

# Obje Tabanlı Sınıflandırmada Bölgeleme Esasına Dayalı Ölçek Parametresi Tespiti: WorldView-2 Uydu Görüntüsü Örneği (Scale Parameter Determination Based on Zoning Principle in Object Based Classification: A case study of Worldview-2 Imagery)

Ismail ÇÖLKESEN<sup>1</sup>, Tahsin YOMRALIOĞLU<sup>2</sup>, Taşkın KAVZOĞLU<sup>1</sup>

<sup>1</sup>Gebze Teknik Üniversitesi, Jeodezi ve Fotogrametri Mühendisliği Bölümü, Gebze, Kocaeli

<sup>2</sup>İstanbul Teknik Üniversitesi, Geomatik Mühendisliği Bölümü, 34469 Maslak, İstanbul  
icolkesen@gtu.edu.tr

## ÖZET

Son yıllarda yüksek konumsal çözünürlüklü uydu görüntülerinin sınıflandırılmasında geleneksel piksel tabanlı sınıflandırma yaklaşımı yerine obje tabanlı yaklaşımın kullanımı önem kazanmıştır. Objeye tabanlı görüntü analizi iki temel işlem adımından oluşur. Bunlardan ilki benzer spektral özelliklere sahip piksellerin gruplandırılarak homojen yapıya görüntü objelerinin oluşturulmasını içeren segmentasyon işlemidir. İkincisi ise oluşturulan görüntü objelerin spektral, istatistiksel, geometrik ve ilişkisel özelliklerinden yararlanarak gerçekleştirilen sınıflandırma işlemidir. Sınıflandırma işleminde üretilen görüntü objeleri temel sınıflandırma birimi olarak değerlendirilmeye alındığından, obje tabanlı görüntü analizinin doğruluğu segmentasyon işleminin kalitesi ile doğrudan ilişkilidir. Görüntü segmentasyonu ölçek, şekil ve yoğunluk olarak bilinen üç farklı parametre yardımıyla gerçekleştirilmekte olup, bunlar arasında görüntü objelerinin büyüklüğünü kontrol eden ölçek parametresinin tespiti segmentasyonun başarısı açısından büyük bir öneme sahiptir. Bu çalışmada yüksek çözünürlüklü WorldView-2 uydu görüntüsünün obje tabanlı yaklaşımla sınıflandırılması problemi ele alınmıştır. Bu çalışmada, görüntü segmentasyonu işleminin gerçekleştirilmesinde tüm görüntü için tek bir ölçek parametresi uygulamak yerine, görüntüdeki doğal ve yapay nesnelerin dağılımları göz önüne alan bölgesel ölçek parametresi kullanımı önerilmiştir. Tek ölçek parametresi ve farklı ölçek parametreleri ile oluşturulan görüntü objelerinin sınıflandırılmasında en yakın komşuluk (EYK) ve destek vektör makineleri (DVM) algoritmaları kullanılmıştır. Sonuçlar, farklı ölçek parametreleri kullanımıyla DVM ve EYK algoritmalarının hesaplanan sınıflandırma doğruluklarında %6 ve %3'e varan seviyede önemli iyileşmeler olduğunu göstermektedir. McNemar's testi sonuçlarına göre algoritmaların sınıflandırma performansındaki bu artışların istatistiksel olarak anlamlı olduğu ortaya konulmuştur.

**Anahtar Kelimeler:** Worldview-2, obje-tabanlı sınıflandırma, ölçek parametresi, destek vektör makineleri, McNemar's testi, segmentasyon.

## ABSTRACT

In recent years, instead of traditional pixel-based approach, object-based approach has significantly gained importance for the classification of high spatial resolution satellite image. Object-based image analysis

consists of two major processing steps. First one is the segmentation step comprising homogenous image objects creation operations through the grouping set of pixels having similar spectral features. Second one is the classification of created image objects based on their spectral, statistical, geometric and relational features. Because of the fact that image objects are considered as the basic classification units in the classification process, accuracy of object-based image analysis is directly related to the quality of segmentation process. In segmentation process, image objects are created based on three parameters known as scale, shape and compactness. Within these parameters, determination of scale parameter controlling the relative size of image objects has a great importance for the success of the segmentation. This study addresses the problem of the classification of high resolution WorldView-2 imagery using object-based approach. The idea of determine different scale parameters, instead of selecting a single scale parameter for a whole image, considering the spatial distribution of natural and artificial surface objects on the image is proposed. Nearest neighbor (NN) and support vector machine (SVM) algorithms were used for the classification of image objects generated from the single scale and different scale parameters. Results indicated that with the use of different scale parameters, significant improvements were achieved in the estimated classification accuracies of SVM and NN algorithms up to 6% and 3%, respectively. The improvements in the performances of the algorithms were also found to be statistically significant considering the McNemar's test results.

**Key Words:** WorldView-2, object-based classification, scale parameter, support vector machine, McNemar's test, segmentation.

## 1. GİRİŞ

Yüksek çözünürlüklü uydu görüntüleri yeryüzü nesnelerinin konumsal olarak dağılımları hakkında çok daha detaylı bilgiler elde edilmesine imkan sağlamaktadır. Bununla birlikte konumsal çözünürlükteki artış, görüntü üzerinden bilgi çıkarımında ve görüntülerin analizi noktasında önemli problemler ortaya çıkarmaktadır. Bu problemlerin başında yüksek çözünürlüklü görüntülerin birbiriyle spektral olarak benzer özelliklere sahip piksellerden oluşan bir veri yapısına sahip olmasıdır (Zhou, vd., 2009; Lu

vd., 2011; Wieland, vd., 2014). Literatürde farklı boyutta, şekilde ve dağılımda birçok yüzey özelliğini içeren yüksek çözünürlüklü görüntülerin işlenmesi ve analizinde geleneksel sınıflandırma yaklaşımlarının yetersiz kaldığı ve problem çözümüne katkı sağlayacak yeni ve gelişmiş yaklaşımlara ihtiyaç duyulduğu açık bir şekilde ifade edilmiştir (Lu, vd., 2010; Myint, vd., 2011; Tehrany vd., 2014). Son yıllarda özellikle yüksek çözünürlüklü uydu görüntülerinin sınıflandırılmasında piksel tabanlı yaklaşım yerine obje tabanlı yaklaşımın kullanılmasının sınıflandırma doğruluğunu arttırdığı ve karmaşık yapıdaki sınıflandırma probleminin çözümünde önemli derecede başarı sağladığı birçok çalışmada vurgulanmıştır (Blaschke, 2010; Myint, vd., 2011).

Obje tabanlı sınıflandırma yaklaşımında temel düşünce benzer spektral özelliklere sahip görüntü piksellerinden oluşan homojen yapıları görüntü objelerinin oluşturulması ve objeler için tanımlanan spektral, istatistiksel, doku ve geometrik özellikler dikkate alınarak görüntü objelerinin sınıflandırılmasıdır (Baatz, vd., 2000; Belgiu, vd., 2014). Objeye tabanlı sınıflandırma yaklaşımında dört temel işlem adımı mevcuttur. Bunlardan ilki çeşitli algoritmalar ve yaklaşımlar yardımıyla görüntü piksellerinden homojen görüntü objelerinin üretilmesi olarak bilinen segmentasyon işlemi, ikincisi üretilen görüntü objeleri için farklı özelliklerin tanımlanması, üçüncü olarak kontrollü sınıflandırma işleminin esasları olan arazi örtüsü ve kullanım sınıflarına ilişkin örnekleme veri setlerinin oluşturulması ve son olarak tanımlanan özellikler yardımıyla görüntü objelerinin sınıflandırılmasıdır (Belgiu, vd., 2014).

Genel anlamda segmentasyon büyük objelerin daha küçük parçalara ayrılması anlamına gelmektedir. Objeye tabanlı görüntü sınıflandırma işleminde ise benzer spektral özelliklere sahip piksellerin gruplandırılması ve görüntü objelerinin oluşturulması işlemleri görüntü segmentasyonu olarak tanımlanmaktadır. Bu açıdan ele alındığında segmentasyon işlemi küçük parçalara bölme, birleştirme veya yeniden şekillendirme işlemleri olarak da tanımlanabilmektedir. Segmentasyon işleminin gerçekleştirilmesinde çoklu çözünürlük segmentasyonu (multiresolution) algoritması yaygın olarak kullanılmaktadır (Baatz, vd., 2000; Benz, vd., 2004). Temel olarak, çoklu çözünürlük segmentasyonu başlangıçta görüntüdeki her bir pikseli bağımsız bir obje olarak değerlendirmeye alır. Daha sonra her bir görüntü objesi veya piksel belirli bir homojenlik kriteri esas alınarak

komşu pikseller ile birleştirilerek daha büyük görüntü objeleri elde edilir. Söz konusu homojenlik kriteri spektral ve şekil kriterlerinin birleşimi olarak ifade edilen ölçek parametresi ile belirlenir. Ölçek parametresi arttıkça daha büyük görüntü objeleri üretilirken, küçük parametre değerleri için daha küçük boyutlu ve fazla sayıda görüntü objeleri elde edilir (Baatz, vd., 2000).


Johnson (2013), obje tabanlı sınıflandırma yaklaşımında en önemli problemde birinin oluşturulacak görüntü objelerinin ortalama boyutunu belirleyen görüntü segmentasyon parametrelerinin tespiti noktasında yaşandığını vurgulamıştır. İlgi duyulan arazi örtüsü özelliğinden daha küçük boyutta görüntü objeleri üreten segmentasyon parametreleri kullanıldığında görüntü objeleri için hesaplanan spektral olmayan bilgilerin (örneğin şekil ve geometri) sınıflandırma doğruluğuna olumlu bir katkısını olmayacağını ifade etmiştir. İlgi duyulan yeryüzü nesnesinden daha büyük boyutta görüntü objesi üretecek şekilde segmentasyon parametrelerinin belirlenmesi durumunda ise birden fazla sınıfa ait piksellerin bir obje içerisine dahil edilmesi söz konusu olmaktadır. Bu nedenle segmentasyon işlemi öncesinde optimum segmentasyon parametrelerinin belirlenmesi esastır.

Çoklu çözünürlük segmentasyonu algoritma yardımıyla görüntü segmentasyonunun gerçekleştirilmesinde temel olarak ölçek, şekil ve yoğunluk olarak adlandırılan üç farklı parametrenin kullanıcı tarafından belirlenmesi gerekmektedir. Bunlardan en önemlisi ölçek parametresi olarak ifade edilmektedir (Myint, vd., 2011). Bunun en önemli nedeni seçilecek ölçek parametresinin direkt olarak segmentasyon sonucu oluşturulacak görüntü objelerinin boyutu ile ilişkili olmasıdır. Çok büyük ölçek parametresi kullanılması neticesinde görüntüdeki birçok detay kaybolmakta dolayısıyla üretilen görüntü objeleri farklı arazi örtüsü/kullanımı sınıfına ait pikselleri içerisine alabilmektedir. Bu durum özellikle hatalı sınıflandırmalara dolayısıyla sınıflandırma doğruluğunun önemli düzeyde azalmasına neden olabilmektedir. Diğer taraftan ölçek parametresinin çok küçük seçilmesi beraberinde görüntü üzerinde olması gerekenden çok daha fazla sayıda obje oluşmasına, dolayısıyla sınıflandırma için gereken işlem süresinin artmasında neden olmaktadır.

Ölçek parametresi ile ilgili bir başka husus ise tüm görüntü için tek bir ölçek parametresi tanımlanması ile ilgilidir. Bu noktada karşılaşılan en önemli problemlerden biriside farklı arazi

örtüsü/kullanım sınıflarının farklı ölçeklerde daha iyi sınıflandırılmasıdır (Johnson, 2013). Tüm görüntü için en uygun ölçek parametresi belirlense dahi tek bir ölçek parametresinin kullanılması durumunda bazı arazi örtüsü sınıfları için optimum segmentasyon gerçekleştirilememektedir. Literatürde bu problemin çözümünde farklı ölçekli parametrelerinin kullanılmasına yönelik çalışmalar mevcuttur (Trias-Sanz, vd., 2008; Blaschke, 2010; Anders, vd., 2011; Myint, vd., 2011; De Pinho, vd., 2012; Zhang, vd., 2014).

Görüntü üzerindeki doğal ve yapay nesnelere büyüklükleri ve yoğunluklarına göre değişiklik göstermektedir. Şekil 1a'dan da görüleceği üzere ölçek parametresi 100 olarak belirlendiğinde bir görüntü objesi içerisinde birden çok fıstık çamı ağacının, ağaçlara ait gölge alanların ve ağaçların zeminindeki bozkır alanların dahil edildiği görülmektedir. Diğer bir ifadeyle bir tek sınıfı temsil edecek görüntü objesi yerine birden çok sınıfı içerisine alan karmaşık yapıdaki görüntü objesi elde edilmiştir. Ölçek parametresi 50 olarak belirlendiğinde fıstık çamı, gölge ve bozkır alanlarının ayrı görüntü objeleri içerisinde kaldığı görülmektedir. Ölçek parametresi 50'den 20'ye düşürüldüğünde ise segmentasyon sonucu üretilen görüntü objesi sayısındaki artış net olarak gözükmemekte ve aynı sınıfın birden çok obje ile temsil edildiği görülmektedir.



Şekil 1. Farklı ölçek parametreleri kullanımı.

Buna karşın bina ve yol gibi sürekli özellikler gösteren objeler küçük ölçek parametresi kullanımıyla yüzlerce obje ile tanımlanmak durumunda kalırken, büyük ölçek parametresi ile birkaç görüntü objesi ile temsil edilebilmektedir. Örneğin Şekil 1b'de ölçek parametresinin 100 olarak seçildiği segmentasyon işlemi sonucunda kiremit çatıya sahip bir binanın birkaç görüntü objesi ile temsil edildiği görülmektedir. Ölçek parametresinin artırılması ile söz konusu bina çatısını temsil eden görüntü objesi sayısı artmaktadır.

Bu bina çatısı için ölçek parametresi 20 olarak seçildiğinde, süreklilik gösteren bina çatısı çok fazla obje ile tanımlanabilmektedir. Bu durum oluşturulan bina objelerinin bazı kısımlarının benzer spektral özelliklere sahip diğer sınıflarla karıştırılmasına, dolayısıyla hatalı sınıflandırılmasına neden olmaktadır. Benzer durum yine süreklilik özelliği gösteren ve doğrusal karakteristiğe sahip yol alanları içinde geçerlidir. Şekil 1c'den de görüleceği üzere ölçek parametresi 20 olarak seçildiğinde doğrusal özelliğe sahip asfalt yol yüzlerce farklı görüntü objesi ile temsil edilmek zorunda kalmaktadır. Buna karşın büyük ölçek parametreleri ile aynı yol birkaç veya sınırlı sayıda görüntü objesi ile temsil edilebilmektedir. Bu nedenle özellikle yüksek çözünürlüklü uydu görüntülerinin obje tabanlı yaklaşımla sınıflandırılmasında optimum ölçek parametresinin belirlenmesi hem sınıflandırma sonucu üretilen tematik haritanın doğruluğu hem de sınıflandırma işlemi için gerekli olan işlem süresi açısından kritik bir öneme sahiptir.

Bu çalışmada, WV-2 uydu görüntüsünün obje tabanlı yaklaşımla sınıflandırılmasında çoklu çözünürlük segmentasyonu algoritması kullanılmıştır. Algoritma ile segmentasyon işleminin gerçekleştirilmesinde klasik yaklaşım olarak bilinen tüm görüntü için tek bir ölçek parametresi kullanımı yerine, görüntüdeki doğal ve yapay nesnelere göz önüne alınarak görüntünün bölgelere ayrılması ve her bir bölge için ayrı bir ölçek parametresi belirlenmesi yaklaşımı önerilmiştir. Önerilen yaklaşımın geçerliliğini test etmek amacıyla, tüm görüntü için tek bir ölçek parametresi belirlenerek segmentasyon işlemi gerçekleştirilmiş ve her iki yaklaşımla üretilen görüntü objeleri sınıflandırma işlemine tabi tutulmuştur. Sınıflandırma işleminin gerçekleştirilmesinde geleneksel EYK algoritmasının yanında son yıllarda birçok uygulamada başarı ile kullanılan DVM algoritması da değerlendirilmeye alınmıştır.

## 2. ÇALIŞMA ALANI VE KULLANILAN VERİ

Kocaeli iline bağlı Gebze ilçesinin batı kısmında, İstanbul ili sınırında yer alan ve Gebze Teknik Üniversitesi (GTÜ) Çayırova kampüsünü de kapsayan yaklaşık 220 hektarlık bölge çalışma alanı olarak belirlenmiştir (Şekil 2). Çalışma alanı içerisinde yer alan GTÜ kampüsü toplam 140 hektar açık ve kapalı alana sahip olup, birçok geniş ve iğne yapraklı ağaç türünü bünyesinde barındıran 25 hektarlık yeşil alanıyla yoğun sanayi bölgesi olarak bilinen ilçede doğal hayatı koruyabilmiş ender alanlardandır.

Gerçekleştirilen arazi çalışmaları neticesinde çalışma alanının da 12 farklı arazi örtüsü ve arazi kullanım sınıfının varlığı tespit edilmiştir. Çalışma alanında su, toprak ve bozkır gibi temel arazi örtüsü sınıflarının yayında benzer spektral özelliklere sahip iğne (fıstık çamı, kızılçam ve sedir) ve geniş yapraklı (zeytin ve çınar) ağaç türleri için ayrı ayrı arazi örtüsü sınıfları tanımlanmıştır. Bununla birlikte bölge içerisinde beyaz, turuncu (kırmızı) ve gri renkli çatıya sahip binaların ve çalışma alanını çevreleyen ana ve ara yolların olduğu görülmüş ve her bir arazi kullanımını temsil eden bir sınıf tanımlanmıştır. Söz konusu arazi örtüsü ve kullanım sınıflarına ilave olarak gölge probleminden kaynaklanabilecek sınıflandırma hatalarının azaltılması amacıyla gölge sınıfı tanımlanmıştır.

## 3. MATERYAL VE YÖNTEM

Uygulamada temel veri seti olarak 07 Temmuz 2013 tarihinde kaydedilen Worldview-2 (WV-2) uydu görüntüsü kullanılmıştır. WV-2 uydusu klasik kırmızı (630-690 nm), yeşil (510-580 nm), mavi (450-510 nm) ve yakın kızılötesi (770-895 nm) bantlarına ilave olarak kıyı (400-450nm), sarı (585-625 nm), kırmızı-kenar (705-745 nm) ve ikinci bir kızılötesi (860-1040 nm) bantta görüntüleme yapmaktadır

WV-2 görüntüsünün geometrik olarak düzeltilmesi ve UTM koordinat sistemine dönüşümünde mevcut halihazır haritalar ve bölgeye ait yüksek çözünürlüklü görüntüler üzerinden tespit edilen 20 yer kontrol noktası kullanılmış ve birinci derece Afin dönüşümü yardımıyla yaklaşık 0.5 piksel karesel ortalama hata ile düzeltme işlemi gerçekleştirilmiştir. WV-2'nin pankromatik ve multispektral görüntülerin kaynaştırılmasında Gram-Schmidt algoritmasından yararlanılmış ve kaynaştırma sonucu elde edilen görüntülerin yeniden örneklemeinde Bilineer enterpolasyon tekniği kullanılmıştır.



Şekil 2. Çalışma alanı ve konumu.

Çalışma alanı içerisindeki geniş ve iğne yapraklı ağaç türlerine ilişkin örnekleme alanlarının tespitinde 350nm ile 2500nm spektral aralığında algılama özelliğine sahip ASD FieldSpec3 spektrometresi yardımıyla ölçülen spektral yansıma eğrilerinden yararlanılmıştır. Diğer sınıflar için örnekleme alanları farklı tarihlerde çekilmiş hava fotoğrafları, uydu görüntüleri ve arazide el GPS aleti ile belirlenen noktalar yardımıyla tespit edilmiştir.

Obje-tabanlı sınıflandırma performanslarının değerlendirilmesinde öncelikli olarak genel sınıflandırma doğrulukları kullanılmıştır. Bu değerlendirmelerin yanı sıra tek ve farklı ölçek parametreleri kullanımını sonucunda elde edilen genel doğruluklar arasındaki farkların istatistiksel olarak anlamlılığı McNemar's testi kullanılarak analiz edilmiştir. Ki-kare dağılımını esas alan McNemar's testi temel olarak iki sınıflandırma algoritmasının sınıflandırma hatalarının karşılaştırılması esasına dayanmaktadır (Foody, 2004; Japkowicz, vd., 2011). McNemar's test istatistiğinin hesaplanmasında Tablo 1'de gösterilen  $2 \times 2$  boyutlu bir hata matrisinden ( $C_{MC}$ ) yararlanılmaktadır.

Tablo 1.  $A_1$  ve  $A_2$  sınıflandırıcıları için hesaplanan McNemar's hata matrisi.

		$A_2$ algoritması	
		$f_2$	
		0	1
$A_1$ algoritması	0	$C_{00}^{Mc}$	$C_{01}^{Mc}$
	1	$C_{10}^{Mc}$	$C_{11}^{Mc}$

$A_1$  ve  $A_2$  olarak adlandırılan iki sınıflandırma algoritmasının test veri seti ( $S_{test}$ ) için elde ettiği sınıflandırma sonuçlarının karşılaştırılmasında  $f_1$  ve  $f_2$  olduğu düşünülür. Tablo 1 de verilen hata matrisinde  $c_{00}^{Mc}$ ,  $A_1$  ve  $A_2$  algoritmanın her ikisinin de hatalı sınıflandırdığı piksel sayısını;  $c_{01}^{Mc}$ ,  $A_1$  algoritmasının yanlış  $A_2$  algoritmasının doğru sınıflandırdığı piksel sayısını;  $c_{10}^{Mc}$ ,  $A_1$  algoritmasının doğru  $A_2$  algoritmasının yanlış sınıflandırdığı piksel sayısını ve  $c_{11}^{Mc}$ ,  $A_1$  ve  $A_2$  algoritmanın her ikisinin de doğru sınıflandırdığı piksel sayısını göstermektedir.

Sıfır hipotezi  $A_1$  ve  $A_2$  algoritmalarının aynı performansa ve dolayısıyla aynı hata oranına sahip olduğu kabulünü yapmaktadır. Bu nedenle  $c_{01}^{Mc} = c_{10}^{Mc} = c_{null}^{Mc}$  olduğu kabul edilir. Bir sonraki adımda matris elemanları kullanılarak Eşitlik (1) yardımıyla ki-kare ( $\chi^2$ ) dağılımındaki McNemar's test istatistiği hesaplanır.

$$\chi_{Mc}^2 = \frac{(|c_{01}^{Mc} - c_{10}^{Mc}| - 1)^2}{c_{01}^{Mc} + c_{10}^{Mc}} \quad (1)$$

Hesaplanan istatistik değer ki-kare dağılımını gösteren tablo değerinden belirlenen güven aralığında büyük olduğunda sıfır hipotezi reddedilir. Örneğin hesaplanan istatistik değer ( $\chi_{Mc}^2$ ), %95 güven aralığında kritik tablo değerinden ( $\chi^2 = 3,841$ ) büyük olduğunda sıfır hipotezi reddedilerek  $A_1$  ve  $A_2$  algoritmalarının sınıflandırma performansları ve hata oranları arasındaki farkın istatistiksel olarak anlamlı olduğu sonucuna ulaşılır. Diğer ifadeyle bu sonuç algoritmaların birinin diğerinden daha iyi performans gösterdiğinin istatistiksel olarak desteklenmektedir.

#### 4. SINIFLANDIRMA ALGORİTMALARI

##### a. En Yakın Komşuluk (EYK)

Örnek tabanlı öğrenme algoritmalarından birisi olan EYK algoritması, uzaktan algılama alanında geleneksel sınıflandırıcı olarak kabul edilen parametrik bir algoritmadır. EYK algoritması öncelikli olarak eğitim kümesi içerisindeki sınıfları temsil eden ortalama değer vektörleri hesaplar. Daha sonra sınıflandırılmak istenen aday pikselin hesaplanan sınıf ortalama vektörleri arasındaki spektral uzaklıklar hesaplanır. Hesaplanan spektral uzaklıklara göre

aday piksel en yakın mesafedeki örnek sınıfa atanır (Lillesand, vd., 2007).

Sınıflara ait ortalama vektörler ile aday piksel arasındaki spektral uzaklık Eşitlik (2)'de verilen Öklit uzaklığı esasına dayanmaktadır. Eşitlikte;  $k$ , bant sayısını;  $i$ , belirli bir bandı;  $c$ , belli bir sınıfı;  $X_{xyi}$ ,  $i$ . banttaki pikselin  $x, y$  değerlerini;  $\mu_{ci}$ ,  $i$  bandındaki  $c$  sınıfına ait örneklere ait değerlerin ortalamasını;  $d_{xyc}$ , aday piksel  $x, y$ 'nin  $c$  sınıfına ait ortalama vektöre olan spektral uzaklığı olarak ifade edilebilir.

$$d_{xyc} = \sqrt{\sum_{i=1}^k (\mu_{ci} - X_{xyi})^2} \quad (2)$$

##### b. Destek Vektör Makineleri (DVM)

Parametrik olmayan bir yapıya sahip DVM son yıllarda birçok sınıflandırma ve örüntü tanıma probleminde başarıyla kullanılan bir makine öğrenme algoritmasıdır (Huang vd., 2002; Kavzoğlu vd., 2010; Mountrakis vd., 2011). DVM ile sınıflandırma probleminin çözümünde temel prensip iki sınıfa ait pikselleri birbirinden optimum şekilde ayırabilen bir hiperdüzlemin belirlenmesidir (Vapnik, 1995). Söz konusu hiper düzlem sınıflandırma hatalarını minimum yapan ve sınıflar arasındaki karar sınırlarını optimum şekilde belirleyen bir özelliğe sahiptir.

Yüksek konumsal çözünürlüğe sahip uydu görüntülerinin sınıflandırılması problemine olduğu gibi, doğrusal olarak birbirinden ayrılamayan ve lineer eşitliklerle karar sınırlarının belirlenemediği veri setleri için DVM kernel fonksiyonlarından yararlanmaktadır. Söz konusu fonksiyonlar yardımıyla doğrusal olmayan veri seti yüksek boyutlu bir uzaya dönüştürülerek sınıflar arasında doğrusal ayrımların yapılabilmesi mümkün olmaktadır (Mathur vd., 2008). Literatürde doğrusal olmayan yapıya sahip veri setlerinin sınıflandırılmasında birçok kernel fonksiyonu kullanılmış, bunlar arasında amacıyla farklı kernel fonksiyonu tanımlanmıştır. Bunlar arasında radyal tabanlı fonksiyon problem çözümündeki etkinliği ve yüksek sınıflandırma doğruluğu üretmesi nedeniyle en çok tercih edilen kernel fonksiyonu olma özelliğine sahiptir (Kavzoğlu vd., 2010). SVM son yıllarda uzaktan algılama alanında yoğun bir şekilde kullanılmıştır (Kavzoglu vd., 2009; Kavzoglu vd., 2011; Kavzoglu vd., 2012; Çölkesen vd., 2014).

## 5. UYGULAMA

WV-2 uydu görüntüsünün segmente edilmesinde çoklu çözünürlük segmentasyonu algoritması kullanılmıştır. Algoritma ile segmentasyon işleminin gerçekleştirilmesinde klasik yaklaşım olarak bilinen tüm görüntü için tek bir ölçek parametresi kullanımı yerine, görüntüdeki doğal ve yapay nesnelere göz önüne alınarak görüntünün bölgelere ayrılması ve her bir bölge için ayrı bir ölçek parametresi belirlenmesi yaklaşımı önerilmiştir. Optimum ölçek parametresinin seçiminde Drăguț, vd. (2010) tarafından önerilen ESP yazılımından yararlanılmıştır. Önerilen yaklaşımın geçerliliğini test etmek amacıyla, öncelikli olarak tüm görüntü için 50 olarak belirlenen ölçek parametresi yardımıyla segmentasyon işlemi yapılmış ve segmentasyon işlemi sonucunda 377.190 görüntü objesi elde edilmiştir.

Uygulamada önerilen segmentasyon yaklaşımının uygulanması amacıyla çalışma bölgesi önce Şekil 3'de gösterildiği üzere 6 farklı bölgeye ayrılmış ve her bir bölge kendi içerisinde değerlendirilerek bölgelere özgü ölçek parametreleri tespit edilmiştir. Şekilde Bölge-1, 3 ve 5 olarak tanımlanan alanlar için en uygun ölçek parametresi 50 olarak belirlenmiştir. Bunun temel nedeni söz konusu bölgeler içerisinde diğer doğal ve yapay nesnelere kıyasla daha küçük bir kanopiye sahip olan zeytin (Bölge-1) ve genç fıstık çamı (Bölge-3 ve 5) ağaçlarının bulunmasıdır. Ölçek parametresinin 50'den küçük seçilmesi durumunda ağaçlar birden çok objeyle temsil edilirken, büyük ölçek kullanımında ağaçların gölgesinin ve etrafındaki bozkır alanlarının objeler içerisine dahil edilmektedir. Şekilde Bölge-2 olarak adlandırılan kısımda olgun fıstık çamları ve kızılçamların bir arada bulunduğu yoğun bir orman örtüsü mevcuttur. Bu bölge için 70 olarak belirlenen ölçek parametresi ile ağaç türlerini temsil edebilen ideal görüntü objeleri oluşturulmuştur. Ölçek parametresi daha yüksek değerler aldığı anda, objeler içerisinde gölge alanlarının dahil edildiği görülmüştür.

Görüntü üzerinde diğer bölgelere göre en yüksek ölçek parametresinin belirlendiği alanlar 4. ve 6. bölgedir. Bölge-4 içerisinde su geçirimsiz yüzey olarak tanımlanan bina ve beton yapılar ile birlikte su sınıfı olarak tanımlanan deniz, dere ve arıtma tesisi içerisindeki havuz alanları bulunmaktadır. Bölge-6 içerisinde ise yoğun bozkır ve toprak örtüsü mevcuttur. Bu bölgeler için seçilecek küçük ölçek parametreleri ile söz konusu alanlar çok fazla obje ile temsil edilmekte ve obje sayısı artmaktadır.



Şekil 3. Farklı ölçek parametrelerinin belirlendiği bölgeler.

Bölgelere göre tespit edilen ve Tablo 2'de gösterilen ölçek parametreleri kullanılarak çoklu segmentasyon algoritması ile her bölge ayrı ayrı segmente edilmiştir. Daha sonra her bir bölge birbiriyle entegre edilip birleştirilerek farklı ölçek parametrelerinin tek bir görüntü elde edilmiştir. Elde edilen entegre görüntüde toplam 250.850 görüntü objesi bulunmaktadır. Farklı ölçek parametreleri ile segmentasyon yaklaşımı sonucunda üretilen obje sayısı, tek ölçek parametresi kullanılarak elde edilen obje sayısından %34 daha azdır. Diğer bir ifadeyle farklı ölçek yaklaşımı ile daha az görüntü objesi üretildiğinden sınıflandırma için gereken işlem zamanı daha az olacaktır.

Tablo 2. Segmentasyon işleminde kullanılan ölçek parametreleri ve üretilen obje sayıları.

	Ölçek	Objeye Sayısı
Bölge -1	50	47.160
Bölge -2	70	84.403
Bölge -3	50	48.549
Bölge -4	90	18.060
Bölge -5	50	31.835
Bölge -6	100	20.843
<b>Toplam</b>		<b>250.850</b>

Klasik ve önerilen segmentasyon yaklaşımıyla görüntünün segmente edilmesinin ardından, her iki görüntü üzerindeki objeler için aynı temel özellikler (ortalama, standart sapma, minimum ve maksimum piksel değerleri) tanımlanarak sınıflandırma işlemi gerçekleştirilmiştir. Objelerin sınıflandırılmasında DVM ve EYK algoritmaları kullanılmıştır. Elde edilen sınıflandırma doğruluklarının karşılaştırılmasında objektifliği sağlamak amacıyla aynı test veri seti kullanılmış ve test veri seti için elde genel sınıflandırma doğrulukları Tablo 3'de gösterilmiştir.

Tablodan da görüleceği gibi tüm görüntü için belirlenen tek ölçek parametresi ile DVM algoritması %85,86 doğruluğa ulaşırken, farklı ölçek parametreleri ile üretilen görüntü objelerinin sınıflandırılması sonucunda %91,78 doğruluğa ulaşmıştır. Diğer bir ifadeyle farklı ölçek parametreleri kullanımıyla sınıflandırma doğruluğunda %5,92'lik bir iyileşme gerçekleşmiştir. Sınıflandırma doğruluğundaki artışın istatistiksel olarak anlamlılığı McNemar's testi kullanılarak analiz edildiğinde, söz konusu doğruluk farkının %95 güven aralığında istatistiksel olarak anlamlı bir fark olduğu belirlenmiştir (Tablo 3). Diğer bir ifadeyle farklı ölçek parametreleri kullanımıyla DVM'nin sınıflandırma doğruluğunda istatistiksel olarak anlamlı bir artış olduğu ifade edilebilir.

EYK algoritması için Tablo 3'de gösterilen sınıflandırma doğrulukları analiz edildiğinde, tek ölçek parametresi ile üretilen görüntü objelerinin %80,82 doğrulukla, farklı ölçek parametresi ile üretilen objelerin ise %83,76 doğrulukla sınıflandırıldığı görülmektedir. Bu sonuçlar farklı ölçek parametreleriyle EYK algoritmasının performansında %2,94 artış olduğunu göstermektedir. Tablo 3'den de görüleceği üzere bu artış %95 güven aralığında McNemar's test

istatistiğine göre anlamlı bir farktır. Dolayısıyla farklı ölçek parametreleri kullanımıyla EYK algoritmasının sınıflandırma performansında istatistiksel olarak anlamlı bir iyileşme olduğu ifade edilebilir. Tablo 3'de sunulan sınıflandırma sonuçları kullanılan algoritmalar açısından ele alındığında DVM'nin tek ölçek parametresi kullanımında EYK algoritmasından %5, farklı ölçek parametreleri kullanımında ise %8 daha yüksek sınıflandırma doğruluğuna ulaştığı görülmektedir. Ulaşılan bu sonuç obje tabanlı sınıflandırma yaklaşımında parametrik olmayan DVM'nin sınıflandırma doğruluğu üzerindeki pozitif etkisini gösterir niteliktedir.

Tek ve farklı ölçek parametreleri için oluşturulan DVM ve EYK sınıflandırma modelleri segmente edilen görüntüye ayrı ayrı uygulanarak çalışma alanına ait tematik haritalar üretilmiştir. Bu haritalara örnek olarak en yüksek sınıflandırma doğruluğuna ulaşılan farklı ölçek parametrelerinin kullanıldığı DVM sınıflandırma modeli ile üretilen tematik harita Şekil 4'te gösterilmiştir. Tematik haritadan da görüleceği üzere çalışma alanı içerisindeki bezer spektral özelliklere sahip iğne ve geniş yapraklı ağaç türlerinin büyük ölçüde ayırt edilebildiği görülmektedir. Söz konusu ağaç türlerinden zeytin ağaçlarına ait piksellerin özellikle bozkır sınıfına ait pikseller ile karıştığı görülmektedir. Bu durumun zeytin ağaçlarının diğer ağaç türlerine göre çok küçük bir kanopiye sahip olması nedeniyle bu ağaç türlerini temsil eden örnek alanların tespitinde karşılaşılan zorluklardan kaynaklandığı söylenebilir. Çalışma alanı içerisinde spektral olarak en yüksek yansımaya sahip çınar ağacına ait piksellerin genel olarak doğru sınıflandırıldığı, tematik haritanın belirli kısımlarda bozkır sınıfına ait pikseller ile karıştığı görülmektedir.

Tablo 3. Tek ve farklı ölçek parametreleri kullanılarak elde edilen genel sınıflandırma doğrulukları ve McNemar's test sonuçları.

Sınıflandırma Yöntemi	Tek ölçek parametresi (%)	Farklı ölçek parametreleri (%)	Doğruluk farkı (%)	McNemar's test istatistiği
DVM	85,86	91,78	5,92	56,21
EYK	80,82	83,76	2,94	22,58



Şekil 4. WV-2 görüntüsünün DVM yöntemi ile sınıflandırılması sonucunda elde edilen tematik harita.

Tematik haritadan da görüleceği üzere, çalışma alanı içerisinde en canlı ve spektral olarak en yüksek yansımaya sahip çınar ağacına ait piksellerin genel olarak doğru sınıflandırıldığı, tematik haritanın belirli kısımlarda bozkır sınıfı içerisindeki canlı bitki örtüsüne ait pikseller ile karıştığı görülmektedir. Çalışma alanının kuzey kesiminde yer alan yoğun iğne yapraklı orman yapısı içerisindeki kızılçam ve fıstık çamı türlerinin ayırt edilmesinin büyük ölçüde başarılı olduğu, ancak gölge etkisi ile birlikte bazı kesimlerde iki ağaç türünün ayırt edilmesinde zorluklar yaşandığı görülmektedir. Çalışma alanının orta ve batı kesimlerinde bulunan genç fıstık çamlarının yüksek doğrulukla sınıflandırıldığı tespit edilmiştir. Çalışmada dikkate alınan bina türlerinden gri çatılı bina piksellerinin yol sınıfına ait pikseller ile karıştığı kolaylıkla görülmektedir. Kırmızı çatılı bina sınıfına ait piksellerin ise çalışma alanının bazı kesimlerinde toprak sınıfındaki pikseller ile karıştığı tespit edilmiştir.

## 6. SONUÇ VE ÖNERİLER

Uzaktan algılanmış görüntülerin sınıflandırılması problemi özellikle yüksek konumsal çözünürlüğe sahip görüntülerin varlığı

ile birlikte daha karmaşık bir hal almıştır. Artan konumsal çözünürlük, farklı arazi örtüsü sınıflarını temsil eden ve spektral olarak benzer özellik gösteren pikselleri içeren bir veri yapısını ortaya çıkarmıştır. Son yıllarda, her bir pikselin ayrı ayrı sınıflandırılması yerine, piksellerinin belirli algoritmalar yardımıyla bir araya getirilerek homojen yapıya görüntü objelerinin oluşturulması ve oluşturulan görüntü objelerinin sınıflandırılması esasına dayanan obje-tabanlı yaklaşım özellikle yüksek çözünürlüklü görüntülerin sınıflandırılmasında başarıyla kullanılmaktadır. Objeye-tabanlı yaklaşım için esas teşkil eden görüntü segmentasyon işleminde üretilecek obje boyutunu dolayısıyla homojenliği belirleyen en önemli parametre ölçek parametresidir. Bu çalışmada, segmentasyon işleminin gerçekleştirilmesinde tüm görüntü için tek bir ölçek parametresi seçimi yerine, görüntünün mevcut yüzey özellikleri dikkate alınarak bölgelere ayrılması daha sonra her bir bölge için ölçek parametresinin tespit edilmesi yaklaşımı önerilmiştir ve sınıflandırma doğruluğuna etkileri incelenmiştir.

Çalışma sonuçları analiz edildiğinde önemli bulgulara ulaşılmıştır. Bunlardan ilki tüm görüntü için tek bir ölçek parametresi tespiti yerine farklı



ölçek parametreleri kullanımıyla segmentasyon sonucunda üretilen obje sayısı %34 oranında azalmaktadır. Bu durum özellikle sınıflandırma işlemi için gerekli olan hesaplama zamanını azaltarak tematik harita üretim sürecini hızlandırmaktadır. İkinci olarak, bölgeye özgü belirlenen ölçek parametreleri ile mevcut yüzey özelliklerini temsil eden daha anlamlı ve homojenliği yüksek görüntü objeleri üretilmekte, dolayısıyla tematik harita doğruluğunu artmaktadır. Nitekim EYK ve SVM algoritmaları için elde edilen sınıflandırma sonuçları farklı ölçek parametreleri yaklaşımıyla tematik harita doğruluğunda %3-6 seviyelerinde iyileşmeler olduğunu göstermektedir. McNemar's test sonuçları da farklı ölçek parametreleri kullanımıyla sınıflandırma doğruluğunda istatistiksel olarak anlamlı olduğunu desteklemektedir. Üçüncü olarak, DVM hem tek ölçek hem de farklı ölçek parametreleri ile üretilen görüntü objelerinin sınıflandırılmasında klasik sınıflandırma yöntemi olan EYK algoritmasından %5-8 seviyelerinde daha yüksek sonuçlar üretmiştir. Elde edilen bu sonuç DVM gibi parametrik olmayan sınıflandırma algoritmalarının obje tabanlı sınıflandırmadaki etkinliğini gösterir niteliktedir.

#### KAYNAKLAR

- Anders, N. S., Seijmonsbergen, A. C., Bouten, W., 2011, **Segmentation optimization and stratified object-based analysis for semi-automated geomorphological mapping**, Remote Sensing of Environment, 115(12): 2976-2985.
- Baatz, M., Schape, A., 2000, **Multi resolution segmentation-an optimization approach for high quality multi scale image segmentation**, Proceedings of Twelfth Angewandte Geographische Informationsverarbeitung, Germany: Karlsruhe Institute of Technology, May 25-27.
- Belgiu, M., Drăguț, L., 2014, **Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery**, ISPRS Journal of Photogrammetry and Remote Sensing, 96:67-75.
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004, **Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information**, ISPRS Journal of Photogrammetry and Remote Sensing, 58(3-4): 239-258.
- Blaschke, T., 2010, **Object based image analysis for remote sensing**, ISPRS Journal of Photogrammetry and Remote Sensing, 65(1): 2-16.
- Çölkesen, İ., Yomralıoğlu, T., 2014, **Arazi Örtüsü ve Kullanımının Haritalanmasında WorldView-2 Uydu Görüntüsü ve Yardımcı Verilerin Kullanımı**, Harita Dergisi, 152(2):12-24.
- De Pinho, C. M. D., Fonseca, L. M. G., Korting, T. S., De Almeida, C. M., Kux, H. J. H., 2012, **Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis**, International Journal of Remote Sensing, 33(19): 5973-5995.
- Drăguț, L., Tiede, D., Levick, S. R., 2010, **ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data**, International Journal of Geographical Information Science, 24 (6):859-71.
- Foody, G. M., 2004, **Thematic map comparison: Evaluating the statistical significance of differences in classification accuracy**, Photogrammetric Engineering and Remote Sensing, 70(5): 627-633.
- Huang, C., Davis, L. S., Townshend, J. R. G., 2002, **An assessment of support vector machines for land cover classification**, International Journal of Remote Sensing, 23(4): 725-749.
- Japkowicz, N., Shah, M., 2011. **Evaluating Learning Algorithm: A classification Perspective**, New York, USA: Cambridge University Press.
- Johnson, B. A., 2013, **High-resolution urban land-cover classification using a competitive multi-scale object-based approach**, Remote Sensing Letters, 4(2): 131-140.
- Kavzoglu, T., Colkesen, I., 2009, **A kernel functions analysis for support vector machines for land cover classification**, International Journal of Applied Earth Observation and Geoinformation, 11(5): 352-359.

- Kavzoglu, T., Colkesen, I., 2011, **Assessment of environmental change and land degradation using time series of remote sensing images**, Fresenius Environmental Bulletin, 20(1a): 274-281.
- Kavzoglu, T., Colkesen, I., 2012, **The Effects of Training Set Size for the Performance of Support Vector Machines and Decision Trees**, Proceedings of 10th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences (ACCURACY2012), 10-13 July, Florianópolis, SC, Brazil.
- Kavzoğlu, T., Çölkesen, İ., 2010, **Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi**, Harita Dergisi, 144(7):73-82.
- Lillesand, T.M., Kiefer, R.W. Chipman, J.W., 2007. **Remote Sensing and Image Interpretation**, Sixth edition, New York, USA: John Wiley & Sons.
- Lu, D.S., Hetrick, S., Moran, E., 2011, **Impervious surface mapping with Quickbird imagery**, International Journal of Remote Sensing, 32(9): 2519-2533.
- Mathur, A. and Foody, G.M., 2008, **Multiclass and binary SVM classification: Implications for training and classification users**, IEEE Geoscience and Remote Sensing Letters, 5(2): 241-245.
- Mountrakis, G., Im, J., Ogole, C., 2011, **Support vector machines in remote sensing: A review**, ISPRS Journal of Photogrammetry and Remote Sensing, 66(3): 247-259.
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., Weng, Q. H., 2011, **Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery**, Remote Sensing of Environment, 115(5): 1145-1161.
- Tehrany, M. S., Pradhan, B., Jebuv, M. N., 2014, **A comparative assessment between object and pixel-based classification approaches for land-use/land-cover mapping using SPOT 5 imagery**. Geocarto International, 29(4): 351-369.
- Trias-Sanz, R., Stamon, G., Louchet, J., 2008, **Using colour, texture, and hierarchical segmentation for high-resolution remote sensing**. ISPRS Journal of Photogrammetry and Remote Sensing, 63(2): 156-168.
- Vapnik, V. N., 1995, **The nature of statistical learning theory**, New York, USA: Springer-Verlag.
- Wieland, M., Pittore, M., 2014, **Performance Evaluation of Machine Learning Algorithms for Urban Pattern Recognition from Multi-spectral Satellite Images**, Remote Sensing, 6(4): 2912-2939.
- Zhang, L., Jia, K., Li, X. S., Yuan, Q. Z., Zhao, X. F., 2014, **Multi-scale segmentation approach for object-based land-cover classification using high-resolution imagery**, Remote Sensing Letters, 5(1): 73-82.
- Zhou, W.Q., Huang, G.L., Troy, A., Cadenasso, M.L., 2009, **Object-based land cover classification of shaded areas in high spatial resolution imagery of urban areas: A comparison study**, Remote Sensing of Environment, 113(8): 1769-1777.