

Nesne Tabanlı Görüntü Analizinde Görüntü Bölütleme Yaklaşımları ve Bölütleme Kalitesinin Analizi

(Image Segmentation Approaches in Object-Based Image Analysis and Analysis of Segmentation Quality)

Hasan TONBUL, Taşkın KAVZOĞLU

Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, Gebze, Kocaeli
htonbul@gtu.edu.tr, kavzoglu@gtu.edu.tr

ÖZ

Son yıllarda yüksek mekânsal çözünürlüklü uydu görüntü miktarındaki artış ile birlikte yüksek spektral heterojenlik içeren bu görüntülerden bilgi çıkarımı önemli bir araştırma konusu olmuştur. Bu görüntülerden bilgi çıkarabilmek için geleneksel yaklaşımların kullanımı yeterli olmamaktadır. Nesne tabanlı görüntü analizi (NTGA), yüksek çözünürlüklü uzaktan algılanmış görüntülerinin analizinde etkin şekilde kullanılan yeni bir paradigma olarak ortaya çıkmıştır. NTGA'nın ilk ve en temel adımını görüntü nesnelere ayırma yarayan görüntü bölütleme adımı oluşturmaktadır. Nesnelere şekli, boyutu ve spektral özellikleri bölütleme yaklaşımına bağlı olarak belirlenmektedir. Optimum görüntü bölütleme için gerekli yöntem ve parametre seçimi, görüntü sınıflandırması veya özellik çıkarımı işleminden önce karar verilmesi gereken çok önemli hususlardır. Bu çalışma, NTGA alanında kullanılan görüntü bölütleme algoritmaları, parametre seçim stratejileri ve görüntü bölütleme kalitesi konusunda yapılan çalışmalar hakkında detaylı bilgiler ve literatür taraması sunmaktadır. Görüntü bölütleme işlemini doğru şekilde gerçekleştirmek için araştırmacılara rehberlik edecek ve uygulamada dikkat edilmesi gereken kritik hususları içeren değerlendirmeler ayrıca sunulmuştur.

Anahtar Kelimeler: Uzaktan Algılama, Görüntü Bölütleme, Nesne tabanlı görüntü analizi, Görüntü İşleme.

ABSTRACT

In recent years, with the increase in the amount of satellite images with high spatial resolution, the extraction of information from these images containing high spectral heterogeneity has been an important subject of research. Conventional approaches are deficient to extract information from these images. Object-based image analysis (OBIA) has emerged as a new paradigm that is effectively used in the analysis of high-resolution remote sensing images. The first and basic step of NTGA is the image segmentation that is applied to create image objects. The shape, size, and spectral properties of the objects are determined by the segmentation approach. Selection of appropriate method and its parameters is crucial for optimal image segmentation before the image classification or feature extraction stages. This study provides detailed information about the image segmentation algorithms, parameter selection strategies and image segmentation quality studies with literature review. Moreover, some guidelines and considerations are presented for

researchers to conduct segmentation properly focusing on some crucial research issues.

Keywords: Remote Sensing, Image Segmentation, Object based image analysis, Image Processing.

1. GİRİŞ

Yüksek mekânsal çözünürlüklü yer gözlem uydularının ilk görüntü sağlamaya başladıkları 2000'li yıllardan itibaren sayıları önemli ölçüde artmış (IKONOS, QuickBird, Worldview, vb.) sağlanan veri özellikleri iyileşirken paralel olarak uygulanan görüntü işleme teknikleri de önemli ölçüde geliştirilmiştir. Bu tür görüntülerdeki pikseller, arazi karakteristiğine ve algılayıcı sensörün çözünürlüğüne bağlı olarak genellikle birden fazla yeryüzü nesnesini (doğal veya yapay) içermektedir (Kavzoglu, 2009). Buna bağlı olarak, sınıf içi spektral heterojenlikte artış gözlenmektedir. Bu nedenle sınıflandırmada tek başına piksel spektral bilgisinin kullanımı sınıfları ayırt etmede yetersiz kalmaktadır. Ayrıca topoğrafyadan kaynaklanan gölgelik alanlar, yüksek binaların ve ağaçların gölgeleri sınıflandırma doğruluğunu ciddi anlamda olumsuz yönde etkilemektedir. Bu tür görüntülere uygulanan piksel tabanlı yaklaşımların sınıflandırma ve özellik çıkarımı konusunda istenen sonuçları vermediği görülmüştür (Yu vd., 2006). Özellikle, sadece piksellerin spektral değerlerinin dikkate alındığı birçok arazi örtüsü/arazi kullanımı uygulamasında, yüksek sınıf içi spektral değişkenlik ve sınıflar arası spektral benzerlik nedeni ile düşük sınıflandırma doğrulukları elde edilmektedir (Blaschke vd., 2004; Myint vd., 2011). Buna ek olarak, geleneksel piksel tabanlı yaklaşımlar ile yüksek çözünürlüklü görüntülerin sınıflandırılmasında tuz-biber etkisi adı verilen görüntü oluşmakta, yüksek sınıflandırma doğruluğu beklentileri karşılanamamakta ve coğrafi bilgi sistemlerine aktarımda sorunlar ortaya çıkmaktadır (Duveiller vd., 2008; Hussain vd., 2013). Bu zorlukların üstesinden gelmek ve görüntü analizinin kalitesini arttırmak amacıyla, nesne tabanlı görüntü analizi (NTGA) veya coğrafi nesne tabanlı görüntü analizi (CNTGA) adı verilen yaklaşım kullanılmaya başlamıştır (Blaschke, 2010; Blaschke vd., 2014).

NTGA yaklaşımı, uzaktan algılanmış görüntülerin makine öğrenme (machine learning) algoritmalarıyla analizi için yeni ve benzersiz bir bakış açısı sunmaktadır.

Uzaktan algılama alanında nesne tabanlı görüntü analizi kavramı ilk olarak Blaschke ve Strobl (2001) tarafından dile getirilmiş ve günümüze kadar sürekli gelişim göstermiştir. Özellikle, sonraki yıllarda NTGA teknikleri ve uygulamaları alanında düzenlenen uluslararası konferanslar ve hakemli dergilerdeki özel sayılar, uzaktan algılama alanında yapılan uygulama sayısının arttığını göstermiştir (Gamanya vd., 2009). NTGA piksellerin gruplandırılmasını, dolayısı ile homojen piksel kümelerinin spektral özelliklere ek olarak boyut, şekil, doku gibi özellikleriyle de analiz edilebilmelerini, hatta nesnelere konumları ve komşulukları gibi özelliklerle de sorgulanabilmelerini sağlar. (Kalkan, 2011). Böylelikle, NTGA daha karmaşık görüntü analiz görevlerini yürütme potansiyeline sahip olmaktadır (Kavzoglu vd., 2017).

Son yıllarda arazi örtüsü/arazi kullanımı sınıflandırması (Zhang ve Jia, 2014), bina çıkarımı (Belgiu ve Drăgut, 2014), orman yönetimi (Wells, 2010), tarım uygulamaları (Sertel ve Yay, 2014), su havzası sınıflandırması (Uca Avcı vd., 2014), deprem hasar sınıflandırması (Sabuncu ve Sunar, 2017), ürün tipi belirlenmesi (Uca Avcı ve Sunar, 2015; Delen ve Şanlı, 2017), değişim analizi (Hussain, vd., 2013) gibi birçok farklı alanda yapılan literatür çalışmaları ele alındığında, uzaktan algılama topluluğunun önemli bir bölümünün görüntülerden bilgi çıkarımı için piksel temelli sınıflandırma yerine NTGA yaklaşımını tercih ettiği görülmektedir (Gamanya vd., 2009). Piksel tabanlı ve nesne tabanlı görüntü analizi sonuçları karşılaştırması da son yıllarda birçok yazar tarafından gerçekleştirilmiştir (Alganci vd., 2013; Blaschke, vd., 2014; Colkesen ve Kavzoglu, 2016). Örneğin, Yan vd. (2006) piksel tabanlı sınıflandırma için en yüksek olasılık yöntemini ve nesne tabanlı sınıflandırma için k-en yakın komşuluk yöntemini ASTER görüntüsü üzerinde kullanarak karşılaştırma yapmışlardır. Çalışmalarında, nesne tabanlı en yakın k komşuluk sınıflandırmasının genel doğruluğunun piksel tabanlı en yüksek olasılık sınıflandırmasından daha iyi performans gösterdiğini belirtmişlerdir. Castillejo-González vd. (2009) ise multispektral QuickBird görüntüsü ve çeşitli sınıflandırma algoritmalarını kullanarak, tarımsal alanlar üzerinde piksel tabanlı ve nesne tabanlı sınıflandırma performanslarını karşılaştırmışlardır. En yüksek genel sınıflandırma doğruluğu piksel tabanlı yaklaşım için %89,6,

nesne tabanlı yaklaşım için %93,69 olarak belirlenmiştir. Myint vd. (2011), çalışmalarında şehir arazi örtüsünü sınıflandırmak için QuickBird görüntüsünü kullanmıştır. Bu çalışmada, en yakın k komşuluk sınıflandırmasından ve bir dizi bulanık üyelik fonksiyonunu kullandıkları nesne tabanlı sınıflandırmadan elde ettikleri sonuçları, piksel tabanlı sınıflandırma (en yüksek olasılık algoritması) sonuçları ile karşılaştırmışlardır. Nesne tabanlı sınıflandırmanın (%90,4), piksel tabanlı sınıflandırmaya göre (%67,6), büyük ölçüde üstünlük sağladığı sonucuna varmışlardır.

NTGA, temel olarak görüntü bölütleme ve sınıflandırma olmak üzere iki aşamadan oluşmaktadır. Görüntü bölütleme, görüntü üzerinde belirleyici özellikleri esas alarak homojen görüntü nesnelere oluşturma işlemidir. Bu işlem, devamında gelen sınıflandırma işlemi doğrudan etkilemesi itibarıyla NTGA'nın temelini oluşturmaktadır. Görüntü bölütleme işleminde hedef, ele alınan yeryüzü nesnesiyle oluşturulan görüntü bölütü sınırlarının tam olarak örtüşmesidir. Ancak, yüksek çözünürlüklü uydu görüntülerinde değişen düzeyde karmaşık yeryüzü özellikleri olmasına bağlı olarak tam anlamıyla örtüşme elde etmek oldukça zordur. Dolayısıyla, bölütleme parametrelerinin kullanıcı tarafından en doğru şekilde belirlenmesi ile bölütleme kalitesinin mümkün olduğu kadar yüksek olması sağlanmaya çalışılır. Görüntü bölütleme kalitesi görüntü kalitesiyle de ilişkilidir ve bant sayısı, görüntü çözünürlüğü ve görüntünün karmaşıklığına bağlı olarak değişebilmektedir (Belgiu ve Drăgut, 2014). Mevcut görüntü bölütleme algoritmalarının çoğu için parametre seçimi deneme-yanılma yöntemiyle gerçekleştirilmektedir. Bu nedenle bu işlem subjektif olarak değerlendirilebilir. Halihazırda literatürde bazı bölütleme algoritmaları için parametre belirleme yöntem ve araçları geliştirilmişse de optimum parametreleri tahmin etmek için kullanılabilecek görüş birliğine varılmış ya da onaylanmış bir yöntem veya algoritma bulunmamaktadır (Kavzoglu vd., 2017).

Görüntü bölütleme çalışmalarında, tek ölçek yerine çoklu-ölçek kullanımı sınıflandırma doğruluğunu artıran bir yaklaşımdır. Tekli-ölçek bölütlemeye optimum bölütleme arazi kullanımı/arazi örtüsü sınıflarına bağlıdır. Bunun sebebi, genel olarak bölütlemenin optimum olması durumunda bile bazı sınıflar için ideal görüntü nesnelere elde edilememesi şeklinde açıklanabilir (Räsänen vd., 2013). Ancak, farklı türlerdeki yeryüzü nesnelere için optimum ölçek belirlenmesi zor bir işlemdir (Li vd., 2010). Literatürde birçok çalışmada, tekli-ölçek

parametre kullanımının yapıldığı gözlemlenmiştir (Espindola vd., 2006; Yu vd., 2006; Neubert vd., 2008). Kullanıcıların görüntü bölütlerini araştırmasını ve her ölçeğe göre sınıflandırma kuralları geliştirmesini gerektirmeyen, çoklu-ölçek yaklaşımı, daha hızlı ve daha objektif bir yaklaşım olarak karşımıza çıkmaktadır (Johnson ve Xie, 2013). Bu yüzden, çoklu-ölçek kullanımı, son yıllarda çalışmalarda daha fazla ön plana çıkmıştır (Blaschke vd., 2004; Zhou ve Troy, 2009; Drägut vd. 2010, 2014; Kavzoglu vd., 2017). Genellikle çoklu-ölçek bölütleme yöntemleri, gözle görülebilen görüntü bileşenleri ile küçük detayların sırasıyla daha kaba ve daha iyi ölçeklerde bölütlere ayrılma eğiliminde olduğunu varsaymaktadır. Örneğin, geniş yollar, konut alanları, ormanlar ve nehir havzaları daha kaba bir ölçekte bölütlenirken, tek ev veya bina, tek tek ağaçlar, tarla ve dereler daha küçük ölçek değerleriyle ayrılabilir. Farklı ölçeklerde bölütleme elde edildikten sonra, hangi nesnelere hangi ölçeklerde sınıflandırılacağı belirlenebilir (Chen vd., 2014).

Bu çalışmanın temel amacı, NTGA ve buna bağlı olarak yapılan görüntü bölütleme çalışmaları hakkında uzaktan algılama kullanıcılarına genel bir değerlendirme yapmak ve literatür taraması sunmaktır. Bu çalışmanın içeriği üç bölüme ayrılabilir: (1) NTGA ile ilgili temel bilgi ve prensipleri vermek, (2) görüntü bölütleme yöntemleri ve gelişimi hakkında bilgi vermek, ayrıca bölütleme uygulamalarının bir özeti sunmak; (3) popüler görüntü bölütleme kalite analizlerinin genel yaklaşım ve prensiplerini ortaya koymaktır.

2. NTGA TEMELİ ve PRENSİPLERİ

NTGA yöntemi genellikle ilk adımı lokal piksel kümelenmelerinden oluşan görüntü bölütleme ve ikinci adımı görüntü nesnelere sınıflandırılması ve doğruluk analizi ile değerlendirmesi olan bir süreçtir.

İlk adım olan görüntü bölütleme işleminde, nesne şekli, boyutu ve spektral özellikleri, araştırma hedeflerine ve bölütleme yaklaşımına bağlı olarak belirlenmektedir (Dronova, 2015). Bu çalışmada, NTGA ile ilgili hakemli dergilerde, kitap bölümlerinde ve konferanslarda yayınlanmış 100'ün üzerinde akademik çalışma tarandıktan sonra NTGA'nın genel anlamda önceleri kullanılan görüntü bölütleme, kenar algılama, öznelik çıkarımı ve sınıflandırma kavramlarına dayandığı söylenebilir. (Haralick, 1983; Levine ve Nazif, 1985; Pal ve Pal, 1993). Burada görüntü bölütleme yöntemleri, bölüt kalitesi ve bölütleme

parametreleri ile ilgili çalışmalar incelenerek sunulmuştur.

NTGA'nın uygulanma süreci hem araştırma hedeflerine hem de yazılıma bağlı olarak büyük ölçüde değişkenlik göstermektedir. İncelenen yayınlar arasında en yaygın yazılımı olarak, özel algoritma geliştirilmesini sağlayan ve kural setleri kombinasyonu, bölütleme, sınıflandırma ve diğer veri analizi adımlarını gerçekleştiren eCognition yazılımı (Trimble Inc) öne çıkmaktadır. Ayrıca, Berkeley ImgSeg, ENVI feature extraction module (Exelis VIS Inc), ESRI ArcMAP, ERDAS MAGINE ticari yazılımları da son zamanlarda NTGA yöntem ve yaklaşımlarını sunmaya başlamıştır. Açık kaynak kodlu yazılımlarda ise Monteverdi-Orfeo Toolbox ve Spring yazılımları ön plana çıkmaktadır.

3. GÖRÜNTÜ BÖLÜTLEME YÖNTEM ve UYGULAMALARI

Görüntü bölütlemenin uzaktan algılama alanında yaygın kullanımı 2000'li yıllarda başlar (Blaschke vd., 2004). Görüntü bölütleme, düşük seviyeli görüntü işleme ve üst düzey görüntü analizi arasındaki semantik boşluk için bir köprü görevi görür (Toro vd., 2015). Görüntü bölütleme, özellikle multispektral görüntüler için karmaşık ve derinlemesine incelenmesi gereken bir çalışma alanıdır. Tek bir algoritmanın tüm görüntüler için yeterli kabul edilemeyeceği ortaya konmuştur (Räsänen vd., 2013). Görüntü bölütleme yöntemleri; kümeleme (özellik-uzay eşikleme) esaslı bölütleme, kenar (gradyan) tabanlı bölütleme, bölge tabanlı bölütleme olmak üzere üç grupta incelenebilir.

a. Kümeleme Esaslı Bölütleme

Kümeleme esaslı bölütleme, bir veri kümesini belirli sayıda gruba bölmek için kullanılan bir yöntemdir. Piksel grupları arasındaki mekansal ilişki göz önünde bulundurulmadan renk veya doku gibi benzer özelliklere sahip pikseller gruplandırılır. K-ortalama, ISODATA ve ortalama kaydırma (mean shift) algoritmaları en çok kullanılan kümeleme yöntemleri arasında yer almaktadır.

En popüler kümeleme esaslı bölütleme yöntemleri arasında süper piksel algoritmaları ön plana çıkmaktadır. Süper pikseller, renk, doku gibi belirli ölçütlere göre oluşturulmuş küçük, lokal ve tutarlı kümelerden oluşan istatistiksel olarak anlamlı homojen görüntü bölgeleridir (Ren ve Malik, 2003; Kavzoglu ve Tonbul, 2017). Yalın Doğrusal Yinelemeli Kümeleme (Simple Linear

Iterative Clustering- SLIC) süper piksel yöntemi, Achanta vd., (2012) tarafından geliştirilmiş olup uzaktan algılama alanında yapılan çalışmalarda sıklıkla tercih edilen yöntemlerden birisidir (Ince vd., 2017; Kavzoglu ve Tonbul, 2017). Bu algoritma, tek bir parametreden oluşmakta olup (k : istenen eşit sayılı süperpiksel boyutu) oldukça basit bir yapıya sahiptir. SLIC yöntemi, renk yakınlığı mesafesi (denklem 2) ve uzaysal yakınlık mesafesini (denklem 3) birleştiren bir mesafe ölçüsü D (denklem 1) kullanarak, her bir pikseli en yakın küme merkezine atayarak başlatır:

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (1)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (2)$$

$$D_s = d_{lab} + \frac{m}{S} d_{xy} \quad (3)$$

Burada L , a ve b renk uzayı değerlerini, m süperpiksel kompaktlığını, D_s lab uzaklığının mesafesinin toplamını (d_{lab}) ve (d_{xy}) xy düzlemi mesafesini, S normalleştirilmiş grid aralığını ifade etmektedir. Renk mesafesi süperpiksel homojenliğini kontrol ederken, mekânsal uzaklık süperpiksel kompaktlığını ayarlamaktadır (Toro vd., 2015). SLIC süperpiksel oluşturma işlemi, açık kaynak kodlu Geospatial Data Abstraction Library (GDAL) uygulaması (<https://github.com/cbalint13/gdal-segment>) üzerinden gerçekleştirilebilmektedir.

b. Kenar (Gradyan) Tabanlı Bölütleme

Kenar tabanlı bölütleme yöntemleri, spektral olarak birbirine benzeyen komşu pikselleri saptamak ve böylece bitişik kesimler arasındaki sınırları tanımlamak için tasarlanmıştır. Kenar filtresi görüntüye uygulanır ve filtre sonucu pikseller kenar veya kenar olmayan olarak ikiye ayrılır. Kenarlar görüntü nesnelere arasındaki sınır olarak kabul edilir ve değer değişikliklerinin meydana geldiği yerde bulunurlar (Canny, 1986). Havza dönüşüm yöntemi, en çok kullanılan kenar tabanlı yöntemlerden olup yaygın olarak kullanılan ENVI yazılımında da mevcuttur. Havza dönüşümü esas olarak hidrolojik havza kavramına dayanır. Havzalar bir yerel minimumdan başlayarak suyla dolmakta ve farklı havzalardan gelen suyun toplanacağı noktalarda barajlar inşa edilmektedir. Su seviyesi en tepeye ulaştığında, işlem durdurulur. Benzer olarak, yatay bölgeler veya havza hatları adı verilen baraj tarafından ayrılmış havzalar bölütlenir (Roerdink ve Meijster, 2001).

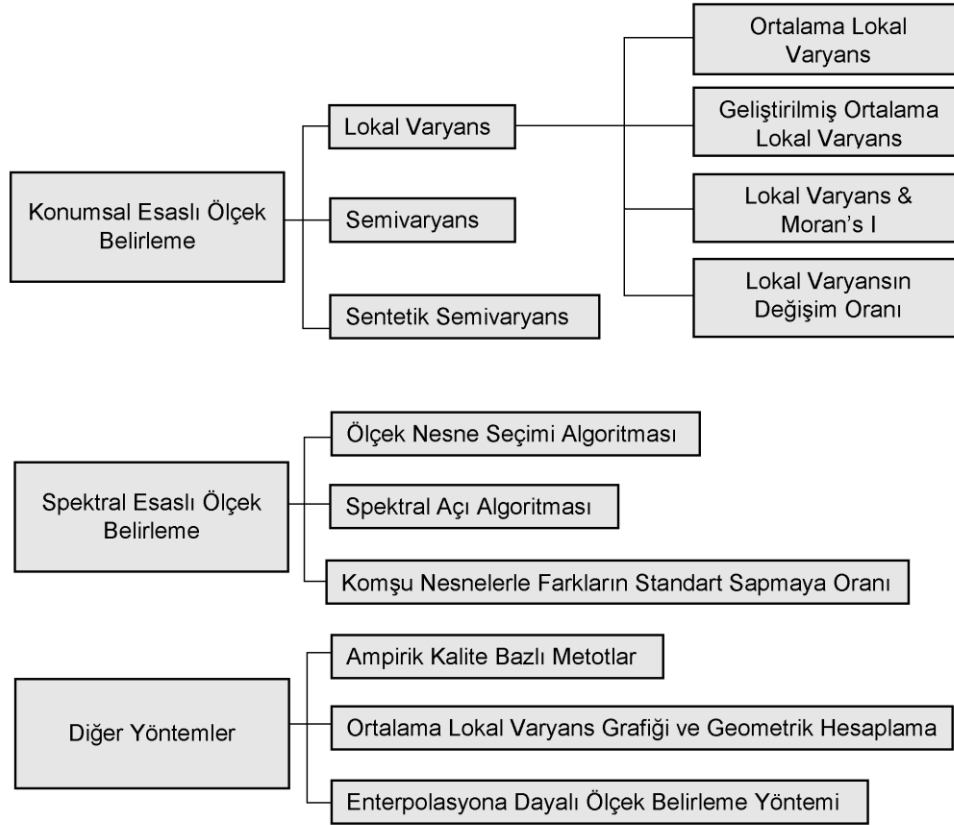
c. Bölge Tabanlı Bölütleme

Bölge tabanlı bölütleme yöntemleri, spektral olarak benzer olan ve dolayısıyla aynı coğrafi nesneye ait olan komşu pikselleri saptamak için tasarlanmıştır. Bu tür yöntemler; pikselleri birleştirme, görüntüyü bölgelere ayırma ve iteratif bir arama şemasında bölme ve birleştirme olarak kategorize edilebilir (Glasbey ve Horgan, 1995). Birçok bölge tabanlı yöntem bulunmasına rağmen, bunların çoğu oldukça karmaşıktır. En çok bilinen ve kullanılan eCognition yazılımı içinde de yer alan çoklu-çözünürlük yöntemidir. Bu yöntemde, her piksel bir görüntü nesnesi olarak düşünülmekte ve komşu piksel kümelenmeleri baz alınarak birleştirilmektedir. Birleştirme işlemi, bitişik görüntü nesnelere benzerliğini tanımlayan yerel homojenlik kriterlerine dayanmakta ve olası bir birleştirme bitinceye kadar sürmektedir.

Çoklu-çözünürlük yöntemi, ölçek, biçim ve bütünlük olmak üzere kullanıcı tanımlı 3 temel parametreden oluşmaktadır (Baatz ve Schäpe, 2000). Ölçek parametresi belirtilen parametreler arasında görüntü nesnelere üretme aşamasında en fazla öneme sahip olan parametredir. Ölçek belirlemeye yönelik birçok yaklaşım bulunmaktadır. Esas olarak, ölçek parametresi nesne boyutunu maksimum heterojenlik kriterine bağlı olarak belirleme işlemidir. Ölçek parametresi arttıkça, görüntü nesnelere boyutları da artmaktadır. Biçim parametresi, mekânsal homojenliği sağlamak ve bu değer ne kadar büyük olursa spektral homojenliğinin nesne üretimine etkisi daha az olmaktadır. Bütünlük parametresi, görüntü bölütünün kenar uzunluklarının oranlanmasında etkilidir ve buna bağlı olarak bölüt kenarlarının daha keskin veya daha yumuşak oluşmasını belirlemektedir.

4. BÖLÜTLEMEDE PARAMETRE SEÇİMİ

Görüntü bölütleme sonucunda semantik görüntü nesnelere fiziksel yeryüzü nesnelere tamamen örtüşmesi beklenir. Fakat, yüksek çözünürlüklü verilerin karmaşıklığı, coğrafi zemin özelliklerinin değişen boyutu, şekli ve bunların mekânsal dağılımı nedeniyle, görüntü bölütleme parametrelerinin ayarlanmasına yönelik global veya yerel ölçekli bir parametre modelini formüle etmek zordur. Farklı yöntemlerin teorilerine ve teknik bileşenlerine dayanarak optimum ölçek belirleme yaklaşımları Şekil 1'de görüldüğü gibi kategorize edilebilir (Liu vd., 2017). Şekil 1'de belirtilen yöntemler içerisinde en çok tercih edilenler konumsal otokorelasyon tekniğine sahip olan Moran's I indeksi ve varyans değerlerini



Şekil 1. Ölçek Belirleme Yaklaşımlarının Sınıflandırması (Liu vd., 2017)

birlikte kullanan yöntemlerdir (Espindola vd., 2006; Johnson ve Xie, 2011; Chen vd., 2014). Bu yaklaşımda nesnelere arasındaki heterojenlik ve nesnelere içerisindeki homojenlik dikkate alınır. Bölütleme içi kalite ölçütü, her bir görüntü bölütleme alanı tarafından ağırlıklandırılan varyans olup, aşağıdaki şekilde hesaplanır:

$$V = \frac{\sum_{i=1}^n a_i \cdot v_i}{\sum_{i=1}^n a_i} \quad (4)$$

Burada v_i , i bölütünün varyansını, a_i ise bu bölütün alanını göstermektedir. Görüntü bölütleri arası kalite ölçütü hesaplanmasında ise, global Moran's I mekânsal otokorelasyon tekniği kullanılmaktadır. Global Moran's I indeksi (MI) aşağıdaki formülle hesaplanmaktadır:

$$MI = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2 (\sum_{i \neq j} w_{ij})} \quad (5)$$

Burada n toplam bölüt sayısını, w_{ij} mekânsal yakınlık ölçüsünü, y_i R_i bölütünün ortalama

spektral değerini ve \bar{y} görüntünün ortalama spektral değerini göstermektedir. MI değeri $[-1, +1]$ değerleri arasında değişmektedir. Bölüt içi ve bölütler arası değerler farklı değer aralıklarında olabilmektedir. Her iki değeri de bir arada kullanabilmek için (0-1) aralığına indirmek ve normalizasyon işlemi yapmak gereklidir. Normalizasyon işlemi aşağıdaki şekilde yapılır:

$$F(V, MI) = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

Burada x_{\min} ve x_{\max} , Moran's I veya varyansın maksimum ve minimum değerlerini göstermektedir. Her bir görüntü bölütlemesine genel bir "Global Skor" (GS) atamak için, normalleştirilmiş ağırlıklı varyans ve Moran'ın I değerleri aşağıdaki şekilde hesaplanır:

$$GS = V_{norm} + MI_{norm} \quad (7)$$

V_{norm} ve MI_{norm} normalize edilmiş varyans ve Moran's I değerlerini göstermektedir. Optimum ölçek değeri GS 'nin minimum olduğu değerden hesaplanır. Yukarıda belirtilen hesaplamalar esas alınarak F-ölçü yöntemi olarak geliştirilmiş bir yaklaşım daha mevcuttur (Johnson vd., 2015). Bu

yaklaşımında GS değeri aşağıdaki şekilde hesaplanır.

$$GS_f = (1+a^2) \frac{MI_{norm} \cdot V_{norm}}{a^2 \cdot MI_{norm} + V_{norm}} \quad (8)$$

Burada a değeri, MI_{norm} ve V_{norm} 'un ağırlığını kontrol eden değerdir. GS_f , en iyi tekil ölçekleme ve üç seviyeli hiyerarşik bölütleme parametrelerini belirlemek üzere her bir ölçek için hesaplanmaktadır. Literatürde, lokal varyans tabanlı ölçek belirleme yöntemleri arasında en çok kullanılan ve iki versiyonu bulunan "Ölçek Parametresi Belirleme" (ESP-1 & ESP-2) yöntemidir (Drăgut vd. 2010, 2014). ESP aracı, eCognition Developer yazılımının Cognition Network Language (CNL) ortamında programlanan ve çoklu-çözünürlük görüntü bölütleme yöntemi için geliştirilmiş bir ölçek belirleme aracıdır. Kullanıcının belirlediği artış miktarına göre otomatik görüntü bölütlemesi gerçekleştirilmekte ve her objenin çıkartımı aşamasında standart sapmaların ortalaması olarak lokal varyanslar hesaplanmaktadır (Kalkan, 2011). Lokal varyans grafikleri, görüntünün veri özelliklerine göre uygun ölçek parametrelerini değerlendirmek için kullanılmaktadır. Lokal varyansın değişim oranlarındaki eşik değerleri hangi ölçek parametresinde anlamlı nesnelere bölütlemesinin yapılacağını ifade etmektedir. Her bir ölçek parametresi için hesaplanan lokal varyans değerinin değişim oranının Eşitlik 9'a göre belirlenmesi sonucunda bir LV-RoC grafiği elde edilmektedir (Kalkan, 2011).

$$R = \left[\frac{L-(L-1)}{L-1} \right] \cdot 100 \quad (9)$$


Burada, L hedef nesnenin lokal varyansını, $L-1$ bir sonraki alt nesne seviyesinin lokal

varyansını göstermektedir. LV-RoC grafiği ani iniş çıkışlardan oluşan pikler şeklindedir ve grafikte ani değişimin görüldüğü pikler seçilebilecek optimum ölçek parametresini göstermektedir (Drăgut vd., 2010; Kavzoglu vd., 2016). Örnek bir LV-RoC grafiği Şekil 2'de gösterilmiştir. Şekil 2'den görüleceği üzere, ani değişimin ve ilk zıplamanın görüldüğü ilk pik noktası olarak 20 değeri optimum ölçek değeri olarak belirlenebilir. Alternatif değer olarak, İkinci pik değeri (29) noktası da kullanılabilir.

ESP-2 aracı, bir önceki versiyonun geliştirilmiş versiyonudur ve lokal varyans hesabında tek bant yerine maksimumda 30 bant hesaba katarak işlem yapmaktadır (Drăgut vd. 2014). Bu çalışma kapsamında yapılan literatür çalışmasında, ESP araçlarının "Web of Science" veri tabanında 200'den fazla bilimsel yayında kullanıldığı tespit edilmiştir.

5. BÖLÜTLEME KALİTE ANALİZLERİ

Uzaktan algılanmış görüntülerde, farklı arazi örtüsü sınıflarına ve uygulanacak olan görüntü bölütleme algoritmasına bağlı olarak görüntü bölütleme kalitesi oldukça değişkenlik göstermektedir. Ayrıca, bölütleme parametre seçimi de olması gerekenden farklı görüntü nesnelere oluşmasına neden olabilir. Bu nedenle, bölütleme algoritmalarının performansını değerlendirmek, etkin bölütleme algoritmaları tanımlamak ve optimum bölütleme parametre tahmini yapmak için önemlidir (Neubert vd., 2008; Johnson ve Xie, 2011). Görüntü bölütleme kalitesi doğruluğunu değerlendirmenin birçok yolu vardır ve bunlar genel olarak, kontrollü ve kontrolsüz yaklaşımlar olmak üzere ikiye ayrılabilirler. Görüntü bölütleme yöntemlerini ve parametrelerini belirleme de bir standart olmadığı gibi, bölütleme kalite belirleme analizi için de herkes tarafından kabul edilen bir standart bulunmamaktadır.



Şekil 2. Örnek lokal varyans (LV-RoC) grafiği

a. Kontrollü yöntemler

Kontrollü yöntemler, bölütleme sonucunu kontrol veya referans nesnelere bağlı olarak sayısal analizler yardımıyla değerlendirirler. İdeal durumda, referans nesnelere oluşturulan görüntü bölütlerinin birebir örtüşmesi beklenir. Mevcut kontrollü değerlendirme teknikleri, ele alınan görüntü nesnelereyle ilgili olan referans nesnelere arasındaki geometrik ve/veya aritmetik ilişkiyi modelleme üzerine kuruludurlar. Esas amaç, fazla bölütleme (görüntü nesnelere referans nesnelere küçük olması durumu) ve yetersiz bölütlemeyi (görüntü nesnelere referans nesnelere büyük olması durumu) belirleyerek görüntü bölütleme kalitesini ölçmektir. Literatürde, en sık kullanılan kontrollü değerlendirme teknikleri, alan uyum indeksi (AUI) ve kalite oranı (KO) metrikleridir.

$$AUI = \frac{A_{r(i)} - A_{s(j)}}{A_{r(i)}} \quad (10)$$

$$KO = \frac{A_{r(i)} \cap A_{s(j)}}{A_{r(i)} \cup A_{s(j)}} \quad (11)$$

AUI , referans nesnelere ve karşılık gelen görüntü nesnelere arasındaki örtüşme derecesini hesaplar (Lucieer ve Stein, 2002). Pozitif AUI fazla bölütlemeyi, negatif AUI yetersiz bölütlemeyi gösterir. KO , görüntü bölütlerine karşılık gelen referans nesnelere arasındaki örtüşmeyi göstermektedir (Winter, 2000) Belirtilen metrikler, 0 ile 1 arasında değerler alır. Referans nesnelere ve üretilen görüntü nesnelere arasında birebir örtüşme olduğunda AUI değeri 0 ve KO değerinin 1 olması beklenmektedir (Clinton vd., 2010). Bazı çalışmalarda fazla bölütleme ve yetersiz bölütlemeyi belirlemek amacıyla bölge esaslı kesinlik (p) ve geri çağırma (r) metrikleri kullanılmaktadır (Yi vd., 2012; Zhang vd., 2015). Burada esas olan, her referans nesnesinin bir görüntü bölütüyle eşleşmesi ve örtüşme oranlarının maksimum olmasıdır. S_i , her bir görüntü nesnesini, R_i her bir referans nesnesini, $R_{i_{max}}$ ise ilgili görüntü nesnesiyle maksimum oranda örtüşen referans nesnesini temsil etmektedir.

$$p = \frac{\sum_{i=1}^n |S_i \cap R_{i_{max}}|}{\sum_{i=1}^n |S_i|} \quad (12)$$

$$r = \frac{\sum_{i=1}^m |R_i \cap S_{i_{max}}|}{\sum_{i=1}^m |R_i|} \quad (13)$$

Bu metriklerin dışında; potansiyel bölütleme hatası (PBH), bölütleme sayısı oranı (BSO) ve öklit uzaklığı 2 ($\ddot{O}U-2$) gibi başka kontrollü değerlendirme yöntemleri de bulunmaktadır. PBH , yetersiz bölütleme olan yerlerin toplam alanını ve referans nesnelere arasındaki oran üzerinden hesaplanan geometrik uyumsuzluğu ölçer. BSO , referans nesnelere ve ilgili görüntü bölütleri arasındaki aritmetik tutarsızlığı ölçmektedir. $\ddot{O}U-2$ indisi ise görüntü bölütleme kalitesini, PBH ve BSO indislerini hesaplayarak belirlemektedir (Liu vd., 2012; Novelli vd., 2017). Aşağıda belirtilen denklemlerde, r_i referans veri seti içindeki referans poligonlarını, s_k karşılık gelen bölütleme veri kümesindeki ilgili görüntü bölütlerini, m referans poligonlarının sayısını, v ise karşılık gelen görüntü bölütleri sayısını ifade etmektedir.

$$PBH = \frac{\sum |s_i - r_k|}{\sum r_k} \quad (14)$$

$$BSO = \frac{|m - v|}{m} \quad (15)$$

$$\ddot{O}U - 2 = \sqrt{(PBH^2) + (BSO)^2} \quad (16)$$

b. Kontrolsüz yöntemler

Kontrolsüz yöntemler, insan algılarını esas alarak görüntüyü değerlendirir ve buna bağlı olarak uyumlu bölütlemeye yönelik olarak belirli ölçütleri kullanırlar (Zhang, 1996; Zhang vd., 2008). Kontrollü yöntemlerden farklı olarak, herhangi bir yer kontrol noktasına veya referans nesnesine ihtiyaç duymazlar. Literatürde, uzaktan algılanmış görüntüler için oluşturulmuş birçok kontrolsüz yöntem yaklaşımı bulunmaktadır. Örneğin; Stein ve De Beurs (2005), iki Landsat görüntüsünün görüntü bölütlerinin semantik doğruluğunu belirlemek için karmaşıklık metriklerini kullanmıştır. Radoux ve Defourny (2008), kırsal alanda bölütleme sonuçlarını değerlendirmek için normalleştirilmiş bölütleme sonrası standart sapma ve kenar uyumsuzluğunun bir kombinasyonunu kullanmıştır. Shi vd. (2017), nesnelere önemli özelliklerini yansıtan yeni bir kontrolsüz yöntem önermiştir. Genel olarak, kontrolsüz yöntemler optimum ölçek parametresi tespitine yönelik olarak görüntüye uygulanırlar. Bu yöntemler yer

kontrol noktası gerektirmedikinden zaman ve maliyet bakımından avantajlı sayılabilirler. Ancak, görsel analiz kantitatif değerlendirme sağlayamaz ve insan algısına bağlı olduğundan öznel olarak değerlendirilmektedir (Su ve Zhang, 2017).

6. TARTIŞMA

Görüntü bölütleme ölçeğinin seçimi için geleneksel yaklaşım, çoğunlukla bölütleme uygunluğunun görsel bir değerlendirmesine dayanan öznel deneme yanılma yöntemlerinin kullanılmasıdır. Bu yaklaşımlar NTGA'nın uzman bilgi birikimine ihtiyacının fazla olması sebebiyle, pek tekrarlanabilir değildirler ve yaklaşımın sağlamlığına ilişkin bazı sınırlamaları ortaya çıkarmaktadırlar. Buna bağlı olarak, optimum ölçek parametresini belirlemeye yönelik otomatik ölçek seçimi yöntemleri oluşturulsa da bazı kısıtlamalar bulunmaktadır.

Karmaşık yeryüzü yapısı, görüntü mekânsal çözünürlüğü, spektral bant sayısı gibi etkenlere bağlı olarak, optimum bölütleme yönteminin belirlenmesinde evrensel olarak kabul görmüş bir standart bulunmamaktadır. Bazı görüntü bölütleme algoritmaları, kentsel alan içeren görüntülerin işlenmesinde iyi performans sağlarken, bazılarının kırsal alanların bölütlenmesinde iyi performans gösterdiği; bazı yöntemlerin sentetik açıklıklı radar (SAR) görüntülerde başarılı sonuçlar verirken bazılarının da optik olanlar için daha iyi sonuç verdiği görülmüştür (Su ve Zhang, 2017). Dolayısıyla, en uygun görüntü bölütleme bilgisinin çıkarımı için dikkat edilmesi gereken başlıca hususlar şunlardır:

- Spektral ve mekânsal özellikleri nedeniyle tüm objeler birbirinden farklı özelliğe sahiptir. Bu nedenle her arazi örtüsü sınıfı özelliği için tekli ölçek kullanımı yeterli olmayabilir (Baatz ve Schäpe, 2000). Ayrıca, tekli ölçeğin kullanılması, bazı arazi örtüsü özellikleri için fazla veya yetersiz bölütlemeye neden olabilmektedir. Bu durumlarda görüntü karakteristiğine göre farklı arazi örtüsü sınıfları için çoklu ölçek yaklaşımları tercih edilmelidir (Kavzoglu vd., 2017).

- Kalite değerlendirme işlemi, NTGA'nın genel iş akışı içinde mutlaka yer almalıdır. Ancak bu yöntemler güçlendirilmelidir. Kontrollü kalite değerlendirme yöntemlerinde, genellikle doğal nesnelere (yani, fiziksel sınırı belli olmayan nesnelere) yerine binalar ve diğer yapay yapılar olan referans arazi kullanım nesnelere kullanılmaktadır (Belgiu ve Drăgăuț, 2014; Doxani vd., 2015). Albrecht vd. (2010)'a göre doğal

nesnelere kavramsal olarak daha belirgin olmalarına rağmen, tematik çalışmalarda bazı belirsizlikler içermektedirler. Ölçek nedeniyle sınırlarda oluşan bulanıklık, doğal nesnelere doğrulanmasını güçleştirmektedir (Kavzoglu vd., 2017).

- Görüntü bölütleme sonucu oluşan görüntü nesnelere, genellikle nesne içi spektral varyasyon veya heterojenite ile ilgili parametrelere bağlı olarak değişmektedir. Çoklu-çözünürlük bölütleme yaklaşımı ile farklı boyutlu nesnelere göreceli ağırlıkları, ile biçim (geometri) ve renk arasındaki uyum (spektral) nesne içi heterojeniteye izin veren ölçekle belirlenebilir. Dolayısıyla, çoklu-çözünürlük yaklaşımı ile çok sayıda potansiyel parametre seçimi mümkün hale gelmekte ve tek ölçek kullanımına kıyasla daha avantajlı olabilmektedir.

- Görüntü bölütleme sürecinin parametre seçimi aşamasının deneme yanılma yaklaşımı yerine, ESP aracı gibi yarı otomatik veya otomatik yöntemler ile gerçekleştirilmesi daha bilimsel ve objektif bir yaklaşım olacaktır.

7. SONUÇ

NTGA yaklaşımının özellikle yüksek çözünürlüklü uydu görüntüleri ve hava fotoğrafları üzerinde yapılan çalışmalarda ciddi katkılar sağladığı ve sunmuş olduğu esnek yapı ile her geçen gün artan sayıda kullanıldığı görülmektedir. Nesneye dayalı yaklaşımlar, sadece bilgisayar dilleri değil görüntü işleme analizine de kolayca adapte edilebilmektedir. Farklı coğrafi uygulamalar için görüntü bölütlemesi kullanan uzaktan algılama/coğrafi bilgi sistemleri uygulayıcılarının büyük bir bilimsel topluluk oluşturduğu söylenebilir. Yaygın kullanım ile NTGA'nın geliştirilmesi, belirli alanlar, disiplinler ve kullanıcı ihtiyaçları için nesne tabanlı çözümlerin uyarlanması daha hızlı ve kolay olacaktır. NTGA, tarım, ormancılık, kentsel alanların izlenmesi ve doğal kaynakların analizi gibi birçok görüntü analizi çalışmalarında başarılı sonuçlar vermektedir. Ancak NTGA, esas olarak, yaklaşımın sağlamlığına ilişkin önemli bilimsel konuları vurgulayan uzman bilgiye dayanmaktadır.

Bu çalışmada, literatürde ifade edilen önemli teknikler ve çalışmalar hakkında bilgiler özetlenerek, NTGA alanındaki son durum ve gelişim ihtiyaçları tartışılmıştır. Literatürden örnekler de verilerek mevcut görüntü bölütleme yöntemleri, görüntü bölütleme parametre seçim yaklaşımı ve araçları, ayrıca görüntü kalite analizi

konularına odaklanılmıştır. Bununla birlikte, görüntü bölütleme işlemini uygun biçimde gerçekleştirmek için ele alınması gereken temel problemler de tartışılmıştır. Bu çalışma ile son yıllarda popüler hale gelen ve yazılımlara entegre edilen görüntü bölütleme ile nesne tabanlı sınıflandırma yaklaşımının, uzaktan algılama alanında daha etkin olarak kullanılacağı ve önemli bir araştırma konusu olacağı değerlendirilmiştir.

KAYNAKLAR

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., Süsstrunk, S., (2012), **SLIC superpixels compared to state-of-the-art superpixel methods**, IEEE Transactions on Pattern Analysis and Machine Intelligence, 34(11), 2274-2282.
- Albrecht, F., Lang, S. Hölbling, D., (2010), **Spatial accuracy assessment of object boundaries for object-based image analysis**, In International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXVIII, No. 4, p. C7.
- Alganci, U., Sertel, E., Ozdogan, M., Ormeci, C., (2013), **Parcel-level identification of crop types using different classification algorithms and multi-resolution imagery in southeastern Turkey**, Photogrammetric Engineering and Remote Sensing, 79(11), 1053–1065.
- 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., Drăgut, 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.
- Blaschke, T., Strobl, J., (2001), **What's wrong with pixels? Some recent developments interfacing remote sensing and GIS**, GeoBIT/GIS, 6, 12–17.
- Blaschke, T., Burnett, C., Pekkarinen, A., (2004), **New contextual approaches using image segmentation for object-based classification**, In F. DeMeer, F., de Jong, S. (Eds.), Remote Sensing Image Analysis: Including the Spatial Domain, Academic Publishers, Dordrecht, 211–236.
- Blaschke, T., (2010), **Object based image analysis for remote sensing**, ISPRS Journal of Photogrammetry and Remote Sensing, 65(1), 2-16.
- Blaschke, T. Hay, G.J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Feitosa, R.Q., Meer, F., Werff, H., Coillie, F., Tiede, D., (2014), **Geographic Object-Based Image Analysis – Towards a new paradigm**, ISPRS Journal of Photogrammetry and Remote Sensing, 87, 180–191.
- Canny, J., (1986), **A computational approach to edge detection**, IEEE Transactions on Pattern Analysis and Machine Intelligence, 8(6), 679–698.
- Castillejo-González, I. L., López-Granados, F., García-Ferrer, A., Peña-Barragán, J. M., Jurado-Expósito, M., de la Orden, M. S, et al. (2009), **Object- and pixel-based analysis for mapping crops and their agro-environmental associated measures using QuickBird imagery**, Computers and Electronics in Agriculture, 68(2), 207–215.
- Chen, J., Deng, M., Mei, X., Chen, T., Shao, Q., Hong, L., (2014), **Optimal segmentation of a high-resolution remote-sensing image guided by area and boundary**, International Journal of Remote Sensing, 35(19), 6914-6939.
- Clinton, N., Holt, A., Scarborough, J., Yan, L., Gong, P., (2010), **Accuracy assessment measures for object-based image segmentation goodness**, Photogrammetric Engineering and Remote Sensing, 76(3), 289-299.
- Colkesen, I, Kavzoglu, T., (2016), **The use of logistic model tree (LMT) for pixel- and object-based classifications using high-resolution WorldView-2 imagery**, Geocarto International, 1–16.
- Delen, A., Şanlı, F.B., (2017), **Nesne-Tabanlı Sınıflandırma Yöntemi ile Tarımsal Ürün Deseninin Belirlenmesi**, Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, Özel Sayı, 242-247.

- Doxani, G., Karantzas, K., Tsakiri, M., (2015), **Object-based building change detection from a single multispectral image and pre-existing geospatial information**, Photogrammetric Engineering and Remote Sensing 81(6), 481–489.
- Drăgut, 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), 859-871.
- Drăgut, L., Csillik, O., Eisank, C., Tiede D., (2014), **Automated Parameterisation for Multi-Scale Image Segmentation on Multiple Layers**, ISPRS Journal of Photogrammetry and Remote Sensing 88(100), 119–127.
- Dronova, I., (2015), **Object-based image analysis in wetland research: a review**, Remote Sensing, 7, 6380–6413.
- Duveiller, G., Defourny, P., Desclée, B., Mayaux, P., (2008), **Deforestation in Central Africa: Estimates at regional, national and landscape levels by advanced processing of systematically-distributed Landsat extracts**, Remote Sensing of Environment, 112(5), 1969-1981.
- Espindola, G.M., Camara, G., Reis, I.A., Bins, L.S., Monteiro, A.M., (2006), **Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation**, International Journal of Remote Sensing, 27(14), 3035-3040.
- Gamanya, R., de Maeyer, P., De Dapper, M., (2009), **Object-oriented change detection for the city of Harare, Zimbabwe**, Expert Systems with Applications, 36(1), 571–588.
- Glasbey, C. A., Horgan, G. W., (1995), **Image analysis for the biological sciences**, Chichester: John Wiley & Sons.
- Haralick, R.M., (1983), **Decision making in context**, IEEE Transactions on Pattern Analysis and Machine Intelligence, 5(4), 417–428.
- Hussain, M., Chen, D., Cheng, A., Wei, H., Stanley, D., (2013), **Change detection from remotely sensed images: from pixel-based to object-based approaches**, ISPRS Journal of Photogrammetry and Remote Sensing, 80, 91–106.
- Johnson, B., Xie, Z., (2011), **Unsupervised image segmentation evaluation and refinement using a multi-scale approach**, ISPRS Journal of Photogrammetry and Remote Sensing, 66(4), 473-483.
- Johnson, B., Xie, Z., (2013), **Classifying a high resolution image of an urban area using super-object information**, ISPRS Journal of Photogrammetry and Remote Sensing, 83, 40-49.
- Johnson, B., Bragais, M., Endo, I., Macandog, D. M., Macandog, P., (2015), **Image Segmentation Parameter Optimization considering Within- and Between-Segment Heterogeneity at Multiple Scale Levels: Test Case for Mapping Residential Areas Using Landsat Imagery**, ISPRS International Journal of Geo-Information 4(4), 2292–2305.
- Ince, A., Bozkurt, S., Bayram, B., (2017), **Rasat uydu görüntüsünden nesne tabanlı kıyı çizgisi çıkartma: Sapanca gölü örneği**, 16. Türkiye Harita Bilimsel ve Teknik Kurultayı, 3-6 Mayıs 2017, Ankara.
- Kalkan, K., (2011), **Kentsel gelişim için potansiyel açık alanların belirlenmesinde nesne tabanlı sınıflandırma yöntemi ile transfer edilebilir kural dizisi oluşturulması**, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Yüksek Lisans Tezi.
- Kavzoglu, T., Yıldız Erdemir, M., Tonbul, H., (2017), **Classification of semi-urban landscapes from VHR satellite images using a novel regionalized multi-scale segmentation approach**, Journal of Applied Remote Sensing, 11(3), 035016.
- Kavzoglu, T., (2009), **Increasing the accuracy of neural network classification using refined training data**, Environmental Modelling & Software 24 (7), 850–858.
- Kavzoğlu, T., Tonbul, H., Yıldız Erdemir, M., Çölkesen, İ., (2016), **Hiperspektral Görüntülerin Nesne Tabanlı Sınıflandırılmasında Boyutsallık Problemi Ve Parametre Seçimi**, 6. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2016), 5-7 Ekim 2016, Adana.
- Kavzoglu, T., Tonbul, H., (2017), **Selecting Optimal SLIC Superpixels Parameters by Using Discrepancy Measures**, In Asian Conference on Remote Sensing (ACRS), New Delhi, India.

- Levine, M.D., Nazif, A.M., (1985), **Rule-based image segmentation: A dynamic control strategy approach**, Computer Vision, Graphics and Image Processing 32(1), 104–126.
- Li, D., Zhang, G. Wu, Z., Yi, L., (2010). **An Edge Embedded Marker-Based Watershed Algorithm for High Spatial Resolution Remote Sensing Image Segmentation**. IEEE Transactions on Image Processing 19(10), 2781–2787.
- Liu, Y., Bian, L., Meng, Y., Wang, H., Zhang, S., Yang, Y., Shao, X., Wang, B., (2012), **Discrepancy measures for selecting optimal combination of parameter values in object-based image analysis**, ISPRS Journal of Photogrammetry and Remote Sensing, 68, 144–156.
- Liu, J., Du, M., Mao, Z., (2017), **Scale computation on high spatial resolution remotely sensed imagery multi scale segmentation**, International Journal of Remote Sensing, 38(18), 5186-5214.
- Lucieer, A., Stein, A., (2002), **Existential uncertainty of spatial objects segmented from satellite sensor imagery**, IEEE Transactions on Geoscience and Remote Sensing, 40(11), 2518-2521.
- Myint, S.W., Gober, P., Brazel, A., Grossman-Clarke, S., Weng, Q., (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.
- Neubert, M., Herold, H., Meinel, G., (2008), **Assessing Image Segmentation Quality - Concepts, Methods and Application**. In Blaschke, T.; Hay, G. & Lang, S. (Eds.): Object-Based Image Analysis – Spatial concepts for knowledge-driven remote sensing applications. Lecture Notes in Geoinformation & Cartography (LNG&C), Springer, Berlin: 769-784.
- Novelli, A., Aguilar, M.A., Aguilar, F.J., Nemmaoui, A., Tarantino, E., (2017), **AssesSeg – A command line tool to quantify image segmentation quality: a test carried out in southern Spain from satellite imagery**, Remote Sensing, 9(1), 1–11.
- Pal, R., Pal, K., (1993), **A review on image segmentation techniques**. Pattern Recognition 26(9), 1277–1294.
- Radoux, J., Defourny, P., (2008). **Quality assessment results devoted to object-based classification**. In Blaschke, T., Lang, S., Hay, G. (Eds.), Object-Based Image Analysis, Spatial Concepts for Knowledge-Driven Remote Sensing Applications. Springer, Heidelberg, Berlin, New York, pp. 255–271.
- Räsänen, A., Rusanen, A., Kuitunen, M. Lensu, A., (2013), **What makes segmentation good? A case study in boreal forest habitat mapping**, International Journal of Remote Sensing 34(23), 8603–8627.
- Ren, X., Malik, J., (2003), **Learning a classification model for segmentation**, Proceedings of the Ninth IEEE International Conference on Computer Vision, Nice, 10–17.
- Roerdink, J. B., Meijster, A., (2001), **The watershed transform: definitions, algorithms and parallelization strategies**, Fundamenta informaticae, 41(1), 187–228.
- Sabuncu, A., Sunar F., (2017), **Ortofotolar ile Nesne Tabanlı Görüntü Sınıflandırma Uygulaması: Van Erciş Depremi Örneği**, Artvin Çoruh Üniversitesi Doğal Afetler ve Çevre Dergisi, 3(1), 1-8.
- Sertel, E., Yay, I., (2014), **Vineyard parcel identification from Worldview-2 images using object based classification model**, Journal of Applied Remote Sensing, 8(1), 083535.
- Shi, R., Ngan, K.N., Li, S., (2017), **Objectness based unsupervised object segmentation quality evaluation**, In Proceedings of the Seventh International Conference on Information Science and Technology, Da Nang, Vietnam, 16–19 April 2017; pp. 256–258.
- Stein, A, De Beurs, K., (2005), **Complexity metrics to quantify semantic accuracy in segmented Landsat images**, International Journal of Remote Sensing, 26(14), 2937-2951.
- Su, T., Zhang, S., (2017), **Local and global evaluation for remote sensing image segmentation**, ISPRS Journal of Photogrammetry and Remote Sensing, 130 (2017), 256–276.

- Toro O., Gonzalo Martín, C., García Pedrero, Á., Ruiz, E.M., (2015), **Supapixel-based roughness measure for multispectral satellite image segmentation**, Remote Sensing, 7, 14620–14645.
- Uca Avci, Z.D., Karaman, M., Ozelkan, E., Kumral, M., Budakoglu, M., (2014), **OBIA based hierarchical image classification for industrial lake water**, Science of The Total Environment, 487(1), 565-573.
- Uca Avci Z. D., Sunar F., (2015), **Process based image analysis for agricultural mapping A case study in Turkgedli region Turkey**, Advances in Space Research, 56(8), 1635-1644.
- Wells, W.K., (2010), **Object-based segmentation and classification of one meter imagery for use in forest management plans**, MSc Thesis, Utah State University, USA. 49p.
- Winter, S., (2000), **Location similarity of regions**, ISPRS Journal of Photogrammetry and Remote Sensing, 55(3), 189-200.
- Yan, G., Mas, J. F., Maathuis, B. H. P., Xiangmin, Z., & Van Dijk, P. M., (2006). **Comparison of pixel-based and object-oriented image classification approaches-A case study in a coal fire area, Wuda, Inner Mongolia, China**, International Journal of Remote Sensing, 27(18), 4039–4055.
- Yi, L., Zhang, G., Wu, Z., (2012), **A scale-synthesis method for high spatial resolution remote sensing image segmentation**, IEEE Transactions on Geoscience and Remote Sensing, 50(10), 4062–4070.
- Yu, Q., Gong, P., Chinton, N., Biging, G., Kelly, M., Schirokauer, D., (2006), **Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery**, Photogrammetric Engineering & Remote Sensing, 72(7), 799–811.
- Zhang, Y.J., (1996), **A survey on evaluation methods for image segmentation**, Pattern Recognition, 29(8), 1335–1346.
- Zhang, H., Fritts, J.E., Goldman, S.A., (2008), **Image segmentation evaluation: a survey of unsupervised methods**, Computer Vision Image Understanding. 110(2), 260-280.
- Zhang, J.X., Jia, J., (2014), **A comparison of pixel-based and object-based land cover classification methods in an arid/semi-arid environment of northwestern China**, The Third International Workshop on Earth Observation and Remote Sensing Applications (EORSA 2014), Changsha, China, 11-14 June, 403–407.
- Zhang, X., Feng, X., Xiao, P., He, G., Zhu, L., (2015), **Segmentation quality evaluation using region-based precision and recall measures for remote sensing images**, ISPRS Journal of Photogrammetry and Remote Sensing, 102, 73–84.
- Zhou, W., Troy, A., (2009), **Development of an object-based framework for classifying and inventorying human-dominated forest ecosystems**, International Journal of Remote Sensing 30(23), 6343–6360.