yigit ve ark., 2012). YB-YAR sistemleri geleneksel YAR sistemlerine oldukça benzemekle beraber, görüntü ve sinyal işleme tekniklerinde değişiklikler olmaktadır. Genellikle YAR, hedeften yansıyan sinyalleri iki boyutlu (2B) uzamsal-zaman bölgesinde toplar. Ancak, aynı menzilde fakat farklı yanca da bulunan hedeflerden alınan yansımalar da aynı yanca frekansında toplanır. Bunun sonucunda odaklanmamış ham YAR verisi elde edilir. Literatürde ham YAR verisinden odaklanmış görüntü elde etmek için birçok çalışma yapılmıştır. Range Doppler Algoritması (RDA) (Bennet ve Cumming, 1979) en temel odaklama algoritması olup kırk yılı aşkın bir süredir kullanılmaktadır. RDA aynı yanca frekansında toplanmış hedefleri birbirinden ayırmak için Menzül Hücre Göçü Doğrulaması (RMCM) kullanır. RMCM hem menzül hem de yanca bölgesinde gerçekleştirilen bir çeşit interpolasyondur. RDA algoritmasındaki interpolasyon basamağında bazı değişiklikler yapılarak odaklama kalitesi artırılmış ve radar anteninin farklı bakış açıları için algoritma genişletilmiştir (Jin ve Wu, 1984; Smith, 1991). Takip eden yıllarda RDA'daki interpolasyon basamağındaki işlem yükünden kaçınmak için, yeni algoritmalar geliştirilmiştir. Chirp Scaling Algoritması (CSA) herhangi bir interpolasyon adımına ihtiyaç duymadan, sadece ölçeklendirme faktörü çarpımlarıyla menzül göçünü telafi etmiştir (Cumming ve ark., 1992; Raney ve ark., 1994). Hem RDA hem de CSA lineer frekans modülasyon (LFM) dalga formu ile üretilen YAR sinyallerini odaklamaktadır. Gelişen teknoloji ile birlikte, vektör network analizörler (VNA) pratik radar uygulamaları için kullanılabilir hale gelmiş ve adım frekanslı sürekli dalga (SFCW) radarlar birçok YB-YAR sistemlerinde kullanılmaya başlamıştır (Yigit ve ark., 2011; Yigit ve ark., 2012; Yigit ve ark., 2013a). Ancak RDA ve CSA gibi popüler teknikler SFCW radar verisinde kullanılmadığı için Uyumlanmış Filtre

Algoritması (MFA) [Yigit ve ark. 2011], Geriye-İzdüşüm Algoritması (BPA) [Yigit ve ark. 2013b], ve w-k algoritması (WKA) (Yigit ve ark., 2013a) gibi farklı teknikler SFCW yapıları için uygulanmıştır. Bu üç teknik, uzaktan algılama prensiplerinin ve YAR tekniğinin kavranması noktasında birçok araştırmacı için faydalı birer odaklama aracı olmuştur. Her bir tekniğin diğerlerine göre avantaj ve dezavantajları olmasına rağmen bu üç algoritmanın performansları şimdiye kadar karşılaştırılmamıştır. Bu çalışmada MFA, BPA ve WKA'nın YB-YAR verilerindeki performansları kıyaslanmıştır. Bu kıyaslama yapılırken, Çözünürlük, İşlem süresi, Sinyal-Gürültü oranı (SNR), Sinyal-Karışıklık Oranı (SCR) ve Tümlüşik Yan lop Oranı (ISLR) gibi parametrelerden yararlanılmıştır. MFA, BPA ve WKA literatürde sıklıkla kullanılan ve ayrıntıları verilen (Yigit ve ark. 2013a, Yigit ve ark., 2011) yöntemler olduğu için bu çalışmada bu algoritmaların sinyal işleme adımları literatüre havale edilerek performans karşılaştırma parametreleri ikinci bölümde verilmiş ve benzetim sonuçları üçüncü bölümde sunulmuştur. 4. bölümde deneysel sonuçlar ve kıyaslamaları verilirken sonuç bölümünde makale özetlenmiştir ve bulgular değerlendirilmiştir.

2. YÖNTEM

2.1. YB-YAR performans göstergeleri: Çözünürlük

Radar terminolojisinde iki çeşit çözünürlükten bahsedilebilir. Bunlar menzül ve çapraz menzül (azimut) çözünürlükleridir. Menzül çözünürlüğü; aynı azimut açısında bulunan ancak farklı menzülde yer alan iki veya daha fazla hedefin birbirinden ayırt edilebilme yeteneği iken, Azimut çözünürlüğü ise, aynı menzilde fakat farklı azimut açısında bulunana iki ya da daha fazla hedefin ayırt edilebilme yeteneğidir. Menzül çözünürlüğünü belirleyen en önemli etken LFM sinyalde gönderilen darbenin genişliğidir. SFCW radarında ise bant genişliğidir. Buna göre menzül çözünürlüğü şu şekilde tanımlanır;

$$\delta_y = \frac{c}{2B} \quad (1)$$

Burada “c” ışık hızı iken, “B” bant genişliğini ifade etmektedir. Menzül çözünürlüğü tek bir faktör olan bant genişliğine bağlı iken, Azimut çözünürlüğü birkaç parametreye birden bağlıdır. Bunlar radarın hedefe olan mesafesi, kullanılan frekansın dalga boyu ve yapay açıklık mesafesidir. Buna göre kullanılan antenlerin demet genişliğinin taranılan bölge üzerindeki izdüşümü değişecek ve azimut çözünürlüğü artacaktır. YAR uygulamalarında radar anteni belirli bir hat boyunca ilerlerken, anten demet açısı içerisinde kalan hedeflerden alınan geri yansımaları toplamaktadır. Buna göre genel bir ifade

uygulamalarında yerden alınan yansımının bastırılması önem arz ettiğinden SCR yi yüksek veren algoritma üstünlük göstermektedir. Bu çalışmada yapılan uygulamada, odaklama algoritmalarının SCR performanslarını kıyaslayabilmek için iki farklı tarama yapılmıştır. İlk tarama hedefler olmadan sadece arka plan yansımının elde edilmesi için yapılırken ikinci tarama da hedefler konularak yapılmıştır. Böylelikle hedeflerin olduğu verinin maksimum genişliği, arka plan yansımının maksimum genişliğine logaritmik olarak oranlanarak SCR hesaplanmıştır.

$$SCR = 20 \log_{10} \left(\frac{A_{tar}}{A_{bck}} \right) \quad (10)$$

Burada A_{tar} ve A_{bck} sırasıyla hedeften elde edilen sinyal ile arka plandan elde edilen sinyalin maksimum genişliğini ifade etmektedir.

2.6. Tümleşik Yan lop Oranı (Integrated Side lobe Ratio) (ISLR)

Birçok YAR algoritmasının görüntüleme kalitesinin değerlendirilmesinde rol alan diğer bir etken de ISLR'dir. ISLR kısaca, yan loplara bastırabilme kabiliyeti olarak tanımlanabilir ve şu şekilde formüle edilir;

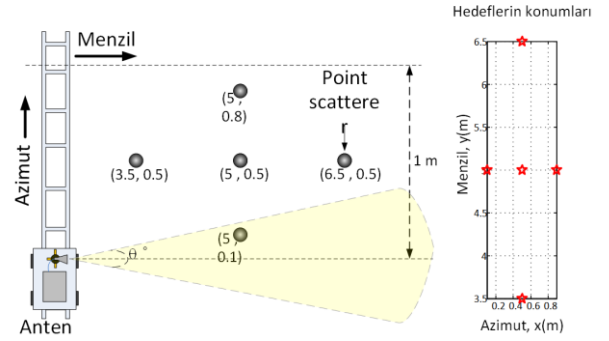
$$ISLR = 10 \log_{10} \left(\frac{E_{total} - E_{main}}{E_{main}} \right) \quad (11)$$

burada E_{total} ve E_{main} sırasıyla sinyalin toplam enerjisi ve ana lopunun enerjisi olarak verilmektedir. Bir odaklama algoritması ISLR değeri ne kadar yüksekse, o derecede de görüntü kirliliği düşük olacaktır. Zira iki boyutlu bir radar görüntüsünde bulunan her hedefin yan loplara görüntüye parazit olarak eklenmektedir.

3. BULGULAR

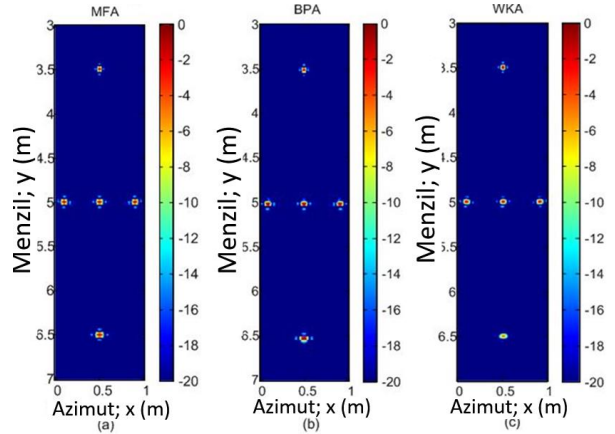
3.1. Benzetim sonuçları

Bu çalışmada sunulan tüm algoritmalar ve benzetim sonuçları MATLAB yazılımında gerçekleştirilmiştir. Konumları Şekil 2'de verilen 4 adet noktasal saçıcı hedef için geri saçılma sinyali $x = 0 m$ den $x = 1 m$ ' ye kadar toplam 201 eşit aralıkta toplanmıştır. Radar anteni olarak 16 GHz merkez frekansında monopollü boynuz tipi anten simüle edilmiştir. Her bir yapay açıklık noktasında frekans 14 GHz ile 18 GHz arasında 201 kesikli adımda değiştirilmiştir. Böylelikle ideal noktasal hedeflerin elektromanyetik benzetimi sonrası 201x201' lik 2-B uzamsal frekans B-Tarama YB-YAR verisi elde edilmiştir.




Şekil 2. Benzetim için YAR görüntüleme sistem geometrisi

Bu veriler ışığında denklem (8) ve (9) a göre yakın alan bölgesi doğrulanmaktadır. Ayrıca menzil ve azimut çözünürlükleri (1). ve (2). denklem yardımıyla 0.0375 m ve 0.0466 m olarak bulunmuştur. Karşılaştırma olarak MFA, BPA ve WKA sonuçları Şekil 3'de verilmektedir. Şekil 3'de verildiği gibi 3 algoritmanın da odaklama performansları oldukça başarılı görülmektedir. Her birisinde de hedefler doğru yerlerinde ve mükemmel olarak odaklanmıştır. Her algoritmanın göreceli çözünürlük performanslarını kıyaslamak için, hedeflerin birer kesitlerinin ($x = 0.5 m, y = 5 m$) incelenmesi gerekmektedir. 1. ve 2. Denklemler verilen formüller -4 db. çözünürlük formülleri olduğu için hedeflerin kesitlerinin Şekil 4' de verilen -4 dB 'lik genişlikleri ölçülerek, gerçek çözünürlük değerleri hesaplanabilir. Tüm çözünürlükler ve odaklamanın gerçekleşmesi için geçen süre Tablo 1' de verilmiştir.



Şekil 3. Simülasyon sonuçları (a) MFA, (b) BPA, (c) WKA





Şekil 4. Hedeflerin çevresindeki kesitler ($x = 0.5 m, y = 5 m$) (a) MFA, (b) BPA and (c) ω -kA

TABLO 1: Algoritmalar için teorik ve ölçüm çözünürlük değerleri ve işlem süreleri


X-bant Benzetimi	Teori	Ölçüm		
		MFA	BPA	WKA
Azimut Çözünürlüğü (-4 dB)	4.66 cm	4.75 cm	4.83 cm	4.78 cm
Menzil Çözünürlüğü (-4 dB)	3.75 cm	3.75 cm	3.75 cm	3.75 cm
İşlem süresi		59.52 s	1.72 s	0.15 s

3.2. Ölçüm sonuçları

Deneysel veriler TUBITAK Marmara Araştırma Merkezi Malzeme Enstitüsü İleri Teknoloji Laboratuvarında üretilen YB-YAR platformu yardımıyla elde edilmiştir. Ölçümde, 2 adet özdeş 10 cm çaplı X-Bant boynuz tipi anten kullanılmıştır (bak şekil 5(a)). 2 adet 2cm uzunluğunda ve 0.5 cm çapında metal vida yaklaşık $x = 0.5 m$ ve $y = 2 m$ pozisyonuna yerleştirilmiştir. Anten yerden 50 cm yukarıya konuşlanmış ve yaklaşık 75 derecelik bakış açısıyla yer yüzeyine yönlendirilmiştir (şekil 5(b)). Yapay açıklık 1m olacak şekilde toplam 201 eşit noktada veri toplanmıştır. Frekans 14 GHz ile 18 GHz arasında 201 adımda değiştirilmiştir. Bu verilere göre teorik olarak menzil ve azimut çözünürlükleri 3.75 cm ve 5 cm olarak hesaplanmıştır. Şekil 6 da üç adet algoritma sonucu elde edilmiş görüntüler verilirken Tablo 2’de ise, işlem süreleri ve çözünürlükler verilmektedir.



Şekil 5. (a) X-Bant boynuz tipi antenler ve metal vidalar (b) Deneyin geometrik gösterimi

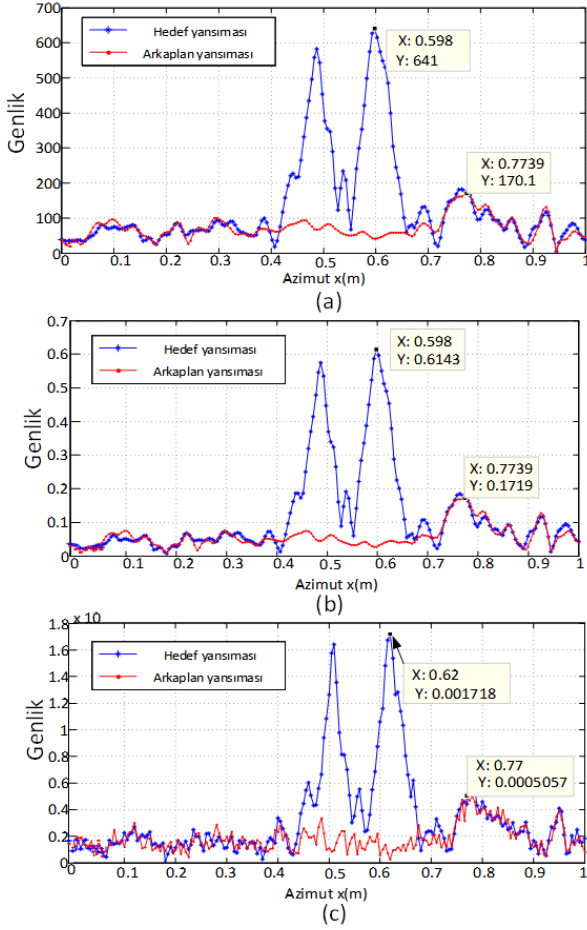


Şekil 6. Çeşitli odaklama algoritmalarıyla görüntülenmiş hedefler (a) MFA (b) BPA, (c) WKA

Her bir algoritmanın SCR ve ISLR değerleri hedeflerin bulunduğu noktalara ait kesitlerin çiziminden elde edilmektedir. Şekil 7’de 3 algoritma için hedeflerin bulunduğu noktalardan alınmış kesitler verilirken Tablo 2’de ise SCR ve ISLR değerleri verilmiştir.

TABLO 2: Algoritmaların karşılaştırılması

	X Bant Ölçüm Sonuçları		
	MFA	BPA	WKA
Azimut Çözünürlüğü	5.4 cm	5.2 cm	4.01 cm
Menzil Çözünürlüğü	4.3 cm	4.5 cm	4.4 cm
ISLR (dB)	-13.57 dB	-10.17 dB	-7.45 dB
SCR (dB)	11.53 dB	11.06 dB	10.62 dB
İşlem süresi	57.15 s	2.11 s	0.64 s
Yakın Alana Uyarlanabilirliği	Uygun	Uygun	Uygun
Eğik Mod adaptasyonu	Kolay	Kolay	Zor
Gerçek zamanlı /paralel işlem	Uygun değil	Uygun	Uygun değil



Şekil 7. Hedeflerin olduğu noktalardan alınan kesitler (a) MFA (b)BPA (c) WKA

4. SONUÇLAR

Bu çalışmada 3 farklı YB-YAR algoritmasının performansları kıyaslanmıştır. MFA en yüksek doğruluğa sahip algoritma olmasına rağmen, işlem süresi değerlendirildiğinde oldukça yüksek işlem hacmine sahip olduğu görülmüştür. Bununla birlikte MFA diğer algoritmaların performanslarının kıyaslanması için bir referans algoritma olarak kullanılabilir. Bu nedenle BPA ve WKA kıyaslanırken referans olarak alınmıştır. Tablo 2'ye bakıldığında WKA'nın gerek menzil gerekse azimut çözünürlüğünün BPA dan daha yüksek olduğu görülmektedir. İşlem süresi bakımından da WKA, BPA'dan daha hızlıdır. Ancak BPA'nın, SCR ve ISLR sonuçları WKA'nın sonuçlarından daha yüksektir. Ayrıca BPA'nın WKA'ya nazaran başka üstünlükleri de mevcuttur. Eğik mod YB-YAR uygulamalarında hem MFA'nın hem de BPA'nın adaptasyonu çok kolay olmakta ve işlem süresine bir yük bindirmemektedir (Yigit ve ark. 2011). Bunun için sadece antenlerin koordinat sistemi eğik mod açısına göre yeniden ayarlanmalıdır. Ancak WKA'nın eğik mod için adaptasyonu çok daha fazla matematiksel denklem içermekte ve ayrıca algoritmanın işlemine ek yük bindirmektedir (Fortuny and L. Sanchez, 2001; Nguyen 2011). WKA blok işlem yaptığı için, tüm verinin toplanması gerekmektedir, ayrıca blok olarak interpolasyon yaptığı için, yapay açıklık

boyunca eşit aralıklarla verilen toplanması çok önemlidir. Bu nedenle WKA gerçek zamanlı işleme müsait değildir. BPA ise her bir menzil profilini ayrı ayrı işlediği için, eşit aralıklı veri toplama zorunluluğu olmamakla birlikte gerçek zamanlı işleme de müsaade etmektedir. Ayrıca son yıllarda yapılan çalışmalarla BPA'nın performansı artırılarak işlem süresi azaltılmış böylelikle kullanım alanı artmıştır (Basu ve Bresler, 2000; Shu ve ark., 2000). Bu sonuçlar ışığında, amaca yönelik olarak farklı algoritmalar kullanılabilir ve geliştirilen yöntemler referans odaklama algoritması olan MFA ile karşılaştırılabilir.

Teşekkür

Yazar YB-YAR ölçümüne olanak sunan TUBITAK Marmara Araştırma Merkezi Malzeme Enstitüsü İleri Teknoloji Laboratuvarına ve deneylerde yardımcı olan Prof. Dr. Caner ÖZDEMİR ile Dr. Şevket Demirci 'ye teşekkürlerini sunar.

KAYNAKÇA

- A. Matthew T. (2008). A Detailed Look at the Omega-K Algorithm for Processing Synthetic Aperture Radar Data. A thesis Master of Science, Dep. of Elec. and Comp. Eng. Brigham Young University.
- Bennett, J. R. and Cumming I.G. (1979). A digital processor for the production of Seasat synthetic aperture radar imagery. Proc. SURGE Workshop, Frascati, ESA-SP-154.
- Barton D. K. (1988). Modern Radar System Analysis. Artech House, 1988
- Cumming, I., Wong, F. and Raney, K. (1992). A SAR processing algorithm with no interpolation. Proc. IGARSS '92, Houston, 376-379.
- Fortuny, J. and Lopez-Sanchez, J. M. (2001). Extension of the 3-D range migration algorithm to cylindrical and spherical scanning geometries. IEEE Trans. on Antennas and Propagation, vol. 49, no. 10, pp. 1434-1444.
- Jin, M. Y. and C. Wu, "A SAR correlation algorithm which accommodates large range migration," IEEE Trans. Geosci. Remote Sensing, vol. GE-22, pp. 592-597, 1984.
- Leva D. , Nico G., Tarchi D., Fortuny-Guasch J., and Sieber A. J. (2003). Temporal analysis of a landslide by means of a ground-based SAR interferometer. IEEE Trans. Geosci. Remote Sensing, (41), 745-752.
- Nguyen M. P. (2011). Omega-K Algorithm – A Generalization for Highly Squinted Spotlight SAR Imaging with Dechirp-on-Receive. Asia-Pacific Conference on Synthetic Aperture Radar, Seoul, Korea, 137-140.

- Raney R.K., Runge H., Bamler R., Cumming I.G., Wong F.H. (1994). Precision SAR Processing Using ChirpScaling. IEEE Trans. Geosci. Remote Sensing, vol. 32(4), 786-799.
- Basu, S. and Bresler, Y. (2000). $O(N^2 \log^2 N)$ filtered backprojection reconstruction algorithm for tomography. IEEE Transactions on Image Processing, 9(10), 1760-1773.
- Smith, A. M. (1991). A new approach to range-Doppler SAR processing. Int. J. Remote Sensing, vol. 12, 235-251.
- Shu X., Munson, D. C., Basu, S. and Bresler, Y. (2000). An $N^2 \log^2 N$ back-projection algorithm for SAR image formation. The Thirty-Fourth Asilomar Conference on Signals, Systems and Computers, Pacific Grove, CA, USA, vol. 1, 3-7.
- Yigit E., Demirci Ş., Özdemir C., Tekbaş M. (2013a). Short range ground based synthetic aperture radar imaging performance comparison between frequency wavenumber migration and back projection algorithms. Journal of Applied Remote Sensing, 7(1), 1-15.
- Yigit E., Demirci Ş., Ünal A., Özdemir C., Vertiy A. (2012). Millimeter wave Ground based Synthetic Aperture Radar Imaging for Foreign Object Debris Detection Experimental Studies at Short Ranges. Journal of Infrared, Millimeter, and Terahertz Waves, 33(12), 1227-1238.
- Yigit E., Demirci S., Yilmaz B., Ozdemir C. (2013b). Short range Ground based SAR Imaging Experiments Application of Back projection Algorithm. PIERS Proceedings, 872-875.
- Yigit E., Unal A., Demirci S., Vertiy A., Ozdemir C. (2011). An adapted matched filter algorithm for millimeter wave ground based squint mode SAR applications. IEEE, 2011 International Conference on Infrared, Millimeter, and Terahertz Waves.
- Zhou Z. S., Boerner V., Sato M. (2004). Development of a Ground-Based Polarimetric Broadband SAR System for Non-Invasive Ground-truth Validation in Vegetation Monitoring. IEEE Trans. Geoscience and Remote Sensing, 42(9), 1803-1810.



Sentinel-2A ürünlerinin yanmış orman alanlarının haritalanmasındaki başarının araştırılması

İbrahim Halil Saylan^{1*}, Resul Çömert¹

¹Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Gümüşhane

Anahtar Kelimeler:

Yanmış Alan
Değişim Saptama
Sentinel-2A
Bant İndeksi

ÖZ

Dünyanın akciğerleri olarak nitelendirilebileceğimiz ormanlar, dünya kara yüzeyinin üçte birini kapsamakta ve biyolojik çeşitliliğin ana kaynağı olarak görülmektedir. Bu biyolojik çeşitliliği tehdit eden en büyük etkenlerden biri ise orman yangınlarıdır. Yangın alanlarının haritalanması; hasar tespitinin belirlenmesi ve yangın bölgesine yapılacak müdahalelerin planlanmasında çok önemli bir etkidir. Hızlı ve maliyeti düşük bir haritalama yöntemi olması nedeniyle uzaktan algılama yöntemi ideal bir metot olarak karşımıza çıkmaktadır. Bu çalışmada orta çözünürlüklü Sentinel-2A uydusunun Seviye-1c ve Seviye-2a görüntü bantlarından faydalanılarak üretilen farklı bant indekslerinin yanmış alanların haritalanmasındaki başarısı irdelenmiştir. Uygulama için araştırma sahası olarak Yunanistan'ın Kineta şehrinde 23 Temmuz 2018 tarihinde meydana gelen yangın alanı seçilmiştir. Bu kapsamda bant indeksi olarak DVI (Fark Vegetasyon İndeksi), NDVI (Normalize Edilmiş Fark Vegetasyon İndeksi), NBR-1 (Normalize Edilmiş Yanmış Alan İndeksi 1) ve NBR-2 (Normalize Edilmiş Yanmış Alan İndeksi 2) kullanılmıştır. Çalışma kapsamında öncelikle üretilen indekslerden NBR-1 ve NBR-2 olay sonrası görüntülerine uygulanarak yanmış alanların haritalanması yapılmış, ancak elde edilen sonuçların yetersiz olduğu görülmüştür. Bu nedenle yangın öncesi uydu görüntüleri temin edilerek, olay öncesi ve olay sonrası fark indeksleri üretilmiştir. Elde edilen sınıflandırma sonuçları hata matrisine göre değerlendirilmiştir. Seviye-1c ve Seviye-2a indeksleri genel olarak karşılaştırıldığında; d-NBR-1 ve d-NBR-2 indeksleri Seviye-1C için, d-DVI ve d-NDVI indeksleri ise Seviye-2a için daha yüksek doğruluk değerleri verdiği gözlemlenmiştir.

Investigation of the success of Sentinel-2A products in mapping of burned forest areas

Keywords:

Burnt Area
Change Detection
Sentinel-2A
Band Index

ABSTRACT

Forests, which can be defined as the lungs of the world, cover one third of the world's land surface and are considered as the main source of biodiversity. One of the biggest factors threatening this biodiversity is forest fires. Mapping of burned areas is a very important factor in determining the damage assessment and planning the interventions in the fire zone. Because it is a fast and cost-effective method, remote sensing is an ideal tool for mapping burned areas. In this study, the success of different band indices produced from Level-1C and Level-2A images of Sentinel-2A satellite in change detection of burned area was examined. The research area was selected as the burned forest area in Kineta, Greece in 2018. In this context, DVI (Difference Vegetation Index), NDVI (Normalized Difference Vegetation Index), NBR-1 (Normalized Burned Area Index 1) and NBR-2 (Normalized Burned Area Index 2) were used as band indices. Within the scope of the study, firstly produced indexes NBR-1 and NBR-2 were applied to post-event images and mapped the burned areas, but the results were found to be insufficient. Therefore, pre-event and post-event difference indices were obtained by providing satellite images before fire. When Level-1C and Level-2A indexes are compared; it was observed that d-NBR-1 and d-NBR-2 indices gave higher accuracy values for Level-1C and d-DVI and d-NDVI indices for Level-2A.

*Sorumlu Yazar

Kaynak Göster(APA);

*(i_h_s_23@hotmail.com) ORCID ID 0000-0003-0703-4118
(rcomert@gumushane.edu.tr) ORCID ID 0000-0003-0125-4646

SAYLAN, İ., ÇÖMERT, R. (2019). Sentinel-2A ürünlerinin yanmış orman alanlarının haritalanmasındaki başarının araştırılması. *Türkiye Uzaktan Algılama Dergisi*, 1 (1), 8-15. Retrieved from <https://dergipark.org.tr/tr/pub/tuzal/issue/50531/647104>

Araştırma Makalesi
DOI: XXXXXXXXXXXXX

Geliş Tarihi: 14/11/2019; Kabul Tarihi: 09/12/2019

1. GİRİŞ

Dünyada her yıl yaklaşık olarak 2 milyon hektar (ha) alan orman yangınları sonucu zarar görmektedir. Bu miktarın 550.000 ha Akdeniz çevresinde bulunan ülkelerde, Türkiye, Yunanistan, İtalya, İspanya, Portekiz ve Fransa'da etkili olmaktadır (Sayın vd, 2014). Orman yangınları, ormanların olduğu kadar, doğal dengenin bozulmasına neden olmaktadır. Orman yangınlarına bağlı olarak ağaçların azalması çölleşme, erozyon ve heyelan gibi felaketlerin ortaya çıkması söz konusudur. Ayrıca insan ve diğer canlı türlerinin yaşamlarını doğrudan veya dolaylı yollardan etkilemektedir.

Yanmış orman alanlarını tespit etmek mevcut durumun analiz edilmesi, hasar tespiti ve alana yapılacak müdahaleler açısından önemlidir. Yersel ölçümlerle yanmış alanların haritalanması oldukça zaman alıcıdır. Yersel yöntemlerle karşılaştırıldıklarında uzaktan algılama yöntemleri yanmış orman alanlarının belirlenmesinde daha düşük iş gücü harcamasının yanında hızlı ve ucuz bir yöntem olarak karşımıza çıkmaktadır. Uzaktan algılama bilimindeki gelişmeler, son yıllarda birçok uydu görüntüsüne ücretsiz erişim imkânını beraberinde getirmiştir. Bu doğrultuda orta çözünürlüklü ve kısa zaman aralıklarında yayımlanan uydu görüntüleri yanmış orman alanlarının haritalanmasında önemli avantajlar sunmaktadır.

Yanmış alanların haritalanmasında uzaktan algılama yöntemlerinden sınıflandırma yaklaşımları (Palandjian vd., 2009; Petropoulos vd., 2011; Ramo ve Chuvieco, 2017), değişim saptama (Loboda vd, 2007) ve bant indekslerine bağlı haritalama sıklıkla tercih edilen yöntemlerdendir. Uydu görüntülerinden bilgi çıkarmada kullanılan yöntemlerden bir tanesi de değişim saptama analizleridir. Çok zamanlı uydu görüntüleri kullanarak bir bölgede meydana gelen değişimler bu yöntem ile belirlenebilmektedir. Görüntü bantlarından üretilen bant indisleri değişim saptama uygulamalarında sıklıkla tercih edilmektedir. Orman yangınları genellikle bölgedeki bitki ve ormanları yoğun bir şekilde etkilemektedir. Yüksek spektral yansıma özelliğine, yeşil bitkiler yakın kızılötesi bölgede sahip olurlar. Bitkilerin yoğun olduğu alanlarda meydana gelen yangınlardan sonra, yakın kızılötesi bölgede spektral yansıma değerleri düşerken kısa dalga kızılötesi bölgede spektral yansıma değerleri yükselmektedir. Olay öncesi ve olay sonrası görüntülerden, yakın kızılötesi ve kısa dalga kızılötesi bantlardan üretilen bant indekslerin farklarından yararlanılarak yapılan değişim saptama işlemi yanmış alanların haritalanmasında önemli avantajlar sağlamaktadır (Chen vd., 2015; Escuin vd., 2008).

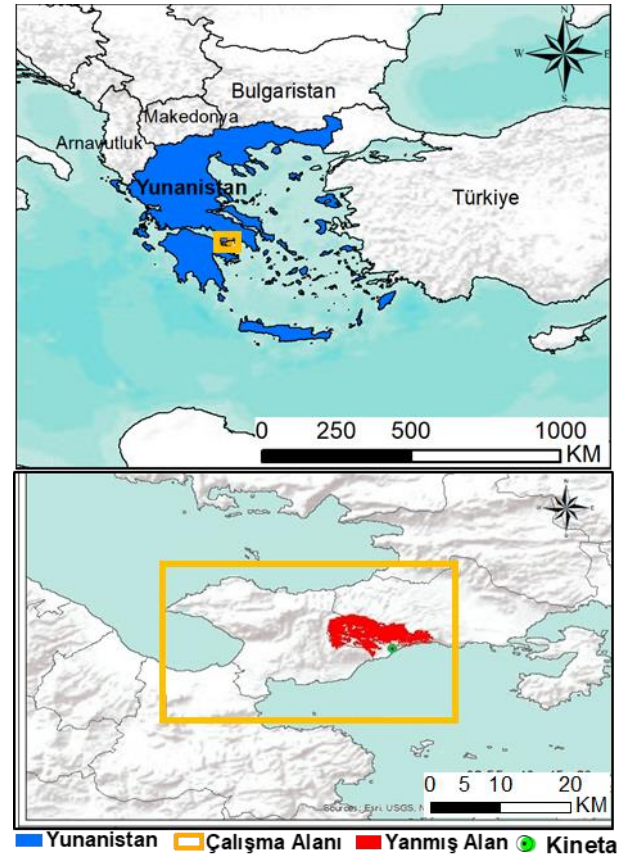
Bu çalışma kapsamında 23.07.2018 tarihinde Yunanistan'ın Kineta Bölgesinde meydana gelen orman yangın alanı incelenmiştir. Yanmış alanların belirlenmesinde Sentinel-2A uydusunun Seviye-1C

ve Seviye-2A görüntülerden yararlanılmıştır. Farklı seviye görüntülerinden üretilen yanmış alan indeksleri ve bitki indeksleri kullanılarak farklı seviye görüntülerinin orman yangınlarını haritalanmasındaki başarısı araştırılmıştır. Bu kapsamda araştırma (i) olay sonrası yanmış alan indekslerinin yanmış alanların tespitindeki başarısının araştırılması (ii) olay öncesi ve olay sonrası yanmış alan ve bitki indeksi fark haritalarının yanmış alan haritalamadaki başarısının araştırılması (iii) çözüm önerisi olmak üzere 3 adımda şekillendirilmiştir.

2. ÇALIŞMA ALANI VE VERİ SETİ

2.1. Çalışma Alanı

Bu çalışma kapsamında Yunanistan'ın Kineta bölgesinde 23 Temmuz 2018 tarihinde meydana gelen yangın sonrası ortaya çıkan yanmış orman alanı ve çevresi çalışma alanı olarak seçilmiştir (Şekil 1). Bölgenin seçilmesinde; yakın zamanda (23.07.2018) bir yangının meydana gelmiş olması ve hasar verdiği alanın büyüklüğü etkili olmuştur.



Şekil 1. Çalışma alanı olarak seçilen Kineta Bölgesi kırmızı renk, yanmış alan sarı renk ile gösterilmiştir.

Kineta Atina-Korint Ulusal Karayolunun yanında, Atina'ya 45 km, Gerania Dağı'nın gölgesinde, Megara'ya 14 km. uzaklıkta yer almaktadır. Kineta 1960'lardan bu yana tatil evlerinin inşa edilmeye başlandığı çam ağaçlarının yoğunlukta olduğu bir tatil bölgesidir. Batı

Attika'daki en iyi yerleşim yerlerinden biri olarak kabul edilmektedir. İlin en batı bölgesidir ve 6 km uzunluğun da beyaz çakıl taşları ve kumsaldan oluşan plajı vardır (URL-1).

2.2. Veri Seti

Sentinel uyduları Avrupa Uzay Ajansının Kopernik program kapsamında uzaya gönderilen uzaktan algılama amaçlı bir uydu filosudur. Bu uydu filosu, temel olarak gıda güvenliğinin yönetilmesine yardımcı olmak, tarım ve ormancılık uygulamaları çevresel yönetim, iklim değişikliğinin etkilerini anlama ve çözüm önerileri geliştirme gibi birçok amaca hizmet etmektedir. Sentinel-2 uyduları iki uydu ile 5 günde bir 56° güney ve 83° kuzey enlemler arasındaki kara ve kıyı alanları için görüntüleme yapmaktadır. Dalga boyuna bağlı olarak 10 m, 20 m ve 60 m mekânsal çözünürlüğe sahip ücretsiz veri sağlayan Sentinel-2 uyduları 13 banttan oluşmaktadır (Tablo 1) (Suhet, 2013).

Tablo 1. Sentinel-2 bant özellikleri

Sentinel-2 Grupları	Merkezi Dalga Boyu (µm)	Çözünürlük (m)
Bant 1- Kıyı aerosol	0.443	60
Bant 2- Mavi	0.490	10
Bant 3- Yeşil	0.560	10
Bant 4- Kırmızı	0.665	10
Bant 5- Kırmızı Kenar	0.705	20
Bant 6- Kırmızı Kenar	0.740	20
Bant 7- Kırmızı Kenar	0.783	20
Bant 8- NIR	0.842	10
Bant 8A- Kırmızı Kenar	0.865	20
Bant 9- Su Buharı	0.945	60
Bant 10- SWIR - Sirus	1.375	60
Bant 11- SWIR	1.610	20
Bant 12- SWIR	2.190	20

Sentinel-2 kullanıcılar için mevcut olarak atmosfer üstü gözlemlerle elde edilen Seviye-1C ve Seviye-1C verilerine getirilen atmosferik düzeltmeler sonucu elde edilen Seviye-2A görüntüleri olmak üzere 2 adet ürün sağlamaktadır (Tablo 2).

Tablo 2. Sentinel-2 ürünleri

Adı	Üst Seviye Tanım	Üretim ve Dağıtım
Seviye 1C	Kartografik geometride atmosferin üstündeki yansımalar	Sistemantik üretim ve çevrim içi dağıtım
Seviye 2A	Kartografik geometride atmosferin altındaki yansımalar	Sistemantik ve çevrim için dağıtım

Çalışma kapsamında yanmış orman alanın haritalanması ve farklı seviye görüntülerinin başarısının araştırılması için olay öncesi ve olay

sonra uydu görüntülerinin temini yapılmıştır. Sentinel-2A 5 günde bir görüntüleme yapmasına rağmen, bulutluluk gibi etkenler göz önünde bulundurularak görüntüler incelendiğinde yangın bölgesi için kullanılabilir en uygun görüntülerin olay öncesi için 03.07.2018 tarihli görüntü, olay sonrası için 19.08.2018 tarihli görüntü olduğu anlaşılmıştır. Söz konusu tarihlere ait görüntüler, atmosfer üstü (Seviye-1C) ve atmosferik düzeltmelerle elde edilen atmosfer altı görüntüler (Seviye-2A) için temin edilmiştir.

3. YÖNTEM

Çalışmada uygulanan yöntem 3 işlem adımından oluşmaktadır. Bunlar olay sonrası görüntülerden yanmış alan indeksleri ile yanmış alanların haritalanması, olay öncesi ve olay sonrası görüntülerde üretilen indeks farklarına göre değişim saptama ile yanmış alanların haritalanması ve elde edilen sonuçlara göre çözüm önerisi geliştirmektir.

Çalışma kapsamında öncelikle 20 m'lik mekânsal çözünürlüğe sahip olan 2 adet (B11 ve B12) bantta yeniden örnekleme yapılarak mekânsal çözünürlükleri 10 m'ye yükseltilmiştir. Yeniden örnekleme için en yakın komşuluk tercih edilmiştir. Bu şekilde 10 m mekânsal çözünürlüğe sahip bantlarla aynı mekânsal çözünürlükte çalışılmıştır.

Yanmış orman alanlarının belirlenmesinde ilk aşama olarak olay sonrası Sentinel-2A bantları yardımı ile yaygın olarak kullanılan Normalize Edilmiş Yanmış Alan indeksleri (NBR) hesaplanmış ve bunlara bağlı olarak yanmış alanların haritalanması gerçekleştirilmiştir. Eşitlik 1 (Key ve Benson, 2005) ve Eşitlik 2'de (Roteta, 2019) yanmış alan indekslerinin formülleri verilmiştir. (Şekil 2).

$$\text{NBR1} = (B08 - B12) / (B08 + B12) \quad (1)$$

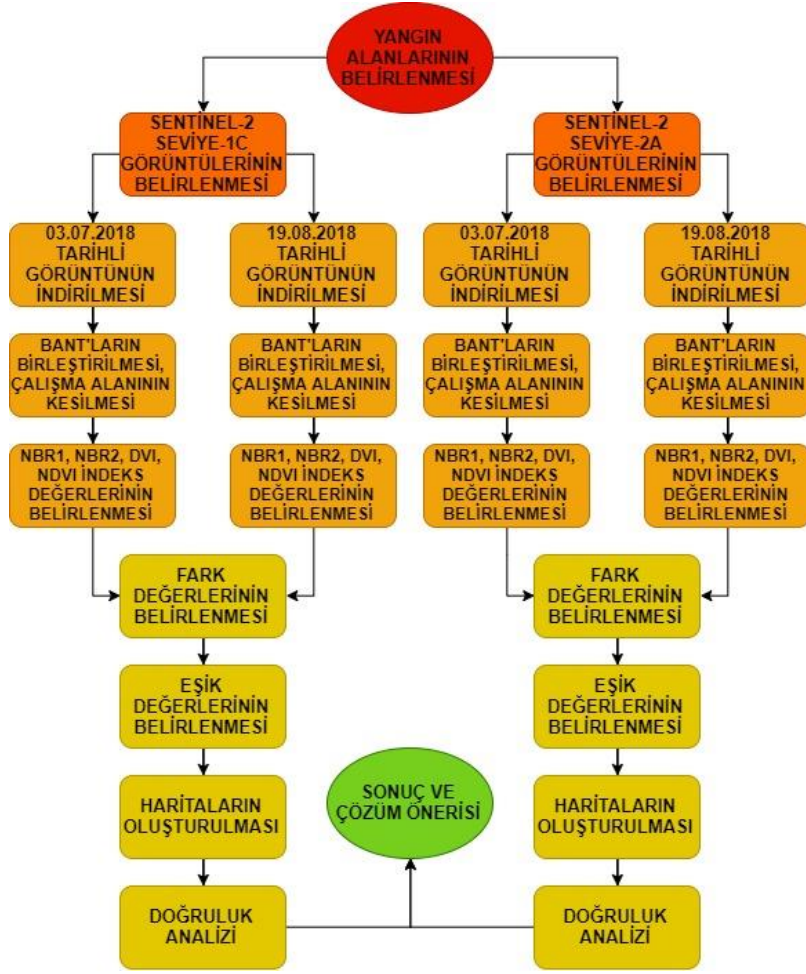
$$\text{NBR2} = (B11 - B12) / (B11 + B12) \quad (2)$$

Çalışma kapsamında ikinci olarak olay öncesi ve olay sonrası görüntülerden elde edilen bant indekslerine göre yanmış alanların haritalanması gerçekleştirilmiştir. Bu kapsamda Eşitlik 1 ve Eşitlik 2'de verilen indekslere ek olarak bitki analizlerinde sıklıkla tercih edilen fark bitki indeksi (DVI) (Richardson ve Wiegand) ve normalize edilmiş fark bitki indeksi (NDVI) (Rouse vd., 1974) de fark haritalarının üretilmesinde kullanılmıştır. DVI ve NDVI indekslerine ait formüller Eşitlik 3 ve Eşitlik 4'de verilmiştir.

$$\text{DVI} = B08 - B04 \quad (3)$$

$$\text{NDVI} = \frac{(B08 - B04)}{(B08 + B04)} \quad (4)$$

Değişim saptama amacı ile üretilen fark haritalarının elde edilmesinde uygulanan iş akışı Şekil 2'de sunulmuştur. Çalışmanın son aşamasında ise elde edilen en iyi sonuç indeksine göre problemler alanları filtreleyerek yanmış orman alanlarının haritalanması için bir çözüm önerisi sunulmuştur.



Şekil 2. Çalışma kapsamında uygulanan yönteme ait iş akış şeması


4. BULGULAR VE TARTIŞMALAR

Çalışma kapsamında öncelikle olay sonrası Seviye 1C ve Seviye 2A verilerinden yanmış alan indeksleri hesaplanarak NBR1 ve NBR2 indeks haritaları üretilmiştir. Üretilen indeksler için deneme yanılma yöntemiyle eşikler belirlenmiş, yanmış alan ve diğer alanlar olmak üzere ikiye ayrılmıştır (Tablo 3).

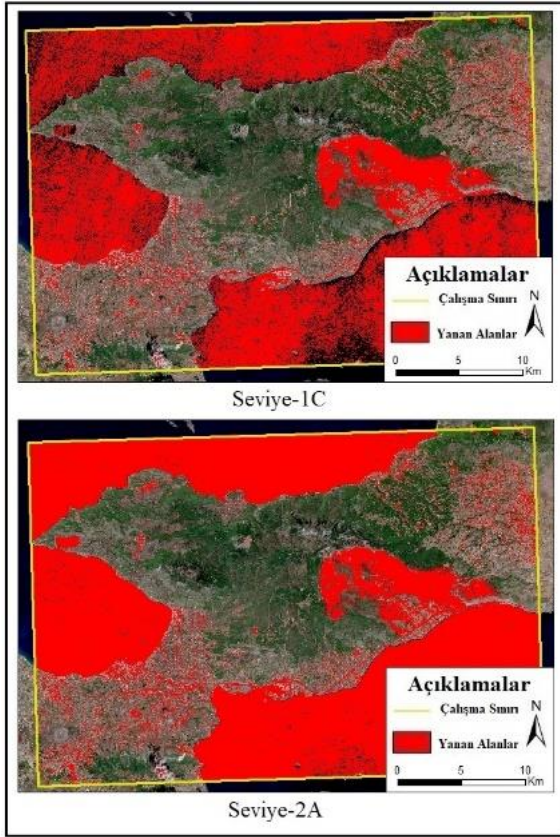
Tablo 3. Olay sonrası 19.08.2018 tarihli NBR1 ve NBR2 eşik değerleri

Seviye	İndeks	Üst Değer	Alt Değer	Eşik Değer
1C	NBR1	0.905389	-0.638325	0.05
	NBR2	0.879107	-0.647059	0.15
2A	NBR1	1	-1	0.02
	NBR2	1	-1	0.11

Belirlenen eşik değerler yardımıyla her seviye için iki adet olmak üzere toplam dört adet yangın alanı haritası üretilmiştir (Şekil 3 ve Şekil 4).



Şekil 3. Olay sonrası Seviye 1C ve Seviye 2A için üretilen NBR1 haritaları



Şekil 4. Olay sonrası Seviye 1C ve Seviye 2A için üretilen NBR2 haritaları

Elde edilen haritaların değerlendirilmesi için çalışma alanı içerisinde 550 adet rastgele kontrol noktası atılmıştır. Kontrol noktalarının gerçek değerleri bölgenin orta çözünürlüklü uydu görüntüsünden yararlanılarak elde edilmiştir. Kontrol noktaları yardımıyla üretici doğruluğu, kullanıcı doğruluğu, genel doğruluk ve kappa değerleri bulunmuştur (Tablo 4).

Tablo 4. Doğruluk analizi sonucunda elde edilen değerler Ü.D: Üretici Doğruluğu, K.D: Kullanıcı Doğruluğu, G.D: Genel Doğruluk

DOĞRULUKLAR		OLAY SONRASI	
		NBR1 (%)	NBR2 (%)
SEVİYE-1C	Ü.D	87,368	32,568
	K.D	59,286	74,736
	G.D	87,455	68,909
	KAPPA	63,030	28,058
SEVİYE-2A	Ü.D	89,474	28,294
	K.D	40,670	76,842
	G.D	75,636	62,363
	KAPPA	42,192	21,553


Üretilen haritalar ve elde edilen doğruluk değerleri incelendiğinde yangın alanının belirlenmesinde sadece olay sonrası görüntülerin yetersiz kaldığı görülmektedir. Bu nedenle yangın alanının haritalanması için olay öncesi ve olay sonrası bant indekslerinin farkları alınarak değişim

saptama ile yanmış alanların haritalanmasının başarıları araştırılmıştır. Değişim saptama yöntemi hem Seviye-1C hem de Seviye-2A veri setlerine uygulanmıştır. Bu kapsamda olay öncesi ve olay sonrası bant indekslerinden d-NBR-1, d-NBR2, d-DVI ve d-NDVI fark haritaları üretilmiştir. Üretilen fark haritalarından yanmış alanları ayırt etmek için haritalara eşik değeri belirleme işlemi gerçekleştirilmiştir. Eşik değerleri deneme yanılma yöntemiyle belirlenmiş ve elde edilen sonuçlar Tablo 5'te sunulmuştur.

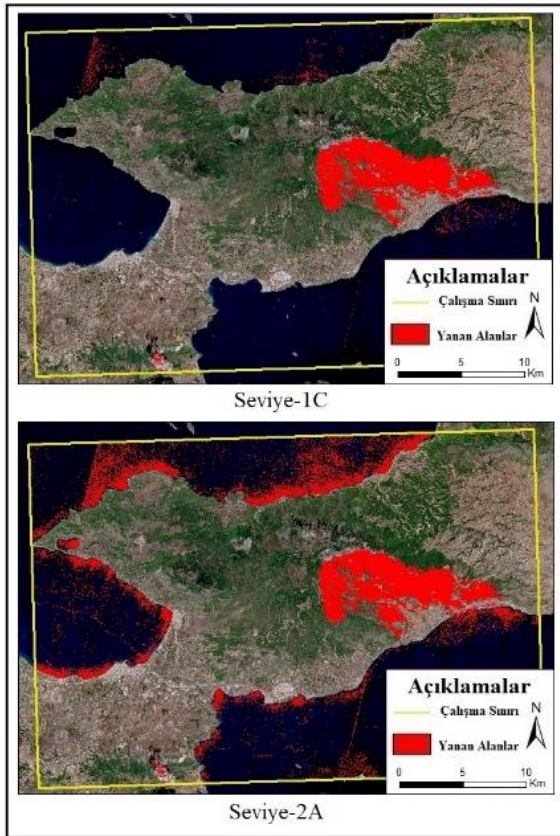
Tablo 5. 19.08.2018 tarihli NBR1 ve NBR2 eşik değerleri

Seviye	İndeks	Üst Değer	Alt Değer	Eşik Değer
1C	DVI	4855	-4233	333
	NDVI	0.793607	-0.71841	0.16
	NBR1	1.09681	-0.989632	0.11
	NBR2	0.792125	-0.879415	0.08
2A	DVI	6126	-6002	350
	NDVI	1.57207	-1.97778	0.16
	NBR1	1.65949	-1.14251	0.11
	NBR2	1.59899	-1.27334	0.08

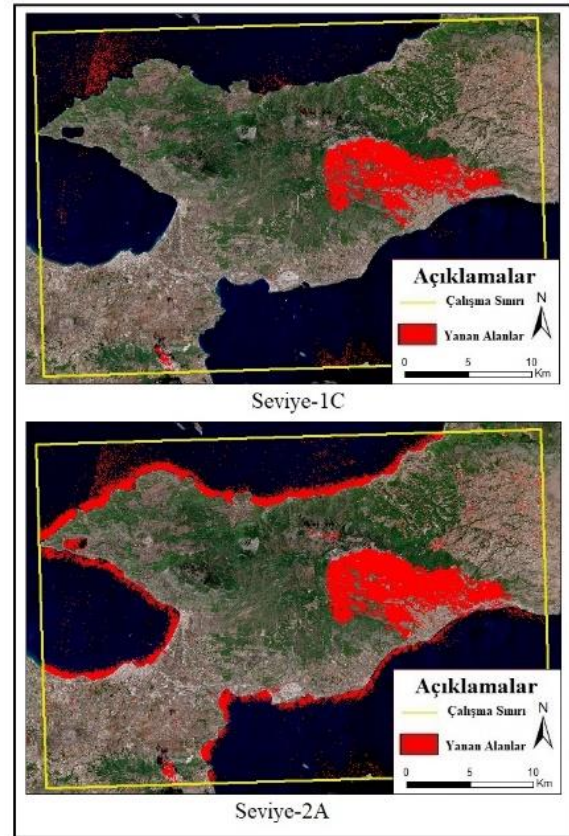
Belirlenen eşik değerlerine göre yanmış alan haritaları üretilmiştir. Üretilen bu haritalar Şekil 5, Şekil 6, Şekil 7 ve Şekil 8'de her bir fark indeksine göre Seviye 1C ve Seviye 2A için gösterilmiştir.



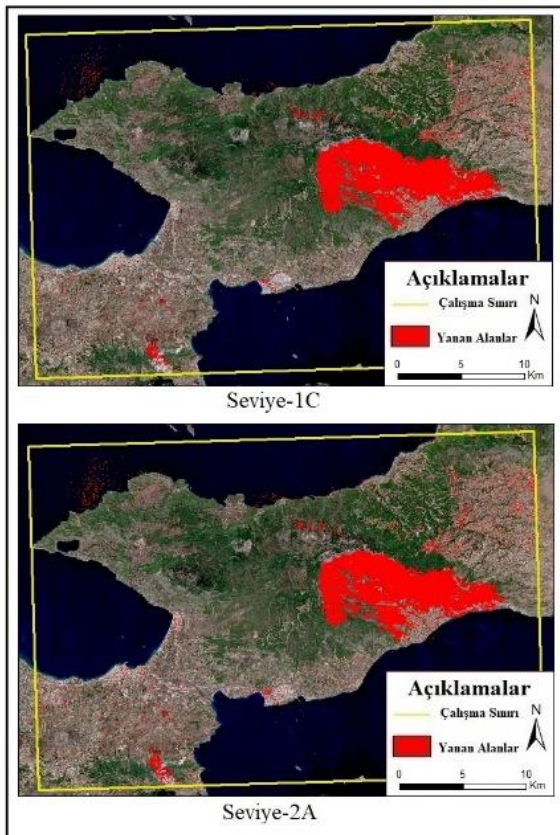
Şekil 5. Belirlenen eşik değerine göre üretilen d-NBR1 yanmış alan haritası



Şekil 6. Belirlenen eşik değerine göre üretilen d-NBR2 yanmış alan haritası



Şekil 8. Belirlenen eşik değerine göre üretilen d-NDVI yanmış alan haritası



Şekil 7. Belirlenen eşik değerine göre üretilen d-DVI yanmış alan haritası

Doğruluk analizi için daha önceden oluşturulmuş olan 550 adet rastgele kontrol noktası kullanılmış ve NBR1, NBR2, DVI ve NDVI için üretici doğruluğu, kullanıcı doğruluğu, genel doğruluk ve Kappa değerleri bulunmuştur (Tablo 6)

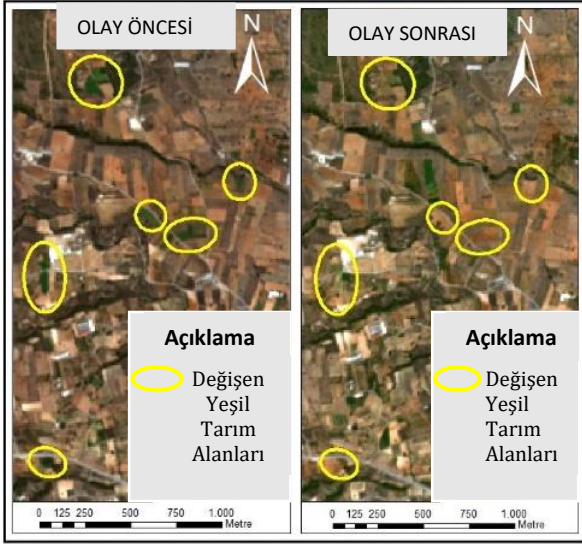
Tablo 6. Olay öncesi olay sonrası indeks farklarının doğruluk analizi sonucunda elde edilen değerler Ü.D: Üretici Doğruluğu, K.D: Kullanıcı Doğruluğu, G.D: Genel Doğruluk

DOĞRULUKLAR		OLAY ÖNCESİ VE SONRASI FARKLAR			
		DVI (%)	NBR1 (%)	NBR2 (%)	NDVI (%)
SEVİYE 1C	Ü.D	89,47	95,79	95,79	89,47
	K.D	80,95	79,13	78,45	61,15
	G.D	94,54	94,91	94,73	88,36
	KAPPA	81,68	83,56	84,66	65,56
SEVİYE 2A	Ü.D	91,58	94,74	93,68	90,53
	K.D	81,31	59,60	60,96	76,11
	G.D	94,91	88,00	88,55	93,46
	KAPPA	83,03	65,95	75,17	78,69

Tablo 6 incelendiğinde elde edilen doğruluk değerlerinin yüksek bir oranda olduğu görülmektedir. Ancak üretilen haritaların tamamı için su alanlarında hatalar meydana gelmektedir. Özellikle Seviye-2A için üretilen haritalarda hataların su alanlarında yoğunlaştığı görülmektedir.

Haritaların kuzeydoğusun tarım alanları yer almaktadır. Bu alanlarda bazı yerler yanmış alan

olarak çıkarılmıştır. Olay öncesi ve sonrası görüntüler arasında 47 günlük bir zaman farkı bulunmaktadır. Bu zaman dilimi arasında alanda yer alan bazı ekili tarım alanlarında hasat toplama gibi bir eylemin gerçekleştiği görülmektedir. Bu işlem sonucunda da bu alanlarda da yeşil bitki örtüsü değiştiği için değişim saptama aşamasında, uygulanan yöntem ile yanmış alan olarak çıkarılmıştır (Şekil 9).



Şekil 9. Olay öncesi ve olay sonrası görüntülerde alandaki yeşil alanların yangın dışındaki etkenlerden dolayı değişimi

Üretilen haritalar incelendiğinde hataların büyük bir kısmının su alanlarından kaynaklandığı ve Seviye-2A da bu hataların daha yoğun olduğu görülmektedir.

Haritalarda tarım alanlarından dolayı meydana gelen hatalar, görüntüler arasındaki zaman farkı kısaltılarak kolay bir şekilde giderilebilir. Zira görüntüler arası zaman farkı kısaltılacak olunursa Şekil 9 söz konusu hasat toplama gibi etkenler sorun olmaktan çıkacaktır.

Çalışma kapsamında öncelikle olay sonrası görüntülerden yanmış alan indeksleri üretilerek, bu haritaların karşılaştırılması yapılmıştır. Elde edilen NBR1 ve NBR2 haritaları incelendiğinde yangın alanı dışında kalan ancak yapılan işlemler sonucunda yangın alanı olarak çıkan alanlar göz ardı edilemeyecek kadar çoktur. Bu nedenle değişim saptama işlemi yapılmış ve indeks farklarından elde edilen d-NBR1, d-NBR2, d-DVI, d-NDVI haritaları her bir görüntü seviyesi için üretilmiştir. Seviye-1C için NBR1 %94,909 doğruluk ile en iyi sonucu, Seviye-2A için Fark Vejetasyon İndeksi DVI %94,909 doğruluk ile en iyi sonucu vermiştir.

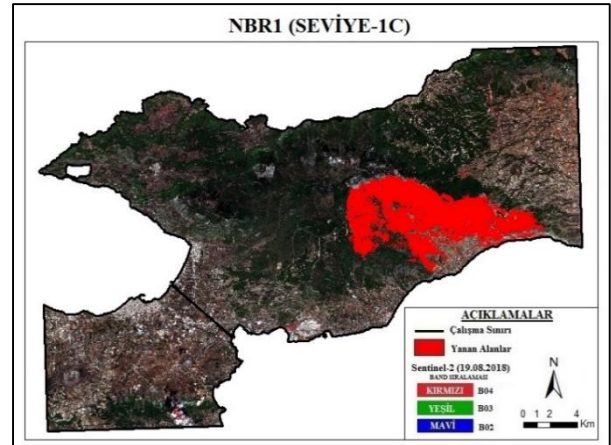
Değişim saptama yönteminde kullanılan yangın öncesi ve sonrası görüntülerde değişimi tespit edilmek istenen yangın bölgesi dışında mevsimsel değişimler, görüntünün elde edildiği saate bağlı gölge ve parlamalar, bulutluluk, denizlerdeki gel-git ve dalgalanma vs. sebeplerden dolayı istenmeyen farklılıklar tespit edilebilmektedir. Bu istenmeyen

tespitlerin elimine edilmesi doğruluk oranını artıracaktır.

Üretilen haritaların hepsi incelendiğinde Seviye-1C için NBR1, NBR2, DVI ve NDVI haritalarında su alanlarında meydana gelen az yoğun hatalar göze çarparken, Seviye-2A için ise DVI haritasında su alanlarında hatalar göze çarpmakta ancak NBR1, NBR2, NDVI haritaları için bu hatalar (özellikle kıyıya yakın bölgelerde) yoğunlaşmaktadır. Su alanlarındaki bu hataların büyük bir kısmının su buharının etkisinden kaynaklandığı düşünülmektedir. Seviye-2A görüntülerinde su alanlarındaki hatanın Seviye-1C görüntülerine göre daha fazla olması ise; Seviye-2A görüntülerinin atmosferik düzeltmeler neticesinde atmosfer altı görüntüye dönüştürülmesine bağlıdır. Hataların kıyı bölgelerinde yoğunlaşmasının nedeni ise kıyı bölgelerinde daha fazla buharlaşmanın olmasıdır.

Haritalardaki meydana gelen su alanlarındaki hataların giderilmesi için su alanları maskelenebilir. Böylece söz konusu su alanlarındaki hatalar sorun olmaktan çıkacak ve yangın alanı daha hassas bir şekilde belirlenebilecektir. Araştırma kapsamında Normalize Edilmiş Fark Su İndeksi (NDWI) (Eşit. 5) kullanılarak su alanları maskelenmiştir (McFeeters, 1996). Maskeleyenme sonucunda Fark haritalarından en iyi sonucu veren d-NBR1 fark indeksine göre yanmış alan haritası tekrardan üretilmiştir (Şekil 10).

$$NDWI = (B08 - B03) / (B08 + B03) \quad (5)$$



Şekil 10. Çözüm önerisi olarak su alanlarının maskelenmesi

5. SONUÇ

Bu çalışma kapsamında öncelikle olay sonrası görüntülerden yanmış orman alanları haritalanmak istenmiş ancak, elde edilen sonuçların bu işlem için yetersiz olduğu görülmüştür. Bundan dolayı değişim saptama ile farklı bitki indekslerinden yanmış alanların haritalanması işlemi gerçekleştirilmiştir. Değişim saptama ile elde edilen sonuçlar irdelendiğinde yanmış orman alanlarının yüksek doğrulukla elde edilebildiği görülmüştür. Ancak özellikle su alanlarında problemler olduğu

görülmüştür. Bu doğrultuda çalışma kapsamında su alanları filtrelenerek ve en iyi sonuç alınan NBR1 indeksi ile yanmış orman alanlarının daha doğru bir şekilde elde edilebileceği gösterilmiştir.

TEŞEKKÜR

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

KAYNAKÇA

Chen, G. ve ark. (2015) Mapping burn severity in a disease-impacted forest landscape using Landsat and MASTER imagery. *International Journal of Applied Earth Observation and Geoinformation*, 40, 91-99.

Escuin, S. ve ark. (2008). Fire severity assessment by using NBR (Normalized Burn Ratio) and NDVI (Normalized Difference Vegetation Index) derived from LANDSAT TM/ETM images. *International Journal of Remote Sensing*, 29(4), 1053-1073.

Key, C. and N. Benson, N. "Landscape Assessment: Remote Sensing of Severity, the Normalized Burn Ratio; and Ground Measure of Severity, the Composite Burn Index." In FIREMON: Fire Effects Monitoring and Inventory System, RMRS-GTR, Ogden, UT: USDA Forest Service, Rocky Mountain Research Station (2005).

Loboda, Tatina, K.J. O'neal, and I. Csiszar. (2007) "Regionally adaptable dNBR-based algorithm for burned area mapping from MODIS data." *Remote Sensing of Environment* 109.4, 429-442.

McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International journal of remote sensing*, 17(7), 1425-1432.

Palandjian, D. ve ark. (2009). Burned area mapping and post-fire impact assessment in the Kassandra peninsula (Greece) using Landsat TM and Quickbird data. *Geocarto International*, 24(3), 193-205.

Petropoulos, G. ve ark. (2011) Burnt area delineation from a uni-temporal perspective based on Landsat TM imagery classification using support vector machines. *International Journal of Applied Earth Observation and Geoinformation*, 13(1), 70-80.

Picotte, J.J. ve Robertson, K. M. (2011) Validation of remote sensing of burn severity in south-eastern US ecosystems. *International Journal of Wildland Fire*, 20: 453-464.

Ramo, R. Ve Chuvieco, E. (2017). Developing a Random Forest Algorithm for MODIS Global Burned Area Classification. *Remote Sensing*, 9(11), 1193.

Richardson, A. J., & Wiegand, C. L. (1977). Distinguishing vegetation from soil background information. *Photogrammetric engineering and remote sensing*, 43(12), 1541-1552.

Roteta, E., Bastarrika, A., Padilla, M., Storm, T., & Chuvieco, E. (2019). Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa. *Remote sensing of environment*, 222, 1-17.

Rouse Jr, J., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS.

Sayın, S. ve ark. (2014) Orman Yangınlarında İş Sağlığı ve Güvenliği, Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi, 15: 168-175.

Suhet, (2013) Sentinel-2 User Handbook 1: 9.

URL-1: <https://www.revolvy.com/page/Kineta>, 20.12.2018



Sınıflandırma yöntemiyle sulak alanların değişimi analizi: Dipsiz Lagün örneği

Şafak Bozduman*¹

¹Mersin Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Mersin, Türkiye

Anahtar Kelimeler

Değişim Tespiti
Veri
ENVI
Maksimum Likelihood
Uydu Görüntüsü
Göl

ÖZ

Sulak alanlar insan hayatı için ekonomik, kültürel ve bilimsel anlamda önemli oluşumlardır. Bu alanlarda yaşamını sürdüren nesli tükenme tehlikesi altında olan birçok bitki veya hayvan türleri için de önemli sahalardır. Bu sebeple sulak alanların korunması çalışmasını yürütmek yeryüzündeki tüm canlı yaşamı için önemli bir husustur. Uzaktan Algılama verileri yardımıyla yıllara göre su alanındaki değişimleri gözlemlemek mümkündür. Bu değişimleri izlemek için Landsat-5 (TM) ve Landsat-8 OLI/TIRS uydu görüntüleri kullanılmıştır. Kontrollü sınıflandırma (maksimum likelihood) yöntemi kullanılarak yıllara göre sınıflandırma yapılmıştır ve değişikliklerin tespit edilmesi için karşılaştırma tekniği kullanılmıştır. Bu karşılaştırma sonunda Mersin-Tarsus ilçesinde bulunan Dipsiz Lagün üzerinde değişimler tespit edilmiştir. Değişim sonuçları analizi yapılmıştır. Analizin sonunda su alanında 2005 yılına göre azalma olduğu tespit edilmiştir.

Analysis of wetland exchange using classification methods: A case study of Dipsiz Lagoon example

Keywords

Change Detection
Data
ENVI
Maksimum Likelihood
Satellite Image
Lake

ABSTRACT

Wetlands are important natural formations for human life in economical, cultural and scientific aspects. These formations are also important for endangered plant or animal species which inhabit there. Therefore, working to protect wetlands is an important task for all living creatures on Earth. With the help of remote sensing data, it is possible to observe the changes of water levels by years. In this study, Landsat-5 (TM) and Landsat-8 OLI/TIRS satellite images were used to analyse said changes. By using supervised classification method, classification was made for each year and comparison technique was used to detect changes through the years. At the end of this comparison, the change of water levels in the Dipsiz Lagoon, which is located in Mersin-Tarsus, was analysed. Following this analysis, it is concluded that the water levels in Dipsiz Lagoon were decreased over the years.

1. GİRİŞ

Lagünler; deniz, akarsu, göl gibi su kütlelerinin etkisinde kalan sığ su alanlarıdır (Kırkgöz, 1998; Orman ve Su İşleri Bakanlığı,2018). Bu sulak alanlar biyolojik kaynaklar, doğal su tasfiye özelliği, kuş göç yolları ve bu kuşlar için beslenme ve konaklama olanağı temin eden ekolojik ve ekonomik yönden büyük bir öneme sahip muhafaza edilmesi gereken kıyı set gölleridir (Beklioğlu ve ark., 2007; Orman ve Su İşleri Bakanlığı,2018). Sulak Alanlar, biyolojik çeşitliliğin fazla olduğu ekosistemlere örnektir. Bu alanlar beşeri ve coğrafi fonksiyonlara sahiptir. İçme suyu eldesi, yeraltı sularının beslenmesi, besin stoğu, doğal tasfiye, hayvancılık, balıkçılık, ve turizm bu fonksiyonlara örnek olarak verilebilmektedir.

Sulak alanlar için oldukça fazla tanım bulunmaktadır fakat dünya üzerinde en çok kabul gören tanım Ramsar Sözleşmesi'nde yer almaktadır (Pakalne, 2004; Orman ve Su İşleri Bakanlığı,2018).

"RAMSAR Sözleşmesi'nde (Özellikle Su Kuşları Yaşama Ortamı Olarak Uluslararası Öneme Sahip Sulak Alanlar Hakkında Sözleşme) (Madde 1) sulak alanlar; "doğal veya yapay, devamlı veya geçici, suları durgun veya akıntılı, tatlı, acı veya tuzlu, denizlerin gel-git hareketinin çekilme devresinde altı metreyi geçmeyen derinlikleri de kapsayan bütün sular, bataklıklar, sazlıklar ve turbalıklar" olarak tanımlanmıştır. Bu tanım 30 Ocak 2002 tarih ve 24656 sayılı Resmi Gazete'de yayımlanan Sulak Alanların Korunması Yönetmeliği'nde, 01/07/2003 kabul tarihli 4915 sayılı Kara Avcılığı Kanunu'nda ve 26/04/2006 tarihinde yürürlüğe giren değişiklikle 2872 sayılı Çevre Kanunu'nda yer alarak ulusal mevzuatımıza girmiştir. 04.04.2014 tarih ve 28962 sayılı (Değişik:01.08.2017-30141 R.G.S) Sulak Alanların Korunması Yönetmeliği' gereğince de mevzuatımızca korunmaktadır."

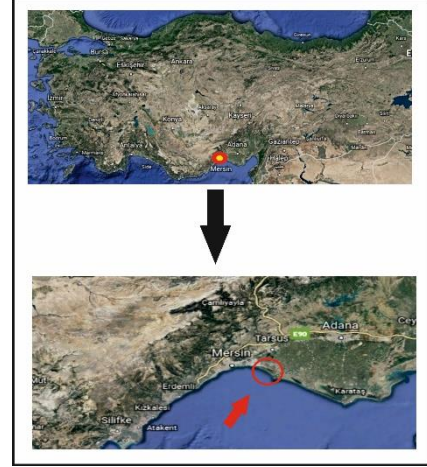
Zamansal değişim analizleriyle korunması ve faydalanılması gereken sulak alanların incelenmesi mümkündür. Bu inceleme ileriye dönük doğru kararların alınmasında oldukça faydalı olmaktadır (Doğan, 2008; Çiçekli vd.,2016). Bu tip alansal değişim analizlerinin görsel şekilde ortaya konulması geçmiş ve güncel yılların karşılaştırılabilmesi için kolaylık sağlayan uzaktan algılama teknikleri mevcuttur (Bahadır, 2013).

Bu çalışmada, Akdeniz Bölgesi'nde bulunan ve ülkemizin önemli lagünlerinden biri olan Dipsiz Lagün'ün, uzaktan algılama teknikleri ile görsel olarak varyasyonların ortaya konulabildiği lagün alanı değişimleri analiz edilmiştir (Özdemir ve Bahadır, 2008a; 2008b; Sener, vd., 2009; Özdemir ve Bahadır, 2010; Uysal, vd., 2011; Bahadır, 2011; Bahadır, 2013).

2. ÇALIŞMA ALANI

Çalışma alanı Doğu Akdeniz Bölgesi'nde, Mersin-Tarsus ilçesi Baharlı köyü sınırları içerisinde yer almaktadır. Toplam alanı 1035 hektar olup bir birine bağlantısı olan kanal ve göletleri içinde

barındırır. Lagün, Seyhan Nehri ve Tarsus Berdan Çayı ile olan bağlantı kanallarından beslenmektedir (Orman ve Su İşleri Bakanlığı, 2018).



Şekil 1. Lagün'ün Haritadaki Yeri



Şekil 2. Dipsiz Lagün

Lagünler çoğunlukla denizle bağlantısı olmayan nehir, çay veya yeraltı suları tarafından beslenen sığ su alanlarıdır (Tosunoğlu vd., 2017). Bu alanlar deniz ve kara arasında yer aldığı için hem karasal hem de denizel özelliklerin etkisinde kalıp geçiş bölgesi de dediğimiz özel ekosistemlerdir. Çalışması yapılan bu alan aynı zamanda restorasyon ve gelişme potansiyeline sahiptir. Alanın Ekoturizm/Doğaturizm açısından gelişme potansiyeli yüksektir. Ayrıca alanda yapılan araştırmalara göre 112 kuş, 9 memeli, 12 balık türü ile 43 familyaya ait 147 bitki taksonu olduğu tespit edilmiştir (Orman ve Su İşleri Bakanlığı,2018).

"Çalışma alanı, Caretta caretta türü deniz kaplumbağalarının korunması amacıyla Mersin-Kazanlı kumsalı ile birlikte 01.10.1999 tarihinde 3520 nolu Adana Kültür Tabiat Varlıklarını Koruma Bölge Kurulu kararı ile 1.Derece Doğal Sit İlan edilmiştir. Alanın korunmasından Mersin İl Çevre ve Şehircilik Müdürlüğü, Mersin İl Tarım ve Orman Müdürlüğü ve Tarım ve Orman Bakanlığı VII. Bölge Müdürlüğü-Mersin Şube Müdürlüğü sorumludur. Alan içerisinde yapılan dalyan balıkçılığına ilişkin uygulamaların denetimi, korunması ve izlenmesi Mersin İl Tarım ve Orman Müdürlüğü tarafından yapılmaktadır."

Tablo 1. Landsat-5 (TM) ve Landsat-8 OLI/TIRS Uydü Görüntüsü Özellikleri

	Landsat-5 (TM)	Landsat-8 OLI/TIRS
Görüntü Özellikleri:	2005	2018
Görüntüleme Tarihi:	10.11.2005	14.11.2018
Görüntüleme Path-Row:	175-35	175-35
Görüntü Bulut Oranı:	0%	13.50%
Görüntü Radyometrik Çözünürlüğü:	8 bit	8 bit

Dipsiz Lagünü, doğa koruma şuurunun artması için bazı bilinçlendirme faaliyetleri, kuş gözlemciliği ve doğa fotoğrafçılığı gibi gününbirlik faaliyetlerin yapılabileceği önemli bir bölgedir. Bu tip çalışmalar alanın tanıtımı, yerli ve yabancı insanların ziyaretleri açısından önemli olmakla beraber yerli halka ekonomik katkı sağlayabilecek potansiyele sahip değerlendirilmesi gereken bir alandır.

**Fotoğraf 1.** Dipsiz Sulak Alana Ait Bir Görüntü (Orman ve Su İşleri Bakanlığı, 2018)

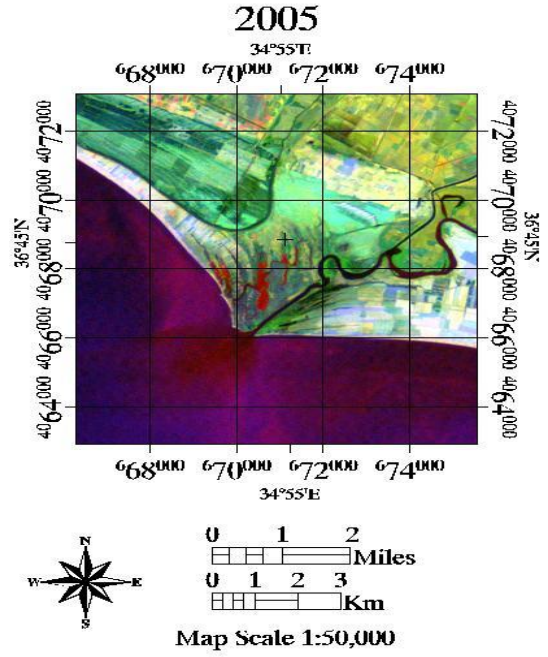
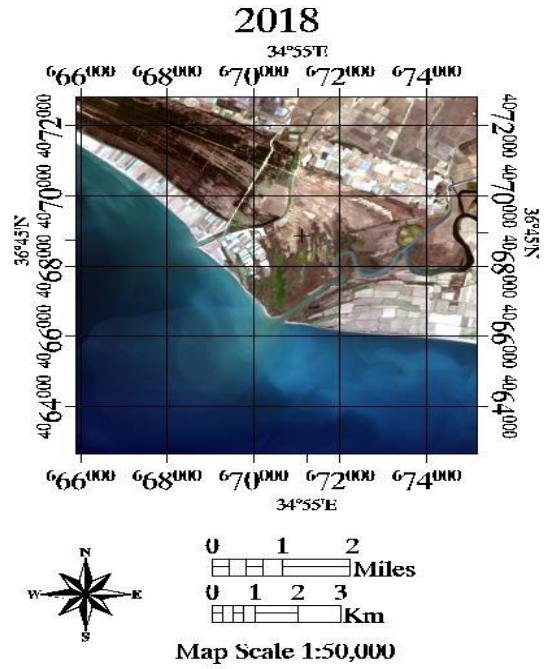
3. MATERYAL VE YÖNTEM

Su kaynaklarının gözlemlenmesi ve yönetiminde, uydudan uzaktan algılama çoğunlukla kullanılmakta olup başarılı sonuçlar elde edilmektedir (McFeeters, 1996; Xu, 2006; Karaman ve ark., 2018). Dipsiz lagün örneği gibi geniş alanlara yayılım göstermiş olan su kütleleri için hızlı ve hassas ölçüm yapan uzaktan algılama yöntemleri, kullanıcının daha kolay veri temin etmesine yardımcı olmaktadır (Karaman ve ark., 2015; Kale ve Acarlı, 2019a).

3.1. Çalışmada Kullanılan Veriler

Bu çalışmada Akdeniz Bölgesi'nde bulunan Dipsiz Lagün'ün zamansal değişimlerinin izlenmesi amacı ile Kasım 2005 tarihine ait Landsat-5 (TM) uydü verisi ve Kasım 2018 tarihine ait Landsat-8 OLI/TIRS uydü verileri kullanılmıştır.

Söz konusu uydü görüntülerinin analizi için ENVİ adlı uzaktan algılama programının 5.3 versiyonu ile kontrollü sınıflandırma analizleri gerçekleştirilmiştir. 2005 yılına ait Landsat-5 (TM) Uydü Görüntüsü Şekil 2' verilmiştir.

**Şekil 3.** Kasım 2005'e Ait Landsat-5 (TM) Uydü Görüntüsü**Şekil 4.** Kasım 2018'e Ait Landsat-8 OLI/TIRS Uydü Görüntüsü

3.2. Yöntem

Görüntülerin analizi ve doğrulanması, değişim analizinde en gerekli işlemdir ve eğer bu görüntü verilerinin kaydı doğru bir şekilde yapılamazsa güvenilirliği düşük sonuçlar üretilir. Bu sebeple yapılacak çalışmalarla orantılı değişim analiz yöntemleri seçilmelidir (Lu vd., 2004; Özşahin, 2011).

Bu çalışmada ise uydü görüntüleri ENVİ 5.3 programı kullanılarak kontrollü sınıflama


(maksimum likelihood) yöntemiyle analiz edilmiştir. Çıkan ürünler karşılaştırma yöntemiyle incelenip, iki yıl için ayrı ayrı Dipsiz Lagün su alanı hesabı yapılmıştır.

4. UYGULAMA

Şekil 4 ve 5'te görülen ham Uydü Görüntüsü programa atılıp sınıflandırma işlemine geçilmeden önce görüntü zenginleştirme (Radyometrik ve Geometrik düzeltmeler) işlemi yapılmıştır.




Şekil 5. 2005 Landsat-5 (TM) Ham Uydü Görüntüsü



Şekil 6. 2018 Landsat-8 OLI/TIRS Ham Uydü Görüntüsü

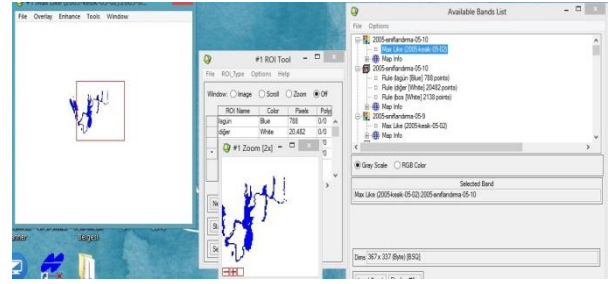
Çalışmada uzaktan algılama tekniklerinden olan kontrollü sınıflandırma tekniğinden faydalanılmıştır. Kontrollü sınıflandırmada ilk iş sınıfların belirlenmesi işidir. Görüntü alanın kaç sınıfa ayrılması gerektiğini ve sınıfların isimlerini belirlemek gerekmektedir. Bu çalışmada Dipsiz Göl'ün su alanının değişimlerini izleyebilmek ve bunun üzerinden su alanının 2005 ve 2018 yılları için su alanı değişim hesabının yapılabilmesi için göl alanına ait piksel değerleri programa tanıtılmıştır (Şekil.7).



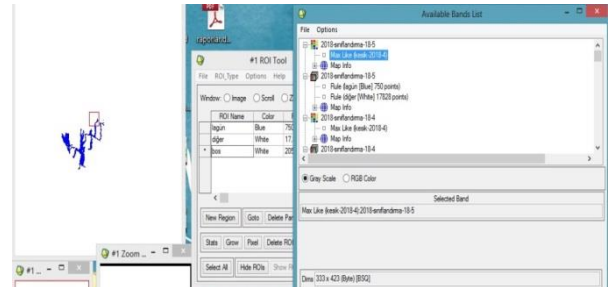
Şekil 7. Göl alanındaki piksellerin ENVI programına tanıtımı

Bu işlemten sonra ise görüntüler ayrı ayrı sınıflandırılma işlemine tabi tutulmuş, Dipsiz

Lagün'deki alansal değişimlerin yıllara göre farklılıkları belirlenmiştir (Şekil 8 ve Şekil 9).





Şekil 8. 2005 Landsat-5 (TM) kontrollü sınıflandırma işlemi sonucu



Şekil 9. 2018 Landsat-8 OLI/TIRS sınıflandırma işlemi sonucu

5. SONUÇLAR

Çalışma kapsamında Dipsiz Lagün'ün 2005 ve 2018 yılları için yüzey ölçümü olarak değişimi 2005 yılı için Landsat-5 (TM) uydu görüntüsüyle, 2018 yılı için ise Landsat-8 OLI/TIRS uydu görüntüsüyle kontrollü sınıflandırma yöntemiyle incelenmiştir (Şekil 10).



Şekil 10. Maksimum Likelihood Kontrollü Sınıflandırma ile Yapılmış Dipsiz Lagün (Soldaki 11/10/2005 sağdaki 11/14/2018 yılına ait görüntülerdir.)

Tablo 2. Hesaplanmış su alanları

Tarih	Sınıf	Alan (ha)
11/10/2005	Su	70,29
11/14/2018	Su	49,05

Su alanında 2005 yılına göre %30,22 azalma olduğu tespit edilmiştir. Bu su alanındaki azalmanın getirdiği sorunlar ve bu alanın özel olarak korunmasının ana sebepleri maddeler halinde sunulmuştur.

- Tarım amaçlı kullanımın sonucunda su seviyesinde bir azalma söz konusudur ve bu azalma biyoçeşitliliği ciddi anlamda etkileyen bir durumdur.
- Sulak Alanların Korunması Yönetmeliğince; Hassas koruma bölgesi, “Koruma Bölgeleri içerisinde yer alan, su kuşlarının yoğun ve toplu olarak kuluçka yaptığı ve gecelediği alanlar; nadir ve nesli tehlikedeki kuş türlerinin önemli üreme bölgeleri ile nesli tehlikede veya dar yayılışlı sulak alana bağımlı doğal bitki türlerinin bulunduğu alanlar” olarak tanımlanmıştır. Buna göre; Kıyı kuşlarının ürettiği ve/veya konakladığı alanlar ve bataklık ve saz kuşlarının ürettiği alanlar özenle korunması gereken alanlardır.
- Lagünler, aynı zamanda tatlı su girdileri ve sığ olmalarından kaynaklı etkin dip karışımı nedeniyle besince zengin oluşumlardır. Bu sebeple, lagünlerde üretim düzeylerinin de yüksek olmasına neden olmaktadır. Lagünler sistemler dünyanın doğal biyolojik zenginlik kaynaklarıdır. Aynı zamanda bilimsel çalışmalar için de önemli bir kaynaktır. Dünyadaki biyolojik çeşitliliğin korunması ve tür devamlılığının sağlanmasında da lagünler oldukça önemli bir yere sahiptirler (Balkaya ve Çelikoba, 2005; Anonim, 2007; Erdem, 2004; Orman ve Su İşleri Bakanlığı, 2018).

BİLGİLENDİRME/TEŞEKKÜR

Bütün çalışmam süresince, bilgisini, ilgi ve desteğini esirgemeyen Sayın Dr. Öğr. Üyesi Lütfiye Kuşak'a sonsuz teşekkürlerimi sunarım.

KAYNAKÇA

- Bahadır, M., & Bahadır, M. (2013). Akşehir Gölü'nde Alansal Değişimlerin Uzaktan Algılama Teknikleri İle Belirlenmesi. *Marmara Coğrafya Dergisi*, (28), 246-275.
- Çiçekli, S. Y., & Özkan, C. (2016). Landsat 8'in Adana Seyhan Baraj Gölü Kıyı Çizgisinin Aylık Değişimin Belirlenmesinde Kullanılması. *Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2016)*, 1078-1082.

Orman Ve Su Bakanlığı, (2018). Dipsiz Lagünü Ulusal Öne Hız Sulak Alan Yönetim Planı Nihai Raporu (2019-2023)

Doğan, İ. (2008). Uzaktan algılama verileri ile kıyı çizgisi değişiminin zamansal olarak belirlenmesi: Alaçatı örneği. *YTÜ, FBE İnşaat Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.*

Özşahin, E. (2011). Gölbaşı (Balık) Gölü'nde (Hatay) Meydana Gelen Değişimin Coğrafi Analizi. *Turkish Studies*, 6, 1.

Acir, N., Günel, H., Mutlu, N., Cankar, S., & Akyol, N. (2013) Drenaj Faaliyetleri Sonrası Kaz Gölü Çevresindeki Toprak Özellikleri ve Vejetasyonun Mesafeye Bağlı Değişimleri. III. Ulusal Toprak ve Su Kaynakları Kongresi.

Özelkan, E. Uzaktan Algılama ile Belirlenen Baraj Gölü Alanının Zamansal Değişiminin Meteorolojik Kuraklık ile Değerlendirilmesi: Atıkhisar Barajı (Çanakkale) Örneği. *Türk Tarım ve Doğa Bilimleri Dergisi*, 6(4), 904-916.

Bilimleri, M. (2019). Çorak Gölü (Burdur) Havzasının Hidrojeolojik Özellikleri Ve Su Kalitesi. *Journal of Engineering Sciences*, 7(1), 103-114.

Köken, S., Ceyhan, T., & Tosunoğlu, Z. (2019). Dalyan balıkçılığının iş sağlığı ve güvenliği açısından değerlendirilmesi. *Su Ürünleri Dergisi*, 36(2), 171-179.

URL-1;<http://www.dogaarastirmalari.org.tr/wp-content/uploads/2016/11/raporlar.dipsiz.pdf> (15.03.2019)



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

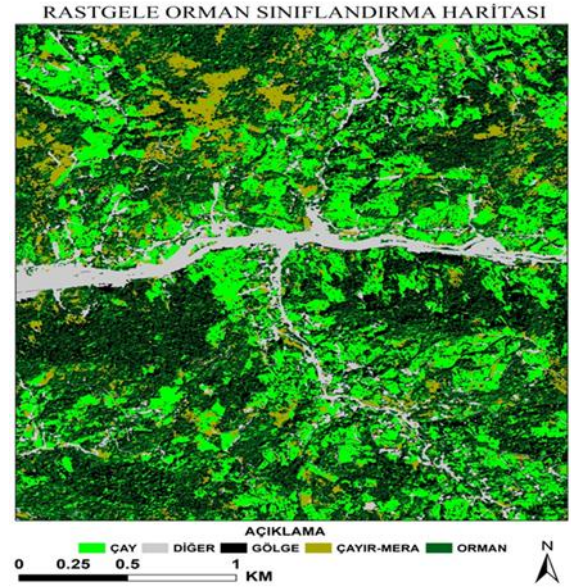
Görüntü nesnesi oluşturma ve eğitim verisi toplama aşamasından sonra toplanan eğitim verilerine göre görüntü nesnelere sınıflandırılmıştır. Sınıflandırma işlemi Rastgele Orman (RO) ve K-En Yakın Komşuluk (KNN) algoritmaları ile aynı eğitim verisi ve aynı değişkenler kullanılarak ayrı ayrı yapılmıştır. 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



Uzaktan algılama verilerinin derin öğrenme algoritmaları ile sınıflandırılması

Mustafa Emre Döş^{1*}, Murat Uysal¹

¹Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Afyonkarahisar

ÖZ

Anahtar Kelimeler:
Uzaktan Algılama
Sınıflandırma
Derin Öğrenme
Ortofoto

Günümüzde teknolojinin hızlı bir şekilde ilerlemesi ile birlikte yaşadığımız çevre hakkında farklı platformlardaki araçlardan faydalanarak detaylı bilgiler elde edilmektedir. Konumsal veri üretiminde hava ve uydu platformlarından elde edilen görüntüler kullanılmaktadır. Bu görüntüler bitki örtüsü tespitinden, doğal afetler ve şehir planlamasına kadar birçok alanda kullanılmaktadır. Uzaktan algılama verilerindeki yüksek çözünürlüklü görüntüler sayesinde insan yapımı yapay unsurların tespitinde kolaylaşmıştır. Ancak yüksek çözünürlüklü verilerinin sunduğu bu avantajların yanında yoğun ayrıntı içeriği nedeni ile sınıflandırmada işlemlerinde insan becerisi ve müdahalesine duyulan gereksinimin fazlalığı günümüzde önemli sorunlardan biri olarak karşımıza çıkmaktadır. Günümüze kadar insan faktörünün azaltılmasına yönelik birçok sınıflandırma yaklaşımı sunulmuştur.

Daha önceden bilgisayar teknolojisinde yeterli olmayan donanımsal ve yazılımsal araçlardan dolayı, yapay zekanın temelleri sayılan makine öğrenmesi ve derin öğrenme gibi konular pek incelenmemiştir. Ancak günümüzde grafik işlemcilerde ve yazılımlardaki ilerlemeler sayesinde popülerliğini arttırmıştır. Son çalışmalarındaki performansı ile derin öğrenme yaklaşımı, makine öğrenmesinden ziyade daha umut vericidir. Bu çalışmada mevcutta bulunan sınıflandırma yöntemlerine alternatif olacak derin öğrenme algoritmalarını kullanarak sınıflandırma yapılmıştır. Algoritmanın test edilmesi için Uluslararası Fotogrametri ve Uzaktan Algılama Topluluğu (UFUAT)' dan temin edilmiş Vaihingen veri seti kullanılmıştır. Kullanılan veri setinden zemin, bina, ağaç, bitki örtüsü ve araç olacak şekilde 5 tane detay sınıfı seçilmiştir. Bu detaylardan algoritma en yüksek olarak bina sınıfına ait olanları ortalama %99 seviyesinde, en düşük olarak araç sınıfına ait detayları ortalama %95 olarak belirlemiştir. Bu çalışmadan elde edilen sonuçlarla, uzaktan algılama verilerinin otomatik sınıflandırılmasında derin öğrenme algoritmalarının iyi bir alternatif olduğu görülmektedir.

Classification of remote sensing data with deep learning algorithms

ABSTRACT

Keywords:
Remote sensing
Classification
Deep Learning
Orthophoto

Today, with the rapid progress of technology, detailed information is obtained by using tools on different platforms about the environment we live in. Images obtained from air and satellite platforms are used in the production of spatial data. These images are used in many areas, from vegetation detection to natural disasters and urban planning. High resolution images in remote sensing data make it easier to detect artifacts. However, in addition to these advantages of high-resolution data, the need for human skill and intervention in the classification process is one of the biggest challenges today due to its comprehensive detail content. To date, many classification approaches have been introduced to reduce human factor.

Due to the hardware and software tools previously insufficient in computer technology, subjects such as machine learning and deep learning which are accepted as the foundations of artificial intelligence have not been studied much. However, today it has increased in popularity thanks to improvements in graphics processors and software. The performance and deep learning approach in recent studies is more promising than machine learning. In this study, classification is made by using deep learning algorithms which will be an alternative to existing classification methods. The International Photogrammetry Society and the Remote Sensing Society (ISPRS) Vaihingen data were used to test the algorithm. In the data set, 5 detail classes have been selected as ground, building, tree, vegetation and vehicle. The algorithm for these details is on average 99% and the lowest 95%. According to the results of this study, it is seen that deep learning algorithms are a good alternative for automatic classification of distance learning data.

*Sorumlu Yazar

Kaynak Göster(APA);

(mustafaemredos@gmail.com) ORCID ID 0000-0002-7605-4270
(muysal@aku.edu.tr) ORCID ID 0000-0001-5202-4387

DÖŞ, M., UYSAL, M. (2019). Uzaktan algılama verilerinin derin öğrenme algoritmaları ile sınıflandırılması. *Türkiye Uzaktan Algılama Dergisi*, 1 (1), 28-34. Retrieved from <https://dergipark.org.tr/tr/pub/tuzal/issue/50531/648988>

Araştırma Makalesi
DOI: XXXXXXXXXXXXX


Geliş Tarihi: 20/11/2019; Kabul Tarihi: 10/12/2019

1. GİRİŞ

İnsanoğlu geçmişten beri çevresindeki yapılardan ve olaylardan etkilenmiş, bunlara ait bilgileri elde etmeye çalışmıştır. Bu bilgileri elde ederken ise farklı disiplinlerdeki bilim alanlarını kullanmıştır. Uzaktan algılama ile hava ve uydu platformlarındaki algılayıcılar ile elde edilen verilerin değerlendirilmesi ile nesne ve çevresi hakkında güvenilir bilgiler elde edilmektedir. Teknolojideki ilerlemeler sayesinde daha yüksek çözünürlüklü elde edilen verilerin değerlendirilmesi ve sınıflandırılmasında önemli sıkıntıların yaşanmasına sebep olmuştur. Bu verilerin değerlendirilmesi için farklı yöntemlere ve donanımlara duyulan ihtiyaç her geçen gün artmaktadır.


Günümüzde popülerliği gittikçe artan ve birçok alanda sorunların çözümünde yapay sinir ağları, makine öğrenmesi ve alt dalı olan derin öğrenme yapıları yaygın bir şekilde kullanılmaktadır. Bu çalışmada derin öğrenme yapıları, hava ve uydu görüntülerinin sınıflandırılması sorununa alternatif bir çözüm yolu olarak sunulmuştur.

Yapay sinir ağları yeni değıllerdir. İlk olarak Rosenblatt'ın yapay nöronları (Perceptron) ile ortaya çıkmıştır (Şekil 1.) (Rosenblatt, F., 1958).



Şekil 1. Yapay nöron (Perceptron) modeli

Çok katmanlı yapay nöronlar ile ilk genel öğrenme yapısı çalışmaları Ivakhnenko ve Lapa tarafından yapılmıştır. Bu çalışmalarda en iyi sonucu veren hücreler bir sonraki katmanda bulunan hücrelere alınarak sadece ileri yayılım kullanılmıştır (Şekil 2.) (Ivakhnenko, A., G., 1966).



Şekil 2. Ivakhnenko'nun çoklu yapay nöron ağı (Dettmers, T. 2015)

Daha sonra derin öğrenme yapısı ile alakalı genel olarak ilk başarılı çalışmayı Yann LeCun ve

arkadaşları posta kutusu yazıları üzerinde geliştirmişlerdir. Bu çalışmada eğitim 3 gün sürmüştür ve pratikte uygun olmadığı görülmüştür (LeCun, Y., ve ark., 1989). Yann LeCun, günümüzde programlamaya girişte ilk olarak öğretilen "Hello World" komutu ile derin öğrenme yapısındaki karşılığı olan MNIST veri setini sınıflandırmak için kıvrımlı ağlarla geri yayılımı birlikte kullanmıştır (LeCun, Y., ve ark., 1989). Ancak bu çalışmalar bilgisayarlardaki donanımsal eksikliklerden ve küçük veri setlerinden dolayı uzun süren eğitimler sonrasında istenilen doğrulukta sonuç ürünleri vermemiştir. Buna karşın Destek Vektör Makineleri (DVM) o zamandaki sorunlara daha iyi çözümler üretiyor ve daha iyi sonuçlar vermişlerdir.

2000'lerden sonra gelişen bilgisayar teknolojisi ile Grafik İşlemci Birimlerinin (GİB) kullanılmasına başlanmasıyla Makine Öğrenmesi yapıları tekrar gündeme gelmiştir. Makine öğrenmesi ile ilgili birçok çalışma yapılmıştır.

Gün geçtikçe teknolojinin gelişmesiyle çevremizdeki doğal ve yapay objeleri algılama ve kayıt etme araçlarımız gelişti. Gelişen araçlar sayesinde, farklı platformlardan yoğun ve çeşitli verilere sahip olunmaktadır. Günümüzde uzaktan algılamada kullanılan objelere ait görüntüler ise içerisinde birçok detaya sahiptir. Bu detay yoğunluğu nedeni ile verilerin elde edilmesi kadar bu verilerin sınıflandırılıp ardından yorumlanması da bir o kadar önem arz etmektedir. Sınıflandırma işleminde hem zamandan hem de maddi tasarruf yapmak için, insan etkisinin mümkün olduğunca azaltılıp işlemin otomatik olarak yapılması arzu edilir. Bu konuda Huang DVM kullanarak uzaktan algılama verisini 7 sınıfa ayırıp incelemiştir (Huang ve ark., 2002.). Daha sonra Kavzoğlu ve Çölkesen 2010 yılında yaptıkları çalışma ile Karar Ağacı (KA) yöntemi ile En Çok Benzerlik (EÇB) yöntemi karşılaştırmıştır. Makine öğrenmesi yöntemi olan KA ile daha iyi sonuçlar alınmıştır (Kavzoğlu, T. ve Çölkesen, İ., 2010). Zhang Z. ve arkadaşları CNN algoritmaları ile uzaktan algılama verilerinde çoklu model farklılıklarının karşılaştırmışlardır (Zhang, Z. ve Vosselman, G. 2018.). Makine öğrenmesi yöntemleri uzaktan algılama verilerinin sınıflandırılmasında iyi bir alternatif olarak görülmektedir. Ancak kullanıcıya bağımlılıktan kurtulma hala istenildiği seviyede değildir. Bu yüzden yeni bir yaklaşım olarak derin öğrenme yapısı karşımıza çıkmaktadır.

Bu çalışmada uzaktan algılama verilerinin hızlı ve yüksek doğrulukla otomatik sınıflandırılması için güncel bir alternatif olan derin öğrenme algoritmaları incelenmiştir. Bu kapsamda Vaihtingen veri seti kullanılarak bir şehirde havadan görüntülenebilecek detayların tespit edilip sınıflandırılması için derin öğrenme algoritmaları ile ne kadar süre aldığı ve ne kadar doğruluk elde edileceği tespit edilmeye çalışılmıştır.


2. YÖNTEM

Son zamanlarda bilgisayar teknolojisindeki gelişme hızı ile orantılı olarak yapay görüş ve yapay öğrenme alanlarında da gelişmeler olmuştur. Bu çalışmalarda popüler olarak derin öğrenme kullanılmaktadır. Derin öğrenme ile makine öğrenmesi arasında önemli bazı farklılıklar olsa da temelde aynı şeyleri ifade ederler. Derin öğrenme, makine öğrenmesinin bir alt kategorisidir(Şekil 3.). Makine öğrenmesi teknikleri ile ilk başlarda iyi sonuçlar elde edilmiştir. Ancak 2010 yılından itibaren artan veri seti boyutları nedeni ile klasik makine öğrenmesi kullanılarak yapılan çalışmalarda istenilen gelişmeler sağlanamamıştır.



Şekil 3. Derin öğrenme ve makine öğrenmesi arasındaki ilişki


Derin öğrenme yapısı günümüzde oldukça popülerdir. Aslında derin öğrenme yapıları yeni gibi görünse de temeli eskiye dayanmaktadır. Genel olarak bakıldığında derin öğrenme ağ yapısı ile makine öğrenmesi ağ yapısı birbirine benzerler. Ancak temelde özellik çıkarımı makine öğrenmesinde kullanıcı tarafından belirlenmekte bu da özellik görüşünü kısıtlamaktadır(Şekil 4.). İnsan yapısındaki kusurlardan dolayı ortaya çıkan bu kısıtlamanın önüne geçmek için veri setindeki özellik haritalarının derin öğrenme yapısına sahip ağ tarafından kendisinin bulması ve bu yönde tahmin yürütmesi sağlanır.



Şekil 4. Derin öğrenme ve makine öğrenmesi arasındaki fark

Derin öğrenme yapısı ile makine öğrenmesi yapısı arasındaki bu farklılıktan dolayı, derin öğrenmede veri miktarının artması ile performans aynı seviyede kalmayıp veri miktarı ile aynı oranda artmaktadır(Şekil 5.). Günümüzde kolaylıkla birçok resim ve görüntüye sahip olunabilmektedir. Bu sayede derin öğrenme yapısı yerinde saymayıp


gelişmekte ve günümüzdeki veri bilimi alanında birçok soruna alternatif çözümler sunmaktadır.



Şekil 5. Derin öğrenme ve makine öğrenmesi arasındaki veri miktarına göre performans eğrisi

2.1. Evrimsel Sınır Ağları(ESA)

Derin öğrenme ile farklı bilim dallarındaki problemlere çözümler sunulmaktadır. Ancak görüntü sınıflandırması söz konusu olduğunda en iyi sonucu Evrimsel Sınır Ağı(ESA) mimarisi vermektedir. Genel olarak ESA görüntü sınıflandırılmasında kullanılır. ESA mimarisi ile alakalı ilk başarılı çalışmayı 1989 yılında LeCun ve arkadaşları LeNet-5 mimarisini kullanarak posta kutusu yazıları ve MNIST veri seti üzerinde çalışmıştır(LeCun, Y., ve ark., 1989). O dönemden sonra bu alandaki çalışmalar uzun bir süre durmuştur. Daha sonra 2012 yılında içerisinde 14 milyon resim ve bin sınıf barındıran IMAGENET yarışmasında birçok alanda birinci olan AlexNet mimarisi tekrar derin öğrenmeyi popüler hale getirmiştir(Şekil 6.) (Krizhevsky, A., ve ark., 2012).




Şekil 6. AlexNet ağ yapısı

2014 yılında ise IMAGENET yarışmasında ana kategoriyi GoogLeNet kazanmıştır(Szegedy, C., ve ark., 2014). İkinci olan VGG modelinde farklı kategorilerde önde gelmiştir. 2015 yılında bu yarışmayı 152 katmanlı çok derin bir ağ olan ResNet mimarisi kazanmıştır(Kaiming, H., ve ark., 2016).

Ancak bu mimariler hem çok ağır bir işlem yükü sunduğu için hem de amacımız kullanılan görüntülerde tek bir özelliğin çıkarılması yerine, görüntülerdeki her bir doğal veya yapay objenin kendisi ve çevresi ile korelasyonunu belirlemektir. Bu konuda derin öğrenme yapılarında semantik segmentasyon mimarileri kullanılır. Sunulan bu çalışmada derin öğrenme algoritmalarının semantik segmentasyona daha uygun hale getirmek için


tasarlanan SegNet mimarisi kullanılmıştır(Şekil 7.) (Badrinarayanan, ve ark., 2016.). SegNet mimarisi bir kodlayıcı ağına ve buna uygun çalışan çözücü ağına sahiptir. Kodlayıcı ağında ise daha önceden VGG16 mimarisi ile eğitilen ağırlık değerleri kullanılmaktadır.



Şekil 7. SegNet ağ yapısı illüstrasyonu

2012 yılında AlexNet' in başarılı sonuçlar vermesi ile derin öğrenme tekrar popüler bir hale geldi. Derin öğrenme ile etkili sonuçlar elde etmek için genel olarak iki ön koşul vardır. Bunlardan birincisi eğitim veri setinin çeşitliliği ve büyüklüğü, bir diğeri ise kullanılan bilgisayarın donanımsal olarak yüksek özellikli donanımsal parçalar(Ekran kartı, İşlemci vb.) barındırması gerekir. İşin bu kısmında maddi açıdan büyük bir yük karşımıza çıkmaktadır. Bu sorunu çözmek için derin öğrenme ve yapay zekanın geleceğe yön vereceğini düşünen Google ve Amazon gibi büyük şirketler ücretli ve ücretsiz bulut sistemleri sunmaktadır. Bu bulut sistemleri sayesinde büyük maliyetlerden kaçınılabılır.

Yapılan bu çalışmada uzaktan algılama verilerindeki sınıflandırma problemine çözüm olarak derin öğrenme yapısı sunulmaktadır. Derin öğrenme sayesinde kullanıcıya bağımlılık diğer alternatif çözüm yöntemlerine göre daha da azalmaktadır.




Şekil 8. Çalışma alanındaki eğitim ve test verilerine ait bölgeler

Bilgisayar görüşü sistemleri artık birçok alanda insan performansının üstüne çıkmaktadır. Onlardan

birisi olan derin öğrenme yapısı da mevcutta bulunan veri setlerinin sınıflandırılmasında insan faktörünün üzerine çıkmaktadır. Derin öğrenmenin bu özelliğinden dolayı çalışmada tercih edilmiştir. UFUAT' ın Vaihingen veri setini kullanarak sınıflandırma yapılmıştır. Veri setinde 3 bantlı IRGB ortofotoların 12 tanesi eğitim, 4 tanesi test verisi olarak ayrılmıştır(Şekil 8.).

Eğitim sırasında sınıflandırmanın doğruluğunu kontrol etmek için daha önceden ayrılmış gerçek zemin görüntüleri ile sonuç ürünler karşılaştırılmıştır. Objelerin sınırlarının daha keskin belirlenmesi içinde gerçek zemin görüntülerinde sınır belirginleştirme işlemi yapılarak ayrıca eğitim verilerine eklenmiştir (Şekil 9.).



Şekil 9. (a) Bölge-1 için ortofoto, (b)gerçek zemin, (c)gerçek zemin sınır belirginleştirme

Veri seti zemin, bina, bitki örtüsü, ağaç ve araba olarak 5 sınıfa ayrılmıştır. En son olarak genel bir sınıf doğruluğu tespit edilmeye çalışılmıştır. Eğitim verilerinde sınıflandırma yaparken semantik segmentasyon yapabilmek için derin öğrenme yapısındaki SegNet mimarisini kullanılmıştır. SegNet yapı olarak iki kısma ayrılır. İlk kısım kodlayıcı olarak adlandırılır, burada eğitim süresini azaltmak için VGG16 ile daha önceden belirlenmiş ağırlık değerleri ile eğitime başlanır. SegNet' in ikinci kısmına ise kod çözücü denir. Burada her bir kodlayıcı kısma uygun gelen kod çözücü kısımlar ile işleme devam edilir. Son olarak sonuç ürün için girdiler Softmax sınıflandırıcısına sokulur(Bozkurt, S., 2018).

Tüm bu eğitim ve test aşamaları yapılırken sistem GİB' in belleğinde büyük bir alan kullanılmaktadır. Bu işlem için en az 12 GB' lik bir GİB gerekmektedir. Böyle donanımsal özelliğe sahip bir GİB maliyeti oldukça yükseltir. Bundan dolayı Google'ın ücretsiz GİB desteği verdiği Colaboratory (Colab) hizmeti kullanılarak eğitim ve test aşamaları gerçekleştirilmiştir. Colab' ta Nvidia' nın Tesla k40 GİB kullanılmaktadır.

3. BULGULAR

Bu çalışma kapsamında veri seti 12 eğitim ve 4 test verisi olarak ikiye ayrılmış ve çalışmanın tamamı Google Colab bulut sistemi üzerinden yapılmıştır. İlk olarak eğitim veri seti üzerinden


rastgele görüntüler algoritmaya sunulmuş ve algoritma tahminine göre ağırlık değerleri düzeltilip çalışmanın eğitim kısmı bitirilmiştir. Eğitim sonunda sınıflara ait doğruluk ve kappa değerleri Tablo 1.' de gösterilmiştir.

Tablo 1.Eğitim setindeki sınıflara ait doğruluk ve genel doğruluk değerleri

	Zemin (%)	Bina (%)	Bitki örtüsü (%)	Ağaç (%)	Araç (%)	Genel doğruluk (%)
1	98.52	99.23	96.65	97.76	94.22	98.45
3	98.66	99.01	95.98	95.83	96.38	97.76
23	97.95	99.13	96.98	97.81	97.59	97.86
26	98.33	98.98	95.26	98.16	93.74	98.24
7	98.65	99.26	96.76	98.48	94.30	98.46
11	98.51	99.11	95.70	97.82	96.92	97.95
13	97.92	99.41	96.77	96.69	92.52	97.40
28	97.83	98.81	96.92	96.89	94.68	97.75
17	98.35	99.48	98.69	97.96	95.42	98.59
32	99.42	99.70	96.22	97.79	96.73	99.00
34	99.09	99.44	97.67	98.13	96.51	98.58
37	99.06	99.27	98.64	96.80	97.73	98.64

Tablo 1' e bakıldığında genel olarak sınıflara ait doğrulukların yüksek olduğu görülmektedir. Bunun sebebi olarak gerçek zemin görüntüsünün yanında sınıflara ait sınırların daha belirgin olduğu sınır belirginleştirme işlemi uygulanan görüntülerin kullanılmış olması olduğu düşünülmektedir. Bir başka değerlendirme olarak her bir tekrar sırasında algoritmanın kullandığı görüntü sayısı ne kadar yüksek olursa algoritma kullandığı ağırlık ve sapma değerlerine getirmesi gereken düzeltme miktarını daha doğru tahmin etmektedir. Bu sebeple Google colab' ın sunduğu Tesla k40 GIB' si ile yüksek tekrar ve her tekrar yapılırken fazla görüntü kullanılması sayesinde algoritmanın yüksek doğrulukla tahminler sunmaktadır.


Aşağıda kayıp değerlerine ait grafik üç aşamada gösterilmiştir.



Şekil 10. (a) Birinci eğitim için kayıp değer grafiği, (b)ikinci eğitim için kayıp grafiği, (c) Üçüncü eğitim için kayıp grafiği


Şekil 10' da sunulan grafiklerden de görülebileceği gibi daha önceden eğitilmiş VGG-16 değerleri sayesinde kayıp değer grafiği değerleri düşmeye başlamıştır. Bu sayede daha uzun sürecek bir eğitim aşamasından kaçınılmıştır. Birinci eğitimde kayıp değer grafiği 1,8 ile 0,2 gibi geniş bir sayı aralığındadır. Daha sonraki aşamalarda 0.32 ile 0.16 ve 0,3 ile 0.125 gibi dar ve uygun değer aralığında bir alanda devam etmektedir. Bundan dolayı eğitim görüntülerindeki küçük yanlış sonuç değerleri nedeni ile dalgalanmalar meydana gelmektedir.

Bu dalgalanmaların ilk sebebi olarak ortofoto görüntülerindeki gölgelerden kaynaklı piksellerin gerekli yansıma değerlerine sahip olmadıkları tespit edilmiştir(Şekil11.).



Şekil 11. (a)Ortofoto görüntü, (b)gerçek zemin görüntüsü, (c)algoritma tahmini

Bir diğer neden ise algoritmanın bitki örtüsü ile ağaçlık alanların iç içe geçmesinden dolayı ikisini birbirinden ayırt edememesinden kaynaklandığı düşünülmektedir (Şekil12.).



Şekil 12. (a)Ortofoto görüntü, (b)gerçek zemin görüntüsü, (c)algoritma tahmini

Eğitimden sonra elde edilen son ağırlık ve sapma değerleri ile daha kaba ve daha hızlı olan test aşamasına geçilmiştir. Burada veri setinden rastgele seçilen 4 tane ortofoto görüntüden test işlemi yapılmış ve Tablo 2'de sonuç değerleri sunulmuştur.

Tablo 2. Test setindeki sınıflara ait doğruluk ve genel doğruluk değerleri

	Zemin (%)	Bina (%)	Bitki örtüsü (%)	Ağaç (%)	Araç (%)	Genel doğruluk (%)
5	98.52	99.26	96.60	97.79	94.20	98.45
21	98.66	99.01	95.98	95.83	96.38	97.76
15	97.95	99.13	96.98	97.81	97.59	97.86
30	98.33	98.98	95.26	98.16	93.74	98.24

Tablo 2' ye bakıldığında genel doğrulukta düşüş olduğu görülmektedir. Bunun sebebi olarak algoritmanın daha hızlı tahmin yapabilmesi için daha kaba tahmin süresi verilmesi olduğu düşünülmektedir. Tablo 2 incelendiğinde zemin ve bina sınıflarının daha iyi tahmin edildiği görülmektedir. Araç sınıfının ise ortofotolardaki düşük parlaklık değerleri nedeni ile algoritma tahmini düşük olduğu düşünülmektedir.

4. SONUÇLAR

Bu çalışmada uzaktan algılama verilerinin otomatik olarak derin öğrenme algoritması ile sınıflandırılması üzerine bir çalışma gerçekleştirilmiştir. Çalışmanın test kısmı için Tablo 2' de genel bölgelere bakıldığında bina ve zemin alanlarını algoritmanın yüksek seviyede tahmin sonuçları vermiş olduğu görülmektedir. 15. Bölgede araç tahmini diğerlerine göre daha iyi sonuç vermiştir. Bunun sebebi olarak araçların gölgede ve ağaçların altında kalmamış olması ve iş makinelerinin az olması sebebi ile algoritmamızın yanlış tahmin etmemesi söylenebilir. Algoritmamızın bitki örtüsünü, ağaç sınıfı ile karıştırması sebebi ile genel olarak doğruluk değeri düşmüştür. Sonuçlara bakılarak yüksek doğruluk değerleri ile algoritmanın sınıflandırma yaptığı görülmektedir. Mümkün olduğunca insan etkisinin azaltılarak uzaktan algılamadaki çalışmaların en

büyük avantajı olan maddi ve zaman açısından tasarrufu sağlayacağı düşünülmektedir. Bu durum uzaktan algılama verilerinin sınıflandırılmasında derin öğrenme yapısının ciddi bir alternatif çözüm olacağı düşünülmektedir. Bu eğitim veri setindeki görüntüler çeşitlendirilip tespit edilen eksikliklerin giderilmesi ile çok daha iyi sonuçlar elde edilebilir. Bu gibi çalışmalarda ciddi maliyet ve donanımsal özelliklere sahip bilgisayarlara ihtiyaç duyulmaktadır. Bu yapılan çalışmada Google' ın bulut sistemi olan Google Colaboratory ile tüm işlemler gerçekleştirip sonuç ürünleri elde edilmiştir. Bir sonraki yapılacak çalışmalarda bu gibi bulut sistemlerinden de yararlanılabileceğini bu çalışmada gösterilmeye çalışılmıştır.

KAYNAKÇA

- Audebert, N., Le Saux, B., & Lefèvre, S. (2018). Beyond RGB: Very high resolution urban remote sensing with multimodal deep networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 140, 20-32.
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12), 2481-2495.
- Bozkurt, S., 2018. Derin öğrenme algoritmaları kullanılarak çay alanlarının otomatik segmentasyonu. Yüksek lisans tezi, Yıldız Teknik Üniversitesi, FBE, İstanbul.
- Dettmers, T., 2015. Deep learning in a nutshell: history and training parallel for all. Available: <https://devblogs.nvidia.com/parallelforall/deep-learning-nutshell-history-training/>[Accessed:12-Apr-2019].
- Huang, C., Davis, L. S. and Townshend, JRG., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23, 725-749.
- Ivakhnenko, A. G., & Lapa, V. G. (1966). Cybernetic predicting devices (No. TR-EE66-5). PURDUE UNIV LAFAYETTE IND SCHOOL OF ELECTRICAL ENGINEERING.
- Kaiming, H., et al., 2016. Deep residual learning for image recognition. 2016 CVPR, Las Vegas, USA, 27-30 June 2016, pp. 770-778
- Kavzoglu, T. ve Çölkesen, İ., 2010. Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği, *Electronic Journal of Map Technologies*, Vol:2, No:1, pp 36-45

- Krizhevsky, A., Sutskever, A. and Hinton, G. E. 2012. Image Net classification with deep convolutional neural networks. Advances in neural information processing systems 25, Nevada, Usa, 3-8 December 2012, pp 1-9
- LeCun Y., Boser B., and Denker, J. S., 1989. Handwritten Digit Recognition with a Back-Propagation Network.
- LeCun, Y., et al., 1989. Backpropagation Applied to Handwritten Zip Code Recognition, *NeuralComput.*, vol. 1, no. 4, pp. 541-551, Dec.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- Zhang, Z., Vosselman, G., Gerke, M., Tuia, D., & Yang, M. Y. (2018). Change detection between multimodal remote sensing data using siamese CNN. arXiv preprint arXiv:1807.09562.